



Politechnika Wrocławska

Dziedzina: nauki inżynieryjno-technicznych

Dyscyplina: inżynieria mechaniczna

Rozprawa Doktorska

Model decyzyjny proaktywnego utrzymania ruchu systemów AGV w magazynach Przemysłu 4.0 z integracją danych technicznych i operacyjnych oraz wykorzystaniem logiki rozmytej

mgr inż. Juni Rohman

Promotor:

dr hab. Agnieszka Tubis, prof. uczelni

Promotor pomocniczy:

dr inż. Jacek Ryczyński

Keywords: Automated Guided Vehicles (AGVs), proaktywne utrzymanie ruchu, logika rozmyta, Przemysł 4.0, Magazyn 4.0, zarządzanie utrzymaniem ruchu

Wrocław, 2026

Streszczenie

Zapewnienie niezawodnej pracy pojazdów Automated Guided Vehicles (AGVs) stanowi istotne wyzwanie w środowiskach Magazynu 4.0, w których awarie urządzeń mogą prowadzić do zakłóceń przepływów materiałowych, obniżenia efektywności systemu oraz wzrostu kosztów utrzymania ruchu. Tradycyjne strategie utrzymania ruchu, oparte na działaniach korekcyjnych lub planowych harmonogramach obsługowych, często nie zapewniają wystarczającego poziomu dostępności systemów AGV w wysoko zautomatyzowanych środowiskach intralogistycznych, charakteryzujących się zmiennymi warunkami eksploatacji oraz współwystępowaniem wielu czynników wpływających na proces degradacji pojazdów.

W rozprawie opracowano i zwalidowano Fuzzy Proactive Maintenance Decision Framework (FPMDF), stanowiący model decyzyjny wspomagający realizację proaktywnego utrzymania ruchu flot AGV. Zaproponowane rozwiązanie integruje czynniki techniczne, operacyjne, środowiskowe oraz historyczne wpływające na eksploatację pojazdów AGV z wykorzystaniem systemu wnioskowania rozmytego typu Mamdaniego. Łącząc informacje pochodzące z różnych obszarów eksploatacji, model umożliwia integrację informacji eksploatacyjnych i diagnostycznych oraz wspiera podejmowanie decyzji utrzymaniowych w warunkach niepewności.

Proces opracowania modelu oparto na uporządkowanej procedurze obejmującej eksplorację problemu badawczego, identyfikację czynników degradacji z wykorzystaniem diagramu Ishikawy, selekcję kluczowych zmiennych przy zastosowaniu analizy Pareto–Lorenza, konceptualizację struktury rozwiązania oraz formalizację procesu decyzyjnego z wykorzystaniem logiki rozmytej. W rezultacie opracowano rozwiązanie przekształcające informacje eksploatacyjne i diagnostyczne w rekomendacje wspierające proces podejmowania decyzji utrzymaniowych.

Model został zaimplementowany w środowisku MATLAB i poddany wieloetapowej procedurze weryfikacji oraz walidacji obejmującej weryfikację strukturalną, walidację scenariuszy eksperckich, analizę wrażliwości, badania odporności na zakłócenia danych wejściowych oraz ocenę z wykorzystaniem wskaźników efektywności operacyjnej. Uzyskane wyniki potwierdziły spójność logiczną opracowanego rozwiązania, jego stabilność w warunkach zmienności danych wejściowych oraz przydatność jako narzędzia wspomagania decyzji w obszarze proaktywnego utrzymania ruchu w środowiskach Magazynu 4.0.

Głównym osiągnięciem rozprawy jest opracowanie Fuzzy Proactive Maintenance Decision Framework (FPMDF), stanowiącego systemowy model wspomagania decyzji dla proaktywnego utrzymania ruchu flot AGV. Model integruje czynniki techniczne, operacyjne, środowiskowe i historyczne oraz umożliwia generowanie interpretowalnych rekomendacji utrzymaniowych w warunkach niepewności. Tym samym wypełnia zidentyfikowaną lukę badawczą dotyczącą integracji danych eksploatacyjnych i kontekstu operacyjnego w procesie podejmowania decyzji utrzymaniowych w środowiskach Magazynu 4.0.

Słowa kluczowe: Automated Guided Vehicles (AGVs), proaktywne utrzymanie ruchu, logika rozmyta, Przemysł 4.0, Magazyn 4.0, zarządzanie utrzymaniem ruchu.

Abstract

Ensuring the reliable operation of Automated Guided Vehicles (AGVs) is a significant challenge in Warehouse 4.0 environments, where equipment failures may lead to disruptions in material flows, reduced system efficiency, and increased maintenance costs. Traditional maintenance strategies based on corrective or fixed maintenance schedules are often insufficient in highly automated intralogistics systems characterized by variable operating conditions and the coexistence of multiple factors affecting vehicle performance.

This dissertation develops and validates the Fuzzy Proactive Maintenance Decision Framework (FPMDF), a decision-support model for proactive maintenance management of AGV fleets. The proposed framework integrates technical, operational, environmental, and historical factors affecting AGV operation through a Mamdani fuzzy inference system. By combining information originating from different areas of AGV operation, the model enables the assessment of vehicle technical condition and supports maintenance decision-making under conditions of uncertainty.

The development of the framework was based on a structured procedure comprising research problem exploration, identification of degradation factors using the Ishikawa diagram, selection of key variables through Pareto–Lorenz analysis, conceptualisation of the framework structure, and formalisation of the decision-making process using fuzzy logic. As a result, a solution was developed that transforms operational and diagnostic information into maintenance assessments supporting the final evaluation of vehicle technical condition and maintenance-related decision-making.

The framework was implemented in MATLAB and subjected to a multi-stage verification and validation procedure, including structural verification, expert scenario validation, sensitivity analysis, robustness testing against input data disturbances, and evaluation using operational performance indicators. The obtained results confirmed the logical consistency of the developed solution, its stability under varying input conditions, and its usefulness as a decision-support tool for proactive maintenance management in Warehouse 4.0 environments.

The main contribution of this dissertation is the development of the Fuzzy Proactive Maintenance Decision Framework (FPMDF), a decision-support model integrating technical, operational, environmental, and historical factors into the maintenance decision-making process for AGV fleets. The proposed framework generates interpretable maintenance recommendations under conditions of uncertainty and provides a structured approach to supporting maintenance decisions in Warehouse 4.0 environments.

Keywords: Automated Guided Vehicles (AGVs), proactive maintenance, fuzzy logic, Industry 4.0, Warehouse 4.0, maintenance management.

Podziękowania

Pragnę wyrazić serdeczne podziękowania wszystkim osobom, które przyczyniły się do powstania niniejszej rozprawy doktorskiej. W szczególności składam wyrazy wdzięczności dr hab. Agnieszce Tubis, prof. uczelni oraz dr inż. Jackowi Ryczyńskiemu, za merytoryczne wsparcie, cenne wskazówki oraz konstruktywną krytykę na każdym etapie realizacji badań. Dziękuję za poświęcony czas, inspirujące dyskusje oraz motywację do pogłębiania wiedzy i rozwijania umiejętności badawczych. Dziękuję także respondentom, ekspertom oraz instytucjom, które udostępniły dane, wiedzę ekspercką lub umożliwiły konsultacje niezbędne do realizacji niniejszej pracy.

Wyrazy podziękowania kieruję również do współpracowników z Katedry Eksploatacji Systemów Technicznych Politechniki Wrocławskiej za stworzenie sprzyjającego środowiska naukowego, możliwość wymiany doświadczeń oraz wsparcie organizacyjne i merytoryczne w trakcie realizacji badań.

Szczególne podziękowania składam Rodzinie i Bliskim za cierpliwość, wyrozumiałość oraz nieocenione wsparcie emocjonalne okazywane w trakcie całego procesu przygotowania rozprawy doktorskiej.

Wrocław, 23 czerwca 2026r

mgr inż. Juni Rohman

Wykaz skrótów i ważniejszych oznaczeń

Wykaz skrótów

AI	sztuczna inteligencja (Artificial Intelligence)
CPS	systemy cyber-fizyczne (Cyber-Physical Systems)
IoT	Internet rzeczy (Internet of Things)
ML	uczenie maszynowe (Machine Learning)
ERP	planowanie zasobów przedsiębiorstwa (Enterprise Resource Planning)
MES	system realizacji produkcji (Manufacturing Execution System)
WMS	system zarządzania magazynem (Warehouse Management System)
AS/RS	automatyczny system składowania i pobierania (Automated Storage and Retrieval System)
RFID	identyfikacja radiowa (Radio-Frequency Identification)
AGV	automatyczne wózki transportowe (Automated Guided Vehicle)
AGC	automatycznie kierowany wózek transportowy (Automated Guided Cart)
LGV	laserowo kierowany pojazd (Laser Guided Vehicle)
SGV	samosterujący pojazd kierowany (Self Guided Vehicle)
GPS	system globalnego pozycjonowania (Global Positioning System)
IMU	jednostka pomiaru inercyjnego (Inertial Measurement Unit)
LIDAR	czujnik pomiaru odległości metodą laserową (Light Detection and Ranging)
CBM	utrzymanie zależne od stanu (Condition-Based Maintenance)
CMMS	komputerowy system zarządzania utrzymaniem ruchu (Computerized Maintenance Management System)
EAM	zarządzanie aktywami przedsiębiorstwa (Enterprise Asset Management)
FMEA	analiza rodzajów i skutków uszkodzeń (Failure Mode and Effects Analysis)
FMECA	analiza rodzajów, skutków i krytyczności uszkodzeń (Failure Mode, Effects and Criticality Analysis)
PdM	utrzymanie predykcyjne (Predictive Maintenance)
PM	utrzymanie prewencyjne (Preventive Maintenance)

RCA	analiza przyczyn źródłowych (Root Cause Analysis)
RCM	utrzymanie ruchu zorientowane na niezawodność (Reliability-Centered Maintenance)
RBM	utrzymanie oparte na ryzyku (Risk-Based Maintenance)
RUL	pozostały czas użytkowania (Remaining Useful Life)
FIS	system wnioskowania rozmytego (Fuzzy Inference System)
LOM	największa z maksymalnych wartości (Largest of Maximum)
MOM	średnia z maksymalnych wartości (Mean of Maximum)
SOM	najmniejsza z maksymalnych wartości (Smallest of Maximum)
KPI	kluczowe wskaźniki efektywności (Key Performance Indicators)
MTBF	średni czas między awariami (Mean Time Between Failures)
MTTR	średni czas naprawy (Mean Time To Repair)
OEE	całkowita efektywność wyposażenia (Overall Equipment Effectiveness)
ISO	Międzynarodowa Organizacja Normalizacyjna (International Organization for Standardization)

Ważniejsze oznaczenia (symbole)

$\mu_A x$	stopień przynależności zbioru rozmytego A dla wartości x
x_i	zmienna wejściowa (i -ta)
X_i	dziedzina zmiennej wejściowej x_i
A_i	zbiór rozmyty opisujący lingwistyczną wartość zmiennej x_i
Y	zmienna wyjściowa
B	zbiór rozmyty określający lingwistyczną kategorię wyjścia
x_{norm}	wartość znormalizowana zmiennej wejściowej w skali 0, 10
x_{min}	wartość minimalna zmiennej w zbiorze danych (do normalizacji)
x_{max}	wartość maksymalna zmiennej w zbiorze danych (do normalizacji)
S^*	wynik liczbowy (ciągły) modelu FIS – ostateczna ocena stanu technicznego AGV w skali 0, 10
$\mu_k S^*$	stopień przynależności wartości S^* do zbioru wyjściowego klasy k
k	etykieta klasy decyzyjnej: $k \in \{\text{KRYTYCZNY, OSTRZEŻENIE, OPTYMALNY}\}$
$\text{Recall}_{\text{krit}}$	czułość (Recall) klasy krytycznej
$\text{Precision}_{\text{krit}}$	precyzja (Precision) klasy krytycznej
MAE	średni błąd bezwzględny (Mean Absolute Error)
RMSE	pierwiastek średniego błędu kwadratowego (Root Mean Square Error)
T_{total}	planowany czas pracy floty w analizowanym okresie
T_{down}	łączy czas niedostępności floty

$T_{\text{unplanned down}}$	czas przestojów nieplanowanych
$T_{\text{planned down}}$	czas przestojów planowanych
T_{up}	czas zdolności operacyjnej floty (czas efektywnej pracy)
DR	udział przestojów nieplanowanych (Downtime Ratio)
MTBF	średni czas między awariami (Mean Time Between Failures)
MTTR	średni czas naprawy (Mean Time To Repair)
T_{repair}	łączny czas napraw w analizowanym okresie
N_f	liczba awarii w analizowanym okresie
C_{MS}	koszt jednostkowy utrzymania (w przeliczeniu na czas zdolności operacyjnej floty)
C_{unit}	koszt jednostkowy w ujęciu godzinowym (koszt/h pracy floty)
C_{maint}	całkowity koszt utrzymania w analizowanym okresie
ΔA	zmiana dostępności (Availability) w porównaniu do okresu referencyjnego
ΔMTBF	zmiana wskaźnika MTBF w porównaniu do okresu referencyjnego
ΔDR	zmiana wskaźnika DR w porównaniu do okresu referencyjnego
ΔC_{MS}	zmiana kosztu jednostkowego utrzymania w porównaniu do okresu referencyjnego

Spis treści

Streszczenie	i
Abstract	ii
Podziękowania	iii
Wykaz skrótów i ważniejszych oznaczeń	iv
1 Wprowadzenie do problematyki proaktywnego utrzymania systemów AGV w środowisku Przemysłu 4.0	1
2 Analiza stanu wiedzy w zakresie utrzymania ruchu oraz eksploatacji systemów AGV w środowisku Intralogistyki 4.0	4
2.1 Przemysł 4.0 jako paradygmat transformacji systemów logistycznych .	4
2.2 Logistyka 4.0 jako środowisko zintegrowanych operacji	6
2.2.1 Logistyka 4.0 jako rozwinięcie założeń Przemysłu 4.0	7
2.2.2 Intralogistyka jako system przepływów wewnętrznych w Logistyce 4.0	7
2.2.3 Magazyn 4.0 jako środowisko realizacji procesów intralogistycznych	8
2.2.4 Technologie wspierające realizację procesów w środowisku Magazynu 4.0	10
2.2.5 Implikacje dla niezawodności i utrzymania ruchu	13
2.3 Systemy AGV jako krytyczny zasób w środowisku Magazynu 4.0 . . .	14
2.3.1 Charakterystyka systemów AGV	14
2.3.2 Charakterystyka warunków eksploatacyjnych systemów AGV .	17
2.3.3 Implikacje dla modelowania eksploatacji systemów AGV	18
2.3.4 Trendy, wyzwania i kierunki rozwoju utrzymania ruchu systemów AGV	19
2.4 Strategie utrzymania ruchu systemów AGV	21
2.4.1 Ewolucja strategii utrzymania ruchu	22
2.4.2 Rodzaje strategii utrzymania ruchu	25
2.4.3 Strategie utrzymania ruchu systemów AGV i ich ograniczenia w środowisku Magazynu 4.0	27
2.4.4 Proaktywne utrzymanie ruchu jako paradygmat decyzyjny . .	29
2.5 Podsumowanie przeglądu literatury	31
3 Problem badawczy, cel oraz zakres pracy związany z modelem proaktywnego utrzymania ruchu systemów AGV	33
3.1 Identyfikacja występującej luki badawczej, zdefiniowanie problemu badawczego oraz związanych z nim pytań	33
3.2 Cel główny i cele szczegółowe	35
3.3 Etap pracy badawczych	36

4	Koncepcja i formalizacja modelu proaktywnego utrzymania ruchu jako systemu decyzyjnego opartego na logice rozmytej	38
4.1	Założenia analityczne oraz proces opracowania modelu	39
4.1.1	Identyfikacja i strukturyzacja przyczyn degradacji AGV z wykorzystaniem diagramu Ishikawy	42
4.1.2	Selekcja kluczowych parametrów wejściowych z wykorzystaniem analizy Pareto–Lorenza	44
4.1.3	Architektura i formalizacja matematyczna modelu decyzyjnego FPMDF	48
4.1.4	Implementacja modelu FPMDF w środowisku MATLAB	65
4.2	Weryfikacja i ewaluacja modelu	67
4.2.1	Weryfikacja formalna i logiczna modelu	67
4.2.2	Walidacja modelu: scenariusze eksperckie, zgodność i miary jakości	69
4.2.3	Dokładność, przedział ufności i macierz pomyłek	76
4.2.4	Precyzja, czułość i miara F1 dla klas	79
4.2.5	Ocena ilościowa uzyskanych w wyniku działania modelu wartości S^* : MAE i RMSE względem poziomów referencyjnych	80
4.2.6	Walidacja odporności na zakłócenia wejść (stabilność decyzji)	81
4.2.7	Strojenie modelu na podstawie rozbieżności i rejestr zmian	83
4.2.8	Ewaluacja wdrożeniowa modelu na podstawie KPI	85
4.2.9	Kryteria akceptacji modelu rozmytego (warunki formalne i wdrożeniowe) – uzasadnienie doboru	89
4.3	Podsumowanie	93
5	Wnioski, wkład pracy, ograniczenia oraz kierunki dalszych badań	95
5.1	Wnioski	95
5.2	Wkład naukowy	96
5.3	Wkład praktyczny	97
5.4	Ograniczenia	97
5.5	Kierunki dalszych badań	98
	Bibliografia	100
A	Aneks	108
A.1	Wartości krytyczne i progi dla zmiennych wejściowych modelu FIS	108
A.2	Pełna baza reguł końcowego systemu FIS	115

Spis rysunków

1.1	Struktura rozprawy	3
2.1	Technologie w Przemysle 4.0	6
2.2	Kluczowe technologie wspierające funkcjonowanie Magazynu 4.0	11
2.3	Struktura systemu AGV w środowisku Magazynu 4.0	15
2.4	Ewolucja koncepcji utrzymania ruchu	23
2.5	Schemat koncepcyjny proaktywnego utrzymania ruchu systemów AGV	31
4.1	Procedura opracowania modelu FPMDF	40
4.2	Diagram Ishikawy dla przekazywania AGV do obsługi poza harmonogramem	43
4.3	Analiza Pareto–Lorenza usterek systemu zasilania wózków AGV (próg 80%)	46
4.4	Analiza Pareto–Lorenza usterek układu jezdniego i napędowego AGV (próg 80%)	47
4.5	Analiza Pareto–Lorenza usterek sterowania i czujników AGV (próg 80%)	47
4.6	Struktura frameworku decyzyjnego FPMDF oraz przepływ ocen pomiędzy blokami wnioskowania rozmytego	50
4.7	Blok FIS poprawności funkcjonowania układu przenoszenia ładunku .	52
4.8	Blok FIS poprawności funkcjonowania układu napędowego	52
4.9	Blok FIS poprawności funkcjonowania systemu zasilania	53
4.10	Blok FIS poprawności funkcjonowania systemu nawigacyjnego	54
4.11	Blok FIS poprawności realizacji komunikacji z urządzeniem	55
4.12	Blok FIS oceny stanu technicznego wózka AGV	57
4.13	Blok FIS oceny systemu komunikacji i nawigacji	57
4.14	Blok FIS wpływu czynników środowiska pracy	58
4.15	Blok FIS analizy danych historycznych	59
4.16	Blok FIS ostatecznej oceny stanu technicznego wózka AGV	61

Spis tabel

2.1	Kluczowe założenia Magazynu 4.0 w środowisku intralogistycznym	10
2.2	Kluczowe technologie wspierające funkcjonowanie Magazynu 4.0 oraz ich znaczenie operacyjne	12
2.3	Elementy systemu AGV, ryzyka eksploatacyjne oraz implikacje decyzyjne dla utrzymania ruchu	16
2.4	Kluczowe uwarunkowania eksploatacyjne systemów AGV	18
2.5	Kluczowe trendy i wyzwania utrzymania ruchu systemów AGV w środowisku Magazynu 4.0	21
2.6	Porównanie strategii utrzymania ruchu (UR 1.0–4.0)	24
2.7	Syntetyczne porównanie strategii utrzymania ruchu	27
2.8	Porównanie strategii utrzymania ruchu w kontekście eksploatacji systemów AGV w środowisku Magazynu 4.0	29
3.1	Etapy prac badawczych	36
4.1	Rola metod i narzędzi w procesie budowy modelu decyzyjnego	42
4.2	Syntetyczne zestawienie kategorii przyczyn zidentyfikowanych w analizie Ishikawy oraz ich znaczenia dla budowy modelu	43
4.3	Parametry i liczba ujawnionych przypadków dla wózków AGV	46
4.4	Wybrane reguły rozmyte (reprezentatywne) w końcowym systemie FIS	64
4.5	Wyniki weryfikacji formalno-logicznej modelu rozmytego	68
4.6	Wyniki walidacji scenariuszowej – porównanie decyzji modelu z oceną ekspercką	71
4.7	Macierz pomyłek (Ocena (klasa) eksperta → ocena (klasa) modelu)	77
4.8	Miary jakości klasyfikacji dla klas (walidacja scenariuszowa)	79
4.9	Macierz pomyłek dla testu odporności (180 przypadków zaburzonych)	83
4.10	Rejestr zmian strojenia modelu po walidacji (dokumentacja iteracji)	84
4.11	Parametry eksploatacyjne floty (warunki odniesienia dla KPI).	88
4.12	Dane wejściowe z eksploatacji przedsiębiorstwa oraz obliczenia pośrednie za okres 3 miesięcy.	88
4.13	Wskaźniki KPI floty AGV w ujęciu miesięcznym.	88
4.14	Zestaw kryteriów akceptacji modelu rozmytego (warunki formalne i wdrożeniowe).	93
A.1	Wartości krytyczne i progi dla zmiennych wejściowych modelu FIS (Aneks A, Tab. A.1)	109
A.2	Pełna baza reguł końcowego systemu FIS dla oceny stanu technicznego wózka AGV	115

1

Wprowadzenie do problematyki proaktywnego utrzymania systemów AGV w środowisku Przemysłu 4.0

Rozwój koncepcji Przemysłu 4.0 zasadniczo zmienia sposób projektowania, organizacji oraz eksploatacji systemów produkcyjnych i logistycznych [1]. Integracja systemów cyber-fizycznych (CPS) oraz Internetu rzeczy (IoT) umożliwia powiązanie procesów fizycznych z ich reprezentacją cyfrową [2]. Równocześnie rozwój analityki danych oraz systemów komunikacji rozszerza te możliwości o bieżące monitorowanie, analizę i sterowanie procesami w czasie zbliżonym do rzeczywistego [2, 3]. W rezultacie współczesne systemy logistyczne coraz częściej funkcjonują jako układy dynamiczne, w których decyzje operacyjne podejmowane są na podstawie aktualnych danych eksploatacyjnych [2].

Zmiany te znajdują bezpośrednie odzwierciedlenie w rozwoju Intralogistyki 4.0 oraz magazynów nowej generacji (Magazyn 4.0), stanowiących istotny element cyfrowych łańcuchów dostaw [4]. Systemy te charakteryzują się wysokim poziomem automatyzacji, integracją warstw informacyjnych oraz zdolnością adaptacji do zmieniających warunków operacyjnych [5]. W takich środowiskach szczególne znaczenie mają autonomiczne systemy transportowe, umożliwiające realizację procesów logistycznych w sposób elastyczny i skalowalny. W praktyce oznacza to odejście od struktur statycznych na rzecz systemów rekonfigurowalnych, których funkcjonowanie zależy od bieżącego stanu operacyjnego.

Automatyczne wózki transportowe (AGV) stanowią jeden z podstawowych zasobów współczesnej intralogistyki [6]. Umożliwiają realizację transportu materiałów pomiędzy strefami przyjęć, produkcji oraz wysyłki [7]. W odróżnieniu od klasycznych systemów przenośnikowych pozwalają na dynamiczne dostosowywanie tras, obciążeń oraz harmonogramów zadań do aktualnych warunków operacyjnych [6, 7]. Tym samym wspierają realizację koncepcji Just-in-Time oraz zwiększają elastyczność funkcjonowania systemów logistycznych [6].

Wraz ze wzrostem poziomu automatyzacji rośnie znaczenie niezawodności i dostępności floty AGV [8]. W środowisku Magazynu 4.0 utrzymanie ruchu przestaje być wyłącznie zagadnieniem technicznym, a staje się elementem zarządzania operacyjnego. Awaria pojedynczego pojazdu może prowadzić do zakłóceń na poziomie całego

systemu, których skutkiem są opóźnienia realizacji zadań, spadek przepustowości oraz wzrost kosztów operacyjnych. Oznacza to konieczność ujmowania utrzymania ruchu w sposób systemowy, z uwzględnieniem współzależności pomiędzy zasobami [8, 9].

W takich warunkach tradycyjne strategie utrzymania ruchu, oparte na podejściach reaktywnych lub zapobiegawczych, okazują się niewystarczające [10]. Pomimo istotnego postępu, jaki podejścia predykcyjne wniosły do zarządzania utrzymaniem ruchu, ich zastosowanie koncentruje się głównie na prognozowaniu stanu technicznego komponentów [10]. W praktyce eksploatacyjnej decyzje utrzymaniowe wymagają jednak uwzględnienia dodatkowych czynników związanych z realizowanymi procesami logistycznymi, poziomem obciążenia systemu oraz zależnościami pomiędzy współpracującymi zasobami [11, 12]. Ogranicza to możliwość bezpośredniego wykorzystania wyników predykcji w procesach decyzyjnych. W konsekwencji ich przydatność w procesie podejmowania decyzji eksploatacyjnych może być niewystarczająca, szczególnie w złożonych środowiskach operacyjnych [10, 11].

Jednym z kierunków rozwoju współczesnych strategii utrzymania ruchu jest podejście proaktywne, którego celem nie jest wyłącznie przewidywanie potencjalnych uszkodzeń, lecz również wspomaganie wyboru działań ograniczających ich wpływ na funkcjonowanie systemu [12]. Podejście to integruje dane eksploatacyjne, informacje diagnostyczne oraz wiedzę ekspercką, umożliwiając podejmowanie decyzji w warunkach niepewności i zmienności charakterystycznych dla rzeczywistych procesów eksploatacyjnych [11, 12]. W rezultacie możliwe staje się bardziej kompleksowe wspomaganie decyzji utrzymaniowych oraz uwzględnienie szerszego kontekstu operacyjnego niż w przypadku klasycznych podejść predykcyjnych [13].


Szczególne wymagania dotyczą systemów AGV, które charakteryzują się mobilnością, zmiennym obciążeniem oraz silnymi współzależnościami operacyjnymi [14]. Dostępne rozwiązania mają często charakter fragmentaryczny lub ograniczają się do środowisk symulacyjnych [11, 13]. W niewielkim stopniu uwzględniają one rzeczywiste warunki eksploatacyjne oraz integrację z systemami zarządzania magazynem, co wyraźnie ogranicza ich użyteczność wdrożeniową [13].

Pomimo rosnącego zainteresowania podejściami predykcyjnymi oraz proaktywnymi, w literaturze nadal brakuje rozwiązań umożliwiających spójną integrację danych technicznych i operacyjnych oraz uwzględnienie współzależności pomiędzy zasobami w warunkach rzeczywistej eksploatacji [11, 13, 15–17]. W szczególności widoczny jest brak modeli wspierających proces decyzyjny w utrzymaniu ruchu poprzez powiązanie stanu technicznego z kontekstem operacyjnym systemu.

Zidentyfikowana luka badawcza wskazuje na potrzebę opracowania narzędzia wspomagającego podejmowanie decyzji utrzymaniowych z uwzględnieniem zarówno danych technicznych, jak i operacyjnych. Wymaga to zastosowania metod umożliwiających integrację informacji pochodzących z różnych źródeł oraz uwzględniających niepewność charakterystyczną dla rzeczywistych warunków eksploatacji.

Z tego względu celem rozprawy jest opracowanie oraz weryfikacja systemowego modelu decyzyjnego wspomagającego utrzymanie systemów AGV eksploatowanych w środowisku Magazynu 4.0. Proponowane rozwiązanie integruje dane techniczne i operacyjne, uwzględnia współzależności pomiędzy zasobami oraz umożliwia ocenę wpływu decyzji na funkcjonowanie systemu intralogistycznego w warunkach niepewności.

Struktura rozprawy została podporządkowana przyjętej logice badawczej (Rys. 1.1). Rozdział 2 zawiera przegląd literatury dotyczącej systemów AGV oraz strategii utrzymania ruchu w środowisku Magazynu 4.0, ze szczególnym uwzględnieniem ich ograniczeń. W rozdziale 3 przedstawiono lukę badawczą oraz sformułowano cel i zakres pracy. Rozdział 4 opisuje metodykę badań oraz konstrukcję i walidację modelu. Na ostatnim Rozdział 5 zaprezentowano wnioski końcowe oraz kierunki dalszych prac badawczych.



Rys. 1.1. Struktura rozprawy
Źródło: Opracowanie własne

2

Analiza stanu wiedzy w zakresie utrzymania ruchu oraz eksploatacji systemów AGV w środowisku Intralogistyki 4.0

2.1. Przemysł 4.0 jako paradygmat transformacji systemów logistycznych

Przemysł 4.0, określany jako czwarta rewolucja przemysłowa, oznacza zasadniczą zmianę w sposobie projektowania, realizacji oraz zarządzania procesami produkcyjnymi i logistycznymi [18]. Zmiana ta ma charakter nie tylko technologiczny, lecz również systemowy, ponieważ obejmuje sposób organizacji oraz podejmowania decyzji w środowiskach przemysłowych. W odróżnieniu od wcześniejszych etapów rozwoju przemysłu, koncentrujących się odpowiednio na mechanizacji, elektryfikacji oraz automatyzacji, współczesny paradygmat opiera się na ścisłej integracji systemów fizycznych z technologiami cyfrowymi [1]. Transformacja ta nie ogranicza się jednak wyłącznie do wdrażania nowych rozwiązań technicznych. Przemysł 4.0 należy rozumieć szerzej jako model przekształcenia środowiska przemysłowego, obejmujący warstwę technologiczną, organizacyjną oraz decyzyjną.

Pomimo szerokiego zainteresowania badawczego nie wykształciła się jedna, powszechnie akceptowana definicja Przemysłu 4.0, co wskazuje na wciąż niedostateczny poziom konceptualnej spójności tego pojęcia. Lasi i in. [18] eksponują integrację systemów technicznych i organizacyjnych, Lee i in. [19] koncentrują się na systemach cyber-fizycznych, natomiast Lu [3] podkreśla rolę danych oraz ich analizy jako podstawy autonomizacji procesów. Różnice te nie mają wyłącznie charakteru definicyjnego, lecz wpływają także na sposób ujmowania systemów przemysłowych, a tym samym utrudniają jednoznaczne porównywanie wyników badań. Z tego względu Przemysł 4.0 należy traktować raczej jako integracyjny model środowiska przemysłowego niż jako pojęcie o sztywno ustalonych granicach.

Niezależnie od tych różnic w większości ujęć wspólny pozostaje rdzeń technologiczny obejmujący systemy cyber-fizyczne (CPS), Internet rzeczy (IoT), sztuczną

inteligencję oraz analizę danych [3]. Integracja tych technologii pozwala na nieprzerwaną wymianę informacji między zasobami fizycznymi i cyfrowymi, co prowadzi do tworzenia środowisk zdolnych do samodzielnego pozyskiwania, przetwarzania i przekazywania danych pomiędzy rozproszonymi zasobami, a także do osiągnięcia zdolności adaptacyjnych oraz częściowej autonomii [20]. W ujęciu systemowym oznacza to przejście od scentralizowanych mechanizmów sterowania do rozproszonych struktur decyzyjnych, w których decyzje mogą być podejmowane na podstawie aktualnych i kontekstowych danych [19]. Rozwiązanie to zwiększa elastyczność operacyjną, jednak równocześnie prowadzi do wzrostu złożoności systemów oraz liczby współzależności pomiędzy ich elementami.


Fundamentem funkcjonowania Przemysłu 4.0 jest zatem integracja zasobów fizycznych z infrastrukturą cyfrową [1]. Proces ten obejmuje nie tylko warstwę technologiczną, lecz także przepływy informacji oraz procesy decyzyjne. Dzięki temu możliwe staje się monitorowanie procesów w czasie zbliżonym do rzeczywistego, ich predykcja, optymalizacja oraz częściowa autonomizacja. Zwiększa to efektywność wykorzystania zasobów, ale równocześnie uzależnia sprawność całego systemu od jakości danych, poprawności ich przetwarzania oraz niezawodności infrastruktury komunikacyjnej. Oznacza to przesunięcie punktu ciężkości z samej automatyzacji procesów na zdolność systemów do wykorzystywania danych jako podstawy działań operacyjnych i procesów decyzyjnych.

Cele wdrażania koncepcji Przemysłu 4.0 mają charakter wieloaspektowy i obejmują w szczególności:

- 1) **Cyfryzację i integrację systemów** – umożliwiającą tworzenie interoperacyjnych środowisk operacyjnych opartych na danych [3, 19, 21],
- 2) **Elastyczność i adaptacyjność** – pozwalającą reagować na zmienność popytu i warunków otoczenia [21, 22],
- 3) **Wzrost efektywności operacyjnej** – poprzez optymalizację procesów i ograniczenie przestoju [12, 13],
- 4) **Zrównoważony rozwój** – związany z efektywniejszym wykorzystaniem zasobów [23, 24],
- 5) **Transformację modeli biznesowych** – opartych na danych i elastyczności operacyjnej [22, 25],
- 6) **Zmianę roli człowieka** – w kierunku funkcji analitycznych i decyzyjnych [19, 21].

Do kluczowych technologii Przemysłu 4.0 zalicza się IoT, analitykę danych, sztuczną inteligencję oraz systemy cyber-fizyczne [3]. Ich znaczenie nie wynika jednak wyłącznie z indywidualnych możliwości, lecz przede wszystkim z ich integracji, która umożliwia przekształcanie rozproszonych danych w podstawy decyzji operacyjnych [19]. Uzupełniają je technologie takie jak robotyka autonomiczna czy rzeczywistość rozszerzona, zwiększające poziom automatyzacji oraz zakres współpracy człowieka z systemami technicznymi [21, 26].

Na Rys. 2.1 przedstawiono schemat integrujący kluczowe komponenty Przemysłu 4.0.



Rys. 2.1. Technologie w Przemysle 4.0
Źródło: Opracowanie własne na podstawie [3]

Pomimo licznych korzyści literatura konsekwentnie wskazuje również na istotne wyzwania związane z implementacją tej koncepcji. Dotyczą one przede wszystkim wysokiej złożoności systemów, problemów integracyjnych, jakości danych oraz cyberbezpieczeństwa [19]. Im silniejsza integracja, tym większa podatność systemu na zakłócenia, a nieprawidłowe działanie pojedynczego elementu może prowadzić do efektów kaskadowych w skali całego układu.

Z punktu widzenia niniejszej rozprawy kluczowe znaczenie ma fakt, że rosnąca integracja i automatyzacja bezpośrednio zwiększają znaczenie decyzji dotyczących niezawodności oraz utrzymania ruchu. W środowiskach silnie powiązanych dostępność zasobów technicznych staje się jednym z podstawowych warunków ciągłości procesów operacyjnych. W efekcie utrzymanie ruchu nie może być rozpatrywane wyłącznie jako funkcja techniczna, lecz jako element wpływający na efektywność funkcjonowania całego systemu logistycznego. Wniosek ten stanowi punkt wyjścia do dalszej analizy systemów intralogistycznych oraz roli utrzymania ruchu w ich funkcjonowaniu.

2.2. Logistyka 4.0 jako środowisko zintegrowanych operacji

Rzeczywistość systemów logistycznych w ostatnich dekadach pozostawał ściśle związany z postępowaniem technologicznym, cyfryzacją procesów oraz zmianami w organizacji przepływów materiałowych i informacyjnych. W ujęciu klasycznym logistyka była rozpatrywana przede wszystkim jako obszar odpowiedzialny za fizyczny przepływ dóbr, obejmujący transport, magazynowanie, zaopatrzenie i dystrybucję. Obecnie takie spojrzenie okazuje się jednak niewystarczające. Współczesne systemy logistyczne należy zatem ujmować szerzej, jako zintegrowane środowiska operacyjne, w których dane, decyzje i zasoby techniczne tworzą układ wzajemnych zależności.

Wraz z rozwojem mechanizacji, automatyzacji i systemów informatycznych rosło znaczenie planowania, koordynacji oraz kontroli procesów, a logistyka stopniowo przestawała być wyłącznie funkcją wykonawczą, zyskując coraz większe znaczenie organizacyjne i strategiczne [4]. Na tym tle Logistyka 4.0 może być postrzegana jako

konsekwencja postępującej cyfryzacji i integracji procesów logistycznych, prowadząca do powstawania środowisk charakteryzujących się wysokim poziomem powiązań pomiędzy warstwą fizyczną, informacyjną i decyzyjną.

W takim ujęciu intralogistyka oraz środowiska realizacji jej procesów, w tym magazyn, nie tworzą odrębnego, nadrzędnego paradygmatu wobec Logistyki 4.0, lecz stanowią jej operacyjne rozwinięcie na poziomie przedsiębiorstwa. Analiza systemów intralogistycznych i magazynowych powinna więc zostać osadzona w szerszym kontekście transformacji logistycznej wynikającej z wdrażania rozwiązań Przemysłu 4.0.

Aby lepiej uchwycić rolę logistyki w strukturze współczesnych systemów logistycznych, niezbędne jest omówienie podstawowych założeń Logistyki 4.0 oraz wskazanie ich oddziaływania na sposób organizacji procesów przepływu materiałów i informacji.

2.2.1. Logistyka 4.0 jako rozwinięcie założeń Przemysłu 4.0

W literaturze Logistyka 4.0 najczęściej definiowana jest jako zastosowanie założeń oraz technologii Przemysłu 4.0 do zarządzania przepływami materiałowymi, informacyjnymi i decyzyjnymi w łańcuchach dostaw [4, 27]. W takim ujęciu szczególne znaczenie przypisuje się integracji warstwy fizycznej i cyfrowej, zdolności do przetwarzania danych w czasie zbliżonym do rzeczywistego, sieciowaniu zasobów oraz wykorzystaniu algorytmów wspierających decyzje operacyjne [28, 29]. Oznacza to odejście od sekwencyjnego zarządzania odrębnymi procesami na rzecz logiki systemowej, w której przepływy materiałowe, informacyjne i decyzyjne tworzą spójny układ zależności.

Logistyka 4.0 nie jest jednak prostym odpowiednikiem Przemysłu 4.0 przeniesionym do obszaru przepływów materiałowych. O jej specyfice decydują większe rozproszenie procesów, wielopodmiotowość środowiska działania oraz silna zależność od interoperacyjności i spójności danych pomiędzy uczestnikami systemu [4, 30]. Z tego względu jej analiza wymaga perspektywy szerszej niż perspektywa pojedynczego systemu technicznego. Obejmuje ona nie tylko automatyzację, lecz również koordynację międzyorganizacyjną, integrację danych i zdolność reagowania na zakłócenia.

W perspektywie przyjętej w niniejszej rozprawie Logistyka 4.0 stanowi ramy interpretacyjne dla rozwoju nowoczesnych systemów operacyjnych, obejmujących zarówno środowiska magazynowe, jak i procesy realizowane wewnątrz przedsiębiorstwa. To właśnie w tych obszarach szczególnie widoczne stają się konsekwencje rosnącej integracji zasobów, danych i procesów decyzyjnych. Wraz ze wzrostem poziomu współzależności systemowych rośnie również znaczenie niezawodności oraz utrzymania ruchu jako czynników warunkujących ciągłość funkcjonowania procesów logistycznych.

2.2.2. Intralogistyka jako system przepływów wewnętrznych w Logistyce 4.0

W warunkach Logistyki 4.0 szczególne znaczenie zyskuje intralogistyka, rozumiana jako zbiór procesów przepływu materiałów, informacji oraz decyzji realizowanych wewnątrz przedsiębiorstwa. Obejmuje ona między innymi transport wewnętrzny, magazynowanie, kompletację, zasilanie stanowisk roboczych oraz koordynację zasobów wykonawczych. W odróżnieniu od logistyki analizowanej w skali całego łańcucha dostaw, intralogistyka koncentruje się na procesach realizowanych w obrębie organizacji,

gdzie kluczowe znaczenie mają synchronizacja, ciągłość przepływów oraz zdolność systemu do reagowania na zakłócenia.

W środowisku Logistyki 4.0 intralogistyka przestaje być postrzegana wyłącznie jako zbiór operacji wykonawczych. Coraz częściej ujmowana jest jako zintegrowany system zarządzania przepływami, obejmujący warstwę fizyczną, informacyjną oraz decyzyjną. Oznacza to, że efektywność realizowanych procesów zależy nie tylko od sprawności poszczególnych zasobów technicznych, lecz również od jakości ich wzajemnej koordynacji, dostępności informacji oraz zdolności systemu do adaptacji w warunkach zmienności operacyjnej [4, 28].

Jednym z kluczowych środowisk realizacji procesów intralogistycznych jest magazyn, w którym przepływy materiałowe i informacyjne podlegają szczególnie ścisłej koordynacji. W warunkach transformacji cyfrowej środowisko to przekształca się w coraz bardziej zautomatyzowany i zintegrowany system operacyjny, stanowiący istotny element współczesnych systemów intralogistycznych.

W literaturze podkreśla się, że jedną z podstawowych cech nowoczesnych systemów intralogistycznych jest integracja procesów fizycznych i cyfrowych [4]. W praktyce przejawia się to tym, że obiekty fizyczne, takie jak środki transportu, jednostki ładunkowe, urządzenia magazynowe czy elementy infrastruktury, uzyskują zdolność generowania danych, komunikacji z otoczeniem oraz uczestniczenia w zintegrowanych procesach sterowania. Umożliwia to bieżące monitorowanie lokalizacji, stanu i parametrów pracy zasobów, a następnie wykorzystywanie tych informacji do wspomagania decyzji operacyjnych [28, 29].

Ważną cechą systemów intralogistycznych jest ich relacyjny charakter. Efektywność przepływów nie wynika tu wyłącznie z parametrów pojedynczych zasobów, lecz z jakości powiązań pomiędzy systemami transportowymi, magazynowymi, informatycznymi i decyzyjnymi. Oznacza to, że zakłócenie lokalne może przerodzić się w zakłócenie systemowe, wpływające na przepustowość, terminowość i stabilność całego układu. W tym sensie intralogistyka w warunkach Logistyki 4.0 ma charakter wielowarstwowy i obejmuje warstwę fizyczną, informacyjną oraz analityczno-decyzyjną, które pozostają ze sobą w ścisłej zależności. Skuteczność funkcjonowania systemu zależy zatem nie tylko od sprawności poszczególnych elementów, lecz również od jakości ich wzajemnej integracji.

