



**Politechnika  
Śląska**

**POLITECHNIKA ŚLĄSKA**  
**WYDZIAŁ AUTOMATYKI, ELEKTRONIKI I INFORMATYKI**  
**KIERUNEK: INFORMATYKA**

Rozprawa doktorska

Zwiększenie niezawodności pracy urządzeń bloków energetycznych  
poprzez zastosowanie analityki predykcyjnej

Autor: mgr inż. Marek Mołęda

Promotor: dr hab. inż. Dariusz Mrozek, prof. PŚ

Konsultant: dr inż. Alina Momot

Gliwice, wrzesień 2022



Dziękuję serdecznie,  
Promotorowi, **dr hab. Dariuszowi Mrozkowi, prof. Politechniki Śląskiej**,  
za motywację i nieocenioną pomoc przy tworzeniu niniejszej rozprawy.

Promotorowi pomocniczemu, **dr inż. Alinie Momot**, za udzielone ogromne wsparcie merytoryczne oraz pomoc przy edycji tekstów.

Opiekunowi, **mgr inż. Stanisławowi Noworycie**, za możliwość konsultacji technicznych oraz trafne sugestie dotyczące kierunku badań.

Prezesowi **Zbigniewowi Kuźmie**, za zaufanie i umożliwienie realizacji projektu doktorskiego.

**Żonie Adrianie**, za cierpliwość i zrozumienie szczególnie w chwilach wytężonej pracy.

**Dziękuję Rodzicom**, za wsparcie na wszystkich etapach edukacji i subtelne akcentowanie ścieżki ku naukom ścisłym.

Niniejszą pracę dedykuję **córcie Jagodzie**, oby poszła w ślady taty i podniosła nieco wyżej poprzeczkę potomnym...



# Spis treści

<b>Streszczenie</b>	<b>2</b>
<b>1 Wstęp</b>	<b>3</b>
1.1 Przemysł energetyczny . . . . .	4
1.1.1 Rola procesów odtworzeniowych i utrzymaniowych . . . . .	5
1.1.2 Charakterystyka przemysłu energetycznego . . . . .	6
1.1.3 Źródła danych przetwarzanych w przemyśle . . . . .	7
1.2 Motywacja . . . . .	9
1.3 Cele pracy . . . . .	10
1.4 Problem badawczy i tezy badawcze . . . . .	11
1.5 Układ pracy . . . . .	12
<b>2 Strategie i metody konserwacji urządzeń w przemyśle</b>	<b>15</b>
2.1 Opis strategii utrzymania ruchu w przemyśle . . . . .	15
2.1.1 Korekcyjne utrzymanie . . . . .	16
2.1.2 Prewencyjne utrzymanie . . . . .	17
2.1.3 Predykcyjne utrzymanie . . . . .	19
2.2 Techniki i metody wspierające procesy utrzymania ruchu . . . . .	26
2.2.1 Całkowite produktywne utrzymanie ruchu maszyn . . . . .	26
2.2.2 Eksploatacja zorientowana na niezawodność . . . . .	27
2.2.3 Analiza trybów i skutków awarii . . . . .	29
2.2.4 Analiza drzewa usterek . . . . .	31
2.2.5 Analiza przyczyn źródłowych . . . . .	32
2.3 Zaawansowana analityka wspierająca procesy utrzymaniowe . . . . .	34
2.3.1 Złożoność i zakres analizy . . . . .	35

---

2.3.2	Klasyfikacja metod prognozowania stanu technicznego urządzeń . . . . .	37
2.3.3	Metody oparte na opracowanym modelu . . . . .	39
2.3.4	Metody oparte na analizie danych . . . . .	43
2.3.5	Metody oparte na analizie sygnałów . . . . .	50
2.3.6	Określanie pozostałego czasu bezawaryjnej pracy . . . . .	53
2.4	Wykaz artykułów podejmujących podobną tematykę . . . . .	57
<b>3</b>	<b>Techniki badawcze oraz metody wykrywania usterek</b>	<b>59</b>
3.1	Metody i techniki badawcze . . . . .	59
3.1.1	Studium przypadku . . . . .	60
3.1.2	Metody symulacji komputerowej . . . . .	61
3.1.3	Proces eksploracji danych . . . . .	63
3.2	Narzędzia analizy i wizualizacji danych użyte w procesie implementacyjnym i przedwdrożeńowym . . . . .	68
3.2.1	KNIME . . . . .	68
3.2.2	Power BI . . . . .	69
3.2.3	Python . . . . .	69
3.3	Opis opracowanych metod i algorytmów . . . . .	69
3.3.1	Opracowane metody na tle uczenia maszynowego . . . . .	70
3.3.2	Algorytm wykrywania anomalii wykorzystujący metodę regresji . . . . .	71
3.3.3	Proces tworzenia modelu . . . . .	73
3.3.4	Parametryzacja modelu i procesu uczenia . . . . .	80
3.3.5	Zjawisko dryfu koncepcji - detekcja i sposoby zapobiegania . . . . .	83
<b>4</b>	<b>Wyniki badań</b>	<b>95</b>
4.1	Algorytm wykrywający usterki wykorzystujący metodę regresji na podstawie zaobserwowanych anomalii . . . . .	96
4.1.1	Koncepcja studium przypadku . . . . .	96
4.1.2	Przedmiot badań . . . . .	97
4.1.3	Audyt i analiza danych . . . . .	98
4.1.4	Opis eksperymentu . . . . .	101

---

4.1.5	Wyniki badań eksperymentalnych . . . . .	103
4.2	Strojenie modelu oraz przenaszalność rozwiązania . . . . .	113
4.2.1	Koncepcja eksperymentu . . . . .	113
4.2.2	Przedmiot badań . . . . .	114
4.2.3	Audyt i analiza danych . . . . .	114
4.2.4	Opis eksperymentu . . . . .	116
4.2.5	Wyniki . . . . .	117
4.3	Aktualizacja modelu i przeciwdziałanie zjawisku dryfu koncepcji . .	126
4.3.1	Koncepcja studium przypadku . . . . .	126
4.3.2	Przedmiot badań . . . . .	127
4.3.3	Audyt i analiza danych . . . . .	127
4.3.4	Opis eksperymentu . . . . .	127
4.3.5	Wyniki . . . . .	128
<b>5</b>	<b>Podsumowanie</b>	<b>139</b>
5.1	Podsumowanie zrealizowanych prac . . . . .	139
5.1.1	Autorski wkład badawczy . . . . .	140
5.1.2	Podsumowanie wyników badań . . . . .	143
5.2	Możliwe kierunki rozwoju . . . . .	146
5.3	Aspekt wdrożeniowy . . . . .	146
	<b>Bibliografia</b>	<b>174</b>
	<b>Spis rysunków</b>	<b>177</b>





# Streszczenie

Temat pracy związany jest z projektowaniem opartych na metodach zaawansowanej eksploracji danych rozwiązań informatycznych wspierających procesy produkcyjne w elektrowni. Zaawansowane technologie pozwalają wykorzystać potencjał istniejących zbiorów danych, dając szansę na usprawnienie tych obszarów, które do tej pory nie były wspierane przez technologie informatyczne ze względu na wysokie koszty lub brak odpowiednich narzędzi. Jednym z obszarów zastosowania tego rodzaju zaawansowanej analityki jest predykcyjne utrzymanie ruchu (ang. *Predictive maintenance*), które polega na wczesnym wykrywaniu usterek na podstawie istniejących pomiarów. Predykcyjne utrzymanie ruchu poprzez identyfikację pierwszych symptomów potencjalnego zagrożenia w urządzeniach produkcyjnych na długo przed wystąpieniem awarii pozwala na ograniczenie zarówno nieplanowanych, jak i planowanych przestojów, zwiększając tym samym współczynnik dyspozycyjności urządzenia lub całej instalacji.