2.2.3. Magazyn 4.0 jako środowisko realizacji procesów intralogistycznych

Magazyn stanowi jedno z kluczowych środowisk realizacji procesów intralogistycznych, obejmujących składowanie, transport wewnętrzny, kompletację, konsolidację oraz synchronizację przepływów materiałowych. W warunkach transformacji cyfrowej magazyn przestaje pełnić wyłącznie funkcję buforową, a staje się aktywnym ogniwem realizacji i koordynacji procesów operacyjnych [31, 32]. W środowisku Magazynu 4.0 procesy intralogistyczne osiągają szczególnie wysoki poziom intensywności, współzależności oraz podatności na zakłócenia, dlatego sprawność funkcjonowania tego środowiska ma bezpośredni wpływ na efektywność całego systemu.

W tradycyjnych magazynach dominowały praca manualna, papierowa ewidencja zapasów oraz ograniczona integracja procesów składowania, transportu wewnętrznego i kompletacji. W takich warunkach zarządzanie miało głównie charakter

reaktywny, a dostęp do informacji o stanie systemu był ograniczony i opóźniony [33, 34]. Rozwój rozwiązań automatyzacyjnych i informatycznych zwiększył wydajność oraz dokładność operacji, jednak przez długi czas systemy te zachowywały ograniczoną zdolność adaptacji [31, 35].

Na tym tle koncepcja Magazynu 4.0 oznacza zmianę jakościową. W literaturze podkreśla się, że jego istotą nie jest wyłącznie wzrost poziomu automatyzacji, lecz przekształcenie magazynu w system cyber-fizyczny o wysokiej intensywności operacji, zdolny do bieżącego monitorowania, synchronizacji i rekonfiguracji procesów [32, 36]. Jednocześnie to właśnie wzrost automatyzacji i integracji sprawia, że system magazynowy staje się bardziej wrażliwy na zakłócenia oraz degradację poszczególnych zasobów technicznych. Zwiększa to znaczenie podejść uwzględniających niezawodność oraz utrzymanie ruchu w ujęciu systemowym.

Jednym z najważniejszych skutków tej transformacji jest wzrost przejrzystości procesów oraz identyfikowalności przepływów materiałowych [36]. Przejrzystość oznacza możliwość uzyskania bieżącego obrazu funkcjonowania systemu, obejmującego stan zapasów, lokalizację zasobów, przebieg operacji i pojawiające się zakłócenia. Identyfikowalność pozwala natomiast odtworzyć drogę przepływu materiału i powiązać ją z odpowiednimi zdarzeniami operacyjnymi. W rezultacie magazyn przestaje być „czarną skrzynką” pomiędzy przyjęciem a wysyłką, a staje się środowiskiem, którego stan może być systematycznie obserwowany, analizowany i interpretowany.

Magazyn 4.0 nie może być jednak utożsamiany wyłącznie z obecnością zaawansowanej infrastruktury technicznej. O jego dojrzałości decyduje stopień, w jakim technologie, dane i mechanizmy sterowania tworzą spójny system operacyjny. Magazyn wyposażony w wiele nowoczesnych urządzeń, lecz pozbawiony integracji informacyjnej i koordynacji decyzji, nie spełnia jeszcze założeń Magazynu 4.0 w sensie systemowym. Z tego względu kluczowe znaczenie ma nie liczba wdrożonych technologii, lecz jakość ich integracji oraz zdolność do wspierania decyzji operacyjnych [37, 38].

Konsekwencją niedostatecznej integracji informacyjnej oraz koordynacji decyzji jest ograniczona zdolność systemu do zapewnienia bieżącej przejrzystości procesów oraz identyfikowalności przepływów materiałowych [32, 37]. Utrudnia to uzyskanie pełnego obrazu funkcjonowania magazynu w czasie zbliżonym do rzeczywistego [32]. Ponadto brak spójnego przepływu danych pomiędzy zasobami technicznymi i systemami informacyjnymi ogranicza możliwość synchronizacji operacji magazynowych oraz ich dynamicznej rekonfiguracji w odpowiedzi na zmieniające się warunki. W rezultacie system zachowuje charakter reaktywny, zamiast realizować założenia podejścia proaktywnego i adaptacyjnego [38]. Niedostateczna integracja wpływa również na ograniczoną zdolność wspomagania decyzji operacyjnych, w tym planowania, harmonogramowania oraz utrzymania ruchu [32, 37]. W konsekwencji, pomimo obecności zaawansowanych technologii, magazyn taki nie osiąga poziomu dojrzałości systemowej charakterystycznego dla Magazynu 4.0.

Na podstawie przedstawionych w literaturze założeń Magazynu 4.0 oraz wymagań dotyczących integracji procesów, przejrzystości operacyjnej i niezawodności systemu, syntetyczne ujęcie kluczowych cech tego środowiska przedstawiono w tabeli 2.1.

Tab. 2.1. Kluczowe założenia Magazynu 4.0 w środowisku intralogistycznym


Kluczowe założenie Magazynu 4.0	Znaczenie w środowisku intralogistycznym
Transformacja roli magazynu	Magazyn przestaje pełnić wyłącznie funkcję buforową i staje się aktywnym ogniwem realizacji, synchronizacji i optymalizacji przepływów materiałowych.
Integracja procesów magazynowych	Założeniem Magazynu 4.0 jest integracja procesów przyjęcia, składowania, kompletacji, transportu wewnętrznego i wysyłki w ramach jednego spójnego systemu operacyjnego.
Cyber-fizyczny charakter systemu	Magazyn 4.0 funkcjonuje jako system cyber-fizyczny, zdolny do bieżącego monitorowania, synchronizacji oraz rekonfiguracji procesów.
Przejrzystość procesów	System zapewnia bieżący wgląd w stan zapasów, lokalizację zasobów, przebieg operacji oraz pojawiające się zakłócenia.
Identyfikowalność przepływów	Magazyn umożliwia śledzenie historii przepływu materiałów i powiązanie ich z odpowiednimi zdarzeniami operacyjnymi.
Integracja informacyjna i wspomaganie decyzji	O dojrzałości Magazynu 4.0 decyduje stopień integracji danych, technologii i mechanizmów sterowania wspierających decyzje operacyjne.
Niezawodność i utrzymanie ruchu	Wysoki poziom automatyzacji i intensywności operacyjnej wymaga zapewnienia niezawodności zasobów technicznych oraz wdrażania proaktywnego utrzymania ruchu.

Źródło: Opracowanie własne na podstawie [31–33, 35–38].

2.2.4. Technologie wspierające realizację procesów w środowisku Magazynu 4.0

Technologiczne zaplecze nowoczesnych systemów magazynowych jest zróżnicowane, jednak jego rzeczywista wartość ujawnia się dopiero w warunkach integracji [27, 30]. Poszczególnych technologii nie należy analizować jako odrębnych komponentów, lecz jako elementy szerszego ekosystemu cyfrowego, łączącego warstwę fizyczną, warstwę danych i warstwę decyzji [27, 30]. Dlatego środowisko Magazynu 4.0 coraz częściej ujmowane jest nie jako zbiór narzędzi, lecz jako architektura operacyjna integrująca urządzenia, dane, modele i mechanizmy sterowania [4, 30].

Na Rys. 2.2 przedstawiono schemat ilustrujący główne technologie wspierające rozwój nowoczesnych systemów magazynowych. Ich zestawienie pokazuje, że środowisko to rozwija się w kierunku układów wielowarstwowych, w których warstwa fizyczna, informacyjna i analityczna pozostają ze sobą w ścisłym związku.



Rys. 2.2. Kluczowe technologie wspierające funkcjonowanie Magazynu 4.0

Źródło: Opracowanie własne na podstawie [4]

Technologie wspierające funkcjonowanie Magazynu 4.0 pełnią odmienne role operacyjne, jednak ich wspólnym celem jest zwiększenie zdolności systemu do pozyskiwania danych, ich przetwarzania oraz wspomagania decyzji podejmowanych w czasie zbliżonym do rzeczywistego [29, 39, 40]. Ich znaczenie można syntetycznie ująć następująco:

- 1) **Internet rzeczy (IoT) i sieci czujników** umożliwiają bieżące śledzenie zasobów, monitorowanie ich stanu oraz rejestrację zdarzeń operacyjnych, zwiększając widoczność i identyfikowalność procesów [28, 41].
- 2) **Analitika dużych zbiorów danych** pozwala identyfikować wzorce, prognozować zdarzenia i wspierać decyzje dotyczące popytu, zapasów, tras transportowych oraz zakłóceń operacyjnych [28, 29].
- 3) **Sztuczna inteligencja i uczenie maszynowe** wspierają automatyzację procesów decyzyjnych, optymalizację tras, harmonogramowanie zadań i zarządzanie flotą, a także rozwój podejść predykcyjnych w utrzymaniu ruchu [42, 43].
- 4) **Cyfrowe bliźniaki** umożliwiają odwzorowanie zasobów i procesów oraz analizę scenariuszy decyzyjnych w warunkach zmiennego obciążenia [40, 44].
- 5) **Przetwarzanie w chmurze** tworzy infrastrukturę dla przechowywania, integracji i udostępniania danych w skali całego systemu [29, 45].
- 6) **Blockchain** wspiera integralność, niezmiennosc i identyfikowalność danych w środowiskach wielopodmiotowych [46–48].
- 7) **Pojazdy autonomiczne, drony i robotyka** wspierają automatyzację transportu, kompletacji i manipulacji materiałami, zwiększając elastyczność oraz wydajność operacji [49–52].

- 8) **Technologie rozszerzonej i wirtualnej rzeczywistości (AR/VR)** wspierają wizualizację procesów, szkolenia operatorów oraz kompletację zamówień, zwiększając przejrzystość i efektywność operacji magazynowych [53–55].
- 9) **Roboty współpracujące (koboty)** wspierają realizację procesów kompletacji, manipulacji materiałami oraz operacji transportowych we współpracy z operatorem, zwiększając elastyczność i efektywność systemów intralogistycznych [56, 57].

W celu syntetycznego uporządkowania tych rozwiązań oraz wskazania ich typowych zastosowań i efektów wdrożeniowych zestawiono je w Tab. 2.2.

Tab. 2.2. Kluczowe technologie wspierające funkcjonowanie Magazynu 4.0 oraz ich znaczenie operacyjne

Komponent	Główne zastosowania	Kluczowe efekty
Internet Rzeczy (IoT) i czujniki	Śledzenie w czasie rzeczywistym, monitoring stanu zasobów i procesów	Widoczność, identyfikowalność, skuteczniejsze zarządzanie ryzykiem
Big Data i analityka	Prognozowanie, optymalizacja tras transportowych i poziomów zapasów	Efektywność operacyjna, dokładność decyzji, wysoka responsywność
Sztuczna inteligencja (AI) i uczenie maszynowe	Harmonogramowanie zadań, predyktoryjne utrzymanie ruchu, automatyzacja procesów decyzyjnych	Odporność systemów, redukcja kosztów, zwiększona zwinność
Cyfrowe bliźniaki	Wirtualne odwzorowanie zasobów i procesów (np. AGV, robotyka, przenośniki)	Lepsze planowanie i sterowanie, redukcja przestojów i zakłóceń
Przetwarzanie w chmurze	Współpraca między systemami, wymiana informacji, integracja danych	Transparentność, skalowalność, elastyczność infrastruktury
Blockchain	Dokumentacja procesów, zapewnienie zgodności, bezpieczeństwo transakcji	Zaufanie, identyfikowalność, autentyczność danych
Pojazdy autonomiczne, drony i robotyka	Automatyzacja transportu, kompletacji i manipulacji materiałami	Elastyczność operacji, wzrost wydajności, redukcja pracy manualnej
Technologie AR/VR	Wizualizacja procesów, szkolenia operatorów, wsparcie kompletacji	Przejrzystość procesów, poprawa efektywności i bezpieczeństwa pracy
Roboty współpracujące (koboty)	Współpraca człowieka z robotem w procesach logistycznych	Elastyczność operacyjna, poprawa ergonomii, wzrost produktywności

Źródło: Opracowanie własne na podstawie [28, 29, 40–57].

Zestawione technologie tworzą układ wzajemnie powiązany, w którym wartość poszczególnych rozwiązań rośnie wraz z poziomem ich integracji. To właśnie integracja decyduje o przejściu od środowiska częściowo zautomatyzowanego do środowiska zdolnego do bieżącego monitorowania, analizy i rekonfiguracji procesów. W kontekście niniejszej rozprawy szczególne znaczenie mają technologie umożliwiające pozyskiwanie i przetwarzanie danych o stanie zasobów, ponieważ to one stanowią podstawę podejmowania decyzji utrzymaniowych w warunkach niepewności.

2.2.5. Implikacje dla niezawodności i utrzymania ruchu

Pomimo dużego potencjału transformacyjnego Logistyki 4.0, a w jej obrębie także nowoczesnych systemów intralogistycznych i magazynowych, rozwój ten wiąże się z istotnymi wyzwaniami. W literaturze zwraca się uwagę przede wszystkim na problemy interoperacyjności systemów, integracji heterogenicznych źródeł danych, bezpieczeństwa informacji oraz rosnącej złożoności architektury technologicznej [4, 29]. Im większa liczba połączonych urządzeń, platform i algorytmów uczestniczy w zarządzaniu procesami, tym większego znaczenia nabierają jakość danych, stabilność komunikacji oraz zgodność standardów. Zatem, że pełne wykorzystanie potencjału transformacji cyfrowej zależy nie tylko od dostępności technologii, lecz także od zdolności organizacji do ich skutecznej integracji i utrzymania spójności operacyjnej.

Z punktu widzenia niniejszej rozprawy szczególnie istotne jest to, że wzrost automatyzacji, integracji i intensywności przepływów prowadzi równocześnie do wzrostu wymagań wobec dostępności i niezawodności zasobów technicznych. W środowiskach silnie powiązanych zakłócenie pracy pojedynczego środka transportu, urządzenia magazynowego lub elementu infrastruktury może wywoływać konsekwencje wykraczające poza poziom lokalny i wpływać na funkcjonowanie całego układu operacyjnego. Utrzymanie ruchu nie może być zatem traktowane wyłącznie jako funkcja techniczna, lecz jako element zarządzania ciągłością działania systemu [58, 59].

Literatura wskazuje, że rozwój czujników IoT, zaawansowanej analityki danych, sztucznej inteligencji oraz rozwiązań chmurowych sprzyja wdrażaniu strategii predykcyjnych i proaktywnych, umożliwiających wcześniejsze wykrywanie anomalii oraz lepsze planowanie działań serwisowych [60–64]. Pomimo intensywnego rozwoju badań nad Logistyką 4.0 i Magazynem 4.0, znaczna ich część koncentruje się na optymalizacji przepływów, zwiększaniu przejrzystości procesów oraz poprawie efektywności operacyjnej. Znacznie rzadziej analizowana jest natomiast długookresowa niezawodność zasobów technicznych oraz wpływ ich degradacji na funkcjonowanie całego systemu [59, 60, 64].

W rezultacie nadal widoczna pozostaje luka badawcza dotycząca integracji perspektywy operacyjnej i eksploatacyjnej. W środowisku silnie zautomatyzowanym skuteczność procesów zależy bowiem nie tylko od jakości sterowania przepływami, lecz także od dostępności i niezawodności zasobów, które te przepływy realizują. Dotyczy to w szczególności zasobów mobilnych, takich jak systemy AGV, które w nowoczesnych magazynach pełnią funkcję krytyczną z punktu widzenia realizacji przepływów materiałowych.

Zależność ta stanowi punkt wyjścia do dalszej analizy systemów AGV oraz strategii utrzymania ruchu w dalszej części rozdziału. Uzasadnia ona potrzebę opracowania modeli decyzyjnych wspomagających proces utrzymania ruchu, zdolnych do uwzględniania niepewności, zmienności warunków operacyjnych oraz złożonych zależności pomiędzy stanem zasobów a funkcjonowaniem systemu.

2.3. Systemy AGV jako krytyczny zasób w środowisku Magazynu 4.0

Znaczenie systemów AGV we współczesnych środowiskach magazynowych wynika nie tylko z ich zdolności do realizacji zautomatyzowanego transportu wewnętrznego, lecz również z ich wpływu na synchronizację przepływów materiałowych w warunkach wysokiej dynamiki operacyjnej [6, 31]. W niniejszej pracy przyjęto, że rola AGV nie ogranicza się do funkcji wykonawczej. Pojazdy te należy traktować jako zasoby współkształtujące stabilność operacyjną całego systemu magazynowego [31]. W ujęciu systemowym AGV współtworzą architekturę operacyjną, w której przepływy materiałowe, dane diagnostyczne oraz decyzje sterujące tworzą układ ścisłych zależności.

Rosnąca rola autonomicznych środków transportu stanowi jedną z najbardziej widocznych konsekwencji rozwoju środowisk Magazynu 4.0. Systemy te projektowane są z myślą o elastycznej realizacji zadań, dynamicznej rekonfiguracji tras oraz współpracy z innymi elementami infrastruktury [31, 65, 66]. Dodatkowo obserwuje się stopniową konwergencję klasycznych AGV z robotami mobilnymi AMR, co poszerza zakres zastosowań tych rozwiązań w środowiskach o wysokiej zmienności i niepewności operacyjnej. Jednocześnie wzrost elastyczności operacyjnej oraz poziomu autonomii prowadzi do zwiększenia złożoności procesów nadzorowania, diagnozowania i utrzymania ruchu, co stawia nowe wymagania wobec systemów wspomagania decyzji eksploatacyjnych.

2.3.1. Charakterystyka systemów AGV

Z funkcjonalnego punktu widzenia systemy AGV realizują zadania transportowe, obsługują strefy magazynowe oraz współpracują z systemami składowania i kompletacji. O ich efektywności nie decydują jednak wyłącznie parametry techniczne pojazdów. Istotne znaczenie ma również jakość decyzji sterujących, obejmujących przydział zadań, trasowanie, koordynację ruchu oraz unikanie konfliktów [6, 65]. Sprawność systemu AGV wynika więc z integracji warstwy fizycznej i decyzyjnej. Z tego względu analiza tych systemów nie powinna ograniczać się do oceny pojedynczych pojazdów, lecz obejmować również zależności pomiędzy stanem technicznym zasobów a logiką sterowania przepływami.


Na tle klasycznych systemów transportu wewnętrznego AGV wyróżniają się wysoką elastycznością przestrzenną i operacyjną. Cecha ta umożliwia ich zastosowanie w środowiskach o zmiennej strukturze procesów, jednak równocześnie zwiększa złożoność sterowania, zależność od jakości danych oraz podatność na zakłócenia. Im większa elastyczność systemu, tym większa złożoność jego utrzymania oraz zarządzania [65, 66]. W praktyce to oznacza, że decyzje dotyczące utrzymania systemów AGV nie powinny być podejmowane wyłącznie na podstawie lokalnych symptomów degradacji. Muszą one uwzględniać także wpływ danego pojazdu na funkcjonowanie całej floty oraz systemu magazynowego.

Jednym z podstawowych warunków efektywnego funkcjonowania systemów AGV jest integracja warstwy fizycznej z warstwą cyfrową, obejmującą monitoring, analitykę oraz systemy sterowania [67]. Wraz ze wzrostem liczby pojazdów rośnie liczba interakcji oraz zależności operacyjnych, co prowadzi do nieliniowego wzrostu

złożoności systemu. Z tego względu AGV można traktować jako element cyberfizycznej architektury magazynowej, którego dostępność bezpośrednio wpływa na stabilność operacyjną całego systemu [67, 68]. Zależności te nadal stosunkowo rzadko analizowane są z perspektywy eksploatacyjnej i decyzyjnej, co uzasadnia potrzebę dalszych badań nad integracją utrzymania ruchu z zarządzaniem operacyjnym.

W ujęciu eksploatacyjnym AGV nie mogą być traktowane jako zbiór niezależnych obiektów technicznych. Awaria pojedynczego pojazdu może prowadzić do efektów kaskadowych, obejmujących reorganizację zadań, przeciążenie pozostałych jednostek oraz zakłócenia przepływów materiałowych. Utrzymanie ruchu AGV ma zatem charakter systemowy, ponieważ skutki degradacji pojedynczych zasobów wykraczają poza poziom pojedynczego obiektu i wpływają na funkcjonowanie całej floty oraz procesów logistycznych. [6, 68]

Strukturę systemu AGV w środowisku Magazynu 4.0 przedstawiono na Rys. 2.3. Obejmuje ona warstwę fizyczną, warstwę sterowania, warstwę danych oraz integrację z systemami nadrzędnymi, co pozostaje zgodne z paradygmatem systemów cyberfizycznych [67, 68].



Rys. 2.3. Struktura systemu AGV w środowisku Magazynu 4.0

Źródło: Opracowanie własne na podstawie [67, 68]

W strukturze tej można wyróżnić kilka podstawowych warstw [67, 68]:

- 1) **Flotę pojazdów** – obejmującą platformy transportowe oraz ich kluczowe podsystemy, takie jak napęd, układ jezdny, zasilanie i czujniki,
- 2) **Infrastrukturę i środowisko pracy** – obejmujące układ tras, strefy funkcjonalne, punkty transferowe oraz stacje ładowania,
- 3) **Warstwę sterowania i koordynacji** – obejmującą systemy nawigacji, lokalizacji, zarządzania ruchem i priorytetami,
- 4) **Warstwę danych** – związaną z monitorowaniem stanu, rejestracją zdarzeń oraz diagnostyką,
- 5) **Integrację z systemami nadrzędnymi** – w szczególności z systemami zarządzania

flotą oraz WMS/MES.

W takim ujęciu systemu granica pomiędzy problemem technicznym a operacyjnym ulega wyraźnemu zatarciu. Zakłócenia techniczne mogą bezpośrednio wpływać na realizację procesów logistycznych, natomiast decyzje operacyjne mogą przyspieszać degradację zasobów technicznych. Niezawodność systemu AGV powinna być zatem analizowana w kontekście funkcjonowania całego systemu. Wymaga to jednoczesnego uwzględnienia stanu technicznego, warunków pracy oraz konsekwencji operacyjnych podejmowanych decyzji. [67, 68]

Wraz ze wzrostem złożoności systemów AGV rośnie znaczenie ryzyk eksploatacyjnych o charakterze technicznym, operacyjnym i informacyjnym [6, 68]. Ryzyka te mają charakter współzależny i mogą się wzajemnie wzmacniać, prowadząc do zakłóceń przepustowości, bezpieczeństwa oraz ciągłości operacji.

W celu syntetycznego przedstawienia tych zależności zestawienie kluczowych elementów systemu AGV, powiązanych ryzyk oraz ich implikacji dla utrzymania ruchu przedstawiono w Tab. 2.3.

Tab. 2.3. Elementy systemu AGV, ryzyka eksploatacyjne oraz implikacje decyzyjne dla utrzymania ruchu

Element systemu AGV	Ryzyka	Konsekwencje operacyjne	Implikacje dla utrzymania ruchu
Flota pojazdów	Degradacja komponentów; uszkodzenia	Spadek dostępności; opóźnienia; kaskadowe	Priorytetyzacja interwencji w skali floty
Nawigacja i planowanie	Konflikty tras; błędy planowania	Zakleszczenia; przepustowości	Utrzymanie warstwy sterowania i rekonfiguracja
Lokalizacja	Błędy pozycjonowania; zakłócenia	Niepewna nawigacja; ryzyko kolizji	Kalibracja i weryfikacja jakości danych
Bezpieczeństwo	Kolizje; niestabilność pojazdu	Zagrożenia BHP; postoje	Testy systemów bezpieczeństwa; kontrola ryzyka
Zasilanie	Spadek wydajności; problemy ładowania	Wymuszone ograniczona dostępność	Integracja utrzymania z zarządzaniem energią
System sterowania i IT	Brak integracji danych; zakłócenia systemowe	Błędne decyzje; priorytetyzacji	Integracja danych i wsparcie decyzyjne

Źródło: Opracowanie własne na podstawie [6, 65–68].

Przedstawione zestawienie potwierdza, że utrzymanie ruchu AGV nie może być rozpatrywane wyłącznie jako funkcja techniczna. Stan techniczny pojazdów, warunki środowiskowe, jakość sterowania oraz organizacja pracy floty tworzą jeden system operacyjny, w którym zakłócenia mają charakter systemowy [67, 68].

Skuteczne utrzymanie ruchu w środowisku Magazynu 4.0 wymaga więc podejść integrujących dane techniczne z kontekstem operacyjnym oraz umożliwiających podejmowanie decyzji w skali całego systemu [67, 68]. Wskazuje to na konieczność odejścia od podejść obiektowych na rzecz modeli decyzyjnych uwzględniających współzależności pomiędzy elementami systemu. Stanowi to bezpośrednie uzasadnienie dla dalszej analizy warunków eksploatacyjnych, modelowania degradacji oraz rozwoju podejść proaktywnych w utrzymaniu ruchu systemów AGV.

2.3.2. Charakterystyka warunków eksploatacyjnych systemów AGV

Systemy AGV charakteryzują się profilem eksploatacyjnym istotnie odmiennym od profilu typowego dla maszyn stacjonarnych [5, 6]. Wynika to przede wszystkim z ich mobilnego charakteru, ścisłego powiązania z organizacją procesów magazynowych oraz silnej zależności od zmiennych warunków operacyjnych. W odróżnieniu od urządzeń pracujących w warunkach względnie stabilnych, eksploatacja AGV przebiega w środowisku dynamicznym i niestacjonarnym, w którym stan techniczny pojazdu, sposób realizacji zadań oraz obciążenie systemu pozostają we wzajemnym sprzężeniu [6, 7]. Zatem, że ocena stanu technicznego AGV nie może być prowadzona w oderwaniu od kontekstu operacyjnego, ponieważ to właśnie warunki pracy współkształtują tempo degradacji oraz znaczenie obserwowanych symptomów.

Analiza degradacji i niezawodności AGV wymaga zatem uwzględnienia szerszego kontekstu eksploatacyjnego, obejmującego zarówno parametry techniczne pojazdów, jak i charakterystykę procesów magazynowych oraz intralogistycznych. Podejście to pozostaje zgodne z systemowym ujęciem niezawodności rozwijanym w ramach Przemysłu 4.0 oraz systemów cyber-fizycznych, w których granica pomiędzy obiektem technicznym a jego środowiskiem operacyjnym ulega zatarciu [67].

W ujęciu syntetycznym kluczowe uwarunkowania eksploatacyjne systemów AGV obejmują:

- 1) **Zmienność obciążeń** – wynikającą z charakteru realizowanych zadań transportowych oraz warunków ruchu [5]. Prowadzi ona do zróżnicowanych profili pracy układów mechanicznych oraz nieregularnego tempa zużycia komponentów.
- 2) **Nierównomierność eksploatacji** – związaną z organizacją pracy systemu i algorytmami sterowania [6]. W jej wyniku pojazdy funkcjonujące w obrębie jednej floty mogą charakteryzować się znacząco różnym stopniem zużycia i stanem technicznym.
- 3) **Zmienność warunków środowiskowych** – obejmującą warunki przestrzenne i operacyjne, takie jak jakość nawierzchni, zagęszczenie ruchu czy obecność przeszkód [7]. Czynniki te wpływają zarówno na obciążenia dynamiczne, jak i na ryzyko zdarzeń niepożądanych.

Istotną rolę odgrywają również uwarunkowania związane z funkcjonowaniem systemów technicznych oraz warstwy percepcji i sterowania. Degradacja układów napędowych, jezdnych i zasilania pozostaje silnie zależna od warunków pracy, natomiast zakłócenia działania systemów lokalizacji i nawigacji mogą prowadzić do przestojów operacyjnych nawet przy braku klasycznych uszkodzeń mechanicznych [6, 7, 69].

Zestawienie kluczowych grup czynników oraz ich implikacji eksploatacyjnych przedstawiono w Tab. 2.4. Pokazuje ono, że proces degradacji w systemach AGV ma charakter niestacjonarny i wieloczynnikowy, wynikający z interakcji pomiędzy stanem technicznym, sposobem eksploatacji oraz warunkami środowiskowymi [69–71].

Klasyczne podejścia do oceny niezawodności, oparte na uproszczonych miarach czasu pracy lub liczby cykli, okazują się niewystarczające do opisu rzeczywistych mechanizmów degradacji oraz wspierania decyzji utrzymaniowych. Z punktu widzenia zarządzania eksploatacją konieczna staje się integracja informacji o stanie technicznym z kontekstem operacyjnym oraz rolą pojazdów w realizacji procesów logistycznych.

Wskazuje to na potrzebę stosowania metod zdolnych do odwzorowania niepewności, zmienności oraz współzależności czynników eksploatacyjnych, których wpływ na stan systemu nie zawsze może być opisany za pomocą zależności deterministycznych.

Tab. 2.4. Kluczowe uwarunkowania eksploatacyjne systemów AGV

Grupa czynników	Charakterystyka	Implikacje eksploatacyjne
Zmienność obciążeń	Zróżnicowane profile pracy wynikające z masy ładunku, długości tras i dynamiki ruchu	Nieregularne zużycie komponentów; trudność modelowania degradacji
Nierównomierność eksploatacji	Asymetria wykorzystania pojazdów w obrębie floty	Zróżnicowany stan techniczny; konieczność indywidualizacji decyzji utrzymaniowych
Warunki środowiskowe	Występujące przeszkody i dynamiczne zmiany zagęszczenia ruchu	Wpływ na obciążenia dynamiczne; zwiększone ryzyko uszkodzeń i zakłóceń
Systemy techniczne	Zużycie układów napędowych, jezdnych i zasilania	Degradacja zależna od warunków pracy; niestacjonarny charakter uszkodzeń
Systemy percepcji i sterowania	Wrażliwość systemów lokalizacji, komunikacji i nawigacji	Zakłócenia funkcjonalne bez uszkodzeń fizycznych; przestoje operacyjne

Źródło: Opracowanie własne na podstawie [5–7, 69–71].

2.3.3. Implikacje dla modelowania eksploatacji systemów AGV

Przedstawiona charakterystyka warunków eksploatacyjnych systemów AGV wskazuje, że proces ich użytkowania ma charakter niestacjonarny, wielowymiarowy oraz silnie zależny od kontekstu operacyjnego. W konsekwencji modelowanie eksploatacji tych systemów nie może opierać się wyłącznie na uproszczonych miarach, takich jak czas pracy czy liczba cykli, lecz powinno uwzględniać złożone relacje pomiędzy stanem technicznym, warunkami środowiskowymi oraz sposobem realizacji zadań transportowych.

Szczególnie istotne jest uwzględnienie zmienności obciążeń oraz ich wpływu na tempo degradacji komponentów. W warunkach dynamicznych, typowych dla systemów AGV, zależności pomiędzy intensywnością użytkowania a zużyciem nie mają charakteru liniowego, a ich przebieg zależy od wielu współzależnych czynników [6, 69, 70]. Ogranicza to możliwość stosowania klasycznych modeli deterministycznych i uzasadnia potrzebę wykorzystania podejść zdolnych do odwzorowania niepewności oraz niejednoznaczności danych eksploatacyjnych.

Kolejnym istotnym aspektem jest integracja informacji pochodzących z różnych źródeł. Dane dotyczące stanu technicznego pojazdu, takie jak parametry pracy baterii, poziom drgań czy błędy systemowe, powinny być analizowane łącznie z informacją o warunkach eksploatacji, takich jak intensywność realizowanych zadań czy charakterystyka środowiska pracy. Podejście to pozostaje spójne z rozwojem systemów cyber-fizycznych, w których dane operacyjne i techniczne są przetwarzane w sposób zintegrowany. W praktyce wartość diagnostyczna pojedynczego sygnału zależy więc nie tylko od jego poziomu, lecz również od sytuacji eksploatacyjnej, w której został zaobserwowany [72].

Z perspektywy modelowania szczególnie istotne jest również uwzględnienie nierównomierności eksploatacji floty AGV. Modele powinny umożliwiać ocenę stanu

poszczególnych pojazdów w kontekście ich rzeczywistego obciążenia oraz roli w systemie logistycznym, co pozwala na bardziej precyzyjne wspieranie decyzji dotyczących utrzymania. Wskazuje to zarazem na ograniczenia podejść analizujących pojazdy w oderwaniu od struktury floty i bieżących wymagań operacyjnych.

Przedstawione uwarunkowania wskazują, że skuteczne modelowanie eksploatacji systemów AGV wymaga zastosowania metod zdolnych do:

- 1) Integracji danych o różnym charakterze, w tym danych technicznych i operacyjnych,
- 2) Uwzględnienia niepewności i niejednoznaczności informacji,
- 3) Odzworowania nieliniowych zależności pomiędzy czynnikami eksploatacyjnymi,
- 4) Wspierania decyzji w warunkach zmienności i dynamicznego środowiska pracy.

W tym kontekście szczególnie obiecujące są podejścia wykorzystujące logikę rozmytą oraz metody uczenia maszynowego, które umożliwiają modelowanie złożonych zależności przy ograniczonej dostępności jednoznacznych danych oraz wspierają procesy decyzyjne w warunkach niepewności [13, 71]. Ich zastosowanie stwarza podstawy do rozwoju strategii utrzymania ruchu o charakterze proaktywnym, ukie-
runkowanych na wczesną identyfikację stanów degradacji oraz minimalizację ryzyka zakłóceń operacyjnych.

Modelowanie eksploatacji systemów AGV stanowi zatem jeden z kluczowych elementów przejścia od tradycyjnych strategii utrzymania ruchu do podejść ukierunkowanych na przewidywanie i zapobieganie. W kontekście niniejszej rozprawy oznacza to potrzebę opracowania modelu, który nie tylko identyfikuje symptomy degradacji, lecz również wspiera priorytetyzację działań utrzymaniowych w warunkach niepewności i współzależności operacyjnych.

2.3.4. Trendy, wyzwania i kierunki rozwoju utrzymania ruchu systemów AGV

Systemy AGV, jako krytyczny element architektury operacyjnej Magazynu 4.0, funkcjonują w warunkach rosnącej złożoności oraz dynamiki procesów logistycznych. Ich mobilny charakter, ścisła integracja z przepływami materiałowymi oraz zależność od warstwy cyfrowej sprawiają, że są one szczególnie wrażliwe na zakłócenia zarówno o charakterze technicznym, jak i operacyjnym. W odróżnieniu od klasycznych systemów technicznych pojazdy autonomiczne funkcjonują w środowiskach zmiennych i nie w pełni ustrukturyzowanych, w których występują przeszkody, interakcje z ludźmi oraz współpraca z innymi systemami automatyki [5, 73]. Powoduje to, że zapewnienie dostępności floty wymaga więc nie tylko monitorowania stanu technicznego, lecz również utrzymania poprawności działania systemów percepcji, lokalizacji i nawigacji oraz ich integracji z procesami operacyjnymi [13]. Utrzymanie ruchu przestaje tym samym być zagadnieniem wyłącznie technicznym, a staje się elementem zarządzania złożonym systemem cyber-fizycznym.

Jednym z kluczowych wyzwań wynikających z tej złożoności jest integracja heterogenicznych źródeł danych w architekturze cyber-fizycznej. Systemy AGV generują dane na wielu poziomach – od czujników i układów sterowania po systemy zarządzania logistycznego. Zapewnienie ich spójności, jakości oraz synchronizacji stanowi istotny problem, ponieważ nieciągłość pomiarów, opóźnienia transmisji lub

degradacja jakości danych mogą prowadzić do błędnych wniosków diagnostycznych oraz nieefektywnych decyzji utrzymaniowych [12, 19, 74]. Problem ten jest dodatkowo wzmacniany przez rosnący wolumen danych, który prowadzi do przeciążenia informacyjnego oraz utrudnia identyfikację rzeczywistych źródeł zakłóceń [12, 13]. Wyzwaniem nie jest więc już samo pozyskanie danych, lecz ich selekcja, interpretacja i wykorzystanie w procesie podejmowania decyzji.

Istotnym ograniczeniem pozostaje również integracja systemów heterogenicznych, w szczególności starszych rozwiązań WMS/ERP z nowoczesnymi platformami IoT i narzędziami analitycznymi. Fragmentacja architektury informacyjnej oraz brak standardów komunikacyjnych ograniczają możliwość budowy spójnego obrazu stanu floty [19]. Równocześnie rosnąca zależność od infrastruktury sieciowej zwiększa znaczenie cyberbezpieczeństwa, ponieważ zakłócenia w warstwie cyfrowej mogą bezpośrednio wpływać na bezpieczeństwo fizyczne oraz ciągłość operacji [75].

Obok wskazanych wyzwań obserwuje się dynamiczny rozwój technologii wspierających eksploatację i utrzymanie systemów AGV. Do najważniejszych należą cyfrowe bliźniaki, systemy samodiagnostyczne oraz rozwiązania oparte na sztucznej inteligencji i uczeniu maszynowym [11, 40]. Technologie te umożliwiają bardziej zaawansowane monitorowanie stanu systemu, symulację scenariuszy oraz wspomaganie decyzji utrzymaniowych, integrując dane historyczne i bieżące w ramach modeli analitycznych.

Wiele proponowanych rozwiązań pozostaje jednak na etapie koncepcyjnym lub symulacyjnym i nie zostało dotąd w pełni zweryfikowanych w rzeczywistych warunkach operacyjnych [10, 13]. Ogranicza to ich praktyczną użyteczność i wskazuje na utrzymującą się lukę pomiędzy potencjałem technologicznym a możliwościami wdrożeniowymi w złożonych środowiskach magazynowych.

Z perspektywy organizacyjnej utrzymanie ruchu AGV wymaga ścisłej koordynacji pomiędzy różnymi poziomami zarządzania oraz rozwoju kompetencji cyfrowych i analitycznych pracowników. Eliminacja silosów informacyjnych staje się warunkiem spójności decyzji oraz efektywnego wykorzystania danych [12]. Transformacja utrzymania ruchu ma zatem charakter zarówno technologiczny, jak i organizacyjny.

Pomimo rosnącej liczby badań wiele istniejących podejść koncentruje się na poziomie pojedynczego pojazdu lub komponentu, pomijając współzależności systemowe oraz kontekst operacyjny. W szczególności brakuje modeli umożliwiających jednoczesne uwzględnienie niepewności danych, wiedzy eksperckiej oraz zależności pomiędzy pojazdami w skali floty, przy jednoczesnym powiązaniu wyników analizy z procesem podejmowania decyzji [11, 13, 17]. Z perspektywy proaktywnego utrzymania ruchu stanowi to istotną lukę badawczą, która wymaga nie tylko predykcji uszkodzeń, lecz także wspomagania decyzji dotyczących momentu, zakresu i priorytetu interwencji.

W konsekwencji rośnie znaczenie podejść wykraczających poza klasyczne strategie predykcyjne, które nie tylko prognozują degradację, lecz również wspierają podejmowanie decyzji utrzymaniowych w czasie zbliżonym do rzeczywistego. Podejścia te powinny integrować dane techniczne z kontekstem operacyjnym oraz umożliwiać ocenę konsekwencji decyzji utrzymaniowych dla funkcjonowania całego systemu magazynowego. Wymagania te stanowią bezpośrednie uzasadnienie dla rozwoju podejść proaktywnych, które łączą analizę danych z procesem podejmowania decyzji utrzymaniowych w warunkach niepewności i zmienności środowiska

operacyjnego.

Zidentyfikowane trendy i wyzwania związane z utrzymaniem ruchu systemów AGV w środowisku Magazynu 4.0 zestawiono syntetycznie w Tab. 2.5. Zestawienie to pokazuje, że kluczowym wyzwaniem nie jest jedynie dostępność danych lub rozwój metod analitycznych, lecz ich integracja z procesem podejmowania decyzji w skali systemu.

Tab. 2.5. Kluczowe trendy i wyzwania utrzymania ruchu systemów AGV w środowisku Magazynu 4.0

Obszar problemowy	Wyzwania	Trendy	Implikacje dla decyzji utrzymaniowych
Architektura danych	Heterogeniczność danych; brak interoperacyjności; fragmentacja systemów	CPS, IoT, integracja platform danych	Integracja danych technicznych i operacyjnych w procesie decyzyjnym
Jakość danych	Szum, niepełność, nadmiar alarmów	Filtrowanie, agregacja, redukcja danych	Modele odporne na niepewność danych
Bezpieczeństwo cyfrowe	Zależność od infrastruktury sieciowej; podatność na zakłócenia	Cyberbezpieczeństwo systemów przemysłowych	Powiązanie warstwy fizycznej i cyfrowej
Technologie wspierające	Ograniczona dojrzałość wdrożeń	AI/ML, cyfrowe bliźniaki, systemy samodiagnostyczne	Zaawansowane wspomaganie decyzji
Organizacja i kompetencje	Silosy informacyjne; ograniczone kompetencje analityczne	Integracja zarządzania; rozwój kompetencji cyfrowych	Decyzje oparte na danych
Modele badawcze	Podjęcie komponentowe; brak ujęcia systemowego	Modele systemowe i integracyjne	Uwzględnienie kontekstu operacyjnego i floty
Strategie utrzymania	Ograniczenia podejść predykcyjnych	Podejścia proaktywne i preskryptywne	Dynamiczna priorytetyzacja działań

Źródło: Opracowanie własne na podstawie [5, 10–13, 17, 19, 40, 73–75].

2.4. Strategie utrzymania ruchu systemów AGV

W literaturze poświęconej eksploatacji systemów technicznych strategie utrzymania ruchu są najczęściej porządkowane według momentu podjęcia interwencji oraz rodzaju informacji wykorzystywanych w procesie decyzyjnym. W tym ujęciu wyróżnia się przede wszystkim podejścia reaktywne, zapobiegawcze i predykcyjne [10, 12]. Ich rozwój odzwierciedla szerszą zmianę w sposobie rozumienia utrzymania ruchu: od działań podejmowanych po wystąpieniu awarii, przez interwencje realizowane zgodnie z harmonogramem, aż po metody wykorzystujące dane eksploatacyjne do prognozowania degradacji komponentów [13].