Głównym celem badań było znalezienie obszarów, gdzie możliwe i efektywne staje się wykorzystanie technik związanych w szczególności z predykcyjnym utrzymaniem ruchu oraz opracowanie narzędzi i modeli analitycznych realizujących te zadania. Z uwagi na skomplikowane procesy technologiczne, szczególna uwaga została skupiona na metodach modelowania niewymagających w dużym stopniu znajomości wiedzy inżynierskiej, a pozwalających osiągnąć skalowalne rozwiązania spełniające zadane oczekiwania odnośnie wiarygodności modelu. Szczegółowym celem badawczym było opracowanie analitycznego modelu na podstawie danych zbieranych w systemach IT oraz systemach technologicznych, umożliwiającego przewidywanie nadchodzących usterek i awarii. Na podstawie historycznych danych pomiarowych oraz informacji o awariach zaproponowany został heurystyczny model predykcyjny wykorzystujący wybrane techniki eksploracji danych.

Uwzględnivszy podejmowaną w literaturze tematykę technik predykcji usterek została zaproponowana technika oparta na metodzie regresji pozwalająca na wykrywanie potencjalnych awarii w przyszłości na podstawie zaobserwowanych anomalii pomiędzy sygnałem zmierzonym, a jego cyfrową rekonstrukcją za pomocą utworzonego modelu. Dzięki wykorzystaniu opracowanego modelu predykcji możliwe stało się przewidywanie i zapobieganie awariom urządzeń oraz w konsekwencji lepsze wsparcie procesów planowania przeglądów urządzeń, remontów i zakupów.

Zakres badań w obszarze predycyjnego utrzymania ruchu w elektrowni obejmuje analizę pracy wybranych urządzeń energetycznych wraz z dokumentacją dotyczącą ich awarii oraz stanu technicznego. Jednym z rozpatrywanych zagadnień jest sposób hierarchizacji i prezentacji danych z systemów analitycznych w sposób zrozumiały dla odbiorcy. Często istotne informacje znajdują się poza percepcją adresata, ginąc w szumie informacyjnym. Zaproponowany został także sposób normalizacji wyników oraz sposób interakcji z użytkownikiem poprzez wizualizację wyników oraz wyzwalanie alarmów. Prawidłowa ocena wiarygodności i wartości informacji jest podstawą do zmiany sposobu podejmowania decyzji z intuicyjnego na oparty na analizie danych. Istotnymi zagadnieniami podejmowanymi w pracy były zatem problemy związane z wdrożeniem i późniejszym utrzymaniem rozwiązania. Zaproponowano proces tworzenia i parametryzacji modeli predycyjnych. Zaproponowane metody zostały zaaplikowane w eksperymencie mającym potwierdzić możliwość automatyzacji procesu tworzenia oraz przenoszenia rozwiązania na inne urządzenia.

W kwestii zagadnień związanych z utrzymaniem rozwiązania zaproponowany został mechanizm ograniczający negatywny wpływ zjawiska dryfu koncepcji na zdolności predycyjne modelu.

Uzyskane w efekcie eksperymentów wyniki potwierdziły skuteczność proponowanej metody w zadaniu wykrywania poważnych usterek urządzeń energetycznych. W toku prac zaprojektowano system pozwalający na wykrywanie i identyfikację usterek oraz opracowano metody pozwalające na automatyzację procesu tworzenia i aktualizacji modeli predycyjnych.

**Słowa kluczowe:** predycyjne utrzymanie ruchu, redundancja analityczna, wykrywanie i identyfikacja usterek, uczenie maszynowe, energetyka

# Rozdział 1

## Wstęp

Niezwalniająco postępy technologiczne, dostępność urządzeń cyfrowych i trend ku cyfryzacji sprawiają, iż często na swojej drodze spotykamy rozwiązania związane z zastosowaniem sztucznej inteligencji lub zaawansowanych metod eksploracji danych. Wraz ze zwiększającymi się możliwościami komputerów w zakresie mocy obliczeniowej i wielkości przetwarzanych danych zwiększa się potencjalny zakres rozwiązań oferowanych przez systemy informatyczne. Obok podstawowych zastosowań pozwalających na gromadzenie danych i wykonywanie obliczeń systemy komputerowe są też wykorzystywane do wspierania decyzji. Mowa tutaj zarówno o systemach raportujących i analizujących dane z systemów informatycznych, jak i o zaawansowanych systemach eksperckich wspierających użytkownika w poszukiwaniu rozwiązania. Możliwość zastosowania analityki deskryptywnej pozwala na lepsze zrozumienie zaistniałych zdarzeń, natomiast metody predykcyjne dają możliwość przewidywania wyników w przyszłości. Korzyści płynące z tych zastosowań to możliwość podejmowania bardziej świadomych i trafnych decyzji, przy czym bazują one w większej mierze na danych i wynikach, niż na intuicji. Jednym z bardziej interesujących zastosowań w obszarze wspierania decyzji jest zastosowanie metod opartych na sztucznej inteligencji pozwalających na całkowite zautomatyzowanie procesu decyzyjnego. Rozwiązania, takie jak wirtualny asystent czy autonomiczny samochód, są przykładami motywującymi do zgłębiania wiedzy w obszarze zaawansowanej analityki i sztucznej inteligencji oraz zachęcają do poszukiwania rozwiązań w różnych dziedzinach życia.

## 1.1 Przemysł energetyczny

Energetyka to dział przemysłu zajmujący się produkcją oraz dystrybucją energii elektrycznej i ciepłej. Energia elektryczna jest niczym krew w żyłach dla wszelkich urządzeń elektrycznych i elektronicznych wykorzystywanych zarówno w gospodarstwach domowych, jak i w dużych ośrodkach przemysłowych. Rozwijająca się gospodarka i postęp technologiczny zwiększają popyt na energię elektryczną, co wymaga podjęcia działań w celu zapewnienia odpowiedniej jej produkcji dla odbiorców. Pod względem sposobu wytwarzania energetykę dzielimy na:

- konwencjonalną – opierającą się przede wszystkim na spalaniu nieodnawialnych źródeł energii, jak węgiel lub gaz;
- niekonwencjonalną – opierającą się na produkcji energii ze źródeł odnawialnych, np. wody, słońca, wiatru.

Z uwagi na brak możliwości magazynowania dużych pojemności energii elektrycznej (w kontekście ogólnokrajowego zapotrzebowania) system energetyczny opiera się na zapewnieniu produkcji takiej ilości energii, na jaką w danej chwili jest zapotrzebowanie. Operator sieci energetycznych steruje jednostkami wytwórczymi w taki sposób, aby osiągnąć wymagany chwilowy poziom produkowanej mocy.

Uwzględniając powyższą charakterystykę przemysłu energetycznego ważnym elementem jest zachowanie wysokiej dyspozycyjności bloków energetycznych w celu zapewnienia pokrycia zapotrzebowania energetycznego. Awarie w elektrowniach mogą powodować różne skutki, zaczynając od pogorszonej jakości dostarczonej energii (spadek częstotliwości dostarczanego napięcia), po przerwy w zasilaniu poszczególnych obszarów dystrybucyjnych (tzw. blackout).

Na utrzymanie w dobrej kondycji jednostek wytwórczych pozwalają dobrze zorganizowane procesy konserwacyjne oraz stały monitoring kondycji urządzeń. Pozwalają one na zapobieganie i wczesne wykrywanie zdarzeń mogących mieć negatywny wpływ na produkcję energii elektrycznej. Istotnym zagadnieniem jest sposób, w jaki nowoczesne urządzenia cyfrowe i postęp technologiczny napędzany energią elektryczną mogą usprawnić proces produkcji energii zwiększając dyspozycyjność poszczególnych jednostek wytwórczych.

### 1.1.1 Rola procesów odtworzeniowych i utrzymaniowych

Remonty i prace eksploatacyjne są nieodzowną częścią prawie każdego procesu produkcyjnego w przemyśle. Stan wiedzy i procedury wykorzystywane w tej dziedzinie ewoluują w szybkim tempie od czasów pierwszej rewolucji przemysłowej. Istotny wpływ na wsparcie bieżących praktyk w zakresie procesów konserwacji mają nowoczesne technologie. Według raportu Deloitte, niewłaściwe strategie konserwacji mogą zmniejszyć całkowitą zdolność produkcyjną o 5 do 20 procent [1]. Podobnie opracowanie McKinsey prognozuje, że cyfryzacja procesów w przemyśle może zwiększyć dostępność aktywów o 5 do 15 procent i zmniejszyć koszty konserwacji o 18 do 25 procent [2]. Istotne przypadki zastosowania nowoczesnych technologii w przemyśle dotyczą przede wszystkim wsparcia procesu utrzymania ruchu, optymalizacji procesu produkcyjnego oraz poprawy jakości inspekcji [3]. Głównymi czynnikami wpływającymi na korzyść stosowania tych podejść są [4]:

- poprawa dyspozycyjności,
- redukcja kosztów operacyjnych,
- poprawa bezpieczeństwa,
- ograniczenie negatywnego wpływu na środowisko,
- wzrost efektywności i jakości produkcji
- wydłużenie okresu eksploatacji aktywów.

Cyfryzacja i transformacja procesów pozwala na lepsze zrozumienie zachodzących zjawisk oraz podejmowanie trafniejszych i bardziej uzasadnionych decyzji, które w mniejszym stopniu opierają się na intuicji. Ponadto wiedza pochodząca ze zintegrowanych źródeł danych i zaawansowanej analityki umożliwia wdrażanie nowych strategii utrzymania ruchu, lepsze harmonogramowanie zadań, zwiększenie wydajności produkcji oraz podniesienie poziomu bezpieczeństwa. Branża energetyczna przechodzi w ostatnich latach istotne przeobrażenia. Przemiany te wynikają z konieczności znajdowania nowych źródeł energii, zmian klimatycznych i uwarunkowań ekologicznych. Sektor ten wymaga więc nowoczesnego podejścia do utrzymania prawidłowego działania urządzeń, aby zapobiec awariom, które mogą mieć poważne konsekwencje zarówno ekologiczne, jak i ekonomiczne.

### 1.1.2 Charakterystyka przemysłu energetycznego

Metody wytwarzania energii elektrycznej są silnie powiązane ze źródłami energii, które mogą być odnawialne (woda, wiatr, słońce, biomasa) oraz nieodnawialne (gaz ziemny, węgiel). Struktura aktywów wytwórczych powinna zapewniać wysoką dyspozycyjność i niezawodność, ponieważ energii elektrycznej nie da się magazynować na dużą skalę, tzn. bieżąca, chwilowa produkcja powinna odpowiadać rzeczywistemu zapotrzebowaniu odbiorców.

Szczególnym wyzwaniem jest zwiększenie udziału odnawialnych źródeł energii ze względu na wymogi ochrony środowiska, co wymaga nowych technik konserwacji tych obiektów, a także pracy w różnych warunkach operacyjnych. W przypadku elektrowni konwencjonalnej większość urządzeń produkcyjnych jest skoncentrowana na niewielkim obszarze. Wówczas procesy konserwacyjne koncentrują się na szczególnym utrzymaniu urządzeń krytycznych, takich jak kotły, pompy zasilające, turbiny i generatory. Typowe usterki zdarzające się w instalacjach energetycznych można podzielić przede wszystkim na:

- usterki mechaniczne, np. uszkodzenia łożysk,
- usterki systemu automatyki, np. awarie systemu sterowania, zadziałanie systemów bezpieczeństwa,
- usterki elektryczne,
- wycieki wody i oleju z maszyn i rurociągów,
- awarie urządzeń dostarczających paliwo, np. młynów, przenośników taśmowych.

Odnawialne źródła energii i sieci dystrybucyjne charakteryzują się rozproszonym rozmieszczeniem, co pociąga za sobą konieczność racjonalnego planowania prac konserwacyjnych i monitorowania stanu aktywów. Koszt przeglądów i prac konserwacyjnych w przypadku np. turbiny wiatrowej wiąże się z wyższymi kosztami związanymi z zapewnieniem bezpieczeństwa i logistyką.

### 1.1.3 Źródła danych przetwarzanych w przemyśle

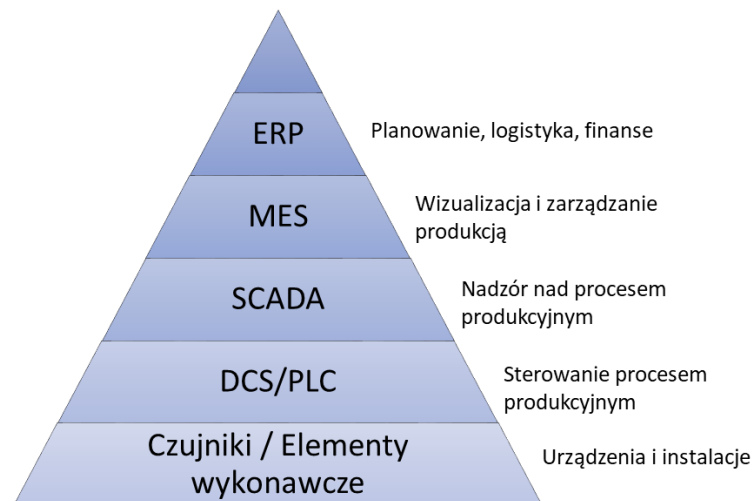
Zasoby danych, które można wykorzystać do analizy utrzymania ruchu, obejmują grupy systemów znajdujących się w przestrzeni informatycznej, aż do systemów sterowania automatyką. Biorąc pod uwagę poszczególne poziomy architektoniczne, możemy wyróżnić następujące rodzaje warstw w funkcjonujących systemach (rys. 1.1):

- ERP (ang. *Enterprise resource planning*) - grupa systemów działających na poziomie biurowym przedsiębiorstwa, obejmująca systemy wspomagające realizację procesów planowania, finansowych i zaopatrzenia firmy.
- MES (ang. *Manufacturing execution system*) - systemy tej klasy operują głównie na danych pochodzących z systemów automatyki przemysłowej (np. SCADA, DCS) i są wykorzystywane do monitorowania oraz optymalizacji procesu produkcji.
- SCADA (ang. *Supervisory control and data acquisition*) - systemy zaprojektowane w celu ułatwienia operatorowi monitorowania i sterowania procesem produkcyjnym w czasie rzeczywistym; jest to również rodzaj interfejsu człowiek-maszyna (ang. *Human-machine interface, HMI*), który umożliwia operatorowi interakcję z urządzeniem/installacją.
- DCS/PLC (ang. *Distributed control system/Programmable logic controller*) - urządzenia sterujące procesem produkcyjnym w sieci łączącej czujniki, elementy wykonawcze i interfejs człowiek-maszyna; automatycznie wysyłają sygnały sterujące do urządzeń, wykorzystując dane z niższych poziomów.
- Czujniki/elementy wykonawcze - najniższa warstwa odpowiedzialna za realizację procesu produkcyjnego; gromadzi dane z czujników oraz manipuluje sygnałami sterującymi w sieciach czasu rzeczywistego.

Dane przetwarzane w środowisku przemysłowym obejmują zarówno te tworzone przez człowieka pochodzące z systemów informatycznych, jak i duże repozytoria danych generowanych maszynowo przez urządzenia. Struktury danych mieszczą się zarówno w relacyjnych bazach danych, jak i mniej ustrukturyzowanych

formach, jak dzienniki zdarzeń, wiadomości e-mail czy galerie obrazów. Stwarza to pewne wyzwania dla analizy danych związane z przetwarzaniem zbiorów typu "Big Data"[5]. Wielopoziomowa integracja różnych systemów otwiera jednak nowe możliwości fuzji i eksploracji danych, przekształcając istniejące zasoby danych w rzeczywistą wartość dla przedsiębiorstwa. Integracja danych może przebiegać w następujących formach [6]:

- pozioma integracja - rozszerza zakres operacyjny dla danej warstwy architektonicznej, analizuje większe liczby danych, wspiera dzielenie się wiedzą w organizacji. Przykładowym celem takiej integracji może być optymalizacja całego łańcucha dostaw, uwzględniając dane z różnych źródeł (np. dane o klientach, dostawcach, zapasach),
- pionowa integracja - polega na łączeniu danych z różnych segmentów wewnętrznych w celu pozyskania dodatkowej wiedzy. Przykładowo, gdy łączymy dane pozyskane maszynowo z czujników i systemów technologicznych z danymi z systemów informatycznych.