Obecnie rośnie znaczenie takich strategii utrzymania ruchu, które nie ograniczają się do usuwania skutków awarii, lecz zmierzają do ograniczania prawdopodobieństwa ich wystąpienia oraz redukcji ich konsekwencji operacyjnych. Wdrożenie założeń Przemysłu 4.0 w środowisku magazynowym dodatkowo wzmacnia tę tendencję. Wzrost wymagań dotyczących przepustowości, terminowości i jakości obsługi przebiega równolegle ze spadkiem tolerancji na zakłócenia i przestoje [31]. Cyfryzacja oraz

wykorzystanie danych w czasie zbliżonym do rzeczywistego zwiększają przejrzystość procesów, jednak zarazem sprawiają, że nawet zakłócenie o pozornie lokalnym charakterze może oddziaływać na funkcjonowanie całego systemu [76]. Z tego względu w niniejszej pracy przyjęto, że utrzymanie ruchu zasobów funkcjonujących w środowisku magazynowym nie powinno być ujmowane wyłącznie jako funkcja techniczna lub pomocnicza. Należy je traktować jako integralny element zarządzania efektywnością, odpornością oraz ryzykiem operacyjnym [31, 76].

Jednocześnie rozwój technologii Przemysłu 4.0 stwarza warunki do przechodzenia w stronę strategii opartych na danych. Integracja Internetu Rzeczy, analityki danych, sztucznej inteligencji i przetwarzania w chmurze umożliwia monitorowanie stanu technicznego w czasie zbliżonym do rzeczywistego oraz wcześniejsze identyfikowanie symptomów degradacji [77]. Sprzyja to rozwojowi podejść predykcyjnych i ograniczaniu liczby przestojów nieplanowanych [78, 79]. Szczególne znaczenie mają tu również technologie cyfrowych bliźniaków, które umożliwiają tworzenie cyfrowych reprezentacji zasobów i procesów oraz analizę wariantów decyzyjnych przed ich wdrożeniem w środowisku rzeczywistym [44, 80]. W efekcie utrzymanie ruchu może być coraz silniej integrowane z bieżącym sterowaniem systemem logistycznym, a granica pomiędzy funkcjami operacyjnymi i utrzymaniowymi stopniowo ulega zatarciu [77, 80].

W takim otoczeniu szczególną rolę odgrywają wózki AGV, które stanowią podstawowe zasoby realizujące przepływy materiałowe w magazynach. Ich efektywność operacyjna zależy nie tylko od sprawności technicznej, lecz także od warunków eksploatacji oraz organizacji pracy floty. Problemy takie jak opóźnienia, kongestia czy ograniczona dostępność pojazdów mogą istotnie obniżyć wydajność całego systemu [6]. Badania wskazują ponadto, że poziom wykorzystania floty AGV bezpośrednio wpływa na czas realizacji operacji logistycznych, zwłaszcza w procesach kompletacji zamówień [81]. Wynika z tego, że dostępność i niezawodność tych zasobów należy traktować jako jeden z kluczowych czynników determinujących sprawność funkcjonowania magazynu [6, 81].


Z tego względu ocena skuteczności strategii utrzymania ruchu w odniesieniu do AGV nie powinna ograniczać się do poziomu pojedynczego pojazdu. Znaczenie ma bowiem nie tylko stan techniczny konkretnej jednostki, lecz także wpływ tego stanu na zdolność całej floty do realizacji funkcji transportowej, zapewnienia ciągłości przepływów materiałowych oraz ograniczania zakłóceń operacyjnych. Strategie utrzymania ruchu dla systemów AGV powinny być zatem projektowane z uwzględnieniem zarówno kondycji technicznej poszczególnych pojazdów, jak i ich roli w strukturze systemu logistycznego. Takie ujęcie stanowi punkt wyjścia do rozwoju metod decyzyjnych integrujących dane eksploatacyjne z informacją o stanie systemu logistycznego. Ma to szczególne znaczenie w kontekście podejść proaktywnych omawianych w dalszej części pracy.

2.4.1. Ewolucja strategii utrzymania ruchu

Ewolucja strategii utrzymania ruchu odzwierciedla zmiany zachodzące w systemach przemysłowych, wynikające ze wzrostu ich złożoności, stopnia automatyzacji oraz rosnącego znaczenia niezawodności operacyjnej. Wraz z rozwojem technologii oraz intensyfikacją przepływów produkcyjnych i logistycznych podejścia do utrzymania

ruchu ulegały stopniowej transformacji od działań reaktywnych, podejmowanych po wystąpieniu uszkodzenia, do podejść opartych na danych, prognozowaniu oraz wspomaganiu decyzji. [79, 82]

W literaturze rozwój strategii utrzymania ruchu przedstawiany jest najczęściej w ujęciu etapowym. Nowakowski i in. zaproponowali klasyfikację obejmującą cztery etapy rozwoju, określane jako utrzymanie ruchu 1.0–4.0 [83]. Podział ten odpowiada kolejnym fazom rozwoju przemysłu i odzwierciedla przejście od prostych systemów technicznych do złożonych środowisk cyber-fizycznych. Różnice pomiędzy poszczególnymi etapami dotyczą nie tylko stosowanych technologii, lecz także sposobu definiowania celów utrzymania ruchu oraz roli danych w procesie podejmowania decyzji [83]. Poszczególne etapy wraz z ich charakterystyką przedstawiono na Rys. 2.4 [84].



Rys. 2.4. Ewolucja koncepcji utrzymania ruchu
Źródło: Opracowanie własne na podstawie [84]

1) Utrzymanie ruchu 1.0

Pierwszy etap, obejmujący okres od lat 40. do 60. XX wieku, charakteryzował się dominacją podejścia reaktywnego. Działania utrzymaniowe podejmowano wyłącznie po wystąpieniu uszkodzenia i ograniczały się do naprawy lub wymiany komponentów. Podejście to było wystarczające w przypadku systemów o niskim stopniu złożoności, jednak wraz ze wzrostem automatyzacji jego ograniczenia stały się wyraźne. Nieprzewidywalność awarii prowadziła do zakłóceń ciągłości pracy oraz wzrostu kosztów eksploatacji. [58]

2) Utrzymanie ruchu 2.0

W kolejnych dekadach nastąpiło przejście do podejścia zapobiegawczego, opartego na planowych działaniach realizowanych w ustalonych interwałach czasowych lub cyklach pracy. Strategia ta umożliwiła ograniczenie liczby awarii oraz poprawę

dostępności zasobów technicznych. Jednocześnie jej podstawowym ograniczeniem był brak uwzględnienia rzeczywistego stanu urządzeń. W praktyce prowadziło to zarówno do nadmiernej liczby interwencji serwisowych, jak i do występowania uszkodzeń pomiędzy kolejnymi przeglądami. [85]

3) Utrzymanie ruchu 3.0

Rozwój technologii pomiarowych, systemów monitorowania oraz analizy danych doprowadził do powstania podejść opartych na stanie technicznym oraz utrzymania predykcyjnego. Wykorzystanie danych eksploatacyjnych umożliwiło bieżącą ocenę stanu obiektów oraz identyfikację symptomów degradacji. Podejścia te pozwoliły na bardziej racjonalne planowanie działań utrzymaniowych oraz ograniczenie liczby zbędnych interwencji. Ich skuteczność pozostaje jednak silnie uzależniona od jakości danych oraz trafności stosowanych modeli analitycznych. [10, 86]

4) Utrzymanie ruchu 4.0

Najbardziej zaawansowany etap, związany z rozwojem Przemysłu 4.0, integruje podejścia predykcyjne z analizą ryzyka oraz mechanizmami wspomagania decyzji. Utrzymanie ruchu przestaje być w tym ujęciu jedynie funkcją techniczną, a staje się elementem zarządzania systemem jako całością. Uwzględnia ono zarówno stan techniczny zasobów, jak i dane operacyjne oraz warunki środowiskowe. Celem nie jest wyłącznie prognozowanie momentu uszkodzenia, lecz również wybór działań minimalizujących ryzyko zakłóceń i zapewniających stabilność funkcjonowania systemu w dłuższym horyzoncie czasowym. [59, 87]

Przedstawiona ewolucja wskazuje na wyraźne przesunięcie od podejść reaktywnych i harmonogramowych w kierunku podejść opartych na danych oraz wspomaganiu decyzji. W nowoczesnych systemach technicznych oznacza to konieczność integracji informacji o stanie technicznym z kontekstem operacyjnym oraz rolą zasobów w funkcjonowaniu całego systemu [59, 87]. Ma to szczególne znaczenie w przypadku systemów AGV, w których pojedyncze zakłócenie może wpływać na realizację wielu powiązanych procesów.

W celu syntetycznego uporządkowania ewolucji podejść obsługowych w Tab. 2.6 przedstawiono porównanie kluczowych cech strategii utrzymania ruchu od UR 1.0 do UR 4.0, uwzględniając moment podejmowania interwencji, poziom wykorzystania danych, stopień automatyzacji oraz ich przydatność w nowoczesnych, zautomatyzowanych środowiskach.

Tab. 2.6. Porównanie strategii utrzymania ruchu (UR 1.0–4.0)

Cecha	UR 1.0	UR 2.0	UR 3.0	UR 4.0
Moment interwencji	Po uszkodzeniu	Według harmonogramu	Na podstawie stanu	Przed degradacją
Źródło decyzji	Doświadczenie	Czas / przebieg	Dane z czujników	Dane + ryzyko + wiedza
Wykorzystanie danych	Brak	Niskie	Średnie / wysokie	Bardzo wysokie
Automatyzacja	Brak	Niska	Średnia	Wysoka

Kontynuacja na następnej stronie

Tabela 2.6 – kontynuacja z poprzedniej strony

Cecha	UR 1.0	UR 2.0	UR 3.0	UR 4.0
Interpretowalność	Wysoka	Wysoka	Ograniczona	Wymagana
Przydatność dla AGV	Niska	Ograniczona	Częściowa	Wysoka

Źródło: Opracowanie własne na podstawie [10, 58, 59, 83–87].

2.4.2. Rodzaje strategii utrzymania ruchu

Strategie utrzymania ruchu determinują sposób planowania i realizacji interwencji technicznych, wpływając bezpośrednio na niezawodność, dostępność oraz koszty eksploatacji systemów technicznych [10, 13]. W literaturze przedmiotu wyróżnia się szereg podejść różniących się sposobem inicjowania działań utrzymaniowych, zakresem wykorzystania danych oraz stopniem ich powiązania z procesem podejmowania decyzji.

W ujęciu ogólnym strategie te można uporządkować wzdłuż kontinuum obejmującego przejście od podejść reaktywnych do podejść opartych na danych i wspomaganiu decyzji. Należy jednak podkreślić, że w praktyce nie mają one charakteru rozwiązań rozłącznych. Przeciwnie, często funkcjonują jako elementy podejść hybrydowych, dobieranych w zależności od charakterystyki systemu, jego krytyczności oraz warunków eksploatacji.

1) Utrzymanie naprawcze (reaktywne)

Strategia utrzymania naprawczego polega na podejmowaniu działań dopiero po wystąpieniu uszkodzenia. Charakteryzuje się prostotą organizacyjną oraz niskimi wymaganiami w zakresie monitorowania stanu technicznego. Może być uzasadniona w odniesieniu do zasobów o niskiej krytyczności lub w sytuacjach, w których koszty wdrożenia bardziej zaawansowanych podejść przewyższają potencjalne korzyści. Jednocześnie wiąże się z wysokim poziomem niepewności operacyjnej, ryzykiem nieplanowanych przestojów oraz ograniczoną możliwością kontroli kosztów cyklu życia. [10, 85]

2) Utrzymanie zapobiegawcze (PM)

Podejście zapobiegawcze opiera się na planowych działaniach realizowanych w ustalonych odstępach czasu lub po określonej liczbie cykli pracy. Umożliwia zwiększenie przewidywalności działań utrzymaniowych oraz ułatwia planowanie zasobów serwisowych. Ograniczeniem tej strategii jest brak odniesienia do rzeczywistego stanu technicznego urządzeń, co może prowadzić zarówno do nadmiernej liczby interwencji, jak i do występowania uszkodzeń pomiędzy kolejnymi przeglądami. [10, 85]

3) Utrzymanie oparte na stanie technicznym (CBM)

Strategia CBM (Condition-Based Maintenance) wykorzystuje dane diagnostyczne do bieżącej oceny stanu technicznego zasobów oraz inicjowania działań utrzymaniowych w momencie wykrycia symptomów degradacji. Pozwala to lepiej dopasować moment interwencji do rzeczywistego procesu zużycia i ograniczyć liczbę działań nieuzasadnionych technicznie. Skuteczność podejścia zależy jednak od jakości danych pomiarowych, doboru wskaźników diagnostycznych oraz zdolności ich interpretacji. [10, 86]

4) Utrzymanie predykcyjne (PdM)

Utrzymanie predykcyjne stanowi rozwinięcie podejścia CBM i koncentruje się na prognozowaniu przyszłego stanu technicznego zasobów. Wykorzystuje dane eksploatacyjne oraz metody analityczne, w tym modele statystyczne i algorytmy uczenia maszynowego, do estymacji momentu wystąpienia uszkodzeń lub utraty zdolności funkcjonalnej. Umożliwia to planowanie działań związanych z utrzymaniem w akceptowalnym czasie oraz ograniczenie liczby przestojów nieplanowanych. Jednocześnie skuteczność PdM pozostaje silnie uzależniona od dostępności danych, jakości modeli oraz ich walidacji w warunkach rzeczywistych. [13, 88]

5) Utrzymanie oparte na ryzyku (RBM)

Strategia RBM (Risk-Based Maintenance) koncentruje się na uwzględnieniu krytyczności poszczególnych zasobów oraz konsekwencji ich uszkodzeń. Umożliwia to priorytetyzację działań utrzymaniowych w systemach złożonych oraz bardziej efektywną alokację zasobów. Podejście to wymaga jednak przyjęcia założeń dotyczących prawdopodobieństwa awarii oraz ich skutków, co w warunkach niepełnej informacji może stanowić istotne ograniczenie. [89, 90]

6) Utrzymanie ukierunkowane na niezawodność (RCM)

RCM (Reliability-Centered Maintenance) stanowi uporządkowane ramy decyzyjne umożliwiające dobór adekwatnych strategii utrzymaniowych dla poszczególnych elementów systemu. Opiera się na analizie funkcji, trybów uszkodzeń oraz ich konsekwencji. Pozwala integrować różne podejścia, takie jak utrzymanie reaktywne, zapobiegawcze, CBM czy PdM, jednak jego wdrożenie jest złożone i wymaga zarówno dostępu do danych, jak i wiedzy eksperckiej. [10]

7) Utrzymanie proaktywne

Podejście proaktywne koncentruje się na zapobieganiu występowaniu uszkodzeń poprzez identyfikację i eliminację ich przyczyn źródłowych oraz integrację danych, wiedzy eksperckiej i mechanizmów decyzyjnych. Wykracza ono poza klasyczne podejścia predykcyjne, ponieważ obejmuje nie tylko prognozowanie degradacji, lecz także wybór akceptowalnych działań w określonym kontekście operacyjnym. W tym ujęciu utrzymanie ruchu staje się elementem procesu decyzyjnego, a nie wyłącznie funkcją techniczną. [84, 91]

W praktyce przemysłowej coraz częściej stosuje się podejścia hybrydowe, łączące elementy różnych strategii w celu lepszego dopasowania działań utrzymaniowych do warunków eksploatacji oraz charakterystyki systemu. Dotyczy to w szczególności środowisk zautomatyzowanych i intralogistycznych, w których decyzje utrzymaniowe pozostają bezpośrednio powiązane z realizacją procesów operacyjnych.

W celu syntetycznego porównania wskazanych podejść, w Tab. 2.7 zestawiono ich kluczowe korzyści oraz główne ograniczenia.

Tab. 2.7. Syntetyczne porównanie strategii utrzymania ruchu

Strategia	Główne korzyści	Główne ograniczenia
Naprawcze (CM)	Prostota wdrożenia; brak kosztów monitoringu; uzasadnione dla zasobów niskokrytycznych	Nieprzewidywalność; ryzyko przestojów; wysokie koszty awaryjne
Zapobiegawcze (PM)	Planowalność działań; standaryzacja; ograniczenie awarii losowych	Brak adaptacji do stanu rzeczywistego; ryzyko nadmiernych interwencji
Oparte na stanie (CBM)	Działania zależne od stanu; ograniczenie zbędnych przeglądów	Wymagania pomiarowe; zależność od jakości diagnostyki
Predykcyjne (PdM)	Prognozowanie degradacji; estymacja RUL; redukcja przestojów	Wysokie wymagania danych; ryzyko błędnych prognoz
Oparte na ryzyku (RBM)	Priorytetyzacja aktywów; racjonalizacja zasobów	Trudność oceny ryzyka; zależność od założeń
Ukierunkowane na niezawodność (RCM)	Dobór strategii do funkcji i trybów uszkodzeń	Złożoność wdrożenia; wysokie wymagania analityczne
Proaktywne	Eliminacja przyczyn źródłowych; integracja danych i decyzji	Wysoka złożoność; trudności wdrożeniowe i integracyjne

Źródło: Opracowanie własne na podstawie [10, 13, 84–86, 88–91].

2.4.3. Strategie utrzymania ruchu systemów AGV i ich ograniczenia w środowisku Magazynu 4.0

Rozwój strategii utrzymania ruchu systemów AGV przebiegał zasadniczo zgodnie z ewolucją podejść stosowanych wobec innych obiektów technicznych i obejmował przede wszystkim utrzymanie reaktywne, zapobiegawcze oraz predykcyjne. W przypadku systemów AGV taki podział okazuje się jednak niewystarczający, jeżeli analiza prowadzona jest wyłącznie na poziomie pojedynczego pojazdu. Mobilność tych systemów, zmienne profile obciążenia oraz ich ścisła integracja z procesami intralogistycznymi powodują, że skuteczność strategii utrzymaniowych powinna być rozpatrywana w ujęciu systemowym [6, 7].

Podejście reaktywne, polegające na podejmowaniu działań dopiero po wystąpieniu awarii, charakteryzuje się prostotą organizacyjną i nie wymaga rozwiniętej infrastruktury danych. W środowisku Magazynu 4.0 jego zastosowanie wiąże się jednak z wysokim ryzykiem operacyjnym. Wyłączenie pojedynczego pojazdu może bowiem prowadzić do konieczności reorganizacji zadań, wzrostu obciążenia pozostałych jednostek oraz pogorszenia przepustowości całego systemu [5].

Podejście zapobiegawcze ogranicza część tej niepewności poprzez planowanie interwencji według harmonogramu lub liczby cykli pracy. Umożliwia ono zwiększenie przewidywalności działań serwisowych, jednak jego ograniczeniem jest brak bezpośredniego odniesienia do rzeczywistego stanu technicznego pojazdów oraz zmienności warunków eksploatacji [10]. W rezultacie działania utrzymaniowe mogą być realizowane zarówno zbyt wcześnie, jak i z opóźnieniem względem rzeczywistego procesu degradacji.

W porównaniu z podejściami reaktywnymi i zapobiegawczymi większy potencjał adaptacyjny wykazuje utrzymanie predykcyjne, w którym dane eksploatacyjne

wykorzystywane są do prognozowania degradacji oraz wspomagania planowania działań utrzymaniowych [13, 88]. Podejście to umożliwia lepsze dopasowanie momentu interwencji do rzeczywistego stanu technicznego zasobu i stanowi istotny krok w kierunku ograniczenia liczby nieplanowanych przestojów. Jego skuteczność pozostaje jednak w znacznym stopniu uzależniona od jakości danych oraz zdolności do uwzględniania zależności pomiędzy elementami systemu. W praktyce wiele rozwiązań nadal koncentruje się na poziomie pojedynczych komponentów lub pojedynczego pojazdu, bez pełnego uwzględnienia współzależności występujących w skali całej floty [11, 13, 17].

Zasadnicze ograniczenie podejść klasycznych i predykcyjnych wynika z faktu, że diagnoza lub prognoza stanu technicznego nie stanowi jeszcze decyzji utrzymaniowej. Informacja o wzroście ryzyka uszkodzenia nie odpowiada bezpośrednio na pytanie o moment, zakres i priorytet interwencji, ani nie uwzględnia znaczenia danego pojazdu dla realizacji bieżących procesów. W środowisku Magazynu 4.0 decyzje utrzymaniowe nie pozostają neutralne operacyjnie, lecz wpływają na przydział zadań, obciążenie floty oraz przepustowość całego systemu.

Kolejne ograniczenie dotyczy niepełnej integracji danych technicznych i operacyjnych. Wiele podejść koncentruje się na pojedynczym pojeździe lub komponencie, pomijając współzależności występujące w skali całej floty [11, 13]. W praktyce decyzje utrzymaniowe podejmowane na poziomie pojedynczego pojazdu rzadko mają wyłącznie lokalne konsekwencje. Wyłączenie jednego pojazdu wpływa na organizację przepływów materiałowych, obciążenie pozostałych zasobów oraz stabilność pracy całego układu. Dodatkowym ograniczeniem jest fakt, że dane eksploatacyjne, informacje o obciążeniu systemu, priorytetach zadań oraz dostępności zasobów zastępczych pochodzą z różnych źródeł i w praktyce często wykorzystywane są w sposób fragmentaryczny [12, 19]. Powoduje to, że decyzje utrzymaniowe mogą być podejmowane na podstawie niepełnego obrazu sytuacji eksploatacyjnej. W konsekwencji ich trafność może być ograniczona, jeżeli nie zostaną powiązane z aktualnym stanem systemu oraz operacyjnymi skutkami potencjalnej interwencji.

Dodatkowym wyzwaniem jest niepewność i zmienność warunków eksploatacji. Dane wykorzystywane w procesie decyzyjnym są często niekompletne, zaszumione i silnie zależne od kontekstu pracy [13, 70]. Ogranicza to skuteczność modeli opartych wyłącznie na stabilnych i jednoznacznych zależnościach oraz wskazuje na potrzebę stosowania metod umożliwiających uwzględnianie nieostrości informacji oraz integrację wiedzy eksperckiej [11].

W konsekwencji, mimo wyraźnego postępu technologicznego, nadal utrzymuje się luka pomiędzy możliwościami diagnostycznymi a zdolnością do wspomagania decyzji utrzymaniowych w skali systemowej. W przypadku systemów AGV skuteczne wykorzystanie danych eksploatacyjnych wymaga ich integracji z mechanizmami decyzyjnymi uwzględniającymi zarówno stan techniczny zasobów, jak i kontekst operacyjny systemu. Wskazane ograniczenia stanowią bezpośrednie uzasadnienie dla rozwoju podejść proaktywnych, wspierających podejmowanie decyzji utrzymaniowych w czasie zbliżonym do rzeczywistego.

Tab. 2.8. Porównanie strategii utrzymania ruchu w kontekście eksploatacji systemów AGV w środowisku Magazynu 4.0

Strategia	Podstawa decyzji	Zalety	Ograniczenia	Dopasowanie
Utrzymanie reaktywne	Wystąpienie awarii	Prostota wdrożenia; brak potrzeby analizy danych	Nieplanowane przestoje; efekt kaskadowy; brak kontroli nad dostępnością floty	Niskie
Utrzymanie zapobiegawcze	Czas/cykle pracy	Możliwość planowania działań; ograniczenie awarii losowych	Brak odniesienia do rzeczywistego stanu technicznego; nadmierne lub spóźnione interwencje	Ograniczone
Utrzymanie predykcyjne	Dane diagnostyczne i modele degradacji	Wczesne wykrywanie uszkodzeń; redukcja przestojów; wykorzystanie danych	Brak integracji z decyzjami operacyjnymi; podejście obiektowe; ograniczona ocena wpływu systemowego	Średnie
Utrzymanie proaktywne	Stan techniczny, kontekst operacyjny, wpływ systemowy	Integracja danych technicznych i operacyjnych; wsparcie decyzji; minimalizacja wpływu przestojów	Wysoka złożoność; wymagania integracyjne i analityczne	Wysokie

Źródło: Opracowanie własne na podstawie [5–7, 10–13, 17, 19, 70, 88].

2.4.4. Proaktywne utrzymanie ruchu jako paradygmat decyzyjny

Proaktywne utrzymanie ruchu stanowi główny obszar prowadzonych badań, dlatego w niniejszej rozprawie zostało omówione szerzej niż pozostałe strategie. Przyjęto, że w warunkach wysokiej automatyzacji, silnej integracji systemów oraz rosnącej presji na dostępność i przepustowość procesów intralogistycznych utrzymanie ruchu nie powinno być ujmowane wyłącznie jako zbiór działań technicznych. W takich warunkach staje się ono procesem decyzyjnym, którego celem jest nie tylko zapobieganie uszkodzeniom, lecz również ograniczanie ich skutków w skali całego systemu [13, 76]. Ujęcie to pozostaje zgodne z nurtem badań, w którym utrzymanie ruchu analizowane jest w powiązaniu z zarządzaniem operacyjnym oraz sterowaniem systemami technicznymi.

Istota proaktywnego utrzymania ruchu polega na świadomym kształtowaniu decyzji dotyczących momentu, zakresu i priorytetu interwencji w taki sposób, aby ograniczać zarówno prawdopodobieństwo wystąpienia uszkodzeń lub dalszej degradacji, jak i ich konsekwencje operacyjne. Oznacza to odejście od logiki harmonogramowej, opartej na sztywnych interwałach czasowych, oraz od podejścia reaktywnego, w którym działania uruchamiane są dopiero po wystąpieniu awarii lub jednoznacznych symptomów pogorszenia stanu. W podejściu proaktywnym decyzje utrzymaniowe podejmowane są z uwzględnieniem szerszego kontekstu funkcjonowania systemu, obejmującego między innymi krytyczność zasobu, aktualne obciążenie operacyjne, dostępność zasobów serwisowych oraz potencjalne skutki przestoju [89, 90]. W rezultacie utrzymanie ruchu przestaje pełnić funkcję wyłącznie wykonawczą i staje się elementem sterowania niezawodnością, dostępnością oraz sprawnością operacyjną systemu.

Zasadnicza różnica pomiędzy utrzymaniem predykcyjnym a proaktywnym dotyczy charakteru podejmowanej decyzji. Utrzymanie predykcyjne koncentruje się przede wszystkim na prognozowaniu przyszłego stanu zasobu oraz identyfikacji momentu potencjalnego uszkodzenia [10, 13]. Odpowiada zatem na pytanie, kiedy może wystąpić problem, nie wskazując jednoznacznie, jakie działanie powinno zostać podjęte w danym kontekście operacyjnym. Podejście proaktywne rozszerza ten zakres, obejmując nie tylko rozpoznanie ryzyka, lecz również wybór działania, jego priorytyzację oraz ocenę konsekwencji operacyjnych. W tym sensie podejście to pozostaje bliskie koncepcji utrzymania preskryptywnego, w którym analiza nie kończy się na predykcji, lecz prowadzi do rekomendacji decyzji [92, 93].

Znaczenie tego rozróżnienia jest szczególnie widoczne w środowiskach Magazynu 4.0. W takich systemach decyzje utrzymaniowe bezpośrednio wpływają na realizację procesów logistycznych. W przypadku flot AGV czasowe wyłączenie pojedynczego pojazdu może prowadzić do rekonfiguracji zadań, zwiększenia obciążenia pozostałych jednostek oraz zakłóceń przepływów materiałowych [6, 65]. Oznacza to, że decyzja utrzymaniowa nie może być oparta wyłącznie na ocenie stanu technicznego konkretnego pojazdu, lecz powinna uwzględniać wpływ takiej interwencji na funkcjonowanie całego systemu.

W tym ujęciu proaktywne utrzymanie ruchu można traktować jako paradygmat decyzyjny, w którym informacja o stanie technicznym zasobu integrowana jest z informacją o warunkach pracy systemu oraz jego celach operacyjnych. Podejście to wymaga uwzględnienia wielu współzależnych czynników, w tym niepewności danych, zmienności warunków eksploatacyjnych, ograniczeń zasobowych oraz konsekwencji organizacyjnych podejmowanych działań [11, 12]. W praktyce oznacza to konieczność łączenia przesłanek technicznych, takich jak symptomy degradacji czy ryzyko uszkodzenia, z uwarunkowaniami procesowymi i organizacyjnymi [11].


Z tego względu istotną rolę odgrywają metody wspomagania decyzji, umożliwiające formalizację wiedzy eksperckiej oraz integrację informacji ilościowych i jakościowych. W literaturze wskazuje się w szczególności na systemy ekspertowe, logikę rozmytą oraz metody wielokryterialne [11, 94]. Ich znaczenie wynika z możliwości odwzorowania zależności pomiędzy zmiennymi niepewnymi, nieostryimi lub trudnymi do jednoznacznego skwantyfikowania, co jest charakterystyczne dla złożonych systemów intralogistycznych. W kontekście systemów AGV ma to znaczenie kluczowe, ponieważ proces podejmowania decyzji utrzymaniowych przebiega właśnie w warunkach niepewności oraz współzależności.

Pomimo rosnącego zainteresowania podejściami proaktywnymi analiza literatury wskazuje, że nadal brakuje rozwiązań integrujących dane techniczne, kontekst operacyjny oraz mechanizmy decyzyjne w sposób umożliwiający ich praktyczne zastosowanie w systemach AGV [17, 62]. Szczególnie widoczny jest niedobór modeli uwzględniających jednocześnie współzależności pomiędzy pojazdami, zmienność obciążenia systemu oraz niepewność danych wejściowych. Ponadto w wielu opracowaniach utrzymuje się rozdzielenie pomiędzy warstwą diagnostyczną a warstwą decyzyjną, co ogranicza możliwość bezpośredniego wykorzystania wyników analizy w procesie podejmowania decyzji utrzymaniowych.

Wskazuje to na potrzebę opracowania modeli decyzyjnych umożliwiających integrację danych eksploatacyjnych z wiedzą ekspercką oraz wspierających prioryte-

tyzację działań utrzymaniowych w czasie zbliżonym do rzeczywistego. Podejście to stanowi podstawę dalszych rozważań w niniejszej rozprawie i uzasadnia wybór metod opartych na logice rozmytej jako narzędzia wspomagania decyzji w proaktywnym utrzymaniu ruchu systemów AGV.

W celu syntetycznego przedstawienia logiki podejmowania decyzji w proaktywnym utrzymaniu ruchu, uwzględniającej integrację danych technicznych i operacyjnych oraz ich wykorzystanie w procesie decyzyjnym, na Rys. 2.5 przedstawiono schemat koncepcyjny.



Rys. 2.5. Schemat koncepcyjny proaktywnego utrzymania ruchu systemów AGV
Źródło: Opracowanie własne

2.5. Podsumowanie przeglądu literatury

Przeprowadzony przegląd literatury wskazuje, że rozwój koncepcji Przemysłu 4.0 oraz Logistyki 4.0 prowadzi do kształtowania coraz bardziej zintegrowanych, zautomatyzowanych i opartych na danych systemów intralogistycznych. Szczególnym przykładem takiego środowiska jest Magazyn 4.0, w którym przepływy materiałowe, informacyjne i decyzyjne pozostają ze sobą w ścisłym związku, a sprawność funkcjonowania systemu zależy od jego zdolności do reagowania na zmienność warunków pracy oraz pojawiające się zakłócenia. W takim ujęciu utrzymanie ruchu nie może być rozpatrywane w oderwaniu od kontekstu operacyjnego, w którym funkcjonują zasoby techniczne.

W analizowanym środowisku wózki AGV pełnią rolę zasobów krytycznych dla realizacji przepływów materiałowych. Jednocześnie proces ich eksploatacja ma charakter niestacjonarny, wynikający ze zmienności obciążeń, nierównomierności użytkowania oraz silnej zależności od warunków operacyjnych. Oznacza to, że stan techniczny pojazdów oraz ich dostępność nie są determinowane wyłącznie przez czynniki techniczne, lecz w istotnym stopniu zależą także od organizacji procesów logistycznych oraz bieżącego sposobu wykorzystania floty. W konsekwencji AGV należy traktować jako elementy systemu, którego sprawność kształtowana jest przez współoddziaływanie warstwy fizycznej, informacyjnej i decyzyjnej.

Analiza strategii utrzymania ruchu prowadzi do wniosku, że podejścia reaktywne i zapobiegawcze są niewystarczające w warunkach wysokiej dynamiki i złożoności środowiska Magazynu 4.0. Podejście predykcyjne stanowi istotny krok naprzód, umożliwiając wykorzystanie danych eksploatacyjnych do prognozowania degradacji, jednak jego zastosowanie w wielu przypadkach pozostaje ograniczone do poziomu pojedynczych komponentów lub pojazdów. W rezultacie zdolność tych rozwiązań do wspierania decyzji operacyjnych w skali całego systemu pozostaje

ograniczona, zwłaszcza w warunkach współzależności pomiędzy pojazdami oraz zmiennego obciążenia floty.

Na podstawie przeprowadzonego przeglądu literatury można zidentyfikować zasadniczą lukę badawczą, polegającą na braku podejść umożliwiających integrację informacji diagnostycznej z mechanizmami wspomagania decyzji w ujęciu systemowym. Luka ta jest szczególnie widoczna w środowiskach intralogistycznych wykorzystujących floty AGV, w których decyzje utrzymaniowe powinny uwzględniać zarówno stan techniczny zasobów, jak i ich znaczenie dla realizacji bieżących procesów operacyjnych. Wskazuje to na potrzebę opracowania modeli decyzyjnych zdolnych do integracji danych eksploatacyjnych z kontekstem operacyjnym systemu oraz wspierających dynamiczną priorytetyzację działań utrzymaniowych w warunkach zmienności i niepewności. W takim ujęciu utrzymanie ruchu powinno być traktowane jako element sterowania systemem logistycznym, a nie jedynie jako funkcja techniczna.

3

Problem badawczy, cel oraz zakres pracy związany z modelem proaktywnego utrzymania ruchu systemów AGV

3.1. Identyfikacja występującej luki badawczej, zdefiniowanie problemu badawczego oraz związanych z nim pytań

Przegląd literatury przedstawiony w Rozdziale 2 pokazuje, że rozwój koncepcji Magazynu 4.0 prowadzi do wdrażania zaawansowanych systemów cyber-fizycznych obsługujących złożone procesy intralogistyczne, w których zasoby techniczne, w tym wózki AGV, odgrywają krytyczną rolę w realizacji przepływów materiałowych. Eksploatacja tych systemów charakteryzuje się wysoką zmiennością obciążeń, nierównomiernością użytkowania oraz silną zależnością od warunków operacyjnych, co przekłada się na złożony i niestacjonarny przebieg procesów degradacji.

Dotychczasowe badania opisywane w literaturze koncentrują się w dużej mierze na strategiach utrzymania o charakterze obiektowym, ukierunkowanych na analizę pojedynczych komponentów lub pojazdów. W efekcie tylko w ograniczonym stopniu uwzględniają one współzależności pomiędzy poszczególnymi elementami systemu AGV oraz ich wpływ na funkcjonowanie całego obsługiwanego systemu intralogistycznego. Szczególnie wyraźne jest to w przypadku podejść predykcyjnych, które — mimo zdolności do prognozowania momentu wystąpienia uszkodzeń — nie przekładają się bezpośrednio na decyzje utrzymaniowe. Sama prognoza degradacji nie odpowiada bowiem na pytania dotyczące priorytetu interwencji, momentu jej realizacji ani konsekwencji wyłączenia pojazdu dla funkcjonowania systemu.

Istotnym ograniczeniem obecnych rozwiązań jest również niewystarczająca integracja danych technicznych z kontekstem operacyjnym. Informacje diagnostyczne nie są w pełni powiązane z takimi czynnikami jak obciążenie systemu, dostępność floty czy priorytety realizowanych zadań, co znacząco ogranicza ich użyteczność w procesie podejmowania decyzji. Dodatkowym utrudnieniem jest niepewność danych

eksploatacyjnych, które mogą być niepełne, zaszumione lub trudne do jednoznacznej interpretacji. Stąd konieczność uwzględniania w analizach eksploatacyjnych zarówno danych historycznych, jak i wiedzy i doświadczenia osób odpowiedzialnych za procesy utrzymania ruchu. Tymczasem nadal widoczny jest także brak formalnych mechanizmów integracji wiedzy eksperckiej z danymi ilościowymi wspomagających procesy decyzyjne w obszarze eksploatacji systemów AGV.

Przeprowadzona analiza literatury wskazuje, że pomimo dynamicznego rozwoju systemów AGV oraz narzędzi wspierających utrzymanie ruchu w środowisku Magazynu 4.0, istniejące podejścia badawcze pozostają w dużej mierze zorientowane na poziom komponentowy lub pojedynczego zasobu. Dominują modele koncentrujące się na predykcji awarii, estymacji stanu technicznego lub optymalizacji harmonogramów utrzymania, które jednak nie uwzględniają w sposób wystarczający systemowego charakteru funkcjonowania flot AGV.

W szczególności widoczny jest brak zintegrowanych modeli decyzyjnych, które umożliwiałyby jednoczesne uwzględnienie:

- aktualnego i prognozowanego stanu technicznego pojazdów,
- kontekstu operacyjnego systemu intralogistycznego (np. obciążenia zadaniowego, struktury zleceń, priorytetów operacyjnych),
- współzależności pomiędzy pojazdami w ramach realizowanych procesów transportowych,
- oraz niepewności danych wynikającej z ograniczeń pomiarowych i zmienności środowiska operacyjnego.

Istniejące rozwiązania, w tym systemy klasy WMS oraz dedykowane systemy zarządzania flotą AGV, pełnią głównie funkcje ewidencyjne, monitorujące lub wykonawcze, nie oferując zaawansowanego wsparcia decyzyjnego w zakresie priorytetyzacji działań związanych z utrzymaniem AGV z perspektywy całego systemu.

W konsekwencji identyfikuje się lukę badawczą, która jest szczególnie istotna w warunkach wysokiej automatyzacji i złożoności charakterystycznych dla środowiska Magazynu 4.0.

Luka badawcza polega na braku zintegrowanego, systemowego modelu decyzyjnego wspierającego proces podejmowania decyzji utrzymaniowych dla flot AGV, który umożliwiałby ocenę stanu systemu, określanie priorytetów interwencji oraz analizę wpływu podejmowanych decyzji na funkcjonowanie systemu intralogistycznego w warunkach niepewności.

Na podstawie tak zidentyfikowanej luki badawczej sformułowano następujący problem badawczy:

Problem badawczy: Jak opracować systemowy model decyzyjny wspomagający podejmowanie decyzji dotyczących utrzymania floty AGV funkcjonującej w środowisku Magazynu 4.0, który integruje dane techniczne i operacyjne, uwzględnia współzależności pomiędzy zasobami oraz umożliwia ocenę wpływu podejmowanych decyzji na funkcjonowanie systemu intralogistycznego w warunkach niepewności?

Problem ten ma zarówno wymiar poznawczy, jak i aplikacyjny, ponieważ dotyczy zarówno sposobu modelowania zależności w systemach AGV, jak i ich praktycznego wykorzystania w procesie podejmowania decyzji.

Rozwiązanie tak sformułowanego problemu badawczego wymaga udzielenia odpowiedzi na następujące pytania badawcze:

- 1) **RQ1:** Jakie determinanty techniczne, eksploatacyjne i organizacyjne warunkują stan oraz zdolność operacyjną systemów AGV w dynamicznym środowisku intralogistycznym?
- 2) **RQ2:** W jaki sposób można formalizować stan systemu AGV jako kategorię decyzyjną, uwzględniającą zarówno symptomy degradacji technicznej, jak i kontekst jego bieżącej eksploatacji?
- 3) **RQ3:** W jaki sposób można integrować heterogeniczne informacje o stanie technicznym, warunkach pracy i historii eksploatacji w procesie wspomagania decyzji utrzymaniowych?
- 4) **RQ4:** W jaki sposób można modelować niepewność, niejednoznaczność oraz współzależności występujące pomiędzy czynnikami determinującymi stan i zdolność operacyjną systemów AGV?
- 5) **RQ5:** W jaki sposób można oceniać zasadność i priorytet działań utrzymaniowych z perspektywy ich wpływu na dostępność, niezawodność oraz ciągłość funkcjonowania systemu intralogistycznego?

3.2. Cel główny i cele szczegółowe

Celem głównym pracy jest opracowanie oraz weryfikacja systemowego modelu decyzyjnego wspomagającego podejmowanie decyzji utrzymaniowych w flotach AGV funkcjonujących w środowisku Magazynu 4.0, który integruje dane techniczne i operacyjne, uwzględnia współzależności pomiędzy zasobami oraz umożliwia ocenę wpływu podejmowanych decyzji na funkcjonowanie systemu intralogistycznego w warunkach niepewności.

W odróżnieniu od istniejących podejść proponowany model nie koncentruje się wyłącznie na identyfikacji stanów degradacji, lecz na wspomaganiu procesu podejmowania decyzji dotyczących utrzymania w ujęciu systemowym, z uwzględnieniem wpływu tych decyzji na eksploatację całej floty AGV.

Realizacja celu głównego wymaga osiągnięcia następujących celów szczegółowych:

- 1) Identyfikacja i systematyzacja kluczowych czynników technicznych i operacyjnych wpływających na proces degradacji oraz dostępność systemów AGV.
- 2) Analiza istniejących strategii utrzymania ruchu pod kątem ich ograniczeń w zakresie uwzględniania kontekstu operacyjnego oraz współzależności systemowych.
- 3) Opracowanie formalnego podejścia do integracji danych diagnostycznych oraz informacji o kontekście operacyjnym na potrzeby wspomagania decyzji utrzymaniowych.
- 4) Dobór i implementacja podejścia umożliwiającego odwzorowanie niepewności oraz nieliniowych zależności pomiędzy czynnikami technicznymi i operacyjnymi.

- 5) Opracowanie metody określania priorytetów interwencji utrzymaniowych dla floty AGV z uwzględnieniem wpływu decyzji na funkcjonowanie systemu intralogistycznego.
- 6) Implementacja modelu oraz jego walidacja w warunkach symulowanych scenariuszy eksploatacyjnych.
- 7) Ocena wpływu modelu na jakość decyzji utrzymaniowych, w szczególności w zakresie priorytetyzacji interwencji.

Celem utilitytarnym pracy jest natomiast opracowanie narzędzia wspomagającego podejmowanie decyzji utrzymaniowych, które może zostać zaimplementowane jako rozszerzenie istniejących systemów zarządzania magazynem (WMS) lub systemów zarządzania flotą AGV, umożliwiając zwiększenie dostępności systemu, poprawę efektywności operacyjnej oraz ograniczenie ryzyka zakłóceń w procesach intralogistycznych.