Rysunek 1.1: Klasyfikacja systemów w zakładzie przemysłowym



## 1.2 Motywacja

System energetyczny wymaga wysokiej dyspozycyjności bloków energetycznych w celu zapewnienia zarówno wymaganej produkcji energii elektrycznej, jak i zabezpieczenia odpowiedniej rezerwy mocy. Klasyczne podejścia i procesy związane z utrzymaniem ruchu w elektrowni oraz zarządzaniem aktywami, mogą zostać uzupełnione lub zastąpione rozwiązaniami opartymi na zaawansowanych metodach eksploracji danych. Rozwiązania takie pozwalają na podejmowanie decyzji w sposób w mniejszym stopniu bazującym na intuicji, a w większym na wiedzy i faktach. Czynnikiem sprzyjającym rozwojowi takiego podejścia jest ciągły rozwój technologiczny pozwalający na aplikację nowoczesnych rozwiązań oraz rozszerzenia wykorzystania istniejących systemów do celów innych niż pierwotnie zakładano.

W związku z postępującą komputeryzacją i cyfryzacją w zakładach przemysłowych przetwarzane są duże liczby danych różnego typu, zarówno w systemach technologicznych, jak i systemach informatycznych. Przetwarzane są dane pomiarowe z systemów produkcyjnych, dane z relacyjnych baz danych, obrazy z monitoringu, czy ręcznie tworzone rejestry i dokumenty. Liczby przetwarzanych danych, złożoność procesów technologicznych, fakt rozproszenia źródeł danych oraz niejasne korelacje między nimi utrudniają ich optymalne wykorzystanie, dające korzyści z uzyskanej wiedzy w wyniku analizy danych. Wiedza dotycząca możliwości wykorzystania tych danych, ich powiązań z procesami biznesowymi oraz opracowanie innowacyjnych narzędzi analitycznych będzie optymalizowała korzyści wynikające z wdrożenia nowoczesnych rozwiązań z obszaru predykcyjnego utrzymania ruchu, a także pokaże ich potencjalny wpływ na procesy biznesowe i technologiczne realizowane w TAURON Wytwarzanie S.A.

Wdrożenie predykcyjnego utrzymania ruchu wymaga wysokich nakładów w postaci inwestycji w dodatkowe systemy pomiarowe, a także systemu informacyjnego oraz wyspecjalizowanej wiedzy eksperckiej. Dlatego główną motywacją w pracy jest wykorzystanie istniejących repozytoriów danych oraz w ograniczonym stopniu wiedzy eksperckiej w celu utworzenia systemu realizującego zadania z obszaru predykcyjnego utrzymania ruchu.

## 1.3 Cele pracy

Ogólnym celem praktycznej części pracy będzie zatem znalezienie obszarów, gdzie możliwe i efektywne będzie wykorzystanie technik związanych z predykcijnym utrzymaniem ruchu oraz opracowanie narzędzi i modeli analitycznych realizujących te zadania. Z uwagi na skomplikowane procesy technologiczne szczególna uwaga zostanie skupiona na metodach modelowania niewymagających w dużym stopniu znajomości branżowej wiedzy inżynierskiej, a pozwalających osiągnąć skalowalne rozwiązania spełniające zadane oczekiwania odnośnie wymaganych funkcjonalności i jakości systemu.

Szczegółowym celem badawczym będzie opracowanie modelu matematycznego umożliwiającego przewidywanie nadchodzących usterek i awarii na podstawie danych zbieranych w systemach IT oraz systemach technologicznych. Na podstawie historycznych danych pomiarowych oraz informacji o awariach zaproponowany zostanie heurystyczny model predykcyjny oparty na wybranych technikach zaawansowanej analityki.

Dzięki wykorzystaniu opracowanego modelu możliwe będzie przewidywanie i zapobieganie awariom urządzeń oraz, w konsekwencji, lepsze wsparcie dla planowania przeglądów urządzeń i lepsze planowanie produkcji.

Podstawowymi źródłami danych będących obiektem badań i analiz będą dane procesowe z wybranych repozytoriów danych historycznych, systemów analiz technicznych, systemu ERP oraz pozostałych systemów i rejestrów przetwarzających istotne dane z punktu widzenia planowania i zarządzania pracami konserwacyjnymi.

## 1.4 Problem badawczy i tezy badawcze

Głównym problemem badawczym, którego dotyczy praca jest utworzenie modelu analitycznego pozwalającego na predycyjne wykrywanie awarii w sytuacjach niewystarczająco dużego lub braku zbioru testowego w postaci odnotowanych awarii. Awarie w urządzeniach będących przedmiotem badań zdarzają się bardzo rzadko lub wcale, co jest skutkiem regularnych przeglądów i częstych remontów.

Jednym z rozpatrywanych zagadnień jest zatem sposób hierarchizacji i prezentacji danych z systemów analitycznych w sposób zrozumiały dla odbiorcy. Często istotne informacje znajdują się poza percepcją adresata, ginąc w szumie informacyjnym. Prawidłowa ocena wiarygodności i wartości informacji jest podstawą do efektywnego wykorzystania systemu do zadań planistycznych i zarządczych.

Problemem natury technicznej jest pozyskanie dobrej jakości, wiarygodnych danych w sytuacji, kiedy dane te nie były gromadzone w celach przedmiotowej analizy (np. dane z czujników służą do sterowania procesem, natomiast dane o awariach do koordynacji i rozliczeń prac). Brak dobrze opisanych zdarzeń, niespójność danych archiwalnych, czy braki spowodowane czułością systemu są wyzwaniem, które podejmuje niniejsza praca.

Biorąc pod uwagę zarówno cele badawcze, jak i wdrożeniowe projektu oraz wyżej wymienione wyzwania, a także ograniczone możliwości rozwiązań w zakresie predycyjnego utrzymania ruchu przedstawionych w rozdziale 2.3 i podsumowanych w tabeli 2.1, zostały sformułowane następujące hipotezy badawcze:

1. Zastosowanie opartych na regresji metod redundancji analitycznej operujących na dużych zbiorach danych z systemów przemysłowych pozwala na realizację zadania przewidywania awarii i usterek w sytuacji:
  - ograniczonej liczby analizowanych cech i zdarzeń,
  - zmiennych warunków pracy wynikających z częstych remontów i wpływu czynników zewnętrznych.
2. Algorytm adaptacyjnego okna przesuwonego oparty na analizie średnich wartości cząstkowych elementów tego okna pozwala zachować parametry jakościowe modelu predycyjnego wykrywającego usterki, jednocześnie ograniczając potrzebę okresowej nadzorowanej aktualizacji modeli.

3. Proces inżynierii danych i tworzenia modeli predykcyjnych oparty na danych generowanych maszynowo z urządzeń przemysłowych może zostać zautomatyzowany dla zastosowania względem nowych urządzeń, zachowując zbliżone zdolności predykcyjne.

Weryfikacja sformułowanych hipotez składa się z następujących etapów:

- Analiza zjawiska poprzez studium przypadku.
- Opracowanie modelu predykcyjnego dla wybranego urządzenia.
- Przeprowadzenie analizy porównawczej jakości zaproponowanego rozwiązania.
- Opracowanie procesu tworzenia, parametryzacji oraz aktualizacji modelu predykcyjnego.
- Weryfikacja wyników otrzymanych w eksperymentach prowadzonych w symulowanym środowisku.