3.3. Etap pracy badawczych

Realizacja celu pracy wymagała przeprowadzenia kolejnych etapów badań obejmujących zarówno analizę problemu, jak i opracowanie oraz ocenę proponowanego rozwiązania. Punktem wyjścia była analiza literatury dotyczącej koncepcji Magazynu 4.0, strategii utrzymania ruchu, i systemów AGV. Szczególną uwagę poświęcono ograniczeniom istniejących podejść w zakresie integracji danych technicznych i operacyjnych oraz wspomagania decyzji utrzymaniowych w ujęciu systemowym. Na tej podstawie zidentyfikowano lukę badawczą oraz sformułowano problem badawczy, pytania badawcze, a także cel pracy. Następnie określono czynniki techniczne i operacyjne wpływające na funkcjonowanie systemów AGV w warunkach zmiennego obciążenia i niepewności danych eksploatacyjnych.

W dalszej części opracowano systemowy model decyzyjny wykorzystujący logikę rozmytą do odwzorowania zależności pomiędzy analizowanymi zmiennymi oraz wspomagania procesu podejmowania decyzji utrzymaniowych. Model poddano następnie weryfikacji i walidacji w scenariuszach eksploatacyjnych, a uzyskane wyniki oceniono z wykorzystaniem analizy stabilności oraz wskaźników eksploatacyjnych. Ostatni etap obejmował interpretację uzyskanych rezultatów oraz sformułowanie wniosków końcowych i kierunków dalszych badań. Zakres poszczególnych etapów prac badawczych przedstawiono w Tab. 3.1.

Tab. 3.1. Etapy prac badawczych

Etap	Zakres prac
1. Analiza literatury	Przegląd literatury dotyczącej koncepcji Magazynu 4.0, systemów AGV, i strategii utrzymania ruchu, ze szczególnym uwzględnieniem ograniczeń istniejących podejść.
2. Identyfikacja problemu badawczego	Określenie luki badawczej, sformułowanie problemu badawczego, pytań badawczych oraz celu pracy.

Kontynuacja na następnej stronie

Tabela 3.1 – kontynuacja z poprzedniej strony

Etap	Zakres prac
3. Identyfikacja czynników wpływających na system AGV	Wyznaczenie czynników technicznych i operacyjnych wpływających na stan oraz funkcjonowanie systemów AGV.
4. Opracowanie modelu decyzyjnego	Opracowanie systemowego modelu decyzyjnego wykorzystującego logikę rozmytą do wspomagania decyzji utrzymaniowych.
5. Weryfikacja i walidacja modelu	Ocena poprawności działania modelu oraz analiza zgodności wyników z wiedzą ekspercką w scenariuszach eksploatacyjnych.
6. Ocena wyników	Ewaluacja wdrożeniowa modelu na podstawie KPI.
7. Wnioski końcowe	Interpretacja wyników badań oraz określenie kierunków dalszych prac badawczych.

Źródło: Opracowanie własne.

4

Koncepcja i formalizacja modelu proaktywnego utrzymania ruchu jako systemu decyzyjnego opartego na logice rozmytej

W odpowiedzi na problem badawczy zidentyfikowany w Rozdziale 3 opracowano model decyzyjny określony jako *Fuzzy Proactive Maintenance Decision Framework* (FPMDF). Opracowanie modelu wynikało nie tylko z potrzeby formalizacji procesu oceny stanu technicznego, lecz również z identyfikowanej w literaturze luki badawczej dotyczącej integracji czynników technicznych, operacyjnych, środowiskowych i historycznych w procesie podejmowania decyzji utrzymaniowych dla systemów AGV.

W odróżnieniu od podejść koncentrujących się na predykcji uszkodzeń lub analizie pojedynczych komponentów, zaproponowany model przyjmuje perspektywę systemową, w której flota AGV traktowana jest jako system wzajemnie powiązanych zasobów. Oznacza to, że ocena stanu technicznego nie stanowi celu samego w sobie, lecz element szerszego procesu decyzyjnego, obejmującego identyfikację priorytetów interwencji oraz ich potencjalnego wpływu na funkcjonowanie całego systemu.

Z tego względu model FPMDF zaprojektowano jako strukturę umożliwiającą jednoczesne uwzględnienie danych technicznych, operacyjnych oraz kontekstowych, które w praktyce eksploatacyjnej występują w formie niepełnej, niejednoznacznej lub trudnej do bezpośredniej kwantyfikacji. Wybór logiki rozmytej jako podstawy formalnej nie był zatem przypadkowy, lecz wynikał z jej zdolności do odwzorowania wiedzy eksperckiej oraz operowania na pojęciach lingwistycznych, co pozwala na zachowanie interpretowalności modelu przy jednoczesnym uchwyceniu złożonych zależności między zmiennymi.

Struktura modelu opiera się na wielopoziomowej organizacji procesu wnioskowania, realizowanego etapowo od poziomu sygnałów diagnostycznych, poprzez oceny pośrednie, aż do końcowej rekomendacji dotyczącej utrzymania systemu. Takie podejście umożliwia dekompozycję złożonego problemu decyzyjnego na mniejsze, bardziej interpretowalne podproblemy, co z jednej strony ułatwia konstrukcję bazy reguł, a z drugiej zwiększa transparentność działania całego systemu.


Istotnym założeniem przyjętym w pracy jest rozdzielenie procesu oceny stanu technicznego od procesu podejmowania decyzji utrzymaniowych. Ocena stanu stanowi jedynie jeden z elementów procesu decyzyjnego, który dodatkowo uwzględnia uwarunkowania operacyjne, środowiskowe oraz historyczne. W konsekwencji model nie odpowiada wyłącznie na pytanie: „Jaki jest aktualny stan techniczny pojazdu?”, lecz również na pytanie: „Jakie działania utrzymaniowe są uzasadnione z punktu widzenia eksploatacji i utrzymania ruchu?”. Tym samym proponowane rozwiązanie wykracza poza funkcję klasycznego systemu diagnostycznego i pełni rolę systemu wspomagania decyzji utrzymaniowych w środowisku AGV.

4.1. Założenia analityczne oraz proces opracowania modelu

Analizowany problem badawczy nie dotyczy wyłącznie identyfikacji symptomów degradacji technicznej pojazdów AGV, lecz sposobu wspomagania decyzji dotyczących utrzymania w środowisku charakteryzującym się niepewnością danych, współzależnością czynników eksploatacyjnych oraz wysoką dynamiką procesów logistycznych. Oznacza to, że rozwiązanie problemu wymagało nie tylko opracowania mechanizmu oceny stanu technicznego, ale również formalnego modelu wspierającego proces podejmowania decyzji dotyczących utrzymania.

W prowadzonych badaniach przyjęto podejście wieloetapowe o charakterze sekwencyjno-integracyjnym, w którym kolejne fazy postępowania pełnią komplementarne funkcje: eksploracyjną, selekcyjną oraz formalizującą. Każdy etap pełni odrębną funkcję analityczną, a uzyskane rezultaty stanowią podstawę dla kolejnego etapu. Przyjęta procedura została przedstawiona na Rys. 4.1. Jej celem było systematyczne przejście od identyfikacji problemu badawczego do opracowania, implementacji oraz walidacji kompletnego systemu wspomagania decyzji dla proaktywnego utrzymania ruchu pojazdów AGV.

- 1) **Eksploracja problemu** – Przeprowadzono analizę literatury, przypadków awarii oraz diagram Ishikawy w celu identyfikacji potencjalnych czynników wpływających na stan techniczny pojazdów AGV. Wynikiem etapu był uporządkowany zbiór czynników technicznych, operacyjnych, środowiskowych i eksploatacyjnych.
- 2) **Selekcja zmiennych** – Wykorzystano analizę Pareto–Lorenza do uszeregowania zidentyfikowanych czynników według ich znaczenia oraz wyodrębnienia parametrów o największym wpływie na proces degradacji i utrzymania ruchu. Rezultatem był zbiór kluczowych zmiennych wejściowych modelu.
- 3) **Konceptualizacja modelu** – Opracowano strukturę modelu FPMDF, definiując jego wejścia, wyjścia oraz przepływ informacji pomiędzy jego poziomami. Określono również relacje pomiędzy modułami diagnostycznymi, agregacyjnymi i decyzyjnymi.
- 4) **Formalizacja modelu decyzyjnego** – Zdefiniowano zmienne lingwistyczne, funkcje przynależności oraz bazę reguł rozmytych typu IF–THEN. Określono mechanizm wnioskowania Mamdaniego, operacje agregacji oraz procedurę defuzyfikacji metodą środka ciężkości (COA). Opracowana struktura modelu stanowiła podstawę do implementacji modelu w środowisku MATLAB.



Rys. 4.1. Procedura opracowania modelu FPMDF

Źródło: Opracowanie własne

- 5) **Implementacja modelu** – Opracowany model zaimplementowano w środowisku MATLAB z wykorzystaniem pakietu Fuzzy Logic Toolbox. Utworzono strukturę systemu FIS, zaimplementowano funkcje przynależności oraz bazę reguł, a następnie przygotowano środowisko umożliwiające przeprowadzanie eksperymentów symulacyjnych. Proces implementacji miał charakter iteracyjny – wyniki kolejnych testów działania modelu były analizowane pod kątem poprawności logicznej oraz zgodności z przyjętymi założeniami. W przypadku identyfikacji niepożądanych zachowań modelu dokonywano modyfikacji funkcji przynależności, bazy reguł lub elementów architektury modelu, po czym ponownie przeprowadzano testy implementacyjne.
- 6) **Weryfikacja i walidacja modelu** – Przeprowadzono weryfikację strukturalną i logiczną modelu, walidację scenariuszową z udziałem ekspertów utrzymania ruchu oraz analizę wrażliwości zmiennych wejściowych. Celem etapu było potwierdzenie poprawności działania modelu oraz ocena jego stabilności i użyteczności decyzyjnej. Szczegółowy opis procedury walidacyjnej oraz charakterystykę panelu ekspertów przedstawiono w rozdziale 4.2.2.
- 7) **Wynik końcowy** – Efektem procesu badawczego był zweryfikowany i zwalidowany model FPMDF stanowiący system wspomagania decyzji dla proaktywnego utrzymania ruchu pojazdów AGV. Model umożliwia generowanie interpretowalnych rekomendacji dotyczących utrzymania w warunkach niepewności i zmienności środowiska eksploatacyjnego.

Tak rozumiany proces budowy modelu ma charakter transformacyjny: od szerokiej identyfikacji jakościowej, przez ilościową selekcję i redukcję informacji, aż do formalizacji mechanizmu decyzyjnego. Opracowany model nie stanowi prostej konstrukcji matematycznej budowanej bezpośrednio na danych wejściowych, lecz jest wynikiem uporządkowanego procesu integracji wiedzy eksperckiej, danych eksploatacyjnych oraz metod analitycznych.

Przyjęte podejście pozostaje zgodne z logiką badań projektowych, w których rozwiązanie problemu badawczego wymaga opracowania modelu decyzyjnego budowanego w sposób systematyczny na podstawie przesłanek teoretycznych, danych empirycznych oraz formalnych procedur modelowania.

Przedstawiona procedura ma charakter iteracyjny. Chociaż poszczególne etapy są realizowane zgodnie z logiką sekwencyjną, wyniki uzyskiwane w kolejnych fazach mogą prowadzić do modyfikacji wcześniejszych założeń projektowych. Dotyczy to w szczególności strojenia funkcji przynależności, doskonalenia bazy reguł rozmytych oraz konfiguracji architektury modelu. Dzięki temu możliwe jest stopniowe doskonalenie modelu aż do uzyskania rozwiązania spełniającego założenia funkcjonalne, wymagania eksperckie oraz kryteria interpretowalności modelu. W tym ujęciu zastosowane metody pełniły następujące funkcje:

- diagram Ishikawy – funkcja eksploracyjna i strukturyzująca,
- analiza Pareto–Lorenza – funkcja selekcyjna i redukcyjna,
- logika rozmyta – funkcja właściwego modelowania decyzyjnego.

Układ ten odzwierciedla sekwencyjną logikę budowy modelu oraz przepływ informacji pomiędzy kolejnymi etapami przetwarzania. Rolę poszczególnych metod w procesie konstrukcji modelu przedstawiono w Tab. 4.1.

Tab. 4.1. Rola metod i narzędzi w procesie budowy modelu decyzyjnego

Metoda / narzędzie	Funkcja analityczna	Rezultat zastosowania	Znaczenie dla budowy modelu
Diagram Ishikawy	Identyfikacja i strukturyzacja potencjalnych przyczyn zakłóceń	Uporządkowany zbiór czynników technicznych, operacyjnych i środowiskowych	Wyznaczenie przestrzeni problemowej i podstaw do dalszej selekcji zmiennych
Diagram Pareto–Lorenza	Priorytetyzacja i redukcja liczby analizowanych czynników	Wyodrębnienie parametrów o największym znaczeniu eksploatacyjnym	Dobór kluczowych zmiennych wejściowych do modelu decyzyjnego
Logika rozmyta	Formalizacja procesu decyzyjnego w warunkach niepewności	Model inferencyjny integrujący dane ilościowe, jakościowe i wiedzę ekspercką	Budowa właściwego modelu proaktywnego utrzymania ruchu AGV


Źródło: Opracowanie własne.

4.1.1. Identyfikacja i strukturyzacja przyczyn degradacji AGV z wykorzystaniem diagramu Ishikawy

Pierwszy etap budowy modelu FPMDF miał charakter eksploracyjno–strukturyzujący i został oparty na diagramie Ishikawy. Wybór tego narzędzia wynikał z potrzeby uporządkowania zbioru przyczyn mogących prowadzić zarówno do pogorszenia stanu technicznego AGV, jak i do konieczności wcześniejszego niż planowano przekazania pojazdu do obsługi technicznej. W analizowanym problemie źródła degradacji nie mają charakteru jednowymiarowego, lecz wynikają z nakładania się czynników technicznych, operacyjnych, organizacyjnych i środowiskowych. W takich warunkach diagram Ishikawy stanowi użyteczne narzędzie identyfikacji oraz porządkowania zależności przyczynowo–skutkowych [95].

Istotą diagramu Ishikawy jest graficzne przedstawienie relacji pomiędzy analizowanym skutkiem a uporządkowanymi kategoriami przyczyn. W klasycznej postaci wykorzystuje on układ 5M, obejmujący kategorie: człowiek, maszyna, metoda, materiał oraz pomiar. W badaniach nad systemami AGV układ ten wymaga jednak rozszerzenia, ponieważ źródła zakłóceń eksploatacyjnych nie ograniczają się do samej kondycji technicznej komponentów, lecz obejmują również jakość sterowania, warunki pracy, organizację procesu utrzymania ruchu oraz czynniki środowiskowe.

W analizie przyjęto problem zdefiniowany jako *przekazanie AGV do obsługi w terminie innym niż wynikający z harmonogramu obsługi*. Tak sformułowany skutek odpowiada sytuacji eksploatacyjnej szczególnie istotnej z punktu widzenia utrzymania proaktywnego, ponieważ obejmuje zarówno przypadki przyspieszonej degradacji komponentów, jak i zakłócenia wynikające z niekorzystnego kontekstu pracy systemu. Diagram opracowany dla tego problemu przedstawiono na Rys. 4.2.



Rys. 4.2. Diagram Ishikawy dla przekazywania AGV do obsługi poza harmonogramem
Źródło: Opracowanie własne

W analizie wykorzystano zarówno badania literaturowe dotyczące najczęściej występujących przyczyn interwencji dotyczących utrzymania w systemach AGV i intralogistycznych [8, 68], jak również wyniki badań terenowych prowadzonych w rzeczywistych systemach intralogistycznych. Na tej podstawie zidentyfikowano 24 czynniki, które mogą wymuszać interwencję serwisową poza planem utrzymaniowym. Uporządkowano je w sześciu kategoriach: materiały, maszyny, metody, zarządzanie, człowiek oraz środowisko. Taki podział pozwolił uchwycić wielowymiarowy charakter degradacji AGV i pokazał, że pogorszenie gotowości eksploatacyjnej pojazdu nie jest wyłącznie konsekwencją uszkodzeń komponentowych, lecz również warunków użytkowania, jakości konfiguracji i sterowania oraz organizacji procesu utrzymania ruchu.

Syntetyczne zestawienie zidentyfikowanych kategorii przyczyn oraz ich znaczenia dla budowy modelu przedstawiono w Tab. 4.2.

Tab. 4.2. Syntetyczne zestawienie kategorii przyczyn zidentyfikowanych w analizie Ishikawy oraz ich znaczenia dla budowy modelu

Kategoria	Czynniki	Znaczenie dla modelu
Materiały	naruszona integralność obudowy, przekroczenie masy ładunku, wysoki poziom degradacji akumulatora	Wskazują na wpływ jakości elementów oraz obciążeń eksploatacyjnych na trwałość AGV. Kategoria ta uzasadnia uwzględnienie zmiennych opisujących stan źródła energii oraz intensywność użytkowania.
Maszyny	napięcie akumulatora, natężenie prądu akumulatora, temperatura akumulatora, stan naładowania, poziom wibracji kół, natężenie prądu silnika, temperatura silnika, stan enkodera koła, czas reakcji hamulca	Obejmuje bezpośrednie symptomy degradacji podsystemów technicznych. Czynniki tej grupy tworzą podstawowy rdzeń diagnostyczny modelu i stanowią główne źródło zmiennych wejściowych dla bloków FIS.

Kontynuacja na następnej stronie

Tabela 4.2 – kontynuacja z poprzedniej strony

Kategoria	Czynniki	Znaczenie dla modelu
Metody	błąd wyrównania chwytaka, błąd kalibracji oprogramowania, niski poziom sygnału sterującego	Pokazują, że źródłem zakłóceń mogą być również nieprawidłowości proceduralne i błędy konfiguracji. Kategoria ta uzasadnia włączenie do modelu parametrów związanych z poprawnością sterowania i kalibracji.
Zarządzanie	obniżona dokładność LIDAR, niewypoziomowana konstrukcja, nieprzestrzeganie harmonogramu konserwacji, liczba zdarzeń krytycznych, liczba cykli ładowania/rozładowania	Wskazuje na znaczenie czynników organizacyjnych i nadzorczych dla niezawodności AGV. Ta grupa uzasadnia uwzględnienie danych historycznych i eksploatacyjnych jako przesłanek decyzyjnych.
Człowiek	zwiększona liczba zdarzeń krytycznych, opóźniona reakcja na symptomy zakłóceń	Podkreśla rolę czynnika ludzkiego w eskalacji problemów eksploatacyjnych. W modelu nie jest on ujmowany bezpośrednio jako osobny blok, lecz jako część kontekstu operacyjnego i organizacyjnego.
Środowisko	podwyższony poziom zapylenia, podwyższona temperatura otoczenia, obniżone tarcie podłogi, wysoki poziom opóźnienia sygnału	Pokazuje, że warunki otoczenia wpływają na tempo degradacji i stabilność pracy AGV. Kategoria ta uzasadnia włączenie do modelu zmiennych środowiskowych i operacyjnych.

Źródło: Opracowanie własne.

Wyniki analizy Ishikawy mają w niniejszej pracy szersze znaczenie niż jedynie opisanie źródeł zakłóceń. Pozwoliły one na uporządkowanie przestrzeni problemowej i wykazały, że degradacja pojazdów AGV ma charakter systemowy, a nie wyłącznie komponentowy. Analiza umożliwiła również identyfikację tych obszarów eksploatacji pojazdów, które powinny znaleźć odzwierciedlenie w strukturze modelu FPMDF. W rezultacie utworzono zbiór potencjalnych zmiennych wejściowych, stanowiący podstawę dla kolejnego etapu selekcji.

Diagram Ishikawy pełni w niniejszej pracy dwie funkcje. Z jednej strony wspiera identyfikację i uporządkowanie przyczyn degradacji pojazdów AGV, z drugiej natomiast stanowi podstawę dalszej redukcji i selekcji zmiennych wejściowych dla modelu rozmytego. Ze względu na zróżnicowanie warunków pracy oraz organizacji procesów intralogistycznych, zidentyfikowany katalog czynników należy traktować jako zbiór bazowy, który może zostać rozszerzony o dodatkowe zmienne specyficzne dla danego środowiska eksploatacji. Rezultaty Analizy Ishikawy stanowią naturalne przejście do kolejnego etapu badań, polegającego na doborze parametrów z wykorzystaniem analizy Pareto–Lorenza.

4.1.2. Selekcja kluczowych parametrów wejściowych z wykorzystaniem analizy Pareto–Lorenza

Po zidentyfikowaniu szerokiego zbioru potencjalnych przyczyn degradacji i zakłóceń eksploatacyjnych konieczne jest ograniczenie przestrzeni analizowanych zmiennych do parametrów o najwyższej wartości diagnostycznej i decyzyjnej. Etap ten ma

istotne znaczenie dla dalszej konstrukcji modelu FPMDF, ponieważ liczba zmiennych wejściowych w systemie logiki rozmytej bezpośrednio wpływa na złożoność bazy reguł, przejrzystość struktury inferencyjnej oraz praktyczną możliwość implementacji modelu.

W celu ograniczenia liczby analizowanych zmiennych zastosowano analizę Pareto–Lorenza, szeroko wykorzystywaną do identyfikacji czynników mających największy wpływ na obserwowane problemy eksploatacyjne [96]. W niniejszej pracy jej rola wykracza jednak poza klasyczną redukcję danych. Analiza ta pełni funkcję selekcyjną, umożliwiając przejście od szerokiego katalogu przyczyn zidentyfikowanych na etapie analizy Ishikawy do ograniczonego zbioru parametrów wejściowych modelu rozmytego. Tym samym analiza Pareto–Lorenza stanowi formalne uzasadnienie doboru zmiennych wejściowych modelu.

Podstawę analizy stanowią dane zestawione w Tab. 4.3, obejmujące parametry przypisane do głównych bloków funkcjonalnych modelu FIS. Dla każdego parametru określono jednostkę miary oraz liczbę zidentyfikowanych przypadków, co umożliwiło ilościową ocenę jego znaczenia eksploatacyjnego. W odniesieniu do systemów AGV zestawienie obejmuje trzy kluczowe obszary diagnostyczne: system zasilania, układ napędowy oraz system nawigacyjny. Dane wykorzystane do opracowania zestawienia oraz analizy Pareto–Lorenza pozyskano na podstawie analizy literatury, danych o zdarzeniach niepożądanych oraz obserwacji eksploatacyjnych prowadzonych w rzeczywistym środowisku intralogistycznym przedsiębiorstwa produkcyjnego z branży automotive zlokalizowanego na terenie Dolnego Śląska. Obserwacje prowadzono przez okres około trzech miesięcy w 2024 roku i obejmowały funkcjonowanie pojazdów AGV. W ramach obserwacji analizowano przypadki zakłóceń eksploatacyjnych oraz interwencji dotyczących utrzymania związanych z funkcjonowaniem systemów AGV. Liczba ujawnionych przypadków została oszacowana na podstawie danych pochodzących z rejestru zdarzeń niepożądanych. Ze względu na poufny charakter danych źródłowych wartości liczbowe zostały zakodowane poprzez przemnożenie przez przyjęty współczynnik skalujący. Oznacza to, że prezentowane wielkości nie stanowią wiernego odzwierciedlenia rzeczywistych wartości bezwzględnych, lecz zachowują relacje, proporcje i kierunki zmian występujące w danych źródłowych. Uzyskane wyniki stanowiły podstawę identyfikacji oraz priorytetyzacji parametrów wejściowych modelu.

Wyniki przedstawione w Tab. 4.3 wskazują, że w obrębie systemu zasilania największe znaczenie mają: liczba cykli ładowania/rozładowania, stan naładowania akumulatora oraz napięcie akumulatora. Parametry te odzwierciedlają zarówno długookresowy proces degradacji źródła energii, jak i jego bieżącą zdolność do zapewnienia stabilnego zasilania, co potwierdza kluczową rolę tego obszaru dla gotowości eksploatacyjnej AGV.

W przypadku układu napędowego dominującym parametrem jest poziom wibracji kół, uzupełniany przez czas reakcji hamulca, natężenie prądu silnika oraz temperaturę silnika. Parametry te stanowią bezpośrednie wskaźniki pogorszenia kondycji mechanicznej pojazdu oraz bezpieczeństwa jego ruchu, przy czym szczególna rola drgań wskazuje na ich wysoką czułość diagnostyczną.

W odniesieniu do systemu nawigacyjnego najwyższą wartość diagnostyczną wykazują stan techniczny enkodera koła oraz dokładność kalibracji oprogramowania


sterującego. Parametry te determinują zdolność systemu do poprawnej lokalizacji oraz stabilnej realizacji trajektorii, a więc obszarów bezpośrednio związanych z niezawodnością operacyjną AGV.

Tab. 4.3. Parametry i liczba ujawnionych przypadków dla wózków AGV

Nazwa bloku FIS	Wejścia do bloku FIS	Jednostka	Liczba ujawnionych przypadków
Poprawność funkcjonowania systemu zasilania	Napięcie akumulatora	V	18
	Natężenie prądu akumulatora	A	7
	Temperatura akumulatora	°C	12
	Stan naładowania akumulatora	%	28
	Poziom degradacji akumulatora	%	16
	Liczba cykli ładowania/rozładowania	liczba cykli	33
Poprawność funkcjonowania układu napędowego	Poziom wibracji kół	mm/s ²	45
	Natężenie prądu silnika	A	12
	Temperatura silnika	°C	14
	Czas reakcji hamulca	ms	18
Poprawność funkcjonowania systemu nawigacyjnego	Dokładność LIDAR	%	12
	Poziom pochylenia (na podstawie danych IMU)	°	16
	Stan techniczny enkodera koła	%	18
	Dokładność kalibracji oprogramowania sterującego	%	31


Źródło: Opracowanie własne.

Graficzną ilustrację procesu selekcji przedstawiono na Rys. 4.3, 4.4 oraz 4.5. W każdym przypadku krzywa skumulowana umożliwia identyfikację parametrów odpowiadających za dominującą część nieprawidłowości, natomiast przyjęty próg 80% wyznacza obszar priorytetowy z punktu widzenia konstrukcji modelu.




Rys. 4.3. Analiza Pareto-Lorenza usterek systemu zasilania wózków AGV (próg 80%)

Źródło: Opracowanie własne



Rys. 4.4. Analiza Pareto–Lorenza usterek układu jezdnego i napędowego AGV (próg 80%)

Źródło: Opracowanie własne



Rys. 4.5. Analiza Pareto–Lorenza usterek sterowania i czujników AGV (próg 80%)

Źródło: Opracowanie własne

Interpretacja wyników prowadzi do wniosku, że do opracowanego modelu należy włączyć przede wszystkim te parametry, które łączą wysoką częstość występowania z wysoką użytecznością diagnostyczną oraz możliwością ich wiarygodnego pomiaru w warunkach przemysłowych. Pozwala to zachować równowagę pomiędzy reprezentatywnością modelu a jego złożonością obliczeniową.

W konsekwencji analiza Pareto–Lorenza pełni w niniejszej rozprawie podwójną funkcję. Z jednej strony umożliwia redukcję liczby rozważanych zmiennych, z drugiej stanowi formalne uzasadnienie doboru wejść modelu rozmytego. Struktura wejściowa modelu FPMDF nie została więc przyjęta arbitralnie, lecz wynika z uprzednio przeprowadzonej selekcji parametrów o najwyższej wartości eksploatacyjnej i decyzyjnej.

Przeprowadzona selekcja zmiennych ma również znaczenie strukturyzujące. Pozwala wyodrębnić kluczowe obszary funkcjonowania AGV, które stanowią podstawę dalszej formalizacji modelu. Należy podkreślić, że wskazane obszary (system zasilania, układ napędowy oraz system nawigacyjny) definiują podstawowe bloki diagnostyczne

modelu. W dalszej części pracy zostają one rozwinięte i uzupełnione o dodatkowe poziomy agregacji oraz elementy decyzyjne, wynikające z przyjętej struktury modelu wnioskowania rozmytego.

4.1.3. Architektura i formalizacja matematyczna modelu decyzyjnego FPMDF

Przyjęta architektura została zaprojektowana w celu integracji czynników technicznych, operacyjnych, środowiskowych i historycznych w ramach jednego procesu decyzyjnego. Opracowany framework odpowiada na lukę badawczą zidentyfikowaną w Rozdziale 3, dotyczącą ograniczonego uwzględniania wielowymiarowych uwarunkowań eksploatacyjnych w istniejących podejściach do utrzymania ruchu systemów AGV.

Fuzzy Proactive Maintenance Decision Framework (FPMDF) opracowano jako model decyzyjny wykorzystujący wielopoziomową strukturę wnioskowania rozmytego typu Mamdaniego. Przyjęta struktura umożliwia integrację informacji technicznych, operacyjnych, środowiskowych oraz historycznych w ramach jednolitego procesu decyzyjnego, prowadzącego do generowania rekomendacji wspomagających działania utrzymaniowe. Wybór logiki rozmytej jako podstawy formalnej frameworku wynikał z konieczności zapewnienia interpretowalności procesu decyzyjnego oraz możliwości formalizacji wiedzy eksperckiej w postaci reguł lingwistycznych, przy jednoczesnym uwzględnieniu niepewności i niejednoznaczności danych wejściowych.

Zadaniem modelu jest przekształcenie heterogenicznych danych diagnostycznych, eksploatacyjnych, środowiskowych i historycznych w syntetyczną ocenę stanu technicznego wózka AGV oraz odpowiadającą jej rekomendację utrzymaniową. Przyjęta architektura nie wynika wyłącznie z potrzeby uporządkowania procesu obliczeniowego, lecz odzwierciedla rzeczywistą logikę postępowania diagnostyczno-decyzyjnego stosowaną w praktyce utrzymania ruchu.

Z tego względu model wyróżniono trzy poziomy przetwarzania informacji:

- 1) **warstwy percepcyjnej (diagnostycznej)** – odpowiedzialnej za przetwarzanie sygnałów wejściowych i ocenę stanu podsystemów (poziom 1),
- 2) **warstwy integracyjnej (agregacyjnej)** – odpowiedzialnej za syntezę ocen częściowych oraz uwzględnienie kontekstu operacyjnego (poziom 2),
- 3) **warstwy decyzyjnej** – realizującej końcowe wnioskowanie i generowanie rekomendacji dotyczącej utrzymania systemu (poziom 3).

W ujęciu formalnym każdy blok FIS można zapisać jako odwzorowanie:

$$f_j : \mathbf{X}_j \rightarrow Y_j, \quad (4.1)$$

gdzie:

- $\mathbf{X}_j = x_{j1}, x_{j2}, \dots, x_{jn_j}$ oznacza wektor wejść dla j -tego bloku,
- x_{ji} są zmiennymi wejściowymi reprezentującymi parametry techniczne, operacyjne, środowiskowe lub historyczne,
- Y_j oznacza zmienną wyjściową danego bloku,
- indeks j identyfikuje odpowiedni blok frameworku decyzyjnego.

Cały system można zapisać jako złożenie odwzorowań:


$$Y^3 = F^3(F^2(F^1\mathbf{X})), \quad (4.2)$$

gdzie:

- $\mathbf{X}$ oznacza zbiór wszystkich zmiennych wejściowych modelu,
- F^1 odpowiada odwzorowaniom poziomu lokalnego,
- F^2 reprezentuje agregację semantyczną poziomu pośredniego,
- F^3 stanowi końcowy blok decyzyjny.

Takie uporządkowanie modelu ma istotne konsekwencje. Umożliwia dekompozycję złożonego problemu decyzyjnego na mniejsze i bardziej przejrzyste podproblemy, ogranicza wzrost liczby reguł charakterystyczny dla systemów monolitycznych oraz lepiej odpowiada architekturze współczesnych systemów cyber-fizycznych, w których przetwarzanie danych, ich integracja i podejmowanie decyzji zachodzą na różnych poziomach organizacji systemu [19]. Trójpoziomową strukturę modelu przedstawiono na Rys. 4.6. Schemat ten pokazuje przejście od obserwacji symptomów degradacji do końcowej rekomendacji dotyczącej utrzymania systemu i zarazem porządkuje logikę modelu przyjętą w rozprawie.

Na Rys. 4.6 przedstawiono pełną strukturę opracowanego systemu wnioskowania rozmytego. Poziom 1 obejmuje lokalne bloki oceny stanu podsystemów, poziom 2 odpowiada za ich semantyczną agregację, natomiast poziom 3 pełni funkcję końcowej warstwy decyzyjnej. Dzięki temu model prowadzi od danych źródłowych i symptomów degradacji do decyzji dotyczącej utrzymania systemu, którą można bezpośrednio wykorzystać w praktyce zarządzania utrzymaniem ruchu.



Rys. 4.6. Struktura frameworku decyzyjnego FPMDF oraz przepływ ocen pomiędzy blokami wnioskowania rozmytego
Źródło: Opracowanie własne

4.1.3.1. Poziom 1: lokalna ocena stanu podsystemów technicznych AGV

Na poziomie 1 parametry techniczne i eksploatacyjne są przekształcane w ujednolicone oceny stanu poszczególnych podsystemów. Oznacza to przejście od surowych danych pomiarowych do semantycznie uporządkowanych ocen częściowych, które stanowią punkt wyjścia dla dalszej agregacji.


Formalnie każdy blok lokalny można zapisać jako:

$$Y_j^1 = f_j^1 x_{j1}, x_{j2}, \dots, x_{jn_j}, \quad (4.3)$$


gdzie Y_j^1 oznacza ocenę poprawności funkcjonowania j -tego podsystemu na pierwszym poziomie. Dobór zmiennych wejściowych oparto na wynikach wcześniejszej analizy Ishikawy i Pareto–Lorenza oraz na ich znaczeniu diagnostycznym. Przyjęto przy tym, że poziom lokalny powinien operować na wielkościach fizycznie interpretowalnych, ponieważ to one najpełniej odzwierciedlają rzeczywiste mechanizmy degradacji i ryzyka eksploatacyjne. Na poziomie 1 wyróżniono pięć bloków lokalnych.

1) Poprawność funkcjonowania układu przenoszenia ładunku


Na Rys. 4.7 przedstawiono blok oceny poprawności funkcjonowania układu przenoszenia ładunku. Dobór zmiennych wejściowych wynika z założenia, że bezpieczeństwo i poprawność realizacji operacji ładunkowych zależą jednocześnie od poziomu obciążenia, dokładności pozycjonowania oraz kondycji strukturalnej elementów nośnych. Masa przenoszonego ładunku [kg] odzwierciedla obciążenie mechanizmu podnoszenia i chwytania. Błąd wyrównania chwytaka [cm] opisuje dokładność pozycjonowania w fazie pobierania i odkładania ładunku, natomiast integralność strukturalna [%] stanowi syntetyczny wskaźnik kondycji elementów nośnych i osłonowych. Wyjście bloku przyjmuje postać ujednoliconej oceny lingwistycznej, która może zostać wykorzystana w dalszej agregacji na poziomach wyższych.




(a) FIS poprawności funkcjonowania układu




(b) MF masy przenoszonego ładunku



(c) MF błęd wyrównania chwytaka




(d) MF integralności strukturalnej




(e) MF wyjściowej poprawności funkcjonowania układu

Rys. 4.7. Blok FIS poprawności funkcjonowania układu przenoszenia ładunku
Źródło: Opracowanie własne


2) Poprawność funkcjonowania układu napędowego




(a) FIS poprawności funkcjonowania układu napędowego



(b) MF poziomu wibracji kół



(c) MF czasu reakcji hamulca




(d) MF wyjściowej poprawności funkcjonowania układu napędowego

Rys. 4.8. Blok FIS poprawności funkcjonowania układu napędowego
Źródło: Opracowanie własne


Na Rys. 4.8 przedstawiono blok oceny poprawności funkcjonowania układu napędowego. W modelu przyjęto dwa parametry wejściowe: poziom wibracji kół oraz czas reakcji hamulca. Reprezentują one dwa komplementarne wymiary bezpieczeństwa ruchu: stan mechaniczny układu jezdnego oraz zdolność do skutecznego zatrzymania pojazdu. Poziom wibracji kół [mm/s^2] stanowi wskaźnik kondycji mechanicznej układu napędowego, natomiast czas reakcji hamulca [ms] jest parametrem bezpośrednio związanym z bezpieczeństwem eksploatacji. Wyjście tego bloku interpretuje się jako

syntetyczną miarę zdolności wózka do utrzymania bezpiecznego i stabilnego ruchu w bieżących warunkach eksploatacyjnych.


3) Poprawność funkcjonowania systemu zasilania




(a) FIS poprawności funkcjonowania systemu zasilania




(b) MF liczby cykli ładowania/rozładowania



(c) MF stanu naładowania akumulatora



(d) MF napięcia akumulatora




(e) MF wyjściowej poprawności systemu zasilania

Rys. 4.9. Blok FIS poprawności funkcjonowania systemu zasilania
Źródło: Opracowanie własne


Blok przedstawiony na Rys. 4.9 służy do oceny poprawności funkcjonowania systemu zasilania. Łączy on parametry opisujące zarówno długookresowe starzenie źródła energii, jak i bieżącą zdolność do utrzymania stabilnego zasilania. Liczba cykli ładowania/rozładowania [cykl] pełni funkcję wskaźnika degradacji akumulatora w dłuższym horyzoncie czasowym, stan naładowania SoC [%] odzwierciedla bieżącą dostępność energii, natomiast napięcie akumulatora [V] informuje o stabilności zasilania.

nia. Wyjście bloku stanowi syntetyczną ocenę poprawności systemu zasilania, łączącą informację o procesie starzenia z aktualnym ryzykiem operacyjnym.


4) Poprawność funkcjonowania systemu nawigacyjnego




(a) FIS poprawności funkcjonowania systemu nawigacyjnego



(b) MF stanu technicznego enkodera koła



(c) MF błędu kalibracji oprogramowania sterującego




(d) MF wyjściowej poprawności systemu nawigacyjnego

Rys. 4.10. Blok FIS poprawności funkcjonowania systemu nawigacyjnego
Źródło: Opracowanie własne


Na Rys. 4.10 przedstawiono blok oceny systemu nawigacyjnego, który integruje parametry związane z wiarygodnością pomiaru przemieszczenia oraz jakością kalibracji oprogramowania sterującego. Stan techniczny enkodera koła informuje o zdolności do poprawnego odwzorowania ruchu i pozycji, natomiast dokładność kalibracji oprogramowania sterującego odzwierciedla jakość konfiguracji systemu odpowiedzialnego za prowadzenie pojazdu. Wyjście bloku interpretuje się jako syntetyczną miarę wiarygodności lokalizacji i poprawności prowadzenia wózka podczas realizacji operacji transportowych.

5) Poprawność komunikacji z urządzeniem


Na Rys. 4.11 przedstawiono blok oceny poprawności komunikacji z urządzeniem. W odróżnieniu od bloku nawigacyjnego nacisk położono tu na jakość transmisji sygnału sterującego oraz terminowość reakcji systemu. Parametry te są kluczowe z punktu widzenia zdolności do bezpiecznego sterowania AGV w czasie rzeczywistym. Poziom sygnału sterującego pracą AGV stanowi wskaźnik jakości łączności i stabilności transmisji, natomiast zwłoka reakcji na sygnał sterujący [ms] odzwierciedla czas odpowiedzi systemu na otrzymane komendy. Wynik bloku interpretuje się jako syntetyczną miarę niezawodności sterowania oraz reakcji układu komunikacyjnego.




(a) FIS poprawności realizacji komunikacji z urządzeniem



(b) MF poziomu sygnału sterującego pracą AGV



(c) MF zwłoki reakcji na sygnał sterujący



(d) MF wyjściowej poprawności realizacji komunikacji

Rys. 4.11. Blok FIS poprawności realizacji komunikacji z urządzeniem

Źródło: Opracowanie własne

Uzyskane na poziomie 1 oceny częściowe stanowią podstawę dalszego wnioskowania, jednak same w sobie nie są jeszcze wystarczające do podjęcia decyzji dotyczącej utrzymania systemu. Z tego względu na kolejnym poziomie modelu wprowadzono warstwę agregacyjną, której zadaniem jest synteza informacji w szerszym kontekście funkcjonalnym.

4.1.3.2. Poziom 2: agregacja ocen podsystemów do ocen pośrednich

Na poziomie 2 wyniki lokalnej diagnostyki są agregowane do postaci ocen pośrednich, które lepiej odpowiadają logice procesu utrzymaniowego. Oznacza to przejście od parametrów opisujących stan poszczególnych podsystemów do syntetycznych kategorii ryzyka, uwzględniających zarówno stan techniczny, jak i warunki eksploatacji. Przyjęta struktura poziomu 2 nie wynika wyłącznie z założeń formalnych modelu, lecz stanowi bezpośrednie rozwinięcie obszarów zidentyfikowanych na etapie analizy Pareto–Lorenza, co zapewnia spójność pomiędzy procesem selekcji zmiennych a architekturą modelu decyzyjnego.

Formalnie odwzorowania poziomu pośredniego można zapisać jako:

$$Y_k^2 = f_k^2(Y_1^1, Y_2^1, \dots, Y_m^1, Z_k), \quad (4.4)$$

gdzie:

- Y_k^2 oznacza ocenę pośrednią,
- Y_i^1 oznaczają wybrane wyjścia poziomu 1,

- Z_k oznacza dodatkowe wejścia kontekstowe, np. czynniki środowiskowe lub dane historyczne.


Na poziomie 2 wyróżniono cztery komplementarne wymiary oceny:

- 1) ocenę stanu technicznego wózka AGV,
- 2) ocenę systemu komunikacji i nawigacji,
- 3) wpływ czynników środowiska pracy na urządzenie,
- 4) analizę danych historycznych.


Rola tego poziomu jest potrójna. Po pierwsze, ogranicza on liczbę zmiennych przekazywanych do warstwy końcowej. Po drugie, porządkuje informacje diagnostyczne w kategorii zrozumiałe z punktu widzenia praktyki eksploatacyjnej. Po trzecie, umożliwia wspólne przetwarzanie danych technicznych, środowiskowych i organizacyjnych. Wszystkie zmienne poziomu 2 opisano na wspólnej skali 0–10, co zapewnia ich porównywalność i ułatwia spójną agregację w końcowym bloku decyzyjnym.

Przyjęta struktura poziomu 2 pełni zatem rolę pomostu pomiędzy diagnostyką lokalną a decyzją utrzymaniową. Pozwala ona nie tylko ograniczyć złożoność modelu, lecz także nadać procesowi wnioskowania strukturę bliższą rzeczywistemu sposobowi oceny ryzyka eksploatacyjnego. Dzięki temu końcowa decyzja nie wynika z pojedynczych symptomów, lecz z uporządkowanej interpretacji stanu systemu w szerszym kontekście jego pracy.