## 1.5 Układ pracy

Niniejsza rozprawa doktorska składa się z rozdziałów wprowadzających w kontekst zagadnienia w części teoretycznej oraz opisujących metodologię i metody użyte w eksperymentach będących źródłem wyników potwierdzających postawione hipotezy. Przedstawia ona główne cele i problemy badawcze na tle przemysłu energetycznego. Zaprezentowano w niej wiodące zagadnienia związane z procesami remontowymi, specyfikę systemów przemysłowych oraz przetwarzanych w nich danych oraz koncepcję predykcyjnego utrzymania ruchu opartego na monitorowaniu stanu zdrowia urządzeń w czasie rzeczywistym.

Teoretyczna część rozprawy przedstawiona w rozdziale 2 koncentruje się na wprowadzeniu do stosowanych strategii utrzymania ruchu oraz technik wspierających procesy utrzymania ruchu zarówno w ujęciu konwencjonalnych rozwiązań, jak i metod opierających się na analizie danych i zaawansowanych metodach statystycznych, wspierających podejmowanie decyzji i procesy planistyczne.

Opis zastosowanej metodologii, narzędzi oraz autorskich metod będących kluczowym punktem projektowanych eksperymentów przedstawiono w rozdziale trzecim. Przedstawiona została koncepcja modelu predykcyjnego oraz proces tworzenia modelu. Dalsza część poświęcona jest rozwiązaniom realizującym zadania interakcji z użytkownikiem i wizualizacji danych, a także usprawnieniu procesu tworzenia i aktualizacji proponowanego systemu predykcyjnego. W kontekście aktualizacji modelu szczególna uwaga została skierowana ku niwelacji zjawiska dryfu koncepcji oraz automatyzacji procesu odświeżania modelu.

Rozdział czwarty przedstawia uzyskane wyniki badań na tle zdefiniowanego problemu badawczego i postawionych tez. Eksperymenty zostały przedstawione chronologicznie, zgodnie z etapami prowadzonych prac badawczych. Pierwszy etap związany jest głównie z eksploracją danych i analizą dostępnych źródeł danych, mając na celu zaprojektowanie modelu analitycznego realizującego główny cel pracy. Kolejne eksperymenty prezentują wyniki dla uzyskanych modyfikacji zaprojektowanego modelu, mających na celu automatyzację procesu tworzenia oraz aktualizacji modelu, a także parametryzację modelu w celu uzyskania akceptowalnych wyników predykcji.

Podsumowanie pracy przedstawia główne produkty, jakie powstały w pracy, a także wiąże postawione tezy z wynikami uzyskanymi w prowadzonych badaniach. Zaprezentowano w nim również obszary wdrożenia wyników badań oraz określono kierunki dalszego rozwoju.



## Rozdział 2

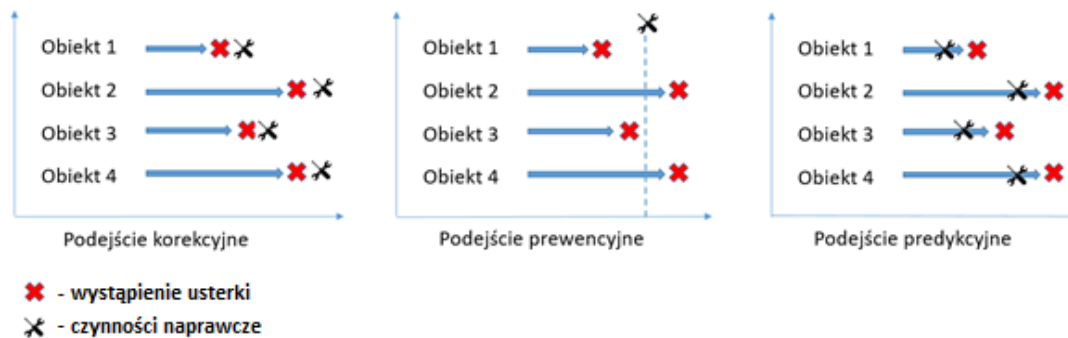
# Strategie i metody konserwacji urządzeń w przemyśle

W niniejszym rozdziale zaprezentowano przegląd strategii utrzymania ruchu oraz wspierających je metod opartych na zaawansowanej analityce, w szczególności akcentujących predykcyjne utrzymanie ruchu. W rozdziale przedstawiono klasyczne rozwiązania w zestawieniu z podejściami opartymi na zaawansowanej analizie danych. Metody analityczne poddano dwuwymiarowej klasyfikacji, gdzie opisywane rozwiązania zostały podzielone na oparte na danych, modelu i sygnale oraz na metody jakościowe i ilościowe. Metody opisano uwzględniając wymagane zasoby, możliwe zastosowania oraz użyte podejścia.

### 2.1 Opis strategii utrzymania ruchu w przemyśle

Utrzymanie urządzeń w dobrym stanie technicznym stanowi istotną kwestię w zapewnieniu wysokiej wydajności procesu produkcyjnego. Prawidłowy serwis i konserwacja przyczyniają się do uzyskania wysokiego poziomu dyspozycyjności oraz ograniczają przerwy w produkcji. Z drugiej strony koszty utrzymania stanowią znaczące obciążenie finansowe dla przedsiębiorstwa. Dlatego istotne jest znalezienie równowagi w taki sposób, aby uzyskać akceptowalne wyniki produkcyjne przy jednoczesnej optymalizacji kosztów serwisowych. Zgodnie z definicją znajdującą się w Europejskim Standardzie EN13306 [7] techniki utrzymania należy rozu-

mieć jako "ogół działań technicznych, administracyjnych oraz zarządczych mających na celu utrzymanie urządzenia w okresie jego eksploatacji w stanie, w którym może pełnić wymaganą funkcję lub przywrócić go do takiego stanu". Jako zakres czynności konserwacyjnych należy mieć na uwadze działania związane z inspekcjami, monitorowaniem stanu urządzenia, cyklicznymi przeglądami, wymianą części, naprawami, remontami, jak również planowaniem i nadzorowaniem wszystkich tych działań. Strategie utrzymania ruchu mogą zostać sklasyfikowane uwzględniając czas, kiedy wykonywana jest naprawa względem momentu wystąpienia awarii. Wyróżniamy trzy podstawowe podejścia, które przedstawiono na rys. 2.1 (rysunek na podstawie [8]). Są to podejścia korekcyjne, prewencyjne oraz predykcyjne, które zostały opisane w kolejnych podrozdziałach.



Rysunek 2.1: Podstawowe strategie konserwacji

### 2.1.1 Korekcyjne utrzymanie

Korekcyjne utrzymanie (ang. *Corrective maintenance*) – zakłada podjęcie działań w następstwie wystąpienia usterki. Takie podejście minimalizuje koszty prewencyjne urządzenia poprzez rezygnację z planowych okresowych przeglądów i inspekcji. Dzieje się to jednak kosztem dyspozycyjności urządzenia. Negatywne skutki korekcyjnego utrzymania mogą się materializować w postaci utraconych zysków związanych z przerwaniem produkcji, kosztami przywrócenia urządzenia do działania, degradacją urządzenia lub uszkodzeniami powiązanych urządzeń w wyniku nastąpienia usterki. Prosty przykładem utrzymania korekcyjnego jest



wymiana żarówki w samochodzie, gdzie żarówkę wymieniamy dopiero w momencie, gdy się spali, na co jesteśmy przygotowani posiadając komplet żarówek w zapasie. Mając na uwadze powyższe cechy to podejście powinno być stosowane w przypadku niekrytycznych urządzeń, łatwych do naprawy. W przypadku urządzeń, których uszkodzenie może powodować przestój, np. kocioł czy turbina w elektrowni należy zastosować bardziej proaktywne podejście. Podobnie w przypadku urządzeń, których usterki mogą przyczynić się do degradacji lub niszczenia urządzeń powiązanych, np. taśmociągi w strefach zagrożonych wybuchem lub parowniki i rurociągi przewodzące parę o wysokim ciśnieniu.