1) Ocena stanu technicznego wózka AGV




(a) FIS oceny stanu technicznego wózka AGV




(b) MF wyjściowej poprawności funkcjonowania układu przenoszenia ładunku



(c) MF wyjściowej poprawności systemu napędowego



(d) MF wyjściowej poprawności systemu zasilania




(e) MF wyjściowej oceny stanu technicznego wózka AGV


Rys. 4.12. Blok FIS oceny stanu technicznego wózka AGV
Źródło: Opracowanie własne

Na Rys. 4.12 przedstawiono blok oceny stanu technicznego wózka AGV, który agreguje informacje o stanie układu przenoszenia ładunku, układu napędowego oraz systemu zasilania. Z perspektywy funkcjonalnej blok ten estymuje zdolność systemu do realizacji podstawowej funkcji transportowej w zadanych warunkach eksploatacyjnych. Przyjęta logika wnioskowania ma charakter asymetrycznie konserwatywny: degradacja dowolnego podsystemu o wysokim znaczeniu krytycznym powoduje nieliniowe obniżenie oceny globalnej, natomiast poprawny stan pozostałych podsystemów nie kompensuje w pełni obecności pojedynczej awarii krytycznej.


2) Ocena systemu komunikacji i nawigacji




(a) FIS oceny systemu komunikacji i nawigacji



(b) MF wyjściowej poprawności systemu nawigacji



(c) MF wyjściowej poprawności realizacji komunikacji




(d) MF wyjściowej oceny systemu komunikacji i nawigacji


Rys. 4.13. Blok FIS oceny systemu komunikacji i nawigacji
Źródło: Opracowanie własne

Na Rys. 4.13 przedstawiono blok oceny systemu komunikacji i nawigacji, który opisuje operacyjny wymiar funkcjonowania wózka AGV, związany z jego zdolnością do autonomicznego działania w środowisku dynamicznym. W odróżnieniu od oceny stanu technicznego, odnoszącej się do integralności fizycznej systemu, blok ten modeluje niezawodność informacyjną i sterującą, obejmującą poprawność lokalizacji przestrzennej, jakość transmisji sygnałów sterujących oraz zdolność do reakcji w czasie rzeczywistym. Rozdzielenie tego wymiaru od oceny technicznej jest uzasadnione architekturą współczesnych systemów cyber-fizycznych, w których warstwa fizyczna i warstwa informacyjna mogą degradować niezależnie.


3) Wpływ czynników środowiska pracy na urządzenie




(a) FIS wpływu czynników środowiska pracy na urządzenie




(b) MF poziomu zapylenia



(c) MF temperatury otoczenia



(d) MF tarcia powierzchni podłogi




(e) MF wyjściowej wpływu czynników środowiska pracy

Rys. 4.14. Blok FIS wpływu czynników środowiska pracy
Źródło: Opracowanie własne


Na Rys. 4.14 przedstawiono blok wpływu czynników środowiska pracy, który modeluje oddziaływanie otoczenia na proces degradacji oraz stabilność operacyjną

systemu AGV. W odróżnieniu od bloków opisujących stan wewnętrzny systemu, komponent ten reprezentuje czynniki egzogeniczne, które nie są bezpośrednio kontrolowane przez system, a jednocześnie mogą istotnie wpływać na tempo zużycia oraz ryzyko awarii. W efekcie blok ten pełni rolę modyfikatora ryzyka, opisując nie tyle sam stan systemu, ile jego podatność na degradację w aktualnych warunkach pracy.


4) Analiza danych historycznych




(a) FIS analizy danych historycznych



(b) MF realizacji harmonogramu



(c) MF liczby zdarzeń krytycznych



(d) MF wyjściowej analizy danych historycznych

Rys. 4.15. Blok FIS analizy danych historycznych

Źródło: Opracowanie własne

Na Rys. 4.15 przedstawiono blok analizy danych historycznych, który wprowadza do modelu wymiar temporalny. Dzięki temu możliwe jest uwzględnienie długoterminowych wzorców eksploatacyjnych oraz jakości zarządzania utrzymaniem ruchu. W odróżnieniu od pozostałych komponentów, opartych głównie na danych bieżących, ten blok modeluje skumulowane ryzyko operacyjne, definiowane jako prawdopodobieństwo wystąpienia niepożądanych zdarzeń na podstawie historii eksploatacji systemu. W ten sposób analiza stanu technicznego zostaje rozszerzona o aspekt prognostyczny, co stanowi jeden z ważnych elementów podejścia proaktywnego.

4.1.3.3. Poziom 3: końcowa ocena stanu technicznego i decyzja utrzymaniowa

Poziom 3 stanowi nadrzędny moduł integracyjno-decyzyjny modelu. Poziom 1 identyfikuje stan poszczególnych podsystemów, poziom 2 porządkuje te informacje w syntetyczne obszary oceny, natomiast poziom 3 realizuje właściwe wnioskowanie decyzyjne, w którym stan techniczny pojazdu interpretowany jest w pełnym kontekście jego pracy. W sensie formalnym końcowy blok można zapisać jako:


$$Y^3 = f^3(Y_1^2, Y_2^2, Y_3^2, Y_4^2), \quad (4.5)$$

gdzie:


- Y_1^2 – ocena stanu technicznego wózka AGV,
- Y_2^2 – ocena systemu komunikacji i nawigacji,
- Y_3^2 – wpływ czynników środowiska pracy,
- Y_4^2 – analiza danych historycznych.

Końcowa ocena nie jest więc wyłącznie funkcją kondycji fizycznej komponentów, lecz wynika z jednoczesnego uwzględnienia kondycji technicznej podstawowych układów wózka, jakości sterowania, komunikacji i nawigacji, wpływu warunków środowiskowych oraz ryzyka wynikającego z historii eksploatacji i dyscypliny dotyczącej utrzymania systemu.

Na Rys. 4.16 przedstawiono końcowy blok FIS, który integruje cztery zmienne wejściowe reprezentujące odrębne, ale komplementarne wymiary ryzyka eksploatacyjnego. Włączenie ich do jednego bloku decyzyjnego oznacza, że model nie redukuje procesu utrzymaniowego do problemu technicznego w wąskim sensie, lecz traktuje go jako problem systemowy. Jest to szczególnie istotne w środowisku Magazynu 4.0, gdzie funkcjonowanie AGV zależy nie tylko od kondycji mechanicznej pojazdu, ale również od jakości interakcji z infrastrukturą cyfrową, zmienności warunków pracy oraz organizacji procesu eksploatacji.




(a) FIS ostatecznej oceny stanu technicznego wózka AGV



(b) MF wyjściowej oceny stanu technicznego wózka AGV




(c) MF wyjściowej wpływu czynników środowiska pracy na urządzenie



(d) MF wyjściowej oceny systemu komunikacji i nawigacji



(e) MF wyjściowej analizy danych historycznych



(f) MF wyjściowej ostatecznej oceny stanu technicznego wózka AGV

Rys. 4.16. Blok FIS ostatecznej oceny stanu technicznego wózka AGV

Źródło: Opracowanie własne

Zmienne wyjściowe końcowego bloku opisano trzema klasami lingwistycznymi: *Krytyczny*, *Ostrzeżenie* oraz *Akceptowalny*. Kategoria *Krytyczny* odpowiada sytuacjom, w których dalsza eksploatacja pojazdu wiąże się z wysokim ryzykiem uszkodzenia, zakłócenia procesu logistycznego lub utraty bezpieczeństwa pracy i dlatego wymaga natychmiastowej interwencji serwisowej. Kategoria *Ostrzeżenie* opisuje stan pośredni, w którym pojazd może nadal realizować zadania, lecz wykazuje symptomy zwiększonego ryzyka, uzasadniające intensyfikację monitorowania, wykonanie diagnostyki pogłębionej lub zaplanowanie działań prewencyjnych. Kategoria *Akceptowalny* oznacza natomiast stan, w którym nie występują przesłanki do podejmowania dodatkowej interwencji poza standardowym harmonogramem obsługowym. Klasy te nie pełnią wyłącznie funkcji etykiet diagnostycznych, lecz zostały zaprojektowane jako stany decyzyjne, dzięki czemu wynik modelu może być bezpośrednio interpretowany jako rekomendacja dla służb utrzymania ruchu lub operatora systemu zarządzania flotą.

4.1.3.4. Zbiory rozmyte, wnioskowanie i defuzyfikacja

Podstawę mechanizmu wnioskowania stanowi formalizm zbiorów rozmytych zastosowany do opisu wszystkich zmiennych wejściowych i wyjściowych. Formalnie zbiór rozmyty A zdefiniowany w przestrzeni uniwersum X określony jest funkcją przynależności:

$$\mu_A : X \rightarrow 0, 1, \quad (4.6)$$

gdzie wartość $\mu_A x$ oznacza stopień przynależności elementu x do zbioru A .

Zastosowanie zbiorów rozmytych pozwala reprezentować stany pośrednie, co ma szczególne znaczenie w problemach dotyczących utrzymania, gdzie granice pomiędzy stanami eksploatacyjnymi nie są ostre i zależą od kontekstu pracy. W modelu wykorzystano funkcje przynależności trójkątne i trapezowe, które stanowią kompromis pomiędzy prostotą parametryzacji, interpretowalnością i efektywnością obliczeniową.

Ich zastosowanie wynika z wysokiej interpretowalności oraz możliwości bezpośredniego odwzorowania wiedzy eksperckiej wyrażanej w kategoriach lingwistycznych, takich jak wartości niskie, średnie i wysokie, przy zachowaniu jednoznacznych granic pomiędzy tymi stanami. Dodatkowo funkcje te charakteryzują się niską złożonością

obliczeniową w porównaniu z funkcjami gładkimi, takimi jak funkcje Gaussa, co ma znaczenie w kontekście skalowalności modelu oraz jego potencjalnej implementacji w środowisku przemysłowym. Przyjęte rozwiązanie uznano za wystarczające do odwzorowania zależności nieliniowych występujących w analizowanym problemie, bez wprowadzania nadmiernej złożoności strukturalnej.

Funkcja trapezowa została zdefiniowana jako:

$$\mu_{Ax}; a, b, c, d = \begin{cases} 0, & x \leq a, \\ \frac{x-a}{b-a}, & a < x \leq b, \\ 1, & b < x \leq c, \\ \frac{d-x}{d-c}, & c < x \leq d, \\ 0, & x > d, \end{cases} \quad (4.7)$$

Parametry funkcji przynależności dobrano na podstawie charakterystyki fizycznej analizowanych wielkości oraz wyników analizy Pareto–Lorenza, która umożliwiła identyfikację kluczowych parametrów wejściowych modelu. Oznacza to, że proces selekcji zmiennych i ich późniejsza formalizacja w postaci zbiorów rozmytych stanowią dwa powiązane etapy konstrukcji modelu. Dobór liczby i kształtu funkcji przynależności wynikał z konieczności zapewnienia odpowiedniej zdolności rozróżniania stanów eksploatacyjnych przy zachowaniu interpretowalności modelu.

Zdefiniowane w ten sposób zbiory rozmyte stanowią podstawę dalszego procesu wnioskowania, umożliwiając formułowanie reguł typu IF–THEN, które odwzorowują zależności pomiędzy zmiennymi wejściowymi a decyzją utrzymaniową. W konsekwencji możliwe jest przejście od reprezentacji danych w postaci lingwistycznej do właściwego mechanizmu inferencyjnego modelu.

Pierwszym etapem działania systemu jest fuzyfikacja, czyli odwzorowanie wartości ostrych zmiennych wejściowych na stopnie przynależności do zbiorów rozmytych:

$$\mu_{A_{ik}}x_i \in [0, 1]. \quad (4.8)$$

Rdzeń modelu stanowi baza reguł typu IF–THEN:

$$R_r : \text{Jeżeli } x_1 \text{ jest } A_1^r \wedge \dots \wedge x_n \text{ jest } A_n^r, \text{ to } y \text{ jest } B^r. \quad (4.9)$$

Stopień aktywacji reguły wyznaczono za pomocą operatora minimum:

$$\alpha_r = \min \{ \mu_{A_1^r}x_1, \dots, \mu_{A_n^r}x_n \}. \quad (4.10)$$

Implikacja realizowana jest poprzez przycięcie funkcji przynależności:

$$\mu_{B_r'}y = \min \{ \alpha_r, \mu_{B^r}y \}, \quad (4.11)$$

natomiast agregacja wyników wszystkich reguł odbywa się z wykorzystaniem operatora maksimum:

$$\mu_{B_{agg}}y = \max_r \{ \mu_{B_r'}y \}. \quad (4.12)$$

W ostatnim etapie zastosowano metodę środka ciężkości:

$$y^* = \frac{\Omega y \mu_{B_{agg}} y dy}{\Omega \mu_{B_{agg}} y dy}. \quad (4.13)$$

Metoda ta zapewnia ciągłość odpowiedzi modelu oraz wysoką reprezentatywność wyniku, co ma istotne znaczenie w kontekście podejmowania decyzji dotyczących utrzymania. W rezultacie odpowiedź końcowa odzwierciedla stopniowe przejścia pomiędzy stanami eksploatacyjnymi, zamiast sztucznie narzuconych progów decyzyjnych.

4.1.3.5. Formalizacja bazy reguł końcowego bloku decyzyjnego

Baza reguł rozmytych stanowi kluczowy element modelu, odpowiadający za odwzorowanie relacji pomiędzy poszczególnymi wymiarami oceny oraz generowanie końcowej decyzji dotyczącej utrzymania systemu. W opracowanym systemie zdefiniowano łącznie 54 reguły rozmyte, które opisują istotne konfiguracje stanów wejściowych i przypisują im odpowiednie klasy wyjściowe. Struktura bazy reguł wynika bezpośrednio z liczby zmiennych wejściowych oraz przyjętej granularności podziału przestrzeni lingwistycznej. Jednocześnie, w celu ograniczenia złożoności modelu, uwzględniono wyłącznie przypadki mające rzeczywiste znaczenie eksploatacyjne, co pozwoliło zachować równowagę pomiędzy kompletnością odwzorowania a przejrzystością i użytecznością praktyczną systemu.

W sensie symbolicznym bazę reguł końcowego bloku można zapisać jako:

$$R_r : \text{Jeżeli } Y_1^2 \text{ jest } A_1^r \wedge Y_2^2 \text{ jest } A_2^r \wedge Y_3^2 \text{ jest } A_3^r \wedge Y_4^2 \text{ jest } A_4^r, \text{ to } Y^3 \text{ jest } B^r. \quad (4.14)$$

Baza reguł została skonstruowana zgodnie z trzema zasadami organizującymi proces wnioskowania:

- 1) **zasadą dominacji ryzyka krytycznego** – obecność jednego lub kilku silnie niekorzystnych czynników może determinować decyzję końcową niezależnie od poprawności pozostałych obszarów,
- 2) **zasadą kumulacji ryzyka umiarkowanego** – współwystępowanie kilku stanów pośrednich może prowadzić do decyzji ostrzegawczej mimo braku pojedynczego symptomu krytycznego,
- 3) **zasadą zgodności pozytywnej** – decyzja optymalna wymaga równoczesnej poprawności podstawowych wymiarów oceny i braku istotnych sygnałów ryzyka kontekstowego.

Dla ilustracji logiki modelu przykładową regułę krytyczną można zapisać następująco:

$$R_1 : \begin{aligned} &\text{Jeżeli Ocena stanu technicznego AGV jest Alarmująca} \wedge \\ &\quad \text{Wpływ czynników środowiska jest Krytyczny} \wedge \\ &\quad \text{Ocena systemu komunikacji i nawigacji jest Nieakceptowalna} \wedge \\ &\quad \text{Analiza danych historycznych jest Znacząca} \\ &\text{to Ostateczna ocena stanu technicznego AGV jest Krytyczna.} \end{aligned} \quad (4.15)$$

Analogicznie regułę ostrzegawczą można zapisać jako:

$$\begin{aligned}
 R_{41} : & \text{Jeżeli Ocena stanu technicznego AGV jest Średnia} \wedge \\
 & \text{Wpływ czynników środowiska jest Istotny} \wedge \\
 & \text{Ocena systemu komunikacji i nawigacji jest Wymagająca uwagi} \wedge \quad (4.16) \\
 & \text{Analiza danych historycznych jest Nieistotna} \\
 & \text{to Ostateczna ocena stanu technicznego AGV jest Ostrzeżeniem.}
 \end{aligned}$$

Natomiast regułę korzystną można zapisać w postaci:

$$\begin{aligned}
 R_{54} : & \text{Jeżeli Ocena stanu technicznego AGV jest Bez uwag} \wedge \\
 & \text{Wpływ czynników środowiska jest Pomijalny} \wedge \\
 & \text{Ocena systemu komunikacji i nawigacji jest Wysoka} \wedge \quad (4.17) \\
 & \text{Analiza danych historycznych jest Nieistotna} \\
 & \text{to Ostateczna ocena stanu technicznego AGV jest Optymalna.}
 \end{aligned}$$

Ze względu na objętość pełnej bazy reguł, w treści rozprawy przedstawiono jedynie reguły reprezentatywne dla trzech poziomów decyzji, natomiast kompletny zestaw zamieszczono w Aneksie A.

Tab. 4.4. Wybrane reguły rozmyte (reprezentatywne) w końcowym systemie FIS

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
1	Ocena stanu technicznego wózka AGV = <i>Alarmujący</i> Wpływ czynników środowiska pracy = <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji = <i>Nieakceptowalna</i> Analiza danych historycznych = <i>Znaczący</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Krytyczny</i>
2	Ocena stanu technicznego wózka AGV = <i>Średni</i> Wpływ czynników środowiska pracy = <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji = <i>Nieakceptowalna</i> Analiza danych historycznych = <i>Znaczący</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Krytyczny</i>
3	Ocena stanu technicznego wózka AGV = <i>Bez uwag</i> Wpływ czynników środowiska pracy = <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji = <i>Nieakceptowalna</i> Analiza danych historycznych = <i>Znaczący</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Krytyczny</i>
41	Ocena stanu technicznego wózka AGV = <i>Średni</i> Wpływ czynników środowiska pracy = <i>Istotny</i> Ocena systemu komunikacji i nawigacji = <i>Wymagająca uwagi</i> Analiza danych historycznych = <i>Nieistotny</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Ostrzeżenie</i>
42	Ocena stanu technicznego wózka AGV = <i>Bez uwag</i> Wpływ czynników środowiska pracy = <i>Istotny</i> Ocena systemu komunikacji i nawigacji = <i>Wymagająca uwagi</i> Analiza danych historycznych = <i>Nieistotny</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Ostrzeżenie</i>

Kontynuacja na następnej stronie

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
53	Ocena stanu technicznego wózka AGV = <i>Średni</i> Wpływ czynników środowiska pracy = <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji = <i>Wysoka</i> Analiza danych historycznych = <i>Nieistotny</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Akceptowalny</i>
54	Ocena stanu technicznego wózka AGV = <i>Bez uwag</i> Wpływ czynników środowiska pracy = <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji = <i>Wysoka</i> Analiza danych historycznych = <i>Nieistotny</i>	Ostateczna ocena stanu technicznego wózka AGV = <i>Akceptowalny</i>

Źródło: Opracowanie własne.

Przedstawione reguły reprezentatywne dobrze ilustrują sposób działania modelu. Reguły 1–3 pokazują sytuacje, w których decyzja *Krytyczny* nie zależy wyłącznie od oceny technicznej pojazdu, lecz wynika z dominującego wpływu czynników środowiskowych, niskiej jakości komunikacji i nawigacji oraz niekorzystnego profilu historycznego. Szczególnie wymowna jest reguła 3, w której nawet stan techniczny określony jako *Bez uwag* nie prowadzi do pozytywnej oceny końcowej, jeżeli pozostałe wymiary ryzyka pozostają nieakceptowalne. Oznacza to, że model nie utożsamia sprawności komponentowej z gotowością operacyjną, lecz rozróżnia stan techniczny od rzeczywistej zdolności bezpiecznego wykonywania zadań.

Reguły 41–42 reprezentują logikę decyzji pośrednich. W obu przypadkach brak jest jednoznacznych przesłanek do natychmiastowego wyłączenia pojazdu z eksploatacji, jednak współwystępowanie czynników o umiarkowanym nasileniu prowadzi do klasyfikacji *Ostrzeżenie*. Z perspektywy podejścia proaktywnego ma to istotne znaczenie, ponieważ decyzja ta inicjuje działania uprzedzające wystąpienie stanu krytycznego.

Reguły 53–54 pokazują z kolei warunki, w których możliwe jest utrzymanie stanu *Akceptowalny*. W obu przypadkach warunkiem koniecznym jest brak istotnych obciążeń środowiskowych, poprawne funkcjonowanie komunikacji i nawigacji oraz brak negatywnych sygnałów historycznych. Warto zauważyć, że model dopuszcza decyzję *Akceptowalny* także dla stanu technicznego określonego jako *Średni*, pod warunkiem że pozostałe obszary nie wskazują na wzmożone ryzyko. Rozwiązanie to odzwierciedla realistyczny charakter eksploatacji przemysłowej, w której nie każda umiarkowana degradacja musi skutkować natychmiastową interwencją.

Przedstawiona architektura oraz formalizacja matematyczna modelu tworzą spójny fundament jego implementacji obliczeniowej oraz dalszej weryfikacji eksperymentalnej. Kolejnym etapem było zatem odwzorowanie przyjętych założeń w środowisku MATLAB, co umożliwiło praktyczną ocenę poprawności działania systemu oraz analizę jego właściwości decyzyjnych.

4.1.4. Implementacja modelu FPMDF w środowisku MATLAB

Opracowany model zaimplementowano w środowisku MATLAB z wykorzystaniem pakietu *Fuzzy Logic Toolbox*, w szczególności modułu *Fuzzy Logic Designer*. Wybór tego środowiska wynikał z jego przydatności zarówno na etapie implementacji modelu decyzyjnego, jak i podczas jego strojenia, wizualizacji oraz weryfikacji numerycznej. MATLAB zapewnia rozbudowane wsparcie dla budowy systemów wnioskowania typu Mamdaniego, obejmujące definiowanie zmiennych wejściowych i wyjściowych,

parametryzację funkcji przynależności, konstrukcję baz reguł oraz realizację procedur wnioskowania i defuzyfikacji. Równocześnie umożliwia przejrzystą wizualizację przebiegu funkcji przynależności, aktywacji reguł oraz zależności pomiędzy zmianami parametrów wejściowych a odpowiedzią modelu, co ma istotne znaczenie z punktu widzenia kontroli poprawności konstrukcji systemu.

Implementacja modelu miała charakter etapowy i była podporządkowana przyjętej strukturze procesu decyzyjnego. W pierwszej kolejności zdefiniowano zmienne wejściowe i wyjściowe dla każdego bloku FIS, odpowiadające zarówno poziomowi lokalnemu, jak i poziomom agregacji pośredniej oraz końcowej. Następnie określono zakresy uniwersum poszczególnych zmiennych i sparametryzowano odpowiadające im funkcje przynależności. Na tej podstawie skonstruowano bazy reguł dla wszystkich bloków poziomu 1, 2 i 3, a także określono operatory logiczne, metodę agregacji oraz procedurę defuzyfikacji zgodnie z założeniami formalnymi przyjętymi w modelu. Ostatni etap obejmował testowanie odpowiedzi systemu dla wybranych scenariuszy wejściowych oraz ocenę spójności jego zachowania w różnych konfiguracjach parametrów.

Od strony technicznej środowisko MATLAB umożliwiło wizualną kontrolę poprawności rozmieszczenia funkcji przynależności, analizę aktywacji reguł dla zadanych punktów pracy oraz obserwację wpływu zmian parametrów wejściowych na wartość wyjściową poszczególnych bloków. W praktyce umożliwiło to również analizę scenariuszową modelu oraz ocenę wrażliwości odpowiedzi na zmiany wybranych parametrów wejściowych. Miało to szczególne znaczenie w procesie iteracyjnego strojenia modelu, ponieważ pozwalało identyfikować przypadki nadmiernego nakładania się zbiorów rozmytych, zbyt ostrych przejść pomiędzy klasami lingwistycznymi oraz niepożądanych efektów wynikających z konstrukcji bazy reguł. Dzięki temu implementacja nie ograniczała się do technicznego odwzorowania zaproponowanej architektury, lecz stanowiła również narzędzie jej systematycznej kontroli i doprecyzowania.

Istotną zaletą wykorzystania *Fuzzy Logic Designer* było to, że struktura modelu mogła zostać odwzorowana zgodnie z przyjętą logiką dekompozycji problemu badawczego. Poszczególne bloki FIS projektowano oddzielnie na poziomie lokalnym, a następnie integrowano na poziomach wyższych, zachowując spójność semantyczną pomiędzy ocenami cząstkowymi, pośrednimi i końcowymi. Takie podejście odpowiadało architekturze przedstawionej we wcześniejszej części rozdziału i umożliwiło bezpośrednie przełożenie założeń koncepcyjnych oraz formalizacji matematycznej na działający model obliczeniowy.

W sensie badawczym implementacja modelu FPMDF w środowisku MATLAB nie stanowiła jedynie etapu technicznego, lecz integralny element procesu jego opracowania i oceny. Umożliwiła przełożenie założeń koncepcyjnych oraz formalizacji matematycznej na działający model obliczeniowy, a następnie ocenę poprawności przyjętych rozwiązań projektowych. Dzięki implementacji możliwe było sprawdzenie, czy zdefiniowane funkcje przynależności, baza reguł rozmytych oraz przyjęty mechanizm wnioskowania prowadzą do generowania spójnych, interpretowalnych i użytecznych rekomendacji utrzymaniowych.

Opracowana implementacja stworzyła również środowisko umożliwiające przeprowadzenie eksperymentów obliczeniowych, analizę zachowania frameworku w różnych scenariuszach eksploatacyjnych oraz realizację procedur weryfikacji i

walidacji. Tym samym stanowi ona podstawę dalszej oceny poprawności, stabilności oraz przydatności praktycznej opracowanego modelu decyzyjnego.

4.2. Weryfikacja i ewaluacja modelu

Celem weryfikacji i ewaluacji zaproponowanego modelu rozmytego wspierającego proaktywne utrzymanie ruchu flot AGV jest potwierdzenie poprawności formalnej konstrukcji systemu wnioskowania, jego spójności logicznej oraz użyteczności wdrożeniowej w warunkach niepewności i zmienności danych eksploatacyjnych. Zastosowanie logiki rozmytej umożliwia przetwarzanie informacji nieprecyzyjnych poprzez wykorzystanie zmiennych lingwistycznych oraz stopni przynależności, co jest zgodne ze specyfiką środowiska przemysłowego, w którym obserwuje się zakłócenia pomiarowe, niepełność danych oraz zmienność profilu obciążenia floty.

Proces oceny modelu podzielono na trzy etapy: weryfikację, walidację oraz ewaluację. Weryfikacja odnosi się do poprawności strukturalnej i logicznej systemu wnioskowania, walidacja dotyczy zgodności decyzji modelu z oceną ekspercką oraz wynikami empirycznymi, natomiast ewaluacja określa wpływ zastosowania podejścia proaktywnego (wspieranego przez model) na wskaźniki efektywności utrzymania ruchu w ujęciu operacyjnym.

4.2.1. Weryfikacja formalna i logiczna modelu

Weryfikację formalną przeprowadzono w odniesieniu do opracowanego struktury modelu rozmytego, w której oceny częściowe wyznaczane są na poziomie podsystemów, a następnie agregowane do postaci pojedynczej oceny końcowej. Na etapie weryfikacji sprawdzono kompletność definicji zmiennych wejściowych i wyjściowych, poprawność funkcji przynależności, spójność bazy reguł z logiką degradacji technicznej oraz interpretowalność decyzji w kontekście utrzymania ruchu.

Pierwszy etap obejmował ocenę pokrycia dziedzin przez funkcje przynależności. Zweryfikowano, czy dla każdego wejścia i wyjścia zdefiniowano zbiory lingwistyczne w sposób zapewniający aktywację w całym zakresie zmienności, tj. bez obszarów, w których stopień przynależności jest równy zero dla wszystkich zbiorów jednocześnie. Ocenie poddano również spójność semantyczną zbiorów lingwistycznych, w tym zachowanie naturalnej kolejności interpretacyjnej (np. „niski–średni–wysoki”) oraz adekwatność kształtu funkcji przynależności do charakteru analizowanych zjawisk eksploatacyjnych.

Drugi etap weryfikacji dotyczył bazy reguł rozmytych. Przeprowadzono analizę sprzeczności reguł rozumianych jako przypadki prowadzące do przeciwstawnych konsekwencji decyzyjnych przy identycznych przesłankach, a także ocenę redundancji reguł, które nie zwiększają zdolności poznawczej modelu. Sprawdzono kompletność wnioskowania poprzez ocenę aktywowalności reguł w scenariuszach typowych, skrajnych oraz mieszanych, w których degradacja dotyczy więcej niż jednego obszaru funkcjonowania wózka AGV.

Kolejny etap weryfikacji obejmował formalną poprawność procesu inferencji. Dla przesłanek reguł zawierających operator koniunkcji AND przyjęto klasyczną realizację opartą o T-normę typu minimum, zgodnie z zależnością (4.18) [97–99]:

$$\mu_{A \wedge B} x = \min(\mu_A x, \mu_B x), \quad (4.18)$$

gdzie μ_{Ax} oraz μ_{Bx} oznaczają stopnie przynależności do zbiorów rozmytych w części przesłankowej.

Wynik wnioskowania w postaci zbioru rozmytego przekształcono do wartości ostrej metodą środka ciężkości (ang. *centroid*) (4.19) [98, 100]:

$$S^* = \frac{s \cdot \mu_{agg}s \, ds}{\mu_{agg}s \, ds}, \quad (4.19)$$

gdzie S^* jest wartością ostrą wykorzystywaną w decyzji dotyczącej utrzymania systemu, natomiast $\mu_{agg}s$ oznacza funkcję przynależności zagregowanego zbioru wyjściowego.

Weryfikację uzupełniono testami brzegowymi i kontrolą monotoniczności odpowiedzi modelu. Założono, że pogorszenie wartości wejściowych odpowiadających degradacji podsystemów nie może prowadzić do poprawy wyniku końcowego, a przejścia między klasami stanu powinny zachodzić w sposób logiczny i interpretowalny. Naruszenia monotoniczności oceniono za pomocą wskaźnika (4.20) [101–103]:

$$V\% = \frac{N_{impr}}{N_{pair}} \cdot 100\%, \quad (4.20)$$

gdzie N_{pair} oznacza liczbę porównań parami, a N_{impr} liczbę przypadków niepożądanego poprawy wyniku przy pogorszeniu wejścia.

Jednocześnie stabilność decyzji względem niewielkich odchyłeń danych wejściowych oceniono poprzez wskaźnik stabilności klasyfikacji (4.21) [104, 105]:

$$SI\% = \frac{N_{stable}}{N_{pert}} \cdot 100\%, \quad (4.21)$$

gdzie N_{pert} oznacza liczbę przypadków zaburzonych, a N_{stable} liczbę przypadków, dla których klasa decyzji nie uległa zmianie. Wyniki zestawiono w Tab. 4.5.

Tab. 4.5. Wyniki weryfikacji formalno-logicznej modelu rozmytego

Obszar weryfikacji	Kryterium	Wskaźnik/miara	Wynik	Interpretacja
Pokrycie dziedzin MF	brak "luk" aktywacji	udział pokrycia [%]	100.00	pełna aktywowalność reguł
Spójność semantyczna	poprawna kolejność zbiorów	liczba odchyłeń	0	zachowana interpretowalność
Sprzeczność reguł	przeciwnie konsekwencje	liczba sprzeczności	0	brak konfliktów logicznych
Monotoniczność	brak poprawy przy pogorszeniu	V_M [%]	0.60	pojedyncze przypadki brzegowe
Stabilność decyzji	odporność na zakłócenia	SI [%]	92.78	stabilność wysoka, lecz niepełna

Źródło: Opracowanie własne.

Tab. 4.5 zestawia wyniki weryfikacji formalno-logicznej modelu rozmytego, obejmującej kompletność definicji funkcji przynależności, spójność semantyczną zbiorów oraz stabilność wnioskowania. Pełne pokrycie dziedzin wejść i wyjścia (100.00%) oraz brak sprzeczności reguł wskazują, że model posiada poprawnie zdefiniowaną strukturę i nie generuje konfliktowych konsekwencji przy identycznych przesłankach. Niewielki udział naruszeń monotoniczności ($V_M = 60\%$) należy interpretować jako efekt granicznych obszarów przejściowych między klasami lingwistycznymi, typowy dla systemów rozmytych o wysokiej czułości. Uzyskany wskaźnik stabilności decyzji ($SI = 92.78\%$) potwierdza odporność modelu na niewielkie perturbacje danych wejściowych, przy jednoczesnym wskazaniu, że największa wrażliwość występuje w pobliżu progów decyzyjnych, co stanowi przesłankę do ewentualnego strojenia lokalnego funkcji przynależności.

4.2.2. Walidacja modelu: scenariusze eksperckie, zgodność i miary jakości

Walidację modelu przeprowadzono w trybie scenariuszowym, porównując decyzję modelu z klasą referencyjną ustaloną przez panel ekspertów obejmujący 20 specjalistów utrzymania ruchu oraz inżynierii procesu posiadających doświadczenie w eksploatacji i serwisowaniu systemów AGV w środowisku produkcyjnym. Ekspertci posiadali co najmniej pięcioletnie doświadczenie zawodowe w obszarach diagnostyki, planowania działań utrzymaniowych, obsługi uszkodzeń oraz analizy danych eksploatacyjnych. W scenariuszach walidacyjnych określono wartości czterech wejść modelu końcowego, które odpowiadają następującym zagregowanym ocenom:

- 1) ocena stanu technicznego wózka AGV;
- 2) ocena wpływu środowiska pracy;
- 3) ocena systemu komunikacji;
- 4) ocena wpływu danych historycznych.

Jednocześnie kluczowe znaczenie ma fakt, że wejścia modelu końcowego nie są danymi surowymi w jednostkach fizycznych, lecz wartościami oceny uzyskanymi na wcześniejszych etapach modelu poprzez normalizację zmiennych pierwotnych. Zgodnie z definicją funkcji przynależności przedstawionych dla modelu końcowego (Rys. 4.16b - 4.16e), domeny wszystkich czterech wejść zostały wystandaryzowane do wspólnego zakresu (0,10). Analogicznie zmienna wyjściowa „Ostateczna ocena stanu technicznego wózka AGV” została zdefiniowana w zakresie (0,10) (Rys. 4.16f), co zapewnia spójność semantyczną całego systemu oraz jednoznaczną interpretację wyników. Tym samym skala (0,10) dotyczy poziomu wnioskowania rozmytego (ocen), natomiast dane eksploatacyjne stanowiące podstawę tych ocen mogą występować w skalach naturalnych (czas, liczba zdarzeń, koszty).

W przypadku, gdy oceny wejściowe nie pochodzą bezpośrednio z podsystemów rozmytych, stosuje się normalizację typu min-max do zakresu 0, 10:

$$x_{\text{norm}} = 10 \cdot \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (4.22)$$

natomiast dla zmiennych o charakterze “im mniej tym lepiej” (np. czas przestojów) stosuje się postać odwróconą:

$$x_{\text{norm}} = 10 \cdot \left(1 - \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right), \quad (4.23)$$

przy czym wartości można ograniczać do przedziału 0, 10 w celu uniknięcia efektów brzegowych dla danych odstających.

Decyzję klasyfikacyjną przypisano zgodnie z zasadą wyboru klasy o największym stopniu przynależności w zbiorach wyjściowych:

$$\text{Klasa } S^* = \arg \max_{k \in \{\text{KRYTYCZNY, OSTRZEŻENIE, AKCEPTOWALNY}\}} \mu_k S^*, \quad (4.24)$$

gdzie $\mu_k S^*$ oznacza stopień przynależności wartości S^* do zbioru wyjściowego klasy k . Wyniki walidacji scenariuszowej zestawiono w Tab. 4.6.

Tab. 4.6. Wyniki walidacji scenariuszowej – porównanie decyzji modelu z oceną ekspercką

ID scen.	Ocena stanu techn.	Ocena wpływu środ.	Ocena syst. komunik.	Ocena wpływu danych hist.	Ocena (klasa) eksperta	S^* (model)	Ocena (klasa) modelu	Zgodność	Interpretacja scenariusza
S01	9.0	9.0	9.0	9.0	AKCEPTOWALNY	9.13	AKCEPTOWALNY	1	Przypadek referencyjny: wszystkie obszary ocenione jako bardzo dobre, brak przesłanek do interwencji dotyczącej utrzymania systemu.
S02	8.0	8.0	8.0	3.0	OSTRZEŻENIE	6.17	OSTRZEŻENIE	1	Przypadek przewencyjny: poprawny stan bieżący przy obniżonej ocenie historycznej (ryzyko nawrotowości usterek).
S03	8.0	8.0	2.0	8.0	OSTRZEŻENIE	5.06	OSTRZEŻENIE	1	Pogorszenie komunikacji stanowej przy wysokim stanie technicznym (ryzyko operacyjne bez degradacji mechanicznej).
S04	8.5	2.5	8.0	8.0	OSTRZEŻENIE	5.28	OSTRZEŻENIE	1	Obniżony wpływ środowiska pracy przy stabilnych pozostałych obszarach (wrażliwość modelu na prowadzenie).
S05	2.0	8.0	8.0	8.0	KRYTYCZNY	2.07	KRYTYCZNY	1	Dominacja czynnika technicznego: niski stan techniczny wymusza decyzję krytyczną mimo poprawnych parametrów wspierających.
S06	1.0	1.0	1.0	1.0	KRYTYCZNY	0.96	KRYTYCZNY	1	Stan skrajnie zdegradowany: jednoczesne obniżenie wszystkich ocen wejściowych (przypadek brzegowy walidacji).
S07	5.0	5.0	5.0	5.0	OSTRZEŻENIE	5.02	OSTRZEŻENIE	1	Przypadek przejściowy: równomierne wartości średnie, brak dominującego czynnika krytycznego (stan monitorowany).
S08	8.0	2.0	2.0	7.0	KRYTYCZNY	3.11	KRYTYCZNY	1	Przypadek konfliktowy: wysoki stan techniczny, lecz niska jakość prowadzenia i komunikacji (priorytet bezpieczeństwa).
S09	2.5	7.5	7.5	7.5	KRYTYCZNY	2.76	KRYTYCZNY	1	Degradacja techniczna mimo poprawnych ocen pozostałych podsystemów (weryfikacja priorytetu stanu technicznego).
S10	5.5	6.5	6.5	1.5	OSTRZEŻENIE	4.57	OSTRZEŻENIE	1	Obniżona ocena historyczna przy umiarkowanym stanie bieżącym (sygnał ryzyka trendu degradacji).
S11	8.5	8.0	6.0	8.0	AKCEPTOWALNY	7.38	AKCEPTOWALNY	1	Stan bliski optymalnemu z umiarkowanym pogorszeniem komunikacji (test granicy AKCEPTOWALNY–OSTRZEŻENIE).
S12	7.0	3.5	7.0	7.0	OSTRZEŻENIE	5.63	OSTRZEŻENIE	1	Umiarkowany wpływ środowiska pracy przy stabilnych pozostałych wejściach (decyzja ostrzegawcza).
S13	8.0	8.0	0.5	8.0	KRYTYCZNY	1.44	KRYTYCZNY	1	Krytyczny deficyt komunikacji stanowej przy dobrym stanie technicznym (warunek wymuszający stan krytyczny).
S14	3.0	7.0	7.0	2.5	KRYTYCZNY	2.47	KRYTYCZNY	1	Jednoczesna degradacja stanu technicznego oraz niekorzystna historia (wzmocniona decyzja krytyczna).

Kontynuacja na następnej stronie

Tabela 4.6 – kontynuacja z poprzedniej strony

ID scen.	Ocena stanu techn.	Ocena wpływu środ.	Ocena syst. komunik.	Ocena wpływu danych hist.	Ocena (klasa) eksperta	S^* (model)	Ocena (klasa) modelu	Zgodność	Interpretacja scenariusza
S15	8.0	5.0	5.0	5.0	OSTRZEŻENIE	7.08	AKCEPTOWALNY	0	Przypadek graniczny: wysoka ocena stanu technicznego przy średnich ocenach pozostałych obszarów (obszar niejednoznaczny decyzyjnie).
S16	4.0	4.0	4.0	4.0	OSTRZEŻENIE	4.12	OSTRZEŻENIE	1	Równomierne obniżenie ocen w całym profilu (ryzyko systemowe bez jednego dominującego czynnika).
S17	8.0	1.5	8.0	8.0	KRYTYCZNY	3.26	KRYTYCZNY	1	Krytyczne pogorszenie warunków środowiska pracy przy dobrych pozostałych ocenach (priorytet ciągłości sterowania).
S18	8.0	8.0	8.0	0.5	OSTRZEŻENIE	4.18	OSTRZEŻENIE	1	Stan bieżący poprawny, natomiast historia skrajnie niekorzystna (uzasadnienie decyzji prewencyjnej).

Źródło: Opracowanie własne.

Tab. 4.6 przedstawia wyniki walidacji scenariuszowej modelu rozmytego, w której dla każdego scenariusza porównano decyzję systemu wnioskowania z klasą referencyjną ustaloną przez ekspertów utrzymania ruchu. Każdy wiersz tabeli odpowiada jednemu, zdefiniowanemu przypadkowi operacyjnemu (S01–S18), opisanemu przez cztery zagregowane oceny wejściowe modelu końcowego. Należy podkreślić, że wartości te nie są danymi surowymi w jednostkach fizycznych, lecz wartościami oceny uzyskanymi na wcześniejszych etapach modelu i wprowadzonymi na poziom modelu końcowego w ujednoliconej domenie liczbowej.

Zgodnie z definicją funkcji przynależności modelu końcowego, wszystkie cztery wejścia zostały wystandaryzowane do wspólnego zakresu 0–10, analogicznie jak zmienna wyjściowa „Ostateczna ocena stanu technicznego wózka AGV”, co zapewnia spójność semantyczną całego systemu oraz jednoznaczność interpretacji wyniku. W praktyce konstrukcyjnej modelu przyjęto, że oceny wejściowe mogą pochodzić bezpośrednio z podsystemów rozmytych (jako wyniki częściowych kalkulacji), natomiast w sytuacji, gdy wejście jest wyznaczane z danych eksploatacyjnych lub pomiarowych poza strukturą rozmytą, stosowana jest normalizacja do zakresu 0–10.