W zależności od procedur określających czas, kiedy ma nastąpić naprawa, działania mogą być podjęte niezwłocznie lub odłożone, w zależności od krytyczności urządzenia i potencjalnych skutków awarii. W przypadku produkcji ciągłej częstym przypadkiem jest praca podzespołów w stanie permanentnej usterki. Ma to miejsce w przypadku, gdy pogorszone są parametry pracy elementu (np. ograniczona wydajność, zwiększone wibracje, grzanie) natomiast nie mają one lub mają ograniczony wpływ na efektywność produkcji.

Podejście korekcyjne od strony informatycznej jest wspierane przede wszystkim poprzez zastosowanie analityki deskryptywnej, pozwalającej na prawidłową estymację skutków awarii oraz przyjęciu w efekcie prawidłowego podejścia, mając na uwadze kalkulację wszystkich potencjalnych zysków i strat. W praktyce oznacza to wdrożenie procesów związanych z zarządzaniem ryzykiem oraz konieczność utrzymania repozytoriów danych dobrej jakości na potrzeby analiz. Przy objęciu tą strategią urządzeń, duże znaczenie ma zastosowanie technologii diagnostycznych pozwalających na detekcję uszkodzeń i monitorowanie stanu urządzenia. Pozwala to na szybsze podjęcie działań w celu usunięcia usterki.

### 2.1.2 Prewencyjne utrzymanie


Celem niniejszego podejścia jest uniknięcie nieplanowanych przestojów poprzez cykliczne inspekcje, kontrole oraz okresową wymianę podzespołów. Typowe prewencyjne zadania obejmują czynności, takie jak: smarowanie, regulacja, wymiana oleju lub diagnostykę wykonaną specjalistycznym sprzętem (np. termowizja, wibroakustyka). Częstotliwość wykonywanych czynności można zaplanować na pod-

stawie zaleceń producenta lub analizy parametrów jakościowych, takich jak MTBF (ang. *Mean time between failure* - średni czas między awariami), MTTF (ang. *Mean time to failure* - średni czas do awarii). Konserwacja zapobiegawcza zapewnia dobry stan urządzeń i zmniejsza ryzyko potencjalnych przestojów. Nie chroni jednak przed nieoczekiwanymi, losowymi awariami, a także usterkami elementów, które nie były objęte inspekcją lub wymianą. W przypadku wymian części lub przeglądów wymagających demontażu elementów urządzenia, paradoksalnie stosowanie intensywnych działań prewencyjnych z dużą częstotliwością może przynieść skutek odwrotny do zamierzonego. Częste wymiany podzespołów nie zawsze są dobrym rozwiązaniem z następujących powodów [9]:

- wymieniając oryginalną część na zamiennik, istnieje ryzyko błędnego montażu i skrócenia okresu użytkowania tej części oraz w efekcie awarii całego urządzenia,
- nowe części i materiały eksploatacyjne mają większe prawdopodobieństwo wadliwości lub awarii niż w przypadku już istniejących (sprawdzonych) materiałów, które są już w użyciu.

Ryzyko wystąpienia awarii w okresie użytkowania jest większe w początkowej fazie życia (np. po wymianie, remoncie) oraz końcowej, co jest związane z zużyciem części lub zmęczeniem materiału. Na rys. 2.2 przedstawiono rozkład prawdopodobieństwa awarii w ciągu cyklu życia przykładowego komponentu. Statystycznie określony okres pomiędzy tymi stanami może być wykorzystany jako wyznacznik okresu wymiany [10, 11].

Efektywne planowanie działań prewencyjnych powinno dopasować częstotliwość inspekcji i napraw dla danego urządzenia do wymaganych parametrów jego dostępności. W kontekście harmonogramowania działań w kilku opracowaniach [12, 13, 14, 15] autorzy proponują wykorzystanie modelu opartego na relacji kosztów do niezawodności w celu znalezienia optymalnej polityki, uzyskując akceptowalną niezawodność w stosunku do założonych kosztów. Planowanie prac wymaga posiadania znaczących zasobów danych archiwalnych do analizy historii realizowanych prac, obecnego stanu zdrowia lub historii awarii. Przy tworzeniu analiz istnieje możliwość wykorzystania specyfikacji i wyników uzyskanych dla przedmiotowego urządzenia lub urządzenia tego samego typu (lub podobnego). Alternatywną grupą



Rysunek 2.2: Wykres "wannicy" (ang. *bathtub*) wizualizujący prawdopodobieństwo wystąpienia awarii na wczesnych i późnych etapach eksploatacji


metod jest planowanie zadań z wykorzystaniem wskaźników KPI (ang. *Key performance indicator*) [16, 17, 18], zakładając odzwierciedlenie stanu technicznego poprzez wyznaczniki na wysokim poziomie abstrakcji; lub bieżące monitorowanie stanu technicznego na podstawie analizy danych procesowych [19, 20, 21].

### 2.1.3 Predykcyjne utrzymanie

Predykcyjne utrzymanie ruchu (ang. *Predictive maintenance*) zakłada dokonywanie czynności serwisowych wtedy, kiedy jest to wymagane, przeważnie jest to czas na krótko przed wystąpieniem spodziewanej usterki. Istotą tego podejścia jest przewidywanie wskaźników zdrowia urządzenia w przyszłości, na podstawie bieżących wyników uzyskanych z okresowych badań diagnostycznych lub monitoringu parametrów urządzenia. Zastosowanie tej metody wymaga posiadania dużego zakresu dobrej jakości danych o stanie technicznym urządzenia, dla którego przewidujemy przyszłe działanie na podstawie bieżących i historycznych pomiarów [22, 23, 24]. Podstawowym zadaniem tej metody jest wczesne wykrywanie potencjalnych usterek na podstawie pierwszych jej symptomów (niekiedy widocznych w czasie inspekcji) [25, 26, 27] jak przedstawiono na rys. 2.3, co w efekcie prowadzi do ograniczenia zarówno planowanych, jak i nieplanowanych przestojów

tzn. :

- ograniczenia zbędnych przeglądów i napraw jeśli urządzenie jest w dobrej kondycji,
- minimalizacji ryzyka awarii poprzez bieżące monitorowanie stanu urządzenia.



Rysunek 2.3: Koszty naprawy w zależności od czasu wykrycia usterki

Predykcyjne utrzymanie ruchu wymaga posiadania wyczerpujących informacji dotyczących aktualnego stanu urządzenia oraz dużego zaangażowania ekspertów w analizowanie danych. Dzięki zaawansowanym technologiom z pogranicza IIoT (ang. *Industrial internet of things*) lub Big Data uzyskujemy możliwość łatwego dostępu i integracji danych z istniejącymi systemami. Rozwijające się techniki przetwarzania danych, w tym sztucznej inteligencji dają natomiast możliwość zautomatyzowania czasochłonnego procesu analizy stanu urządzenia. Systemy OT (ang. *Operational technology*), w tym repozytoria SCADA (ang. *Supervisory control and data acquisition*) mogą być wykorzystywane jako źródła danych procesowych dla systemów wspierających predykcyjne utrzymanie ruchu. W kwestii procesu wspierania decyzji możemy skodyfikować wiedzę ekspercką, np. w postaci reguł i klasyfikatorów, aby monitorować stan zdrowia urządzenia i wykrywać anomalie będące symptomem usterek, literatura przedstawia liczne zastosowania tego

typu podejścia [28, 29, 30, 31]. W ten sposób można stworzyć system konserwacji predykcyjnej oparty na monitorowaniu stanu technicznego w czasie rzeczywistym. Podejście predykcyjne jest swojego rodzaju kompromisem pomiędzy podejściem korekcyjnym, a prewencyjnym. Jednak potencjalne koszty dodatkowego opomiarowania, wdrożenia lub architektury sprawiają, że ewentualne zastosowanie powinno być przeanalizowane na podstawie ewentualnych skutków awarii, jakich można by uniknąć. Uproszczona kalkulacja opłacalności zastosowania predykcyjnego utrzymania ruchu została przedstawiona na rys. 2.4, techniki predykcyjne warto stosować dla urządzeń, których awarie mają wysoki wpływ na produkcję, np. urządzenia krytyczne jak turbina czy kocioł. Przy stosunkowo niskich kosztach wdrożenia, można rozważyć objęcie systemem szerszą grupę urządzeń.