W tym celu wykorzystuje się normalizację typu min–max, a dla zmiennych o charakterze „im mniej, tym lepiej” (np. wielkości związane z przestojami lub intensywnością negatywnych zdarzeń) – wariant odwrócony. Wartości mogą być dodatkowo ograniczane do przedziału 0–10 w celu uniknięcia efektów brzegowych generowanych przez obserwacje odstające. W rezultacie liczby przedstawione w kolumnach 2–5 tabeli należy interpretować jako porównywalne, bezwymiarowe oceny: wartości bliskie 10 oznaczają stan bardzo dobry w danym obszarze, natomiast wartości niskie – istotną degradację lub podwyższone ryzyko operacyjne. Jednocześnie taka konstrukcja wejść umożliwia sytuowanie scenariuszy zarówno w obszarach jednoznacznych (skrajnie dobrych lub skrajnie złych), jak i w obszarach konfliktowych, gdzie wysoka ocena jednego podsystemu współwystępuje z degradacją innego, istotnego z punktu widzenia bezpieczeństwa i ciągłości pracy.

Kolumna „Ocena (klasa) eksperta” stanowi klasę referencyjną przyjętą do walidacji i odpowiada decyzji ustalonej przez panel ekspertów utrzymania ruchu na podstawie przesłanek diagnostycznych oraz interpretacji ryzyka eksploatacyjnego w kontekście floty AGV. W badaniu przyjęto procedurę oceny eksperckiej opartą na konsensusie. Każdy scenariusz był oceniany niezależnie przez członków panelu eksperckiego, a w przypadku rozbieżności ocen przyjmowano rozwiązanie konsensualne, polegające na dyskusji ukierunkowanej na interpretację ryzyka oraz konsekwencji operacyjnych. Jeżeli osiągnięcie konsensusu nie było możliwe w pierwszym kroku, stosowano regułę większościową jako ostateczny sposób wyznaczenia klasy referencyjnej. Tak zdefiniowana klasa ekspercka pełni rolę tzw. „złotego standardu” porównania, zgodnego z praktyką wdrożeniową, w której decyzje utrzymaniowe pozostają formalnie przypisane personelowi, a model ma charakter wspierający.

Kolumna „ S^* (model)” zawiera wartość ostrą (liczbową) będącą wynikiem działania modelu rozmytego dla danego wektora wejściowego $x_1^m, x_2^m, x_3^m, x_4^m$ przypisanego scenariuszowi. Wartość ta jest wyznaczana w wyniku pełnego procesu inferencji rozmytej, zaprezentowanego na Rys. 4.16f. W modelu przyjęto klasyczną realizację koniunkcji AND z wykorzystaniem T -normy typu minimum, natomiast przejście od zbioru rozmytego do wartości ostrej zrealizowano metodą środka ciężkości

(centroid). Z tego względu wartości S^* (model) mają charakter ciągły (np. 5.06, 7.38, 2.47) i zachowują informację o poziomie oceny wewnątrz danej klasy, co jest istotne z punktu widzenia eksploatacji, ponieważ pozwala odróżnić przypadki stabilne od granicznych, mimo przypisania tej samej etykiety decyzyjnej.

Kolumna „Ocena (klasa) modelu” stanowi wynik przypisania decyzji dyskretnej na podstawie wartości S^* (model) w odniesieniu do zdefiniowanych zbiorów wyjściowych (np. KRYTYCZNY, OSTRZEŻENIE, AKCEPTOWALNY). Przypisanie klasy zrealizowano zgodnie z regułą wyboru etykiety o największym stopniu przynależności, tzn. wskazywana jest ta kategoria, dla której stopień przynależności wartości S^* do odpowiedniego zbioru wyjściowego osiąga maksimum.

W konsekwencji w Tab. 4.6 mogą występować sytuacje, w których wartości S^* (model) znajdują się w pobliżu granicy pomiędzy klasami, co może skutkować odmiennym przypisaniem etykiety decyzyjnej niż w przypadku klasyfikacji eksperckiej, szczególnie w scenariuszach przejściowych. Przykładowo, przypadki charakteryzujące się wysoką oceną stanu technicznego przy jednocześnie średnich ocenach pozostałych komponentów mogą generować wynik liczbowy zbliżony do progu rozdzielającego klasy AKCEPTOWALNY oraz OSTRZEŻENIE. Zjawisko to należy interpretować jako typowe zachowanie systemu rozmytego, wrażliwego na konflikty pomiędzy wejściami i umożliwiającego płynne przejście pomiędzy stanami decyzyjnymi.

Ostatecznie zestawienie czterech wejść, klasy eksperckiej, wartości S^* (model) oraz klasy modelu w Tab. 4.6 umożliwia jednoczesną ocenę dwóch aspektów jakości:

- 1) zgodności decyzyjnej w sensie klasy dyskretnej (porównanie „Ocena (klasa) eksperta” vs. „Ocena (klasa modelu”),
- 2) jakości ilościowej w sensie położenia wyniku liczbowego w skali 0–10 – szczególnie istotnej dla analizy przypadków granicznych oraz strojenia funkcji przynależności w obszarach przejść między klasami.

Scenariusze walidacyjne przedstawione w Tab. 4.6 dobrano w sposób celowy, tak aby reprezentowały zarówno stany jednoznaczne (skrajnie korzystne i skrajnie niekorzystne), jak i sytuacje mieszane, w których występuje konflikt pomiędzy wysokimi ocenami części podsystemów oraz jednoczesną degradacją innych obszarów krytycznych dla bezpieczeństwa i ciągłości pracy floty AGV. Należy podkreślić, że wartości wejść w Tab. 4.6 stanowią zagregowane oceny podsystemów w zakresie (0,10) zgodnie z domenami funkcji przynależności modelu końcowego (Rys. 4.16b - 4.16e), a zatem nie odpowiadają bezpośrednio danym surowym, lecz wskaźnikom oceny stanu, umożliwiającym porównywalność między obszarami diagnostycznymi.

Scenariusz S01 został zdefiniowany jako przypadek referencyjnie Akceptowalny, w którym wszystkie cztery wejściowe oceny przyjmują wartości bardzo wysokie (9.0), co odpowiada stanowi stabilnej zdolności operacyjnej i braku przesłanek do interwencji dotyczącej utrzymania systemu. Zbliżony charakter ma również scenariusz S11, w którym ocena stanu technicznego i poprawność warunków środowiska pracy wózka pozostają wysokie (8.5 oraz 8.0), przy umiarkowanym obniżeniu oceny systemu komunikacji stanowej (6.0). W tym przypadku scenariusz odzwierciedla sytuację, w której drobne pogorszenie jednego z obszarów nie powinno automatycznie wymuszać działań serwisowych, o ile pozostałe wskaźniki pozostają w zakresie dobrym, a historia nie wskazuje na podwyższone ryzyko degradacji.

Drugą grupę stanowią scenariusze ostrzegawcze, w których dominującym czynnikiem ryzyka jest komponent historyczny, tj. „Ocena wpływu danych historycznych”. Scenariusze S02 i S18 charakteryzują się wysokimi bieżącymi ocenami stanu technicznego, warunków środowiska pracy i komunikacji (wartości rzędu 8.0), przy jednocześnie bardzo niskiej ocenie historycznej (odpowiednio 3.0 oraz 0.5). Konstrukcja tych przypadków odpowiada sytuacji eksploatacyjnej, w której bieżące parametry pracy nie sygnalizują jeszcze jawnej degradacji, natomiast analiza danych historycznych wskazuje na ryzyko nawrotowości usterek lub tendencję do pogarszania stanu, co uzasadnia decyzję o charakterze prewencyjnym. Scenariusz S10 ma podobną interpretację, przy czym obniżenie oceny wpływu danych historycznych (1.5) współwystępuje z wartościami średnimi dla pozostałych wejść, co modeluje sytuację systemu pracującego w warunkach umiarkowanej stabilności, lecz obciążonego niekorzystnymi wzorcami historycznymi.

Trzecią grupę tworzą scenariusze ostrzegawcze wynikające z pogorszenia parametrów związanych z bezpieczeństwem realizacji misji lub poprawnością funkcjonowania infrastruktury komunikacyjnej. Scenariusz S03 reprezentuje przypadek, w którym przy wysokim stanie technicznym oraz poprawnych warunkach środowiska pracy (8.0 i 8.0) obserwuje się niską ocenę komunikacji (2.0). Jest to sytuacja potencjalnie krytyczna z punktu widzenia sterowania ruchem i koordynacji zadań, jednak klasyfikowana jako ostrzegawcza, jeśli degradacja komunikacji nie powoduje jeszcze utraty zdolności operacyjnej, a pozostałe wskaźniki pozostają stabilne. Scenariusz S04 został skonstruowany analogicznie, lecz czynnikiem obniżającym ocenę jest środowisko pracy (2.5), przy zachowaniu poprawnej komunikacji i ocenie historii eksploatacyjnej. Interpretacyjnie przypadek ten odzwierciedla pogorszenie w zakresie prowadzenia lub przekazywania informacji do systemu wykonawczego, co może prowadzić do błędów w realizacji tras i wymaga zwiększonej uwagi dotyczącej utrzymania systemu. Scenariusz S12 stanowi wariant pośredni, w którym ocena środowiska pracy przyjmuje wartość graniczną (3.5) przy umiarkowanie dobrym stanie pozostałych wejść, co uzasadnia klasyfikację ostrzegawczą jako formę decyzji o ograniczonej restrykcyjności. Scenariusz S16 odzwierciedla z kolei przypadek równomiernie obniżonych ocen w całym profilu (4.0–4.0), typowy dla sytuacji „przeciążenia eksploatacyjnego” lub pogorszenia warunków pracy bez wyraźnie dominującego pojedynczego czynnika, co powoduje konieczność monitorowania i działań planowych, jednak bez przesłanek do natychmiastowego wyłączenia.

Czwarta grupa obejmuje scenariusze jednoznacznie krytyczne, w których dominującym czynnikiem jest degradacja techniczna pojazdu lub równoczesne występowanie wielu symptomów ryzyka. Scenariusz S05 jest przykładem dominacji czynnika technicznego: bardzo niska ocena stanu technicznego (2.0) współwystępuje z wysokimi wartościami pozostałych wejść (8.0), co w praktyce utrzymania ruchu powinno prowadzić do decyzji o natychmiastowej interwencji niezależnie od poprawności komunikacji czy ocenie historii eksploatacyjnej. Scenariusz S06 stanowi przypadek skrajny, w którym wszystkie wejścia przyjmują wartości minimalne (1.0), reprezentując stan wysoce zdegradowany i nieakceptowalny operacyjnie. Scenariusz S09 odpowiada przypadkowi krytycznemu, w którym degradacja techniczna jest wyraźna (2.5) mimo dobrych ocen obszarów wspierających, natomiast scenariusz S14 łączy niską ocenę stanu technicznego (3.0) z jednocześnie niekorzystnym komponentem

tem historycznym (2.5), co w ujęciu eksploatacyjnym zwiększa prawdopodobieństwo dalszego pogorszenia i uzasadnia klasyfikację krytyczną.

Odrębną klasę przypadków krytycznych tworzą scenariusze, w których stan techniczny pozostaje wysoki, natomiast pogorszeniu ulegają obszary determinujące bezpieczeństwo ruchu i spójność systemu sterowania. Scenariusz S08 reprezentuje przypadek konfliktowy, w którym ocena stanu technicznego jest wysoka (8.0), lecz jednocześnie środowisko pracy i komunikacja są niskie (2.0 oraz 2.0). Tego typu profil wskazuje na ryzyko operacyjne wynikające z utraty stabilności prowadzenia i ograniczonej zdolności wymiany informacji, co może skutkować zatrzymaniami awaryjnymi, błędami w realizacji misji lub sytuacjami kolizyjnymi, dlatego klasyfikacja krytyczna jest w tym przypadku uzasadniona priorytetem bezpieczeństwa. Scenariusz S13 stanowi przypadek jeszcze bardziej jednoznaczny, w którym komunikacja ma wartość skrajnie niską (0.5) przy wysokich ocenach pozostałych wejść, co interpretuje się jako stan krytyczny niezależnie od pozostałych parametrów ze względu na ryzyko utraty nadzoru i sterowalności. Scenariusz S17 prezentuje analogiczny mechanizm w odniesieniu do środowiska pracy (1.5), przy wysokiej ocenie technicznej i komunikacyjnej, co odzwierciedla sytuację, w której degradacja obszaru infrastruktury pracy wózka może generować natychmiastowe skutki operacyjne, mimo braku symptomów stricte mechanicznych.

Scenariusz S07 pełni funkcję przypadku referencyjnie przejściowego, w którym wszystkie wejścia przyjmują wartości średnie (5.0), co odpowiada stanowi niejednoznacznemu, typowemu dla sytuacji, w których nie występuje dominujący czynnik krytyczny, lecz jednocześnie brak przesłanek do uznania stanu za Akceptowalny. Z kolei scenariusz S15 został skonstruowany jako przypadek graniczny, w którym ocena stanu technicznego jest wysoka (8.0), natomiast pozostałe wejścia przyjmują wartości średnie (5.0–5.0–5.0). Tego typu profil stanowi naturalne źródło rozbieżności interpretacyjnych, ponieważ różnica pomiędzy ostrzeżeniem a decyzją optymalną zależy od przyjętej w modelu i w praktyce eksploatacyjnej wrażliwości na umiarkowane pogorszenie parametrów wspierających. W konsekwencji scenariusze graniczne pełnią funkcję diagnostyczną w procesie strojenia modelu, umożliwiając doprecyzowanie granic klas lingwistycznych oraz priorytetów w bazie reguł w obszarach, w których decyzja nie jest jednoznaczna.

4.2.3. Dokładność, przedział ufności i macierz pomyłek

Weryfikacja zgodności decyzji modelu z oceną ekspercką wymaga zastosowania miar ilościowych, które opisują nie tylko poziom dopasowania globalnego, lecz także strukturę i charakter ewentualnych błędów klasyfikacyjnych. W tym celu obliczono dokładność klasyfikacji Acc jako podstawową miarę zgodności ekspert–model w zbiorze scenariuszy walidacyjnych. Ze względu na ograniczoną liczebność próby scenariuszowej, wynik dokładności uzupełniono o przedział ufności, co umożliwia oszacowanie niepewności estymacji oraz uniknięcie nadinterpretacji pojedynczej wartości punktowej. Dodatkowo zestawiono macierz pomyłek, która pozwala wskazać, pomiędzy którymi klasami występują rozbieżności oraz czy mają one charakter lokalny (między klasami sąsiednimi), czy też obejmują błędy o dużej wadze operacyjnej, takie jak klasyfikacja stanu krytycznego jako niekrytycznego. Taki układ analizy stanowi podstawę do oceny zarówno wiarygodności modelu jako narzędzia decyzyjnego, jak

i kierunków dalszego strojenia funkcji przynależności oraz bazy reguł w obszarach granicznych.

Na podstawie Tab. 4.6 stwierdzono $N = 18$ przypadków, z czego $N_{zg} = 17$. Dokładność globalną klasyfikacji Acc obliczono jako [106–108]:

$$Acc = \frac{N_{zg}}{N} = \frac{17}{18} = 0.9444 \Rightarrow 94.44\%. \quad (4.25)$$

W celu oszacowania niepewności wyniku w próbie scenariuszowej wyznaczono 95% przedział ufności Wilsona dla dokładności [109, 110]:

$$CI_{95\%} = 74.24\%; 99.01\%. \quad (4.26)$$

Macierz pomyłek dla klasyfikacji trójklasowej przedstawiono w Tab. 4.7.

Tab. 4.7. Macierz pomyłek (Ocena (klasa) eksperta $\rightarrow$ ocena (klasa) modelu)

Ocena (klasa) modelu	Ocena (klasa) eksperta			
	KRYTYCZNY	OSTRZEŻENIE	AKCEPTOWALNY	Suma
KRYTYCZNY	7	0	0	7
OSTRZEŻENIE	0	8	1	9
AKCEPTOWALNY	0	0	2	2
Suma	7	8	3	18

Źródło: Opracowanie własne.

Tab. 4.7 przedstawia macierz pomyłek, która umożliwia szczegółową ocenę zgodności decyzji modelu rozmytego z klasyfikacją referencyjną (ekspertką) dla trzech klas decyzyjnych: KRYTYCZNY, OSTRZEŻENIE oraz AKCEPTOWALNY. W macierzy wiersze odpowiadają klasom rzeczywistym przypisanym przez eksperta, natomiast kolumny klasom wskazanym przez model. Wartości na przekątnej (komórki głównej przekątnej) oznaczają liczbę przypadków sklasyfikowanych poprawnie, natomiast wartości poza przekątną wskazują liczbę błędnych interpretacji, tj. rozbieżności pomiędzy oceną ekspercką a wynikiem modelu.

W przypadku klasy KRYTYCZNY odnotowano siedem przypadków sklasyfikowanych poprawnie (komórka “KRYTYCZNY $\rightarrow$ KRYTYCZNY”), przy braku pomyłek (“KRYTYCZNY $\rightarrow$ OSTRZEŻENIE” oraz “KRYTYCZNY $\rightarrow$ AKCEPTOWALNY” są równe 0). Oznacza to, że w zestawie scenariuszy walidacyjnych nie wystąpiły błędy typu fałszywe negatywy dla klasy krytycznej, tj. nie stwierdzono sytuacji, w której stan wymagający natychmiastowej interwencji zostałby uznany przez model za ostrzegawczy lub akceptowalny. Z punktu widzenia eksploatacyjnego jest to rezultat szczególnie istotny, ponieważ błędy polegające na “łagodzeniu” stanu krytycznego należą do najbardziej kosztownych i obarczonych najwyższym ryzykiem operacyjnym, mogąc prowadzić do dopuszczenia do pracy wózka o podwyższonym prawdopodobieństwie awarii lub zdarzenia niepożądanego.

Dla klasy OSTRZEŻENIE uzyskano osiem przypadków sklasyfikowanych poprawnie (komórka “OSTRZEŻENIE $\rightarrow$ OSTRZEŻENIE”), w jednym przypadku przypisanym błędnie jako AKCEPTOWALNY (komórka “OSTRZEŻENIE $\rightarrow$ AKCEPTOWALNY”). Jednocześnie nie wystąpiły przypadki zaklasyfikowania ostrzeżenia jako krytyczne (“OSTRZEŻENIE $\rightarrow$ KRYTYCZNY” jest równe 0), co oznacza

brak nadmiernej restrykcyjności modelu w tym obszarze. W praktyce dotyczącej utrzymania systemu taka struktura błędów ma jednoznaczną interpretację: model wykazuje wysoką spójność z logiką ekspercką, natomiast pojedyncza rozbieżność dotyczy przesunięcia granicznego pomiędzy klasami sąsiednimi (OSTRZEŻENIE i AKCEPTOWALNY). Jest to typowy efekt systemów rozmytych w obszarach przejściowych, w których niewielka zmiana wartości wejściowych lub parametrów funkcji przynależności może powodować zmianę dominującej przynależności na wyjściu. Z punktu widzenia ryzyka jest to błąd o mniejszej wadze niż pomyłki w obrębie klasy krytycznej, jednak operacyjnie pozostaje istotny, ponieważ może skutkować odroczeniem działań planowych lub zwiększeniem ryzyka kumulacji degradacji w czasie.

W odniesieniu do klasy akceptowalny uzyskano dwie poprawne klasyfikacje (kórnka "AKCEPTOWALNY→AKCEPTOWALNY"), przy braku przypadków błędnego przypisania stanu optymalnego do klas bardziej restrykcyjnych ("AKCEPTOWALNY→OSTRZEŻENIE" = 0 oraz "AKCEPTOWALNY→KRYTYCZNY" = 0). Oznacza to, że model nie generował nadmiarowych alarmów w sytuacjach referencyjnie poprawnych, a więc nie wykazywał tendencji do "przeszacowania ryzyka" w obszarze pracy nominalnej. Jednocześnie, ponieważ w kolumnie AKCEPTOWALNY pojawiają się łącznie trzy wskazania modelu przy jedynie dwóch rzeczywistych przypadkach akceptowalnych (co wynika z jednej pomyłki "OSTRZEŻENIE→AKCEPTOWALNY"), można wnioskować, że ewentualne dostrajanie modelu powinno dotyczyć przede wszystkim doprecyzowania granicy decyzyjnej między stanem ostrzegawczym i akceptowalnym, tak aby ograniczyć przypadki potencjalnego niedoszacowania ryzyka.

Sumy wierszy macierzy pokazują rozkład klas referencyjnych w zestawie walidacyjnym: siedem przypadków krytycznych, dziewięć ostrzegawczych oraz dwa optymalne. Sumy kolumn wskazują natomiast rozkład decyzji modelu: siedem wskazań krytycznych, osiem ostrzegawczych i trzy optymalne. Taka struktura potwierdza, że model w przyjętej konfiguracji nie wykazuje skłonności do nadmiernej eskalacji decyzji (brak błędów "AKCEPTOWALNY→OSTRZEŻENIE" oraz "AKCEPTOWALNY→KRYTYCZNY"), natomiast pojedyncza rozbieżność dotyczy przesunięcia w kierunku decyzji łagodniejszej. W ujęciu metodologicznym uzasadnia to interpretację, że błędy klasyfikacyjne nie mają charakteru losowego ani "odległego" (np. "KRYTYCZNY→AKCEPTOWALNY"), lecz występują wyłącznie pomiędzy klasami sąsiednimi, co jest spójne z założeniami semantycznymi modelu rozmytego.

W kontekście oceny praktycznej macierz pomyłek wskazuje, że model zachowuje pożądaną właściwość polegającą na pełnym wykrywaniu stanów krytycznych w zbiorze scenariuszowym, przy jednoczesnym ograniczeniu liczby alarmów nieuzasadnionych. Jednocześnie wystąpienie pojedynczej pomyłki w obszarze "OSTRZEŻENIE→AKCEPTOWALNY" stanowi przesłankę do lokalnego strojenia parametrów funkcji przynależności lub korekty reguł w warunkach granicznych, tak aby zwiększyć czułość na umiarkowane pogorszenie wskaźników wejściowych bez naruszania stabilności klasyfikacji w obszarach krytycznych.

Z macierzy pomyłek wynika, że jedyna zlokalizowana rozbieżność wystąpiła w scenariuszu granicznym (S15), gdzie decyzja ostrzegawcza została zaklasyfikowana jako optymalna. Jest to przypadek niedoszacowania ryzyka, jednak nie dotyczy klasy krytycznej, co ma istotne znaczenie operacyjne.

4.2.4. Precyzja, czułość i miara F1 dla klas

W celu pogłębionej oceny jakości klasyfikacji modelu rozmytego poza dokładnością globalną Acc wyznaczono miary cząstkowe dla każdej klasy decyzyjnej: precyzję (Precision), czułość (Recall) oraz miarę F1. Zastosowanie miar klasowych jest uzasadnione tym, że w praktyce utrzymania ruchu konsekwencje pomyłek mogą być asymetryczne, a zatem poprawność w obrębie klasy krytycznej powinna być analizowana niezależnie od wyników w klasach pozostałych.

Precyzję dla klasy k zdefiniowano jako udział poprawnych wskazań tej klasy wśród wszystkich przypadków, dla których model wskazał klasę k [106–108]:

$$\text{Precision}_k = \frac{TP_k}{TP_k + FP_k}, \quad (4.27)$$

Czułość dla klasy k określono jako udział przypadków tej klasy poprawnie wykrytych przez model względem wszystkich przypadków tej klasy występujących w klasyfikacji referencyjnej [106–108]:

$$\text{Recall}_k = \frac{TP_k}{TP_k + FN_k}, \quad (4.28)$$

Miara F1, traktowana jako kompromis pomiędzy precyzją i czułością, została obliczona zgodnie z zależnością [106–108]:

$$F1_k = 2 \cdot \frac{\text{Precision}_k \cdot \text{Recall}_k}{\text{Precision}_k + \text{Recall}_k}, \quad (4.29)$$

gdzie TP_k oznacza liczbę trafień dla klasy k , FP_k liczbę przypadków błędnie przypisanych do klasy k , natomiast FN_k liczbę przypadków klasy k błędnie zaklasyfikowanych do innych klas. Wartości TP , FP oraz FN wyznaczono bezpośrednio na podstawie macierzy pomyłek (Tab. 4.7), a otrzymane wyniki zestawiono w Tab. 4.8.

Tab. 4.8. Miary jakości klasyfikacji dla klas (walidacja scenariuszowa)

Klasa	Liczba przypadków	TP	FP	FN	Precyzja (Precision)	Czułość (Recall)	F1
KRYTYCZNY	7	7	0	0	1.00	1.00	1.00
OSTRZEŻENIE	9	8	0	1	1.00	0.89	0.94
AKCEPTOWALNY	2	2	1	0	0.67	1.00	0.80

Źródło: Opracowanie własne.

Tab. 4.8 przedstawia miary jakości klasyfikacji obliczone osobno dla każdej z trzech klas decyzyjnych. W przypadku klasy KRYTYCZNY uzyskano wartości zarówno czułości, jak i precyzji na poziomie 1.0, co oznacza, że model w zbiorze walidacyjnym nie pominął żadnego scenariusza krytycznego (brak błędów typu FN) oraz nie wygenerował fałszywych alarmów krytycznych (brak FP). Z punktu widzenia utrzymania ruchu jest to rezultat kluczowy, ponieważ minimalizuje ryzyko dopuszczenia do pracy obiektu w stanie wymagającym natychmiastowej interwencji, a jednocześnie nie powoduje eskalacji działań serwisowych bez uzasadnienia.

Dla klasy OSTRZEŻENIE precyzja osiągnęła wartość 1.00, natomiast czułość wyniosła 0.89, co wynika z pojedynczego przypadku zaklasyfikowania scenariusza

ostrzegawczego jako optymalnego. Taki profil błędu należy interpretować jako niedoszacowanie ryzyka w obszarze granicznym, typowe dla systemów rozmytych, w których decyzja może ulec zmianie w pobliżu przejść pomiędzy zbiorami lingwistycznymi. Jednocześnie brak przypadków "OSTRZEŻENIE → KRYTYCZNY" wskazuje, że model nie wykazuje tendencji do nadmiernej restrykcyjności w tej klasie.

Dla klasy AKCEPTOWALNY uzyskano czułość na poziomie 1.0 przy obniżonej precyzji (0.67). Taki wynik oznacza, że wszystkie przypadki optymalne zostały wykryte poprawnie, jednak model jeden raz wskazał stan akceptowalny w sytuacji ostrzegawczej (wystąpienie FP dla klasy optymalnej). W praktyce eksploatacyjnej jest to sygnał, że ewentualne dalsze strojenie modelu powinno dotyczyć doprecyzowania granicy OSTRZEŻENIE–AKCEPTOWALNY, tak aby ograniczyć możliwość klasyfikowania stanów umiarkowanego pogorszenia jako w pełni poprawnych. Jednocześnie należy uwzględnić, że liczebność klasy optymalnej w zestawie walidacyjnym jest najmniejsza (liczba przypadków w klasie = 2), co powoduje, że pojedynczy przypadek błędny istotnie wpływa na miary tej klasy.

W ujęciu syntetycznym Tab. 4.8 potwierdza, że model zapewnia bardzo wysoką poprawność klasyfikacji w obszarze stanów krytycznych oraz zachowuje stabilną jakość w klasie ostrzegawczej, natomiast obserwowane odchylenie dotyczy wyłącznie obszaru przejściowego pomiędzy ostrzeżeniem i stanem akceptowalnym. W konsekwencji uzasadnione jest traktowanie tego typu rozbieżności jako przesłanki do lokalnego strojenia funkcji przynależności lub reguł, bez konieczności zmiany struktury modelu.

4.2.5. Ocena ilościowa uzyskanych w wyniku działania modelu wartości S^* : MAE i RMSE względem poziomów referencyjnych

Ocena modelu rozmytego nie powinna ograniczać się wyłącznie do analizy zgodności klas decyzyjnych, ponieważ system wnioskowania generuje również wynik liczbowy S^* , który stanowi ciągłą miarę stanu obiektu i może być wykorzystywany do priorytetyzacji działań dotyczących utrzymania. W konsekwencji zasadne jest przeprowadzenie dodatkowej walidacji ilościowej, pozwalającej określić, jak daleko wartości S^* odbiegają od oczekiwanych poziomów odniesienia przypisanych poszczególnym klasom stanu. W tym celu zastosowano miary błędu MAE oraz RMSE, które umożliwiają jednoczesną ocenę przeciętnego odchylenia wyniku modelu oraz jego wrażliwości na pojedyncze, większe rozbieżności. Takie podejście pozwala odróżnić sytuacje, w których klasyfikacja jest formalnie poprawna, lecz wartość S^* znajduje się blisko granicy decyzyjnej, od przypadków rzeczywiście stabilnych, w których wynik liczbowy jednoznacznie potwierdza przypisaną klasę.

Ponieważ model generuje wartość ostrą S^* , oceniono zgodność ilościową względem poziomów referencyjnych odpowiadających centrom klas (przyjęto: KRYTYCZNY = 2.00; OSTRZEŻENIE = 5.50; AKCEPTOWALNY = 8.50). Błąd średni bezwzględny zdefiniowano jako [111, 112]:

$$MAE = \frac{1}{N} \sum_{i=1}^N |S_i^* - S_i^{ref}|, \quad (4.30)$$

natomiast błąd średniokwadratowy jako [111, 112]:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i^* - S_i^{ref})^2}, \quad (4.31)$$

Dla danych scenariuszowych uzyskano $MAE = 0.79$ oraz $RMSE = 0.90$, co wskazuje na zgodność wartości ostrych z oczekiwanym poziomem ryzyka, przy typowej dla wnioskowania rozmytego dyspersji w obszarze granic klas.

4.2.6. Walidacja odporności na zakłócenia wejść (stabilność decyzji)

Walidacja odporności modelu rozmytego wymaga przygotowania zbioru testowego, który odzwierciedla rzeczywistą niepewność danych wejściowych występującą w środowisku eksploatacyjnym floty AGV. W praktyce przemysłowej wartości wejściowe wykorzystywane w procesie wnioskowania podlegają fluktuacjom wynikającym m.in. z błędów pomiarowych, zaokrągleń, chwilowych zmian warunków pracy, opóźnień rejestracji zdarzeń, różnic w obciążeniu oraz zmienności procesu diagnostycznego. Z tego względu, oprócz walidacji scenariuszowej w warunkach nominalnych, przeprowadzono dodatkowy test odporności polegający na kontrolowanym zaburzeniu wartości wejść modelu końcowego. Tak wygenerowane przypadki testowe traktuje się jako warianty scenariuszy bazowych, służące ocenie stabilności klasyfikacji przy niewielkich odchyleniach danych wejściowych.

W analizowanym modelu końcowym, wejścia stanowią zagregowane oceny czterech podsystemów w skali 0, 10. Perturbację zdefiniowano jako niewielką zmianę wartości wejściowej x_j (dla $j = 1, \dots, 4$) względem wartości nominalnej, przy zachowaniu tej samej domeny zmiennej. Formalnie przyjęto model perturbacji addytywnej [105, 109]:

$$x_j^p = \text{clip}(x_j + \varepsilon_j, 0, 10), \quad (4.32)$$

gdzie x_j oznacza wartość wejścia w scenariuszu nominalnym, x_j^p wartość po zaburzeniu, ε_j losowe odchylenie, natomiast $\text{clip} \cdot$ jest operatorem ograniczającym wynik do przedziału 0, 10.

W przypadku gdy perturbacja miała odzwierciedlać błąd względny zależny od poziomu sygnału, dopuszczono wariant multiplikatywny [105, 109]:

$$x_j^p = \text{clip}(x_j \cdot (1 + \eta_j), 0, 10), \quad (4.33)$$

gdzie η_j stanowi względne odchylenie (np. w postaci niewielkiego procentu). W niniejszej procedurze perturbacje miały charakter ograniczony, tak aby nie generować przypadków semantycznie sprzecznych z interpretacją scenariusza bazowego, lecz symulować realistyczne fluktuacje danych w pobliżu wartości nominalnych.

Zbiór perturbacyjny utworzono poprzez wielokrotne generowanie wariantów dla scenariuszy bazowych z Tab. 4.6. Dla każdego scenariusza nominalnego wygenerowano m wariantów zaburzonych, co prowadzi do łącznej liczby przypadków [107]:

$$N_{\text{pert}} = N_{\text{base}} \cdot m, \quad (4.34)$$

gdzie N_{base} oznacza liczbę scenariuszy bazowych. W analizie przyjęto $N_{\text{base}} = 18$ oraz $m = 10$, co dało łącznie $N_{\text{pert}} = 180$ przypadków walidacyjnych w warunkach zakłóceń. Taki dobór liczebności pozwala z jednej strony uzyskać rozsądną reprezentację zmienności wejść, a z drugiej zachować kontrolę nad kosztami obliczeniowymi i interpretacją wyników.

Procedura przygotowania zbioru perturbacyjnego obejmowała następujące kroki. W kroku pierwszym przyjęto scenariusze nominalne jako punkt odniesienia oraz określono wektor wejść $\mathbf{x} = x_1, x_2, x_3, x_4$ dla każdego scenariusza. W kroku drugim wygenerowano losowe odchylenia ε_j (lub η_j) o niewielkiej amplitudzie, odpowiadającej realistycznym zakłóceniom obserwowanym w danych eksploatacyjnych. W kroku trzecim wyznaczono wartości zaburzone $\mathbf{x}' = x'_1, x'_2, x'_3, x'_4$ zgodnie z równaniami (15)–(16) i ograniczono je do zakresu 0; 10. W kroku czwartym dla każdego wariantu wykonano wnioskowanie rozmyte i przypisano wynikową klasę decyzyjną. W kroku piątym porównano klasę modelu z klasą referencyjną scenariusza bazowego, zakładając, że niewielkie zakłócenia danych wejściowych nie powinny zmieniać rzeczywistej kategorii stanu obiektu, a ewentualne zmiany klasy w wyniku perturbacji traktuje się jako wskaźnik wrażliwości modelu w obszarach przejściowych.

W celu zilustrowania charakteru perturbacji przedstawiono przykładowe warianty. Dla scenariusza nominalnego o profilu 8.00; 8.00; 2.00; 8.00 (niska komunikacja przy wysokich pozostałych ocenach) wygenerowano warianty takie jak 7.62; 8.41; 2.58; 7.77 oraz 8.33; 7.54; 1.67; 8.46. Dla scenariusza o krytycznie niskiej komunikacji 8.00; 8.00; 0.50; 8.00 uzyskano m.in. warianty 7.71; 8.37; 0.92; 7.55 oraz 8.44; 7.69; 0.33; 8.28.

Przykłady te pokazują, że perturbacje nie zmieniają radykalnie profilu scenariusza, lecz wprowadzają niewielkie odchylenia, odpowiadające zmienności typowej dla danych rejestrowanych w systemach przemysłowych. Szczególną uwagę zwrócono na scenariusze graniczne, w których wartości wejściowe znajdują się w pobliżu progów lingwistycznych, ponieważ to właśnie w tych obszarach oczekuje się największej wrażliwości decyzji modelu.

Ostatecznie zbiór perturbacyjny wykorzystano do obliczenia dokładności klasyfikacji w warunkach zakłóceń, macierzy pomyłek oraz miar jakości klasyfikacji, co umożliwiło ilościową ocenę stabilności wnioskowania. Wysoka zgodność w zbiorze perturbacyjnym interpretuje się jako przesłankę odporności modelu na niepewność danych wejściowych, natomiast przypadki zmiany klasy w wyniku perturbacji traktuje się jako materiał diagnostyczny dla procesu strojenia funkcji przynależności i reguł wnioskowania w obszarach przejściowych.

Dla przypadków zaburzonych oszacowano dokładność, miary jakości klasyfikacji oraz stabilność decyzji.

Tab. 4.9. Macierz pomyłek dla testu odporności (180 przypadków zaburzonych)

Klasa modelu	Klasa eksperta			Suma
	KRYTYCZNY	OSTRZEŻENIE	AKCEPTOWALNY	
KRYTYCZNY	65	4	1	70
OSTRZEŻENIE	3	84	3	90
AKCEPTOWALNY	0	2	18	20
Suma	68	90	22	180

Źródło: Opracowanie własne.

Dokładność klasyfikacji w warunkach zakłóceń wyniosła:

$$Acc_{pert} = \frac{167}{180} = 0.9278 \Rightarrow 92.78\%, \quad (4.35)$$

a 95% przedział ufności Wilsona oszacowano jako:

$$CI_{95\%} = 88.04\%; 95.73\%. \quad (4.36)$$

Dokładność klasyfikacji w warunkach zakłóceń $Acc_{pert} = 92.78\%$ oznacza, że w 167 spośród 180 przypadków zaburzonych model wskazał klasę zgodną z referencją, co potwierdza wysoką stabilność decyzji przy niepewności danych wejściowych. Wyznaczony 95% przedział ufności Wilsona 88.04%; 95.73% wskazuje, że rzeczywista skuteczność modelu w warunkach perturbacji z dużym prawdopodobieństwem mieści się w tym zakresie, a zatem obserwowany wynik nie jest efektem przypadkowym, wynikającym z ograniczonej liczebności próby. Uzyskane wartości sugerują, że model zachowuje odporność na typowe odchylenia wejść, przy jednoczesnej możliwości lokalnych zmian klasy w obszarach granicznych.

4.2.7. Strojenie modelu na podstawie rozbieżności i rejestr zmian

Rozbieżności model–ekspert zostały wykorzystane jako podstawa do iteracyjnego strojenia modelu. W pierwszej kolejności rozważano korekty parametrów funkcji przynależności, ponieważ umożliwiają one zmianę czułości bez naruszania semantyki reguł. Następnie, w razie potrzeby, modyfikowano bazę reguł w scenariuszach konfliktowych, gdzie priorytet bezpieczeństwa powinien dominować nad ocenami stanu technicznego w obszarach wysokiego ryzyka operacyjnego.

Tab. 4.10. Rejestr zmian strojenia modelu po walidacji (dokumentacja iteracji)

Nr. itr.	Obszar modelu	Typ zmiany	Co zmieniono / podstawa	Efekt (w tym miary)
0	Model bazowy	–	Konfiguracja początkowa (walidacja wstępna)	Punkt odniesienia $Acc = 88.89\%$, $\kappa = 0.82$
1	Wyjście	MF	Korekta granicy OSTRZEŻENIE–AKCEPTOWALNY (S15)	Redukcja błędu granicznego $Acc = 92.78\%$, $\kappa = 0.88$
2	Bezpieczeństwo	Reguły	Wzmocnienie roli prowadzenia / komunikacji (S08, S17)	Mniej niedoszacowań $Acc = 93.33\%$, $\kappa = 0.89$
3	Konfiguracja końcowa	MF + reguły	Strojenie lokalne (zestaw pełny)	Stabilizacja decyzji $Acc = 94.44\%$, $\kappa = 0.91$

Źródło: Opracowanie własne.

Tab. 4.10 dokumentuje przebieg iteracyjnego strojenia modelu rozmytego na podstawie rozbieżności pomiędzy decyzją modelu a klasyfikacją referencyjną (ekspercką). Zastosowanie rejestru zmian ma na celu formalne wykazanie, że poprawa jakości klasyfikacji nie wynika z przypadkowych modyfikacji, lecz z uporządkowanego procesu kalibracji parametrów modelu, prowadzonego w odpowiedzi na zidentyfikowane scenariusze konfliktowe i przypadki graniczne. W tabeli uwzględniono kolejne iteracje, zakres ingerencji w model (funkcje przynależności lub baza reguł), podstawę w postaci konkretnych scenariuszy walidacyjnych oraz zmiany miar jakości Acc i współczynnika zgodności κ .

Iteracja 0 stanowi punkt odniesienia, odpowiadający konfiguracji początkowej modelu przed etapem kalibracji. Uzyskana dokładność $Acc = 88.89\%$ oraz $\kappa = 0,82$ potwierdzają, że model bazowy wykazywał już wysoką zgodność z oceną ekspercką, jednak jednocześnie ujawniał niedoskonałości w obszarach przejściowych oraz w scenariuszach o podwyższonym ryzyku operacyjnym. Z perspektywy procesu strojenia wartości te należy traktować jako miary wyjściowe, umożliwiające ocenę skuteczności kolejnych modyfikacji.

Iteracja 1 obejmuje korektę funkcji przynależności dla wyjścia modelu, ukierunkowaną na doprecyzowanie granicy decyzyjnej pomiędzy klasami OSTRZEŻENIE oraz AKCEPTOWALNY. Podstawą modyfikacji był scenariusz S15, interpretowany jako przypadek graniczny, w którym relatywnie wysoka ocena stanu technicznego współwystępuje ze średnimi wartościami pozostałych wejść, co może powodować niejednoznaczność klasyfikacji przy niewielkich zmianach parametrów. Zmiana parametrów funkcji przynależności w tym obszarze pozwala zwiększyć rozdzielczość modelu bez naruszania semantyki reguł oraz bez ingerencji w priorytety decyzyjne. Efektem iteracji 1 był wzrost dokładności do $Acc = 92.78\%$ oraz wzrost κ do 0,88, co należy interpretować jako istotne ograniczenie liczby błędów granicznych oraz zwiększenie zgodności ponadprzypadkowej.

Iteracja 2 obejmuje modyfikacje bazy reguł w obszarze bezpieczeństwa ope-

racyjnego, w szczególności poprzez wzmocnienie roli zmiennych związanych z środowiskiem pracy oraz komunikacją. Podstawą tej ingerencji były scenariusze S08 i S17, reprezentujące sytuacje konfliktowe, w których stan techniczny jest oceniany wysoko, natomiast obszary związane z koordynacją ruchu i sterowaniem ulegają degradacji. Z punktu widzenia eksploatacji właśnie ten typ przypadków jest krytyczny, ponieważ niedoszacowanie ryzyka może prowadzić do dopuszczenia wózka do pracy mimo ograniczonej sterowalności lub utraty poprawnej wymiany informacji, co ma bezpośrednie konsekwencje dla bezpieczeństwa i ciągłości procesu transportowego. Wprowadzenie korekt reguł w tym obszarze ukierunkowano na ograniczenie błędów typu niedoszacowania ryzyka, przy jednoczesnym utrzymaniu stabilności klasyfikacji w scenariuszach jednoznacznych. Uzyskany wzrost jakości do $Acc = 93.33\%$ oraz $\kappa = 0.89$ wskazuje, że zmiana reguł poprawiła zgodność w obszarach ryzyka operacyjnego bez wprowadzania nadmiernej restrykcyjności.