		Wpływ		
		niski	średni	wysoki
Koszt	niski			
	średni			
	wysoki			

Rysunek 2.4: Opłacalność wdrożenia predykcyjnego utrzymania ruchu

Na podstawie analizy światowej literatury, można wyróżnić następujące techniki wykorzystywane przy predykcyjnym utrzymaniu ruchu [28, 29, 30, 31], opisane w szczegółowo w poniższych sekcjach.

### Analiza wibracji

Podejście to ma zastosowanie dla wszystkich maszyn będących w ruchu i wirujących i jest szeroko wykorzystywane, w przemyśle zarówno do diagnostyki, monitorowania stanu zdrowia, jak i prognozowania potencjalnych uszkodzeń w przyszłości. Podstawowymi parametrami pomiaru wibracji są: szybkość, przyspieszenie i przemieszczenie. Techniki predykcyjne obejmują analizę trendów dla wybranych parametrów drgań w poszczególnych zakresach częstotliwości lub analizę widma sygnału. Analiza trendów w łatwy i intuicyjny sposób pozwala na określenie estymowanego pozostałego okresu użytkowania oraz na ocenę bieżącej degradacji komponentów (np. łożysk). Ponieważ poziom amplitudy drgań

sam w sobie jest wskaźnikiem złego stanu urządzenia, możliwym jest łatwe tworzenie prognoz na podstawie tylko tego pomiaru i jego analizy. Z kolei analiza widmowa sygnału zapewnia możliwość zarówno wykrywania, jak i klasyfikacji niepożądanych zdarzeń. Analiza charakterystycznych wzorców sygnału umożliwia wykrycie konkretnych usterek dla badanych urządzeń, jak np.: wycieki, zatarcia lub ubytki materiałowe. Stosowanie tej metody jest kosztowne, ponieważ wymaga zastosowania dedykowanego sprzętu pomiarowego. Pomiaru mogą być odczytywane na bieżąco wykorzystując stałe opomiarowanie lub za pomocą przenośnej aparatury przy regularnych, okresowych przeglądach diagnostycznych. W obydwu przypadkach analiza danych wymaga zaangażowania eksperta posiadającego inżynierską wiedzę i poświęcającego czas na opracowanie analiz i raportów. Jednakże, rozwój technologii informatycznych - w tym metod analitycznych, takich, jak uczenie maszynowe - pozwala na szybką diagnozę bez zbędnego angażowania ekspertów do zadań analitycznych. Monitorowanie wibracji stosuje się m.in. do urządzeń takich jak: pompy, wentylatory, sprężarki, przekładnie, silniki, turbiny.

## Termografia

Zaawansowane oprzyrządowanie optyczne pozwala na monitorowanie emisji w podczerwieni za pomocą kamer termowizyjnych, termometrów na podczerwień lub skanerów liniowych. Analiza uzyskanych wyników (temperatury, ich rozkład oraz zmiany w czasie) pozwala określić aktualny stan zdrowia urządzenia i wykryć potencjalne anomalie i usterki. W praktyce termografia jest stosowana jako nieinwazyjna metoda diagnostyczna. Przykładem jest tutaj zastosowanie termografii do wykrywania grubości ścianek w przypadku ubytków spowodowanych korozją i erozją przepływu w wysokotemperaturowych rurach ciśnieniowych [32]. Podobne zastosowania pozwalają na szacowanie ubytków materiału w rurach ścian kotłów [33]. Metoda ta jest również stosowana do diagnozowania urządzeń elektrycznych oraz wykrywania wycieków oleju [34]. Termografia w dobie rozwoju technologii związanych z odnawialnymi źródłami energii jest również szeroko stosowana do wykrywania uszkodzeń farm fotowoltaicznych (ang. *Photovoltaic - PV*), wykorzystując dane z aparatury termowizyjnej umieszczonej na dronie. Takie zastosowanie zwiększa możliwości i bezpieczeństwo inspekcji [35, 36] oraz dostarcza

metod do określenia stanu technicznego paneli [37, 38].

### **Analiza oleju**

Olej jest bardzo ważnym materiałem eksploatacyjnym i odgrywa ważną rolę przy pracy maszyny - jest odpowiedzialny za smarowanie, chłodzenie, czyszczenie, ochronę oraz uszczelnianie [39]. Systematyczna analiza składu chemicznego i zanieczyszczeń oleju pozwala na określenie zużycia elementów maszyn oraz jakości smarowania. Pozwala na określenie stanu zużycia elementów maszyn [40, 41] oraz bardziej efektywne planowanie działań prewencyjnych, takich jak wymiana oleju czy filtrów [42]. Analiza oleju obejmuje badanie: lepkości, zanieczyszczeń, zawartości części stałych, utleniania, nitrowania, całkowitej liczby kwasowej, całkowitej liczby zasadowej, liczby cząstek stałych. Badanie tych właściwości pozwala określić jakość działania środka smarnego, wykryć nieszczelności, korozję lub ubytki spowodowane zużyciem materiału. Technikami uzupełniającymi w tym podejściu są spektrografia i ferrografia, pozwalające na analizę zanieczyszczeń i elementów stałych w składzie próbki. Stosując te techniki, można przeprowadzić analizę w celu określenia rodzajów degradacji, takich jak zużycie przez tarcie, zużycie przez cięcie, zmęczenie toczne i zużycie ślizgowe [43, 44]. Ograniczenia stosowania tej techniki związane są z kosztami sprzętu oraz trudnościami w systematycznym (automatycznym) pobieraniu próbek oleju i interpretacji wyników.

### **Monitorowanie parametrów procesu**

W tej metodzie wykorzystujemy rzeczywiste pomiary w celu określenia wskaźników wydajności procesu lub wskaźnik zdrowia. Monitorując ten wskaźnik (np. sprawność, wydajność) w czasie, można ocenić zmiany stanu urządzenia, bądź instalacji. Technika ta jest szeroko stosowana w połączeniu z technologiami IoT, uczenia maszynowego i technologiami Big Data. Możemy wykorzystać ogromne liczby danych generowanych w systemach technologicznych do zadań predykcyjnych. Wskaźniki wydajności mogą być bezpośrednio obliczane na podstawie danych. Na przykład sprawność pompy może być określana poprzez obliczenie stosunku mocy wyjściowej do mocy wejściowej [45], na podstawie takich parametrów, jak przepływ wody, ciśnienie wyjściowe, ciśnienie wejściowe i pobór mocy.

### Analiza akustyczna

Technika ta obejmuje analizę sygnałów akustycznych, szumu i ultradźwięków. Dzięki stosunkowo niedrogim narzędziom możliwe jest monitorowanie maszyn w sposób podobny do analizy drgań. Analizując sygnał w dziedzinie częstotliwości, możemy wykryć anomalie spowodowane tarciem oraz naprężenia, które mogą być objawami pogorszenia się stanu technicznego urządzenia. W przypadku wykrywania uszkodzeń łożysk lub przekładni, analiza akustyczna może uzupełniać techniki oparte na monitorowaniu drgań w celu wykrywania mniejszych defektów [46]. Analiza ultradźwiękowa jest też wykorzystywana do wykrywania nieszczelności w zaworach i rurach. Nieszczelności generują identyfikowalną sygnaturę w paśmie wysokich częstotliwości [47]. W pracy [48] autorzy wykazali, iż badając kształt i charakterystykę fali ultradźwiękowej, możliwe jest również wykrycie kawitacji w pompie odśrodkowej.