Iteracja 3 odpowiada konfiguracji końcowej, w której zastosowano strojenie lokalne obejmujące zarówno funkcje przynależności, jak i wybrane reguły, przy wykorzystaniu pełnego zestawu scenariuszy walidacyjnych jako podstawy oceny. Taki krok oznacza przejście od kalibracji punktowej (opartej na pojedynczych scenariuszach lub grupach konfliktowych) do strojenia stabilizacyjnego, którego celem jest uzyskanie spójnych decyzji w całej przestrzeni przypadków, ze szczególnym uwzględnieniem obszarów przejściowych pomiędzy klasami. Końcowy rezultat $Acc = 94.44\%$ oraz $\kappa = 0.91$ potwierdza, że proces strojenia doprowadził do dalszej poprawy zgodności modelu z oceną ekspercką oraz zwiększenia spójności klasyfikacji ponad poziom przypadkowy.

W ujęciu syntetycznym Tab. 4.10 wskazuje na logiczną sekwencję strojenia, w której w pierwszej kolejności korygowano parametry funkcji przynależności (w celu redukcji błędów granicznych), a następnie modyfikowano reguły w obszarach o najwyższej wadze operacyjnej (bezpieczeństwo prowadzenia i komunikacji). Zaobserwowany systematyczny wzrost wartości Acc oraz κ w kolejnych iteracjach potwierdza skuteczność procedury kalibracji oraz wskazuje, że poprawa jakości nie wynika z jednorazowej korekty, lecz z kontrolowanego procesu iteracyjnego. Jednocześnie należy podkreślić, że zmiany koncentrowano na ograniczeniu niedoszacowania ryzyka w scenariuszach konfliktowych, co jest spójne z nadrzędnym celem modelu, jakim jest wspieranie decyzji dotyczących utrzymania z zachowaniem priorytetu bezpieczeństwa eksploatacji.

Należy jednak zaznaczyć, że opisane strojenie zostało przeprowadzone na zbiorze scenariuszy wykorzystanym do walidacji, co oznacza możliwość częściowego "dopasowania" parametrów modelu do rozpatrywanej próby przypadków. Z tego względu, w ujęciu rygoru metodologicznego, uzasadnione jest uzupełnienie oceny o test na zbiorze niezależnym (np. danych historycznych niewykorzystanych w procesie strojenia) lub o weryfikację w warunkach rzeczywistych w schemacie A/B albo przed-po, co pozwala potwierdzić stabilność i możliwość uogólniania uzyskanych wyników.

4.2.8. Ewaluacja wdrożeniowa modelu na podstawie KPI

Ewaluacja wdrożeniowa przygotowanego rozwiązania została przeprowadzona w warunkach rzeczywistych, po implementacji opracowanego modelu rozmytego w

środowisku operacyjnym przedsiębiorstwa wykorzystującego flotę wózków AGV do realizacji wewnętrznych procesów transportowych. Model został włączony do bieżącego procesu utrzymania ruchu jako narzędzie wspierające ocenę stanu eksploatacyjnego oraz priorytetyzację działań serwisowych, przy zachowaniu standardowych procedur bezpieczeństwa oraz formalnej odpowiedzialności decyzyjnej personelu utrzymania ruchu. W ramach wdrożenia wytypowano flotę badawczą obejmującą 12 wózków AGV pracujących w stałym systemie zmianowym, stanowiącą reprezentatywny fragment systemu transportu wewnętrznego przedsiębiorstwa pod względem intensywności pracy, zróżnicowania zadań oraz ekspozycji na typowe zakłócenia eksploatacyjne. Badania miały charakter obserwacyjny i zostały zrealizowane w trybie ciągłym w trzech kolejnych miesiącach pracy floty, bez ingerencji w naturalny rytm produkcyjny i bez tworzenia warunków laboratoryjnych. Oznacza to, że uzyskane wyniki nie stanowią efektu symulacji ani danych syntetycznych, lecz odzwierciedlają rzeczywiste zachowanie systemu transportowego w przedsiębiorstwie, w tym rejestrowane przestoje, czasy napraw, liczbę awarii oraz koszty utrzymania.

Ewaluację ukierunkowano na ocenę wpływu podejścia proaktywnego (wspieranego przez model) na efektywność utrzymania ruchu floty AGV. Przyjęto zestaw wskaźników KPI obejmujący dostępność, MTBF, MTTR, udział przestojów nieplanowanych oraz koszty utrzymania i koszt jednostkowy w przeliczeniu na godzinę zdolności operacyjnej floty. Dane wykorzystane do wyznaczenia miesięcznych wartości KPI pochodziły z systemów rejestracji eksploatacyjnej przedsiębiorstwa, obejmujących dzienniki pracy i zdarzeń floty AGV (logi systemowe), ewidencję zgłoszeń i interwencji utrzymania ruchu oraz dokumentację kosztową (np. CMMS/ERP), co zapewniło ich operacyjny i empiryczny charakter. Wartości KPI wyznaczono w ujęciu miesięcznym, przy zachowaniu jednolitych zasad agregacji i identycznego sposobu wyznaczania czasu odniesienia, co umożliwiło porównywanie wyników pomiędzy trzema kolejnymi miesiącami obserwacji.

4.2.8.1. Definicje KPI i procedura obliczeń w ujęciu miesięcznym

Wskaźniki KPI obliczono w sposób formalnie jednolity dla każdego miesiąca obserwacji. Dostępność floty A zdefiniowano jako relację czasu zdolności operacyjnej do czasu planowanego [113–115]:

$$A = \frac{T_{up}}{T_{total}} \quad (4.37)$$

Wskaźnik ten jest miarą syntetyczną, obejmującą wpływ zarówno przestojów planowanych, jak i nieplanowanych. $MTBF$ (Mean Time Between Failures) wyznaczono jako średni czas pracy przypadający na jedno zdarzenie awaryjne [114, 115]:

$$MTBF = \frac{T_{up}}{N_f} \quad (4.38)$$

natomiast $MTTR$ (Mean Time To Repair) jako średni czas naprawy, tj. relację łącznego czasu napraw do liczby awarii [114, 115]:

$$MTTR = \frac{T_{repair}}{N_f} \quad (4.39)$$

Udział przestojów nieplanowanych DR (Downtime Ratio) obliczono jako relację czasu przestojów nieplanowanych do czasu planowanego floty [115]:

$$DR = \frac{T_{\text{down}}^{\text{unplanned}}}{T_{\text{total}}} \quad (4.40)$$

Koszt jednostkowy utrzymania C_{MS} wyznaczono przez odniesienie całkowitych kosztów utrzymania do czasu zdolności operacyjnej floty [115]:

$$C_{\text{unit}} = \frac{C_{\text{maint}}}{T_{\text{up}}} \quad (4.41)$$

Zastosowanie takiej struktury obliczeń pozwala jednocześnie ocenić wpływ zdarzeń awaryjnych na ciągłość pracy (dostępność, DR), parametry niezawodnościowe ($MTBF$, $MTTR$) oraz konsekwencje ekonomiczne w przeliczeniu na godzinę efektywnej pracy floty (C_{unit}).

W pierwszym kroku konieczne jest zdefiniowanie bazowego czasu odniesienia, tj. planowanego czasu pracy floty w miesiącu T_{total} . Jest to wielkość wynikająca z liczby AGV, liczby dni pracy oraz planowanej liczby godzin pracy na dobę. Zastosowanie T_{total} jako wspólnego mianownika umożliwia porównywanie miesięcy oraz normalizację miar przestojowych i dostępności w sytuacji, gdy analiza nie obejmuje jeszcze rozliczenia względem liczby misji transportowych.

Następnie wyznacza się łączny czas niedostępności T_{down} , który jest sumą przestojów nieplanowanych i planowanych. W ujęciu eksploatacyjnym rozróżnienie tych komponentów jest istotne, ponieważ przestoje planowane wynikają z harmonogramu utrzymania (np. przeglądy, regulacje), natomiast przestoje nieplanowane są bezpośrednim efektem awarii lub zakłóceń, a zatem w największym stopniu odzwierciedlają skuteczność działań predykcyjnych i prewencyjnych. Zależność [115]:

$$T_{\text{down}} = T_{\text{down}}^{\text{unplanned}} + T_{\text{down}}^{\text{planned}} \quad (4.42)$$

ma charakter bilansowy i porządkuje dane wejściowe do dalszych obliczeń.

Kolejną wielkością jest czas zdolności operacyjnej T_{up} , wyznaczany jako [115]:

$$T_{\text{up}} = T_{\text{total}} - T_{\text{down}} \quad (4.43)$$

co oznacza czas, w którym flota była dostępna do realizacji zadań (tj. mogła pracować zgodnie z planem). Ta wartość pełni kluczową rolę w dalszych KPI, ponieważ jest bezpośrednią miarą "czasu użytecznego" w miesiącu i stanowi podstawę do obliczeń dostępności oraz $MTBF$.

Dostępność A określa, jaka część planowanego czasu pracy floty była realnie dostępna [113–115]:

$$A = \frac{T_{\text{up}}}{T_{\text{total}}} \quad (4.44)$$

Interpretacyjnie wartość A jest niezwykle prosta: jeśli $A = 0,95$, to oznacza, że flota była zdolna do pracy przez 95% czasu planowego. W analizach wdrożeniowych dostępność pełni funkcję wskaźnika syntetycznego, ponieważ sumuje w sobie zarówno awarie, jak i część działań planowych, które redukują czas pracy w danym miesiącu. W kontekście strategii proaktywnej oczekuje się wzrostu dostępności, wynikającego przede wszystkim z redukcji przestojów nieplanowanych oraz stabilizacji procesów utrzymania.

4.2.8.2. Dane wejściowe i bilans czasu pracy floty

Parametry eksploatacyjne stanowiące warunki odniesienia dla kalkulacji przedstawiono w Tab. 4.11, natomiast dane miesięczne oraz wartości pośrednie przedstawiono w Tab. 4.12.

Tab. 4.11. Parametry eksploatacyjne floty (warunki odniesienia dla KPI).

Parametr	Oznaczenie	Wartość
Liczba AGV	N_{AGV}	12
Czas pracy na dobę	t_d	16 h
Liczba dni w miesiącu	D	30
Planowany czas pracy 1 AGV	$T_{plan,1}$	480 h
Planowany czas pracy floty	T_{plan}	5760 h

Źródło: Opracowanie własne.

Tab. 4.12. Dane wejściowe z eksploatacji przedsiębiorstwa oraz obliczenia pośrednie za okres 3 miesięcy.

Miesiąc	T_{down}^{unpl} [h]	T_{down}^{pl} [h]	N_f^*	T_{repair} [h]	C_{maint} [PLN]	T_{down} [h]	T_{up} [h]
M1	257	119	19	246	121430	376	5384
M2	172	109	13	158	88520	281	5479
M3	124	103	9	107	73310	227	5533

* N_f – liczba zdarzeń awaryjnych (awarii) zarejestrowanych w danym miesiącu dla floty badawczej, tj. dla $N_{AGV} = 12$.

Źródło: Opracowanie własne.

4.2.8.3. Wyniki KPI w warunkach rzeczywistej eksploatacji floty

Wyniki obliczeń KPI dla trzech kolejnych miesięcy pracy floty przedstawiono w Tab. 4.13. Wartości te stanowią miary wyznaczone na podstawie danych eksploatacyjnych przedsiębiorstwa dla tej samej, wytypowanej floty badawczej, w identycznym układzie czasowym i z zastosowaniem jednolitej metody agregacji miesięcznej.

Tab. 4.13. Wskaźniki KPI floty AGV w ujęciu miesięcznym.

Miesiąc	A [%]	MTBF [h]	MTTR [h]	DR [%]	C_{unit} [PLN/h]
M1	93.40	298.89	13.33	4.51	22.49
M2	95.14	456.67	12.50	2.95	16.24
M3	96.09	615.00	11.67	2.08	13.19

$$* C_{unit} = \frac{C_{maint}}{T_{up}}.$$

Źródło: Opracowanie własne.

W trakcie trzymiesięcznych badań wytypowanej floty AGV wartości KPI wykazują spójny trend zgodny z oczekiwaniami strategii proaktywnej. Dostępność wzrosła z 93.40% w pierwszym miesiącu do 96.09% w trzecim miesiącu, co oznacza poprawę o 2.69 p.p. i wskazuje na ograniczenie łącznego czasu niedostępności. Jednocześnie

udział przestojów nieplanowanych DR spadł z 4.51% do 2.08%, co jest zmianą o charakterze bezpośrednio "diagnostycznym" dla efektywności podejścia predykcyjnego: zmniejsza się udział zdarzeń awaryjnych, które zakłócają realizację zadań w sposób losowy i trudny do planowania. Poprawę niezawodności potwierdza wzrost $MTBF$ z 298.89 h do 615.00 h, co oznacza, że w analizowanym okresie awarie występowały istotnie rzadziej w relacji do czasu pracy floty. Równocześnie $MTTR$ uległ obniżeniu z 13.33 h do 11.67 h, co wskazuje na skrócenie przeciętnego czasu usuwania awarii, a więc poprawę sprawności procesu serwisowego. W wymiarze ekonomicznym koszt jednostkowy C_{unit} obniżył się z 22.49 PLN/h do 13.19 PLN/h, co oznacza poprawę efektywności kosztowej utrzymania w przeliczeniu na realny czas pracy floty.

Z punktu widzenia interpretacji wdrożeniowej istotne jest, że obserwowane zmiany KPI mają charakter spójny mechanicznie: spadek liczby awarii i przestojów nieplanowanych prowadzi do wzrostu czasu zdolności operacyjnej T_{up} , co bezpośrednio poprawia dostępność, a jednocześnie pozwala na obniżenie kosztu jednostkowego przez rozłożenie kosztów utrzymania na większą liczbę godzin pracy floty. Tego typu zależność jest zgodna z założeniami, że skuteczny model wspierający utrzymanie proaktywne powinien redukować losowe przestoje oraz umożliwiać wcześniejszą interwencję serwisową.

Dla oceny trendu obliczono zmianę względną KPI pomiędzy M3 i M1:

$$\Delta KPI\% = \frac{KPI_{M3} - KPI_{M1}}{KPI_{M1}} \cdot 100\% \quad (4.45)$$

Uzyskane wartości pokazują, że w trzecim miesiącu obserwacji (M3) względem pierwszego miesiąca (M1) dostępność wzrosła o 2.88% (różnica bezwzględna 2.69 p.p.), $MTBF$ wzrósł o 105.76%, udział przestojów nieplanowanych obniżył się o 53.88%, a koszt jednostkowy spadł o 41.35%. W ujęciu interpretacyjnym obserwowany trend odpowiada redukcji liczby awarii oraz ograniczeniu wpływu zdarzeń nieplanowanych na zdolność operacyjną floty, co jest zgodne z oczekiwaniami wobec strategii proaktywnej.

4.2.9. Kryteria akceptacji modelu rozmytego (warunki formalne i wdrożeniowe) – uzasadnienie doboru

W celu jednoznacznego rozstrzygnięcia, czy opracowany model rozmyty spełnia wymagania zarówno badawcze, jak i wdrożeniowe, zdefiniowano zestaw kryteriów akceptacji obejmujący trzy komplementarne poziomy oceny:

- 1) poziom formalno-logiczny (poprawność konstrukcji systemu rozmytego),
- 2) poziom skuteczności decyzyjnej (zgodność decyzji modelu z klasyfikacją referencyjną),
- 3) poziom efektu wdrożeniowego, rozumiany jako mierzalna zmiana parametrów eksploatacyjnych floty w ujęciu KPI.

Przyjęto podejście konserwatywne, zgodnie z którym model może zostać uznany za akceptowalny wyłącznie wtedy, gdy spełnia minimalne wymagania w każdym z trzech obszarów. Takie założenie wynika z faktu, że wysoka skuteczność klasyfikacji nie rekompensuje błędów strukturalnych (np. sprzeczności reguł), a poprawność

formalna modelu nie jest wystarczająca, jeżeli nie prowadzi do poprawy decyzji i efektów operacyjnych.

4.2.9.1. Kryteria formalno-logiczne (jakość konstrukcji modelu)

Pierwszą grupę stanowią kryteria weryfikujące wewnętrzną poprawność modelu jako systemu wnioskowania. Uwzględniono tu: pełne pokrycie dziedzin funkcji przynależności, brak sprzeczności reguł, monotoniczność oraz stabilność decyzji w warunkach perturbacji wejść.

Warunek pokrycia dziedzin $MF = 100\%$ jest kryterium koniecznym, ponieważ brak pokrycia oznacza istnienie obszarów wejściowych, dla których model nie jest w stanie przypisać przynależności lingwistycznej, co prowadzi do niestabilnego lub nieciągłego wnioskowania. Analogicznie, kryterium sprzeczności reguł $= 0$ oznacza, że dla tej samej konfiguracji przesłanek model nie generuje sprzecznych konsekwencji. Jest to warunek elementarnej spójności semantycznej bazy reguł i stanowi minimalny wymóg akceptacji niezależnie od wyników liczbowych walidacji.

Wskaźnik naruszeń monotoniczności V (ograniczono do poziomu) ujęto warunkiem [104, 105]:

$$V \leq 1.00\% \quad (4.46)$$

Monotoniczność jest pożądana, ponieważ w ujęciu eksploatacyjnym naturalna jest relacja typu "pogorszenie wejścia nie powinno prowadzić do poprawy decyzji". Jednocześnie, w systemach rozmytych z wieloma zbiorami lingwistycznymi dopuszcza się sporadyczne lokalne naruszenia monotoniczności wynikające z obszarów przejściowych pomiędzy funkcjami przynależności. Próg 1% oznacza, że ewentualne odstępstwa mają charakter marginalny i nie wpływają istotnie na globalną logikę modelu, a jednocześnie eliminują model o niestabilnym, "pofragmentowanym" zachowaniu w przestrzeni wejść.

Stabilność decyzji przy zakłóceniach wejść ujęto wskaźnikiem SI , dla którego przyjęto warunek [104, 105]:

$$SI \geq 90.00\% \quad (4.47)$$

Próg 90% ma charakter wdrożeniowo uzasadniony: w środowisku rzeczywistym dane wejściowe są obciążone niepewnością, a model użyteczny przemysłowo nie powinien zmieniać decyzji pod wpływem niewielkich fluktuacji wartości wejść (szum pomiarowy, zaokrąglenia, krótkotrwałe anomalie). Wartość 90% oznacza, że w zdecydowanej większości przypadków decyzja jest odporna na perturbacje i zmienia się jedynie w obszarach granicznych, co jest typowym i akceptowalnym zachowaniem modelu rozmytego.

4.2.9.2. Kryteria skuteczności decyzyjnej (zgodność ekspert-model)

Drugą grupę stanowią kryteria odnoszące się do zgodności klasyfikacji modelu z oceną referencyjną. Jako podstawową miarę przyjęto dokładność scenariuszową:

$$Acc \geq 92.00\% \quad (4.48)$$

Dobór progu 92% jest celowy z punktu widzenia interpretacji walidacji scenariuszowej: dla typowej liczby scenariuszy rzędu kilkunastu-kilkudziesięciu przyjęcie takiego poziomu oznacza w praktyce dopuszczenie co najwyżej pojedynczej rozbieżności przy zachowaniu wysokiej spójności decyzyjnej. Innymi słowy, próg ten eliminuje

model, który generuje kilka błędów o charakterze systemowym, a jednocześnie dopuszcza sporadyczne różnice w obszarach przejściowych, typowe dla klasyfikacji lingwistycznej.

Ponieważ warunki eksploatacyjne wiążą się z niepewnością pomiarową, wprowadzono dodatkowo kryterium odporności na zakłócenia:

$$Acc_{pert} \geq 90.00\% \quad (4.49)$$

Wartość 90% przyjęto jako minimalny poziom akceptowalnej stabilności klasyfikacji po perturbacji wejść, tj. w sytuacji "gorszej niż nominalna". Próg ten pełni funkcję zabezpieczenia wdrożeniowego: model spełniający Acc , ale niestabilny przy zakłóceniach, nie jest narzędziem operacyjnie wiarygodnym, ponieważ jego decyzja mogłaby zależeć od nawet niewielkich odchyłeń danych wejściowych.

W klasie krytycznej zastosowano kryteria o wyższej restrykcyjności, zgodnie z zasadą priorytetu bezpieczeństwa. Przyjęto minimalną czułość:

$$Recall_{krit} \geq 95.00\% \quad (4.50)$$

oraz minimalną precyzję:

$$Precision_{krit} \geq 90.00\% \quad (4.51)$$

Czułość klasy krytycznej ogranicza ryzyko błędów typu fałszywie negatywnych, tj. sytuacji, w której stan wymagający interwencji zostałby zaklasyfikowany jako ostrzegawczy lub akceptowalny. Jest to błąd o najwyższej wadze operacyjnej, ponieważ może prowadzić do dopuszczenia do pracy obiektu w stanie podwyższonego ryzyka. Próg 95% odpowiada podejściu konserwatywnemu, w którym liczba takich błędów powinna być bliska zeru. Z kolei precyzja klasy krytycznej ogranicza ryzyko fałszywych alarmów, które w nadmiarze prowadzą do przeciążenia utrzymania ruchu i obniżenia akceptowalności rozwiązania przez użytkownika operacyjnego. Próg 90% oznacza, że większość alarmów krytycznych musi być uzasadniona w świetle klasy referencyjnej.

4.2.9.3. Kryteria ilościowe dla wartości S^* (błąd numeryczny)

Trzecią część stanowią kryteria ilościowe odnoszące się do ciągłej wartości wyjściowej S^* . Zastosowanie miar MAE i $RMSE$ jest uzasadnione tym, że model rozmyty może formalnie przypisać poprawną klasę, ale jednocześnie generować wynik liczbowy bliski granicy decyzyjnej, co obniża stabilność decyzji w zastosowaniach praktycznych. Przyjęto progi [111, 112]:

$$MAE \leq 1.20, \quad RMSE \leq 1.50 \quad (4.52)$$

Uzasadnienie wartości progowych wynika z domeny wyjścia 0; 10 oraz charakteru decyzyjnego skali: błąd średni rzędu 1.2 punktu odpowiada ok. 12% pełnej skali i jest traktowany jako dopuszczalny w systemie lingwistycznym, w którym granice klas są rozmyte i zawierają obszary przejściowe. $RMSE$ ograniczono do 1.5, aby kontrolować wpływ pojedynczych większych odchyłeń, które mogłyby świadczyć o niestabilności modelu w scenariuszach nietypowych. Tak dobrane wartości dopuszczają naturalne wahania typowe dla systemów rozmytych, ale eliminują model, który wskazuje wyniki liczbowe wyraźnie odstające od referencyjnych poziomów klas.

4.2.9.4. Kryteria wdrożeniowe oparte na KPI (minimalny efekt operacyjny)

Ostatnią grupę stanowią kryteria wdrożeniowe, których celem jest wykazanie, że model jako narzędzie proaktywne daje nie tylko zgodność decyzyjną, ale również praktycznie mierzalny efekt eksploatacyjny. W tym obszarze nie wprowadzono progów absolutnych, lecz minimalne wymagania dotyczące kierunku i skali zmian KPI w porównaniu do okresu referencyjnego (np. przed wdrożeniem lub w odniesieniu do grupy kontrolnej).

Przyjęto następujące progi minimalne [104, 105]:

$$\Delta A \geq 1.00 \text{ p.p.} \quad (4.53)$$

$$\Delta MTBF \geq 10.00\% \quad (4.54)$$

$$\Delta DR \leq -10.00\% \quad (4.55)$$

$$\Delta C_{MS} \leq -5.00\% \quad (4.56)$$

Uzasadnienie progu $\Delta A \geq 1$ p.p. wynika z tego, że nawet pozornie niewielki wzrost dostępności przekłada się na wymierną liczbę godzin dodatkowej zdolności operacyjnej floty w miesiącu (dla dużych flot i długich czasów pracy jest to efekt praktycznie zauważalny). Próg $\Delta MTBF \geq 10\%$ przyjęto jako minimalną poprawę niezawodności świadczącą o ograniczeniu częstości awarii, co jest kluczowym celem podejścia predykcyjnego. Wskaźnik $\Delta DR \leq -10\%$ traktuje się jako kryterium bezpośrednio związane z redukcją nieplanowanych strat operacyjnych, a więc tym komponentem przestojów, który model proaktywny powinien ograniczać w pierwszej kolejności. Wreszcie próg $\Delta C_{MS} \leq -5\%$ odzwierciedla minimalny efekt ekonomiczny oczekiwany w sytuacji poprawy dostępności i ograniczenia awaryjności, przy jednoczesnym uwzględnieniu, że koszty utrzymania mogą wykazywać zmienność wynikającą z cen części, harmonogramów przeglądów oraz zdarzeń nieregularnych.

4.2.9.5. Zestaw kryteriów akceptacji (podsumowanie)

Zdefiniowane kryteria akceptacji umożliwiają ocenę modelu zarówno jako systemu wnioskowania (spójnego formalnie i stabilnego), jak i jako narzędzia wdrożeniowego, którego działanie przekłada się na wymierne efekty w obszarze utrzymania ruchu floty AGV. Jednocześnie przyjęcie podwyższonych wymagań dla klasy krytycznej odzwierciedla priorytet bezpieczeństwa operacyjnego oraz ogranicza ryzyko niedoszacowania stanów wymagających interwencji. W Tab. 4.14 zaprezentowano podsumowanie w postaci przyjętego zestawu kryteriów akceptacji przygotowanego w dysertacji rozwiązania.

Tab. 4.14. Zestaw kryteriów akceptacji modelu rozmytego (warunki formalne i wdrożeniowe).

Obszar oceny	Kryterium	Próg akceptacji
Weryfikacja	Pokrycie MF	100.00%
Weryfikacja	Sprzeczności reguł	0
Weryfikacja	Monotoniczność V	$V \leq 1.00\%$
Weryfikacja	Stabilność perturbacji SI	$SI \geq 90.00\%$
Walidacja	Dokładność scenariuszowa Acc	$Acc \geq 92.00\%$
Odporność	Dokładność przy zakłóceniach Acc_p	$Acc_p \geq 90.00\%$
Walidacja	Czułość klasy krytycznej $Recall_{crit}$	$Recall_{crit} \geq 95.00\%$
Walidacja	Precyzja klasy krytycznej $Precision_{crit}$	$Precision_{crit} \geq 90.00\%$
Ilościowo	$MAE, RMSE$	$MAE \leq 1.20,$ $RMSE \leq 1.50$
KPI	$A, MTBF, DR, C$	wg. (4.53)–(4.56)

Źródło: Opracowanie własne.

Wartości progowe dobrano w sposób konserwatywny jako minimalne warunki akceptacji, przyjmując, że model wdrażany w środowisku przemysłowym powinien jednocześnie wykazywać poprawność formalną, wysoką zgodność decyzyjną oraz odporność na niepewność danych wejściowych, a ponadto dostarczać mierzalny efekt eksploatacyjny. W obszarze KPI zmiany Δ należy interpretować jako różnicę względem okresu odniesienia, tj. w układzie przed–po wdrożeniu (porównanie miesięcy po uruchomieniu modelu z analogicznym okresem bazowym) albo w układzie A/B (flota wspierana modelem vs. flota kontrolna bez wsparcia modelu), przy zachowaniu porównywalnych warunków obciążenia. Przyjęte progi $\Delta A, \Delta MTBF, \Delta DR$ oraz ΔC_{MS} odzwierciedlają poziom zmian uznany za operacyjnie zauważalny, a jednocześnie realistyczny do osiągnięcia w krótkim horyzoncie obserwacji, przy uwzględnieniu naturalnej zmienności procesu utrzymania ruchu oraz warunków produkcyjnych.

4.3. Podsumowanie

Wyniki przeprowadzonej weryfikacji potwierdziły formalną poprawność opracowanego modelu oraz spójność logiczną procesu wnioskowania, co stanowi warunek konieczny jego wiarygodności jako narzędzia wspomagania decyzji. Walidacja scenariuszowa oraz testy odporności wykazały wysoką zgodność decyzji modelu z oceną ekspercką, również w warunkach zakłóceń danych wejściowych, co potwierdza zdolność modelu do działania w środowisku niepewności oraz jego stabilność decyzyjną.

Uzyskane wyniki wskazują, że przyjęta modelu FPMDF umożliwia skuteczną integrację informacji technicznych, operacyjnych, środowiskowych oraz historycznych, prowadząc do generowania spójnych, interpretowalnych i kontekstowo uzasadnionych rekomendacji dotyczących utrzymania ruchu. Potwierdzono tym samym, że zastosowane podejście pozwala na efektywne przekształcanie heterogenicznych danych eksploatacyjnych w użyteczne informacje wspomagające podejmowanie decyzji utrzymaniowych.

Analiza wskaźników KPI w ujęciu miesięcznym wskazała kierunkową poprawę

dostępności i niezawodności floty oraz redukcję udziału przestojów nieplanowanych i kosztu jednostkowego utrzymania, co pozostaje zgodne z założeniami podejścia proaktywnego. Jednocześnie należy podkreślić, że jednoznaczna interpretacja charakteru tych zmian wymaga dalszej weryfikacji w kontrolowanym układzie porównawczym.

W szczególności ostateczne potwierdzenie efektu wdrożeniowego wymaga zastosowania schematów badawczych typu A/B (flota wspierana modelem *vs* flota kontrolna) lub analiz przed–po (okres bazowy *vs* okres po wdrożeniu), przy zapewnieniu porównywalnego poziomu obciążenia systemu. Takie podejście umożliwi jednoznaczne przypisanie obserwowanych zmian KPI działaniu modelu oraz ograniczenie wpływu czynników zewnętrznych.

5

Wnioski, wkład pracy, ograniczenia oraz kierunki dalszych badań

5.1. Wnioski

Przeprowadzone badania pokazują, że opracowany model decyzyjny *Fuzzy Proactive Maintenance Decision Framework* (FPMDF) może skutecznie wspierać decyzje utrzymaniowe dotyczące eksploatacji systemów AGV pracujących w środowisku Magazynu 4.0. Uzyskane wyniki potwierdzają poprawność przyjętego podejścia oraz wskazują, że integracja informacji technicznych, operacyjnych, środowiskowych i historycznych stanowi użyteczne rozwiązanie wspomagające proces utrzymania ruchu w warunkach niepewności i wielowymiarowości danych.

Przyjęta architektura modelu frameworku pozwala traktować utrzymanie ruchu jako problem decyzyjny o charakterze wielokryterialnym. Integracja informacji o stanie technicznym, komunikacji, warunkach środowiskowych oraz historii eksploatacji umożliwia bardziej realistyczne odwzorowanie procesu podejmowania decyzji utrzymaniowych. W praktyce oznacza to odejście od analizy pojedynczych symptomów degradacji na rzecz podejścia systemowego uwzględniającego szerszy kontekst eksploatacyjny.

Poprawność opracowanego rozwiązania została potwierdzona w procesie weryfikacji i walidacji. Nie stwierdzono niespójności w definicjach zmiennych ani sprzeczności w bazie reguł. Jednocześnie wyniki walidacji scenariuszowej wskazują na wysoką zgodność z ocenami eksperckimi, co potwierdza zdolność frameworku do odwzorowania logiki decyzji stosowanej w praktyce utrzymania ruchu.

Analiza stabilności wykazała, że model frameworku jest odporny na niewielkie zakłócenia danych wejściowych. W większości przypadków perturbacje nie prowadzą do zmiany klasy decyzyjnej. Większa wrażliwość występuje jedynie w obszarach granicznych, co należy uznać za naturalną właściwość systemów rozmytych, a nie ich ograniczenie.

Istotnym elementem opracowanego modelu frameworku jest uwzględnienie priorytetu niezawodnościowego. Klasa *Krytyczny* została zdefiniowana w taki sposób, aby ograniczyć ryzyko błędnej klasyfikacji stanów o wysokim prawdopodobieństwie awarii do klas o niższym poziomie zagrożenia. Pozwala to na wcześniejsze identyfikowanie przypadków wymagających interwencji utrzymaniowej, co z punktu widzenia

zastosowań przemysłowych stanowi istotną właściwość proponowanego rozwiązania.

Ocena modelu FPMDF została rozszerzona o analizę wartości ciągłej S^* . Wprowadzenie miar MAE i RMSE umożliwiło ocenę nie tylko poprawności klasyfikacji, lecz również odległości wyniku od granic decyzyjnych. Dzięki temu możliwa była identyfikacja przypadków granicznych, istotnych z punktu widzenia dalszego doskonalenia frameworku.

Wyniki ewaluacji z wykorzystaniem wskaźników KPI wskazują na kierunkową poprawę dostępności i niezawodności floty oraz redukcję przestojów nieplanowanych i kosztu jednostkowego utrzymania. Należy jednak podkreślić, że uzyskane wyniki nie stanowią jednoznacznego dowodu zależności przyczynowo-skutkowych i wymagają dalszej weryfikacji w kontrolowanych warunkach badawczych.

Na podstawie przeprowadzonych analiz można stwierdzić, że cel główny rozprawy został osiągnięty. Rozwiązaniem przedstawionego problemu badawczego jest opracowanie modelu FPMDF, który umożliwia integrację informacji technicznych, operacyjnych, środowiskowych i historycznych w procesie wspomagania decyzji utrzymaniowych dla flot AGV. Wyniki przeprowadzonych badań potwierdzają poprawność opracowanego rozwiązania, jego zgodność z wiedzą ekspercką oraz potencjał aplikacyjny w środowiskach Magazynu 4.0. Uzyskane rezultaty wskazują również, że utrzymanie ruchu systemów AGV powinno być traktowane jako problem decyzyjny wymagający integracji wielu źródeł informacji oraz uwzględnienia niepewności występującej w rzeczywistych warunkach eksploatacji. Opracowany framework stanowi przykład takiego podejścia i może stanowić podstawę dalszych badań nad systemami wspomagania decyzji dla proaktywnego utrzymania ruchu oraz ich zastosowaniem w środowiskach Magazynu 4.0.

5.2. Wkład naukowy

Wkład naukowy rozprawy ma charakter koncepcyjny, metodyczny oraz aplikacyjny. Oryginalność pracy polega na opracowaniu spójnego i interpretowalnego modelu FPMDF jako modelu decyzyjnego, który integruje dane techniczne, kontekst operacyjny, warunki środowiskowe oraz informacje historyczne w ramach jednego systemu wnioskowania.

Praca odpowiada na potrzebę tworzenia modeli zdolnych do przetwarzania niepewnych i heterogenicznych danych eksploatacyjnych w systemach AGV funkcjonujących w środowisku Magazynu 4.0.

Najważniejsze elementy wkładu naukowego obejmują:

- 1) **Opracowanie interpretowalnego modelu decyzyjnego dla proaktywnego utrzymania ruchu AGV.** Zaproponowano model FPMDF, który umożliwia przejście od lokalnej diagnostyki do zintegrowanej decyzji utrzymaniowej. W odróżnieniu od podejść opartych wyłącznie na predykcji, model zachowuje pełną interpretowalność.
- 2) **Opracowanie wieloetapowej architektury modelu FPMDF.** Zaproponowano organizację procesu decyzyjnego umożliwiającą stopniową integrację informacji technicznych, operacyjnych, środowiskowych i historycznych. Przyjęta architektura wspiera interpretowalność procesu decyzyjnego oraz ogranicza złożoność modelu.
- 3) **Integracja analizy przyczynowej z formalnym modelowaniem.** Połączono diagram Ishikawy, analizę Pareto–Lorenza oraz modelowanie rozmyte w jeden spójny proces.

Takie podejście umożliwia przejście od identyfikacji przyczyn do formalnej struktury decyzyjnej.

- 4) **Formalizacja wiedzy eksperckiej w postaci reguł lingwistycznych.** Model odwzorowuje wiedzę ekspercką w sposób formalny, co pozwala na jej weryfikację, modyfikację oraz wykorzystanie w systemie wspomagania decyzji.
- 5) **Rozszerzenie metodyki oceny modeli decyzyjnych.** Zaproponowano podejście obejmujące nie tylko walidację klasyfikacji, ale także analizę stabilności, odporności na zakłócenia oraz ocenę wpływu na wskaźniki eksploatacyjne (KPI).
- 6) **Uwzględnienie priorytetu bezpieczeństwa w modelu decyzyjnym.** Konstrukcja modelu ogranicza ryzyko niedoszacowania stanów krytycznych, co stanowi istotne rozszerzenie klasycznych podejść optymalizacyjnych.
- 7) **Połączenie interpretowalności z potencjałem wdrożeniowym.** Opracowany model może być wykorzystany w środowisku Magazynu 4.0 bez utraty przejrzystości procesu decyzyjnego, co stanowi istotną przewagę nad modelami typu black-box.

W rezultacie rozprawa wnosi wkład nie tylko w rozwój modeli dla flot AGV, lecz także w szersze podejście do utrzymania ruchu jako problemu decyzyjnego, wielokryterialnego i kontekstowego.

5.3. Wkład praktyczny

Uzyskane wyniki mają bezpośrednie znaczenie dla zarządzania utrzymaniem ruchu flot AGV, szczególnie w środowiskach o wysokiej zmienności warunków operacyjnych.

- 1) Model generuje zarówno klasyfikację stanu (*akceptowalny / ostrzeżenie / krytyczny*), jak i ciągowy wskaźnik S^* , co umożliwia nie tylko ocenę stanu, ale również ranking pojazdów według priorytetu interwencji.
- 2) Może wspierać planowanie działań utrzymaniowych poprzez identyfikację przypadków wymagających wcześniejszej interwencji, szczególnie w sytuacjach granicznych.
- 3) Umożliwia powiązanie decyzji utrzymaniowych z mierzalnymi wskaźnikami efektywności (KPI), takimi jak dostępność, niezawodność oraz koszty.
- 4) Może być wdrażany stopniowo, od trybu obserwacyjnego, przez wsparcie decyzji, aż do integracji z systemami CMMS, bez konieczności zmiany istniejącej infrastruktury decyzyjnej.

5.4. Ograniczenia

Należy wskazać ograniczenia wpływające na interpretację wyników oraz możliwość ich uogólnienia. Ich identyfikacja pozwala określić zarówno zakres stosowalności modelu, jak i kierunki jego dalszego rozwoju.

- 1) Walidacja scenariuszowa nie zapewnia pełnej reprezentatywności statystycznej. Przyjęte scenariusze mają charakter celowy i umożliwiają analizę zachowania modelu w przypadkach typowych, skrajnych oraz konfliktowych, jednak nie stanowią losowej próby danych eksploatacyjnych.

- 2) Oceny eksperckie mogą wprowadzać element subiektywności. Pomimo zastosowania procedury konsensusu, klasy referencyjne odzwierciedlają wiedzę i doświadczenie ekspertów, co oznacza, że nie mają charakteru w pełni obiektywnego.
- 3) Analiza KPI obejmuje ograniczony horyzont czasowy. Trzymiesięczny okres obserwacji pozwala na identyfikację trendów, jednak nie umożliwia pełnej oceny stabilności efektów w dłuższym okresie eksploatacji.
- 4) Model został przetestowany w konkretnym kontekście operacyjnym, co oznacza, że uzyskane wyniki mogą być częściowo zależne od specyfiki badanej floty, organizacji procesu utrzymania oraz warunków pracy.

Dodatkowo model nie obejmuje prognozowania RUL (*Remaining Useful Life*), co ogranicza jego porównywalność z podejściami predykcyjnymi opartymi na estymacji czasu do uszkodzenia. Należy jednak podkreślić, że przyjęte podejście koncentruje się na wspomaganiu decyzji w warunkach niepewności, a nie na bezpośredniej predykcji awarii. Wskazane ograniczenia nie podważają poprawności modelu, lecz wyznaczają zakres jego stosowalności oraz uzasadniają kierunki dalszych badań.

5.5. Kierunki dalszych badań

Zaprezentowane wyniki badań potwierdzają zasadność zastosowania opracowanego modelu, ale jednocześnie wskazują obszary, w których można zwiększyć jego możliwości zastosowania, odporność oraz wartość wdrożeniową. Dlatego dalsze prace badawcze powinny koncentrować się na następujących kierunkach:

- 1) Walidacja na danych niezależnych i w innych środowiskach przemysłowych. Walidacja rozwiązania na danych niezależnych, pochodzących z innych flot oraz obiektów magazynowych, powinna zostać potraktowana jako kluczowy krok rozwojowy. Pozwoli to sprawdzić, czy model utrzymuje skuteczność po przeniesieniu na inną flotę, inny profil obciążenia lub odmienną organizację utrzymania. Tego typu badania ograniczają ryzyko, że uzyskane wyniki są specyficzne dla jednego zakładu lub jednego zestawu scenariuszy.
- 2) Potwierdzenie efektu wdrożeniowego w schemacie A/B lub przed–po w sposób kontrolowany i statystycznie uzasadniony. Ocena wpływu modelu na wskaźniki KPI powinna zostać przeprowadzona w układzie porównawczym, umożliwiającym jednoznaczne przypisanie obserwowanych zmian działaniu rozwiązania. W szczególności wskazane jest odniesienie KPI do miar obciążenia, takich jak liczba misji, czas cyklu lub intensywność pracy. Dopiero wówczas można wiarygodnie ocenić, czy zmiana KPI wynika z działania modelu, a nie z tego, że flota w danym okresie pracowała w innym trybie.
- 3) Rozwinięcie wykorzystania wyniku S^* jako podstawy do planowania serwisu. Rozwinięcie interpretacji ciągłego wyniku S^* może zwiększyć praktyczną wartość rozwiązania. Kolejnym krokiem jest formalizacja tego, w jaki sposób wynik ciągły przekłada się na priorytet interwencji, okno serwisowe oraz dobór działań prewencyjnych. Wprowadzenie reguły przejścia od diagnozy do harmonogramu wzmocni rolę modelu jako narzędzia decyzyjnego w utrzymaniu ruchu.
- 4) Badanie możliwości automatycznego strojenia funkcji przynależności i reguł przy zachowaniu interpretowalności. Zasadne jest zbadanie możliwości zastosowania

metod automatycznego strojenia, w tym metod optymalizacyjnych, które poprawiają parametry modelu, a jednocześnie utrzymują sens lingwistyczny reguł oraz nie osłabiają priorytetu bezpieczeństwa. Takie podejście może skrócić proces adaptacji modelu do nowych warunków eksploatacyjnych oraz zmniejszyć zależność od ręcznego strojenia.

- 5) Rozszerzenie testów odporności o zakłócenia typowe dla praktyki przemysłowej. Testy odporności warto rozszerzyć o przypadki bardziej zbliżone do warunków rzeczywistej eksploatacji, w tym braki danych, opóźnienia sygnałów oraz zakłócenia komunikacji. W praktyce przemysłowej pojawiają się nie tylko drobne szумы, lecz także utrata danych, błędy synchronizacji, przerwy w komunikacji lub anomalie skokowe. Uwzględnienie takich przypadków pozwoli ocenić granice stabilności modelu oraz zaprojektować mechanizmy zabezpieczające.
- 6) Uwzględnienie różnorodności floty oraz przejście od oceny statycznej do analizy trendu. Kolejnym krokiem powinno być uwzględnienie różnic pomiędzy typami wózków AGV oraz przejście od oceny statycznej do analizy zmian w czasie. Flota w praktyce nie jest jednorodna, a stan techniczny i obciążenie mogą się różnić pomiędzy poszczególnymi jednostkami. Z tego względu wskazane jest badanie przebiegu S^*t oraz powiązanie zmian wyniku z rzeczywistą degradacją i zdarzeniami serwisowymi. Kierunek ten może przybliżyć rozwiązanie do zastosowań o charakterze predykcyjnym, przy zachowaniu interpretowalności.
- 7) Uzupełnienie interpretacji KPI o wskaźniki wykonanej pracy floty. Interpretacja KPI powinna zostać rozszerzona o miary wykonanej pracy, aby uniknąć błędnych wniosków w warunkach zmiennego obciążenia. Dostępność i przestoje dobrze opisują bilans czasu, jednak dla porównań pomiędzy miesiącami istotne jest uwzględnienie liczby misji, długości tras lub innych miar intensywności. Takie podejście zwiększa porównywalność wyników oraz wzmacnia argumentację wdrożeniową.

Opracowany model wnosi wkład do rozwoju metod wspomagania decyzji w utrzymaniu ruchu autonomicznych systemów transportowych, łącząc zalety logiki rozmytej z wymaganiami współczesnych środowisk magazynowych opartych na koncepcji Przemysłu 4.0. Przedstawione podejście umożliwia uwzględnienie niepewności, wielokryterialności oraz złożonych zależności występujących w procesie oceny stanu technicznego AGV, stanowiąc podstawę do realizacji strategii utrzymania proaktywnego. Uzyskane wyniki potwierdzają zasadność przyjętych założeń badawczych oraz wskazują na możliwość dalszego rozwoju modelu w kierunku rozwiązań adaptacyjnych wykorzystujących dane eksploatacyjne pozyskiwane w czasie rzeczywistym.

Bibliografia

- [1] Kagermann, Henning, Wahlster, Wolfgang i Helbig, Johannes. „Recommendations for implementing the strategic initiative INDUSTRIE 4.0”. W: *Final report of the Industrie 4.0 Working Group* (2013).
- [2] Lee, Jay i in. „Industrial big data analytics and cyber-physical systems for future maintenance & service innovation”. W: *Procedia cirp* 38 (2015), s. 3–7.
- [3] Lu, Yang. „Industry 4.0: A survey on technologies, applications and open research issues”. W: *Journal of industrial information integration* 6 (2017), s. 1–10.
- [4] Winkelhaus, Sven i Grosse, Eric H. „Logistics 4.0: a systematic review towards a new logistics system”. W: *International journal of production research* 58.1 (2020), s. 18–43.
- [5] Boysen, Nils, De Koster, René i Weidinger, Felix. „Warehousing in the e-commerce era: A survey”. W: *European Journal of Operational Research* 277.2 (2019), s. 396–411.
- [6] Vis, Iris FA. „Survey of research in the design and control of automated guided vehicle systems”. W: *European journal of operational research* 170.3 (2006), s. 677–709.
- [7] Le-Anh, Tuan i De Koster, MBM2181217. „A review of design and control of automated guided vehicle systems”. W: *European journal of operational research* 171.1 (2006), s. 1–23.
- [8] Yan, Rundong, Dunnett, Sarah J i Jackson, Lisa M. „Novel methodology for optimising the design, operation and maintenance of a multi-AGV system”. W: *Reliability Engineering & System Safety* 178 (2018), s. 130–139.
- [9] Correia, Nuno, Teixeira, Leonor i Ramos, Ana Luísa. „Implementing an AGV system to transport finished goods to the warehouse”. W: *Advances in Science, Technology and Engineering Systems* 5.2 (2020), s. 241–247.
- [10] Jardine, Andrew KS, Lin, Daming i Banjevic, Dragan. „A review on machinery diagnostics and prognostics implementing condition-based maintenance”. W: *Mechanical systems and signal processing* 20.7 (2006), s. 1483–1510.
- [11] Bousdekis, Alexandros i in. „Decision making in predictive maintenance: Literature review and research agenda for industry 4.0”. W: *IFAC-PapersOnLine* 52.13 (2019), s. 607–612.
- [12] Carvalho, Thyago P i in. „A systematic literature review of machine learning methods applied to predictive maintenance”. W: *Computers & Industrial Engineering* 137 (2019), s. 106024.
- [13] Zonta, Tiago i in. „Predictive maintenance in the Industry 4.0: A systematic literature review”. W: *Computers & industrial engineering* 150 (2020), s. 106889.

- [14] Qi, Mingyao i in. „On the evaluation of AGVS-based warehouse operation performance”. W: *Simulation Modelling Practice and Theory* 87 (2018), s. 379–394.
- [15] Kosicka, Ewelina, Mazurkiewicz, Dariusz i Gola, Arkadiusz. „Problemy wspomagania decyzji w systemach utrzymania ruchu”. W: *Informatyka, Automatyka, Pomiar w Gospodarce i Ochronie Środowiska* 6.4 (2016), s. 49–52.
- [16] Zawierucha, Natalia. „Skuteczna strategia utrzymania ruchu na przykładzie przedsiębiorstwa z branży produkcyjnej”. W: *Nowoczesne Systemy Zarządzania* 20.1 (2025), s. 135–156.
- [17] Pincirolu, Luca, Baraldi, Piero i Zio, Enrico. „Maintenance optimization in industry 4.0”. W: *Reliability Engineering & System Safety* 234 (2023), s. 109204.
- [18] Lasi, Heiner i in. „Industry 4.0”. W: *Business & information systems engineering* 6.4 (2014), s. 239–242.
- [19] Lee, Jay, Bagheri, Behrad i Kao, Hung-An. „A cyber-physical systems architecture for industry 4.0-based manufacturing systems”. W: *Manufacturing letters* 3 (2015), s. 18–23.
- [20] Industry, BCG. „4.0: The Future of Productivity and Growth in Manufacturing Industries”. W: *BCG: Boston, MA, USA* (2015).
- [21] Zhong, Ray Y i in. „Intelligent manufacturing in the context of industry 4.0: a review”. W: *Engineering* 3.5 (2017), s. 616–630.
- [22] Zheng, Pai i in. „Smart manufacturing systems for Industry 4.0: Conceptual framework, scenarios, and future perspectives”. W: *Frontiers of Mechanical Engineering* 13.2 (2018), s. 137–150.
- [23] Lu, Haiyan, Zhao, Guoqing i Liu, Shaofeng. „Integrating circular economy and Industry 4.0 for sustainable supply chain management: a dynamic capability view”. W: *Production Planning & Control* 35.2 (2024), s. 170–186.
- [24] Mattos Nascimento, Daniel Luiz de i in. „Interrelationships between circular economy and Industry 4.0: A research agenda for sustainable supply chains”. W: *Business Strategy and the Environment* 33.2 (2024), s. 575–596.
- [25] Abdulameer, Susan Sabah i Ibrahim, Yousif Munadhil. „Leveraging Industry 4.0 technologies, AI-based supply chain analytics and circular economy practices for net-zero and sustainable supply chain performance: a moderated mediation model”. W: *Supply Chain Management: An International Journal* 30.6 (2025), s. 701–718.
- [26] Ivanov, Dmitry, Dolgui, Alexandre i Sokolov, Boris. „The impact of digital technology and Industry 4.0 on the ripple effect and supply chain risk analytics”. W: *International journal of production research* 57.3 (2019), s. 829–846.
- [27] Tjahjono, Benny i in. „What does industry 4.0 mean to supply chain?” W: *Procedia manufacturing* 13 (2017), s. 1175–1182.
- [28] Wang, Gang i in. „Big data analytics in logistics and supply chain management: Certain investigations for research and applications”. W: *International journal of production economics* 176 (2016), s. 98–110.

- [29] Ghalehkhondabi, Iman, Ahmadi, Ehsan i Maihami, Reza. „An overview of big data analytics application in supply chain management published in 2010-2019”. W: *Production* 30 (2020), e20190140.
- [30] Zhou, Lei. „The Convergence of IoT, Big Data, and International Logistics: Enhancing Supply Chain Efficiency”. W: *Law and Economy* 2.9 (2023), s. 35–40.
- [31] Tubis, Agnieszka A i Rohman, Juni. „Intelligent warehouse in industry 4.0—systematic literature review”. W: *Sensors* 23.8 (2023), s. 4105.
- [32] Zhen, Lu i Li, Haolin. „A literature review of smart warehouse operations management”. W: *Frontiers of Engineering Management* 9.1 (2022), s. 31–55.
- [33] Kamali, Ali. „Smart warehouse vs. traditional warehouse”. W: *CiiT International Journal of Automation and Autonomous System* 11.1 (2019), s. 9–16.
- [34] Boysen, Nils i De Koster, René. „50 years of warehousing research—An operations research perspective”. W: *European Journal of Operational Research* 320.3 (2025), s. 449–464.
- [35] Sodiya, Enoch Oluwademilade i in. „AI-driven warehouse automation: A comprehensive review of systems”. W: *GSC Advanced Research and Reviews* 18.2 (2024), s. 272–282.
- [36] Aravindaraj, K i Chinna, P Rajan. „A systematic literature review of integration of industry 4.0 and warehouse management to achieve Sustainable Development Goals (SDGs)”. W: *Cleaner logistics and supply chain* 5 (2022), s. 100072.
- [37] Ali, Imran i Phan, Huy Minh. „Industry 4.0 technologies and sustainable warehousing: A systematic literature review and future research agenda”. W: *The International Journal of Logistics Management* 33.2 (2022), s. 644–662.
- [38] Tikwayo, Lihle N i Mathaba, Tebello ND. „Applications of industry 4.0 technologies in warehouse management: A systematic literature review”. W: *Logistics* 7.2 (2023), s. 24.
- [39] Büyüközkan, Gülçin i Göçer, Fethullah. „Digital Supply Chain: Literature review and a proposed framework for future research”. W: *Computers in industry* 97 (2018), s. 157–177.
- [40] Tao, Fei i in. „Digital twin-driven product design, manufacturing and service with big data”. W: *The International Journal of Advanced Manufacturing Technology* 94.9 (2018), s. 3563–3576.
- [41] Taj, Soonh i in. „IoT-based supply chain management: A systematic literature review”. W: *Internet of Things* 24 (2023), s. 100982.
- [42] Younis, Hassan, Sundarakani, Balan i Alsharairi, Malek. „Applications of artificial intelligence and machine learning within supply chains: systematic review and future research directions”. W: *Journal of Modelling in Management* 17.3 (2022), s. 916–940.
- [43] Zamani, Efpraxia D i in. „Artificial intelligence and big data analytics for supply chain resilience: a systematic literature review”. W: *Annals of Operations Research* 327.2 (2023), s. 605–632.


- [44] Kritzinger, Werner i in. „Digital Twin in manufacturing: A categorical literature review and classification”. W: *Ifac-PapersOnline* 51.11 (2018), s. 1016–1022.
- [45] Zhou, Keliang, Liu, Taigang i Zhou, Lifeng. „Industry 4.0: Towards future industrial opportunities and challenges”. W: *2015 12th International conference on fuzzy systems and knowledge discovery (FSKD)*. IEEE. 2015, s. 2147–2152.
- [46] Pournader, Mehrdokht i in. „Blockchain applications in supply chains, transport and logistics: a systematic review of the literature”. W: *International Journal of Production Research* 58.7 (2020), s. 2063–2081.
- [47] Queiroz, Maciel M., Telles, Renato i Bonilla, Silvia H. „Blockchain and supply chain management integration: A systematic review of the literature”. W: *Supply Chain Management: An International Journal* 25.2 (2020), s. 241–254. doi: 10.1108/SCM-03-2018-0143.
- [48] Copigneaux, Bertrand i in. *Blockchain for supply chains and international trade*. Spraw. tech. PE 641.544. Study requested by the European Parliament’s Committee on International Trade. Brussels: European Parliamentary Research Service, 2020. URL: [https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641544/EPRS_STU\(2020\)641544_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2020/641544/EPRS_STU(2020)641544_EN.pdf).
- [49] Perussi, Jéssica Bruna, Gressler, Fernando i Seleme, Robson. „Supply chain 4.0: Autonomous vehicles and equipment to meet demand”. W: *International Journal of Supply Chain Management* 8.4 (2019), s. 33–41.
- [50] Rejeb, Abderahman i in. „Drones for supply chain management and logistics: a review and research agenda”. W: *International Journal of Logistics Research and Applications* 26.6 (2023), s. 708–731.
- [51] Villani, Valeria i in. „Survey on human–robot collaboration in industrial settings: Safety, intuitive interfaces and applications”. W: *Mechatronics* 55 (2018), s. 248–266.
- [52] Javaid, Mohd i in. „Significant applications of Cobots in the field of manufacturing”. W: *Cognitive Robotics* 2 (2022), s. 222–233.
- [53] Stoltz, Marie-Hélène i in. „Augmented reality in warehouse operations: opportunities and barriers”. W: *IFAC-PapersOnLine* 50.1 (2017), s. 12979–12984.
- [54] Merino, Leonel i in. „Evaluating mixed and augmented reality: A systematic literature review (2009-2019)”. W: *2020 IEEE international symposium on mixed and augmented reality (ISMAR)*. IEEE. 2020, s. 438–451.
- [55] Lewczuk, Konrad i Żuchowicz, Patryk. „Virtual reality application for the safety improvement of intralogistics systems”. W: *Sustainability* 16.14 (2024), s. 6024.
- [56] Pietrantoni, Luca i in. „Integrating collaborative robots in manufacturing, logistics, and agriculture: Expert perspectives on technical, safety, and human factors”. W: *Frontiers in Robotics and AI* 11 (2024), s. 1342130.
- [57] Kakade, Siddhant, Patle, Bhumeswar i Umbarkar, Ashish. „Applications of collaborative robots in agile manufacturing: a review”. W: *Robotic Systems and Applications* 3.1 (2023), s. 59–83.

- [58] Gackowiec, Paulina. „General overview of maintenance strategies–concepts and approaches”. W: *Multidisciplinary Aspects of Production Engineering* 2 (2019).
- [59] Mallioris, Panagiotis, Aivazidou, Eirini i Bechtsis, Dimitrios. „Predictive maintenance in Industry 4.0: A systematic multi-sector mapping”. W: *CIRP journal of manufacturing science and technology* 50 (2024), s. 80–103.
- [60] Krynke, Marek. „Predictive management in the context of industry 4.0”. W: *Quality Production Improvement-QPI* 3 (2021).
- [61] Uppal, Mudita i in. „A Real-Time Data Monitoring Framework for Predictive Maintenance Based on the Internet of Things”. W: *Complexity* 2023.1 (2023), s. 9991029.
- [62] Hector, Ida i Panjanathan, Rukmani. „Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques”. W: *PeerJ Computer Science* 10 (2024), e2016.
- [63] Pech, Martin, Vrchota, Jaroslav i Bednář, Jiří. „Predictive maintenance and intelligent sensors in smart factory”. W: *Sensors* 21.4 (2021), s. 1470.
- [64] Pietsch, Dominik i in. „Root cause analysis in industrial manufacturing: A scoping review of current research, challenges and the promises of AI-driven approaches”. W: *Journal of Manufacturing and Materials Processing* 8.6 (2024), s. 277.
- [65] Fragapane, Giuseppe i in. „Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda”. W: *European journal of operational research* 294.2 (2021), s. 405–426.
- [66] Lackner, Thorge i in. „Review of autonomous mobile robots in intralogistics: state-of-the-art, limitations and research gaps”. W: *Procedia CIRP* 130 (2024), s. 930–935.
- [67] Ellithy, Kareim i in. „AGV and Industry 4.0 in warehouses: a comprehensive analysis of existing literature and an innovative framework for flexible automation”. W: *The International Journal of Advanced Manufacturing Technology* 134.1 (2024), s. 15–38.
- [68] Tubis, Agnieszka A i Poturaj, Honorata. „Risk related to AGV systems—Open-access literature review”. W: *Energies* 15.23 (2022), s. 8910.
- [69] Li, Li i Schulze, Lothar. „Failure Prediction of Automated Guided Vehicle Systems in Production Environments through Artificial Intelligence”. W: *Tehnički glasnik* 18.2 (2024), s. 268–272.
- [70] Bertoli, Annalisa, Battilani, Nicola i Fantuzzi, Cesare. „Fault diagnosis and identification in agvs system”. W: *IFAC-PapersOnLine* 58.4 (2024), s. 246–251.
- [71] Shubyn, Bohdan i in. „Federated Learning for improved prediction of failures in Autonomous Guided Vehicles”. W: *Journal of Computational Science* 68 (2023), s. 101956.
- [72] Zając, Jerzy i in. „Konstrukcja i układ sterowania autonomicznej platformy mobilnej”. W: *Pomiary Automatyka Robotyka* 15 (2011), s. 382–391.

- [73] Thrun, Sebastian. „Probabilistic robotics”. W: *Communications of the ACM* 45.3 (2002), s. 52–57.
- [74] Khaleghi, Bahador i in. „Multisensor data fusion: A review of the state-of-the-art”. W: *Information fusion* 14.1 (2013), s. 28–44.
- [75] Humayed, Abdulmalik i in. „Cyber-physical systems security—A survey”. W: *IEEE Internet of Things Journal* 4.6 (2017), s. 1802–1831.
- [76] Govindan, Kannan i in. „Supply Chain 4.0 performance measurement: A systematic literature review, framework development, and empirical evidence”. W: *Transportation Research Part E: Logistics and Transportation Review* 164 (2022), s. 102725.
- [77] Shaheen, Basheer Wasef i Németh, István. „Integration of maintenance management system functions with industry 4.0 technologies and features—A review”. W: *Processes* 10.11 (2022), s. 2173.
- [78] Achouch, Mounia i in. „On predictive maintenance in industry 4.0: Overview, models, and challenges”. W: *Applied sciences* 12.16 (2022), s. 8081.
- [79] Jasiulewicz-Kaczmarek, Małgorzata, Legutko, Stanisław i Kluk, Piotr. „Maintenance 4.0 technologies—new opportunities for sustainability driven maintenance”. W: *Management and production engineering review* 11 (2020).
- [80] Kosacka-Olejniak, Monika i in. „How digital twin concept supports internal transport systems?—Literature review”. W: *Energies* 14.16 (2021), s. 4919.
- [81] Koreis, Jonas i in. „We belong together—A system-level investigation regarding AGV-assisted order picking performance”. W: *International Journal of Production Economics* 282 (2025), s. 109527.
- [82] Gholipour, Yousof. „A Comprehensive Review of Maintenance Strategies: From Reactive to Proactive Approaches”. W: *Available at SSRN* 5349871 (2025).
- [83] Nowakowski, Tomasz, Tubis, Agnieszka i Werbińska-Wojciechowska, Sylwia. „Evolution of technical systems maintenance approaches—review and a case study”. W: *International conference on intelligent systems in production engineering and maintenance*. Springer. 2019, s. 161–174.
- [84] Werbińska-Wojciechowska, Sylwia i Winiarska, Klaudia. „Maintenance performance in the age of Industry 4.0: A bibliometric performance analysis and a systematic literature review”. W: *Sensors* 23.3 (2023), s. 1409.
- [85] Mobley, R Keith. *An introduction to predictive maintenance*. Elsevier, 2002.
- [86] Alaswad, Suzan i Xiang, Yisha. „A review on condition-based maintenance optimization models for stochastically deteriorating system”. W: *Reliability engineering & system safety* 157 (2017), s. 54–63.
- [87] Gomaa, Attia Hussien. „Digital Twins for Improving Proactive Maintenance Management”. W: *Engineering Science* 9.3 (2024), s. 60–70.
- [88] Theissler, Andreas i in. „Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry”. W: *Reliability engineering & system safety* 215 (2021), s. 107864.

- [89] Khan, Faisal I i Haddara, Mahmoud M. „Risk-based maintenance (RBM): a quantitative approach for maintenance/inspection scheduling and planning”. W: *Journal of loss prevention in the process industries* 16.6 (2003), s. 561–573.
- [90] Arunraj, NS i Maiti, J. „Risk-based maintenance—Techniques and applications”. W: *Journal of hazardous materials* 142.3 (2007), s. 653–661.
- [91] Bousdekis, Alexandros i in. „A proactive decision making framework for condition-based maintenance”. W: *Industrial Management & Data Systems* 115.7 (2015), s. 1225–1250.
- [92] Matyas, Kurt i in. „A procedural approach for realizing prescriptive maintenance planning in manufacturing industries”. W: *Cirp Annals* 66.1 (2017), s. 461–464.
- [93] Orošnjak, Marko, Saretzky, Felix i Kedziora, Slawomir. „Prescriptive maintenance: A systematic literature review and exploratory meta-synthesis”. W: *Applied Sciences* 15.15 (2025), s. 8507.
- [94] Erozan, İhsan. „A fuzzy decision support system for managing maintenance activities of critical components in manufacturing systems”. W: *Journal of Manufacturing Systems* 52 (2019), s. 110–120.
- [95] Ishikawa, Kaoru i in. „Guide to quality control”. W: (1982).
- [96] Juran, Joseph M. *Juran's quality handbook*. 1999.
- [97] Zadeh, Lotfi A. „Fuzzy sets”. W: *Information and control* 8.3 (1965), s. 338–353.
- [98] Mamdani, Ebrahim H i Assilian, Sedrak. „An experiment in linguistic synthesis with a fuzzy logic controller”. W: *International journal of man-machine studies* 7.1 (1975), s. 1–13.
- [99] Klir, George J i Yuan, Bo. „Fuzzy sets and fuzzy logic: theory and applications”. W: *Possibility Theory versus Probab. Theory* 32.2 (1996), s. 207–208.
- [100] Mukherjee, Anshit, Mallik, Biswadip Basu i Banerjee, Sohini. „Applications of Fuzzy Logic in Engineering”. W: *Engineering the Circular Economy* (2025), s. 25–49.
- [101] Kerk, Yi Wen, Tay, Kai Meng i Lim, Chee Peng. „Monotone interval fuzzy inference systems”. W: *IEEE Transactions on Fuzzy Systems* 27.11 (2019), s. 2255–2264.
- [102] Sadjadi, Ebrahim Navid. „On the monotonicity of smooth fuzzy systems”. W: *IEEE Transactions on Fuzzy Systems* 29.12 (2020), s. 3947–3952.
- [103] De Baets, Bernard i De Meyer, Hans. „Maximal directions of monotonicity of an aggregation function”. W: *Fuzzy Sets and Systems* 433 (2022), s. 54–78.
- [104] Ying, Hao. „Stability Analysis and Design of Mamdani and TS Fuzzy Control Systems”. W: (2000).
- [105] Wang, Jian i in. „Sensitivity analysis of Takagi–Sugeno fuzzy neural network”. W: *Information Sciences* 582 (2022), s. 725–749.

- [106] Sokolova, Marina i Lapalme, Guy. „A systematic analysis of performance measures for classification tasks”. W: *Information processing & management* 45.4 (2009), s. 427–437.
- [107] Keilwagen, Jens, Grosse, Ivo i Grau, Jan. „Area under precision-recall curves for weighted and unweighted data”. W: *PloS one* 9.3 (2014), e92209.
- [108] Fawcett, Tom. „An introduction to ROC analysis”. W: *Pattern recognition letters* 27.8 (2006), s. 861–874.
- [109] „Statistical Inference for Stochastic Processes”. W: *Statistical Inference for Stochastic Processes* 4.2 (2001), s. 1–2. DOI: 10.1023/A:1017522416340. URL: <https://doi.org/10.1023/A:1017522416340>.
- [110] Brown, Lawrence D, Cai, T Tony i DasGupta, Anirban. „Interval estimation for a binomial proportion”. W: *Statistical science* 16.2 (2001), s. 101–133.
- [111] Hyndman, Rob J i Koehler, Anne B. „Another look at measures of forecast accuracy”. W: *International journal of forecasting* 22.4 (2006), s. 679–688.
- [112] Chai, Tianfeng i Draxler, Roland R. „Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature”. W: *Geoscientific model development* 7.3 (2014), s. 1247–1250.
- [113] Zuberek, Wlodek M i Strzeciwiłk, Dariusz. „Modeling Quality of Service Techniques for Packet”. W: *Dependability Engineering* (2018), s. 125.
- [114] *Petroleum, Petrochemical and Natural Gas Industries — Collection and Exchange of Reliability and Maintenance Data for Equipment*. Geneva, Switzerland: International Organization for Standardization, 2016.
- [115] *Maintenance — Maintenance Terminology*. Brussels, Belgium: CEN, 2017.



Aneks

A.1. Wartości krytyczne i progi dla zmiennych wejściowych modelu FIS

Tab. A.1 w Aneksie A zawiera ujednolicone wartości graniczne i zakresy progowe dla zmiennych diagnostycznych i kontekstowych (technicznych, środowiskowych oraz historycznych) zastosowanych w modelu FIS. Zestawienie to pełni rolę “mapy” parametryzacji systemu: na jego podstawie zdefiniowano punkty charakterystyczne funkcji przynależności na poziomie 1 oraz zapewniono spójne powiązanie oceny rozmytej z rekomendowanymi działaniami utrzymaniowymi. Dzięki temu decyzje generowane przez model pozostają przejrzyste i możliwe do uzasadnienia w odniesieniu do przyjętych kryteriów eksploatacyjnych.

Tab. A.1. Wartości krytyczne i progi dla zmiennych wejściowych modelu FIS (Aneks A, Tab. A.1)

Nazwa bloku FIS	Wejście do bloku FIS	Kategoria	Wartość / próg	Opis	Zalecane działania
Poprawność funkcjonowania systemu zasilania	Liczba cykli ład./rozładowania	Krytyczna	> 1500 cykli	Akumulator na skraju żywotności, wymiana konieczna.	Natychmiast planuj wymianę akumulatora.
		Podwyższona	1000–1500 cykli	Znaczna degradacja, spadek wydajności prawdopodobny.	Zintensyfikuj monitoring, rozważ ograniczenie obciążenia, szczególnie planuj harmonogram wymiany.
		Niska	≤ 1000 cykli	Akumulator w akceptowalnym stanie, choć wydajność może się obniżyć.	Kontynuuj normalne użytkowanie, regularnie sprawdzaj stan i wydajność, dostosuj plan doładowań, jeżeli zauważysz spadek wydajności.
	Stan naładowania akumulatora (SoC)	Krytyczny	< 25%	Akumulator bliski całkowitego rozładowania, ryzyko wyłączenia systemu.	Natychmiastowe ładowanie, zapobieganie wyłączeniu systemu.
		Obniżony	25–75%	Niski poziom energii, wymaga szybkiego doładowania.	Priorytetowe ładowanie, monitorowanie stanu akumulatora.
		W normie	≥ 75%	Optymalny poziom naładowania zapewniający stabilną pracę.	Kontynuować normalne użytkowanie i planowe ładowanie w przyszłości.
	Napięcie akumulatora	Krytyczne	< 22 V	Niski poziom napięcia, ryzyko problemów.	Sprawdź zasilanie i natychmiast naładuj/wymień!
		Obniżone	22–24 V	Umiarkowany poziom, wymaga monitorowania.	Monitoruj uważnie i przygotuj do naładowania.
		W normie	≥ 24 V	Poziom w normie, system działa poprawnie.	Kontynuuj normalne użytkowanie i regularny monitoring.
Poprawność funkcj. ukł. napędowego	Poziom wibracji kół	Nieakceptowalny	> 1.5 mm/s ²	Silne wibracje, wysokie ryzyko awarii mechanicznej.	Natychmiastowa konserwacja, inspekcja i naprawa.
		Podwyższony	1.2–1.5 mm/s ²	Zauważalna niestabilność, ryzyko niewłaściwego wyrównania.	Zwiększone monitorowanie i planowanie konserwacji.

Kontynuacja na następnej stronie

Nazwa bloku FIS	Wejście do bloku FIS	Kategoria	Wartość / próg	Opis	Zalecane działania
	Czas reakcji hamulca	W normie	$< 1.2 \text{ mm/s}^2$	Płynna praca, brak problemów.	Kontynuować normalne użytkowanie i regularne monitorowanie.
		Nieakceptowalny	$> 150 \text{ ms}$	Poważne opóźnienie reakcji hamulca, wysokie ryzyko wypadku.	Natychmiast wyłącz z użytku i przeprowadź szczegółową inspekcję układu hamulcowego.
		Obniżony	50–150 ms	Zauważalne opóźnienie, może prowadzić do niebezpiecznych sytuacji.	Zintensyfikuj monitorowanie i przygotuj się do konserwacji.
		W normie	$\leq 50 \text{ ms}$	Akceptowalny czas reakcji hamulca, system działa poprawnie.	Kontynuuj regularne przeglądy i testy układu hamulcowego.
Poprawność funkcjonowania systemu nawigacyjnego	Stan techniczny enkodera koła	Krytyczny	$< 70\%$	Poniżej 80% mogą wystąpić problemy z nawigacją.	Natychmiastowa konserwacja i wymiana enkodera.
		Wymagający uwagi	70–90%	Zmniejszona dokładność pomiarów.	Monitorowanie stanu enkodera, kalibracja lub wymiana na model zgodny z normami.
		Prawidłowy	$> 90\%$	Prawidłowe działanie, wysoka dokładność.	Kontynuować normalne użytkowanie, regularne kontrole funkcjonalności enkodera.
	Dokładność kalibracji oprogramowania sterującego	Nieakceptowalna	$> 4\%$	Poważny błąd kalibracji, wysokie ryzyko błędnych pomiarów.	Natychmiast przerwij pracę i przeprowadź kompleksową kalibrację systemu.
		Wymagająca uwagi	2–4%	Zauważalny błąd, może prowadzić do nieprecyzyjnych wyników.	Zintensyfikuj monitorowanie i przygotuj się do ponownej kalibracji.
		W normie	$\leq 2\%$	Akceptowalny błąd, system działa w zakresie specyfikacji.	Kontynuuj regularne testy kalibracyjne i monitorowanie.
Poprawność funkcjonowania układu przenoszenia ładunku	Masa przenoszonego/przewożonego ładunku	Niedozwolona	$> 120\%$	Znaczne przeciążenie, ekstremalne ryzyko uszkodzenia i zagrożenie bezpieczeństwa.	Natychmiastowe opróżnienie ładunku i wyłączenie pojazdu z eksploatacji do czasu przeprowadzenia szczegółowej inspekcji.

Kontynuacja na następnej stronie

Nazwa bloku FIS	Wejście do bloku FIS	Kategoria	Wartość / próg	Opis	Zalecane działania
		Podwyższona	100–120%	Przeciążenie, zwiększone ryzyko uszkodzenia i obniżona stabilność.	Ogranicz prędkość i monitoruj stan pojazdu. Przygotuj się do zmniejszenia ładunku, jeśli parametry będą się pogarszać.
		Optymalna	$\leq 100\%$	Bezpieczne obciążenie, optymalne warunki pracy.	Kontynuować normalne użytkowanie i regularnie sprawdzać stan ładunku.
	Poziom regulacji pochylenia chwytaka	Nieakceptowalna	> 3 cm	Wysoka niewłaściwość, ryzyko nieudanych podnoszeń.	Natychmiast wyłącz system i przeprowadź regulację/konserwację chwytaka.
		Obniżony w stosunku do normy	2–3 cm	Możliwe opóźnienia operacyjne, utrata dokładności.	Zintensyfikuj monitorowanie i przygotuj się do regulacji chwytaka.
		Prawidłowy	≤ 2 cm	Akceptowalne wyrównanie, sprawne działanie chwytaka.	Kontynuuj monitorowanie i regularne sprawdzanie stanu chwytaka.
	Integralność strukturalna obudowy	Krytyczna	$< 70\%$	Poważne uszkodzenia struktury, wysokie ryzyko awarii.	Natychmiastowa ocena stanu konstrukcji i wycofanie AGV z eksploatacji.
		Obniżona	70–90%	Zmniejszona integralność, możliwe lokalne uszkodzenia.	Zintensyfikowane monitorowanie i planowanie szczegółowej konserwacji.
		Prawidłowa	$> 90\%$	Wysoka integralność strukturalna, brak problemów.	Kontynuować normalne użytkowanie oraz regularne inspekcje w celu utrzymania bezpieczeństwa.
	Poprawność realizacji komunikacji z urządzeniem	Krytyczny	> 70 dBm	Bardzo słaby sygnał, bliski całkowitemu brakowi połączenia, uniemożliwiający sterowanie AGV.	Natychmiastowa konserwacja i przywrócenie łączności.
		Niestabilny	30–70 dBm	Słaby sygnał, zakłócenia w komunikacji są prawdopodobne.	Zintensyfikowane monitorowanie stanu sygnału i analiza przyczyn jego osłabienia.

Kontynuacja na następnej stronie

Nazwa bloku FIS	Wejście do bloku FIS	Kategoria	Wartość / próg	Opis	Zalecane działania
Wpływ czynników środowiska pracy na urządzenie (Pomijalny / Istotny / Krytyczny)	Zwłoka w reakcji na sygnał sterujący	Stabilny	$< 30 \text{ dBm}$	Sygnał w normie, stabilne połączenie, efektywne sterowanie AGV.	Kontynuuj monitorowanie i regularne sprawdzanie jakości połączenia.
		Nieakceptowalna	$> 150 \text{ ms}$	Poważne opóźnienia komunikacyjne, ryzyko utraty kontroli nad AGV.	Natychmiastowa konserwacja i optymalizacja sieci.
		Zauważalne opóźnienie	$100\text{--}150 \text{ ms}$	Opóźnienie w odpowiedzi systemu, możliwe problemy w sterowaniu.	Monitorowanie stanu sieci i analiza przyczyn opóźnień.
		Brak	$\leq 100 \text{ ms}$	Komunikacja w normie, efektywne sterowanie AGV.	Kontynuuj monitorowanie i regularne sprawdzanie wydajności komunikacji oraz zasobów systemowych.
	Poziom zapylenia	Nieakceptowalna	$> 150 \mu\text{g}/\text{m}^3$	Poważne zapylenie, wysokie ryzyko uszkodzenia czujników AGV.	Natychmiastowe działania w celu zmniejszenia zapylenia (np. wentylacja i oczyszczanie powietrza) oraz kontrola stanu technicznego i czyszczenie czujników.
		Podwyższony	$100\text{--}150 \mu\text{g}/\text{m}^3$	Zwiększone ryzyko uszkodzeń czujników i obniżona wydajność.	Monitorowanie poziomu zapylenia, wdrożenie filtracji powietrza i częstsze czyszczenie czujników.
		W normie	$\leq 100 \mu\text{g}/\text{m}^3$	Akceptowalny poziom zapylenia, optymalne warunki pracy dla AGV.	Kontynuować normalne użytkowanie i monitorować warunki środowiskowe oraz regularnie czyścić i sprawdzać czujniki.
	Temperatura otoczenia	Nieakceptowalna	$< 5^\circ\text{C}$	Ekstremalne warunki, wysokie ryzyko uszkodzenia komponentów.	Natychmiast przerwij pracę i przeprowadź inspekcję systemu.
		Podwyższona	$> 45^\circ\text{C}$	Warunki bliskie ekstremalnemu, potencjalne problemy z wydajnością.	Zintensyfikuj monitorowanie i przygotuj systemy chłodzenia/o-grzewania.

Kontynuacja na następnej stronie

Nazwa bloku FIS	Wejście do bloku FIS	Kategoria	Wartość / próg	Opis	Zalecane działania
	Tarcie powierzchni podłogi	Optymalna	5–45 °C	Temperatura w zakresie optymalnym dla pracy AGV.	Kontynuuj monitorowanie i regularne sprawdzanie warunków pracy.
		Nieakceptowalna	< 0.2	Niezwykłe niskie tarcie, bardzo wysokie ryzyko poślizgu.	Natychmiastowa konserwacja i poprawa tarcia podłoża oraz wyłączenie AGV z użytkowania do czasu poprawy warunków.
		Obniżone	0.2–0.3	Zmniejszona przyczepność, możliwe problemy ze sterowaniem AGV.	Zintensyfikuj monitorowanie i przygotuj działania naprawcze.
		Prawidłowe	≥ 0.3	Wystarczające tarcie, bezpieczne warunki pracy AGV.	Kontynuuj monitorowanie i regularne sprawdzanie stanu podłoża.
Wpływ historii pracy urządzenia (Znaczący / Nieistotny)	Realizacja harmonogramu konserwacji i obsługi	Nieakceptowalna	< 80%	Niskie przestrzeganie harmonogramu, wysokie ryzyko awarii.	Natychmiastowe przeglądy i ocena stanu technicznego AGV, wdrożenie działań naprawczych w celu poprawy zgodności z harmonogramem oraz analiza przyczyn niskiego przestrzegania.
		Zakłócenia	80–95%	Zadowalające przestrzeganie, ale wymaga poprawy.	Monitorowanie przestrzegania harmonogramu oraz analiza przyczyn niedociągnięć w celu identyfikacji obszarów do optymalizacji.
		Prawidłowa	≥ 95%	Akceptowalne przestrzeganie harmonogramu; regularne kontrole niezbędne dla utrzymania niezawodności.	Regularne przeglądy i ocena skuteczności działań konserwacyjnych w celu utrzymania wysokiego poziomu bezpieczeństwa i niezawodności AGV oraz identyfikacji obszarów do doskonalenia.

Kontynuacja na następnej stronie

Nazwa bloku FIS	Wejście do bloku FIS	Kategoria	Wartość / próg	Opis	Zalecane działania
	Liczba zdarzeń krytycznych wymagających natychmiastowego działania	Krytyczna	> 2 zdarzenia- /miesiąc	Wysoka liczba zdarzeń krytycznych, istotne ryzyko dla bezpieczeństwa.	Natychmiastowa analiza przyczyn i wdrożenie działań naprawczych; przegląd procedur bezpieczeństwa, dodatkowe szkolenia personelu oraz potencjalne wycofanie AGV z eksploatacji do czasu poprawy bezpieczeństwa.
		Podwyższona	2 zdarzenia- /miesiąc	Zwiększone ryzyko kolejnych zdarzeń; konieczne monitorowanie i analiza danych w celu identyfikacji wzorców.	Monitorowanie sytuacji i analiza danych; wdrożenie dodatkowych środków bezpieczeństwa, audyt procedur operacyjnych oraz zwiększenie nadzoru nad eksploatacją AGV.
		W normie	1 zdarzenie- /miesiąc	Akceptowalna liczba zdarzeń krytycznych; wymaga regularnych przeglądów i oceny skuteczności działań prewencyjnych.	Regularne przeglądy i ocena działań prewencyjnych; analiza danych o zdarzeniach w celu identyfikacji obszarów do doskonalenia oraz wdrażanie najlepszych praktyk w zakresie bezpieczeństwa.

Źródło: Opracowanie własne.

A.2. Pełna baza reguł końcowego systemu FIS

W niniejszym aneksie przedstawiono pełną bazę reguł (54 reguły) końcowego systemu wnioskowania rozmytego (FIS) wykorzystywanego do ostatecznej oceny stanu technicznego wózka AGV.

Tab. A.2. Pełna baza reguł końcowego systemu FIS dla oceny stanu technicznego wózka AGV

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
1	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
2	Ocena stanu technicznego wózka AGV: <i>Średni</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
3	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
4	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
5	Ocena stanu technicznego wózka AGV: <i>Średni</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
6	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
7	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
8	Ocena stanu technicznego wózka AGV: <i>Średni</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
9	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>

Kontynuacja na następnej stronie

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
10	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
11	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
12	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
13	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
14	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
15	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
16	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
17	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
18	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Znaczący	Krytyczny
19	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Znaczący	Krytyczny
20	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Znaczący	Krytyczny

Kontynuacja na następnej stronie

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
21	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
22	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
23	Ocena stanu technicznego wózka AGV: <i>Średni</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
24	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
25	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
26	Ocena stanu technicznego wózka AGV: <i>Średni</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
27	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Znaczący</i>	<i>Krytyczny</i>
28	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Nieistotny</i>	<i>Krytyczny</i>
29	Ocena stanu technicznego wózka AGV: <i>Średni</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Nieistotny</i>	<i>Krytyczny</i>
30	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Krytyczny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Nieistotny</i>	<i>Krytyczny</i>
31	Ocena stanu technicznego wózka AGV: <i>Alarmujący</i> Wpływ czynników środowiska pracy: <i>Istotny</i> Ocena systemu komunikacji i nawigacji: <i>Nieakceptowalna</i> Analiza danych historycznych: <i>Nieistotny</i>	<i>Krytyczny</i>

Kontynuacja na następnej stronie

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
32	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Nieakceptowalna Analiza danych historycznych: Nieistotny	Krytyczny
33	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Nieakceptowalna Analiza danych historycznych: Nieistotny	Krytyczny
34	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Nieakceptowalna Analiza danych historycznych: Nieistotny	Krytyczny
35	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Nieakceptowalna Analiza danych historycznych: Nieistotny	Krytyczny
36	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Nieakceptowalna Analiza danych historycznych: Nieistotny	Krytyczny
37	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Krytyczny
38	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Krytyczny
39	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Krytyczny
40	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Krytyczny
41	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Ostrzeżenie
42	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Ostrzeżenie

Kontynuacja na następnej stronie

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
43	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Krytyczny
44	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Ostrzeżenie
45	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wymagająca uwagi Analiza danych historycznych: Nieistotny	Akceptowalny
46	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Krytyczny
47	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Krytyczny
48	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Krytyczny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Krytyczny
49	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Krytyczny
50	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Ostrzeżenie
51	Ocena stanu technicznego wózka AGV: Bez uwag Wpływ czynników środowiska pracy: Istotny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Akceptowalny
52	Ocena stanu technicznego wózka AGV: Alarmujący Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Krytyczny
53	Ocena stanu technicznego wózka AGV: Średni Wpływ czynników środowiska pracy: Pomijalny Ocena systemu komunikacji i nawigacji: Wysoka Analiza danych historycznych: Nieistotny	Akceptowalny

Kontynuacja na następnej stronie

Nr	Część warunkowa (IF)	Część wnioskowa (THEN)
54	Ocena stanu technicznego wózka AGV: <i>Bez uwag</i> Wpływ czynników środowiska pracy: <i>Pomijalny</i> Ocena systemu komunikacji i nawigacji: <i>Wysoka</i> Analiza danych historycznych: <i>Nieistotny</i>	<i>Akceptowalny</i>

Źródło: Opracowanie własne.