### Analiza prądu silnika

Silniki elektryczne są ważnymi komponentami dla wielu zakładów produkcyjnych. Ich awarie często prowadzą do przestojów w produkcji. Dlatego wymagają one szczególnej uwagi. Pod względem występujących awarii są one narażone zarówno na usterki mechaniczne, charakterystyczne dla maszyn wirujących, jak i na usterki o charakterze elektrycznym. Do typowych awarii należą tutaj zatarcia łożysk, awarie uzwojenia stojana, awarie wirnika, uszkodzenia izolacji [49]. Analiza prądu silnika obejmuje następujące metody:

- Testowanie rezystancji izolacji - izolacja może zostać uszkodzona przez czynniki, takie jak wysoka temperatura lub zanieczyszczona przez wilgoć. Przykładowa technika wykrywania uszkodzeń izolacji polega na uziemieniu ramy silnika i przyłożeniu napięcia stałego do uzwojeń silnika za pomocą urządzenia pomiarowego. Urządzenie odczytuje wartość rezystancji, pozwalając na wykrywanie ewentualnych uszkodzeń w izolacji [50].
- Analiza sygnatury prądu silnika (ang. *Motor current signature analysis*) - technika stosowana do analizy i monitorowania elektrycznych silników indukcyjnych, generatorów, transformatorów mocy i innych urządzeń elek-



trycznych. W tej metodzie badany jest prąd zasilający. W pierwszej fazie na podstawie transformacji widma częstotliwości tworzona jest sygnatura prądowa urządzenia. Usterki w podzespołach silnika - zarówno mechanicznych, jak i elektrycznych - powodują anomalie w polu magnetycznym oraz zmianę indukcyjności wzajemnej i własnej silnika, które pojawiają się w widmie częstotliwościowym prądu zasilającego silnik [51, 52]. Dzięki tej metodzie możliwe jest wykrycie takich uszkodzeń, jak [53, 49]:

- uszkodzenia wirnika - usterka może powodować iskrzenie i przegrzanie silnika. Badanie widma częstotliwości prądów stojana może zapewnić wczesne wykrycie usterki [54, 55];
- awarie łożysk - usterki spowodowane niewspółosiowością, np. po nieprawidłowym montażu łożysk [56], oraz zwiększonymi wibracjami [57];
- usterki związane z mimośrodowością - stan, gdy odległość szczeliny powietrznej między wirnikiem a stojanem nie jest równa [58, 59];
- uszkodzenia stojana lub obudowy - usterki zwykle związane z uszkodzeniem izolacji. Zwarcie zwojów powoduje nadmierne nagrzewanie się cewki stojana i brak równowagi prądowej [60, 61];
- zużycie materiału - degradacja elementów silnika obserwowana w dłuższym okresie czasu. Zużycie sprzętu jest widoczne jako zmiany w widmie prądu.

### Wizualna inspekcja

Nawet najbardziej zaawansowane metody i narzędzia w pewnych sytuacjach nie mogą zastąpić tradycyjnych, wizualnych, metod kontroli. Aby uniknąć przeoczenia usterek, które nie są zdefiniowane przez modele analityczne i nie objęte zainstalowanym opomiarowaniem, zadania prewencyjne powinny być wspierane przez doświadczenie inżynierskie w procesie tradycyjnych inspekcji. Tradycyjny proces może być wspierany przez nowoczesne technologie, które umożliwiają mobilność i dostęp do informacji. Technologiami z pogranicza Przemysłu 4.0 wspierającymi zadania inspekcyjne są: rzeczywistość rozszerzona (ang. *Augmented reality*) [62],

aplikacje mobilne [63], czy technologia RFID (ang. *Radio-frequency identification*) [64].

## 2.2 Techniki i metody wspierające procesy utrzymania ruchu

Wybór adekwatnej strategii utrzymaniowej, klasyfikacja krytyczności urządzeń produkcyjnych oraz gospodarka materiałowa to kluczowe kwestie związane z efektywnym zarządzaniem aktywami. Podejmowane działania opierają się najczęściej na przyjętej metodyce zarządzania aktywami oraz założeniach dotyczących oczekiwanej dostępności i wydajności. Zaadaptowane procesy i techniki pozwalają na ciągłe doskonalenie i osiąganie celów. Czynnikiem wspierającym efektywność przedstawionych metod są aktualna dokumentacja techniczna, dostęp do danych dotyczących historii napraw i remontów, dane diagnostyczne, warunki gwarancyjne oraz zalecenia producenta. Zazwyczaj dane te są przechowywane w dedykowanych systemach informatycznych, mogą to być przykładowo systemy klasy:

- EAM (ang. *Enterprise asset management*) - system zarządzania aktywami przedsiębiorstwa,
- CMMS (ang. *Computerized maintenance management system*) - skomputeryzowany system zarządzania utrzymaniem ruchu.

Specjalizowane systemy dedykowane do przetwarzania i fuzji dużej liczby danych przemysłowych umożliwiają wykorzystanie również danych procesowych (pochodzących z technologii operacyjnej) do określania wskaźników wydajności i stanu urządzeń w zadaniach optymalizujących procesy utrzymania ruchu i zarządzania aktywami. W kolejnych podrozdziałach przedstawione zostaną klasyczne procesy wspierające zadania związane z utrzymaniem i konserwacją aktywów.

### 2.2.1 Całkowite produktywne utrzymanie ruchu maszyn

Całkowite produktywne utrzymanie ruchu maszyn (ang. *Total productive maintenance*, TPM) to metodologia wywodząca się z Japonii. Jej charakterystyczną cechą jest zorientowanie na uczestników procesu. Oznacza to koncentrację na ciągłej

poprawie efektywności urządzeń poprzez zaangażowanie wszystkich pracowników w zadania związane z utrzymaniem ruchu, szkoleniu personelu oraz zapewnieniu właściwej komunikacji pomiędzy operatorami oraz pracownikami technicznymi. Metodologia TPM jest powiązana z koncepcją tzw. szczupłej produkcji (ang. *Lean manufacturing*), czego wspólnym mianownikiem jest dążenie w celu wyeliminowania następujących strat [65]:

- liczba awarii (dostępność),
- przestoje spowodowane przez czynności serwisowe (dostępność),
- nieprawidłowe ustawienia i regulacja (wydajność),
- ograniczenia produkcji spowodowane spadkiem prędkości (wydajność),
- defekty w produkcji (jakość),
- straty wynikające z przygotowania urządzeń do pracy (jakość).

Podstawowym wskaźnikiem wydajności TPM jest współczynnik ogólnej efektywności sprzętu (ang. *Overall equipment effectiveness*, OEE), który jest iloczynem dostępności, wydajności i jakości.

$$OEE = Dostępność \times Wydajność \times Jakość \quad (2.1)$$

TPM może być wspierane przez pozostałe metody związane z szczupłą produkcją, takie jak 5S [66], 5WHYs [67] lub kaizen [68]. Wszystkie działania podporządkowane są następującym pryncypiom:

- edukacja i szkolenia,
- autonomiczna konserwacja,
- konserwacja zapobiegawcza,
- planowanie i tworzenie harmonogramów,
- inżynieria niezawodności i konserwacja predykcyjna,
- projektowanie urządzeń i zarządzanie rozruchem.

### 2.2.2 Eksploatacja zorientowana na niezawodność

Eksploatacja zorientowana na niezawodność (ang. *Reliability centered maintenance*, RCM) koncentruje się na uzyskaniu jak najlepszych wskaźników niezawodności procesu produkcyjnego. Jest definiowana jako proces służący do określenia,

co należy zrobić aby zapewnić, że każde urządzenie będzie spełniało oczekiwania użytkowników w aktualnym kontekście eksploatacyjnym [69]. Podstawowym celem RCM jest zachowanie funkcji systemu, natomiast mniejszy priorytet ma tutaj utrzymanie urządzenia w ciągłej eksploatacji. Wdrożenie RCM wymaga pełnego zrozumienia funkcji składnika aktywów fizycznych oraz charakteru awarii związanych z tymi funkcjami. Ze względu na indywidualne traktowanie każdego rodzaju awarii, możliwym w tej metodzie jest przeoczenie pewnych zdarzeń, które mogą mieć wpływ np. na żywotność, oczekiwaną długość życia lub utratę wydajności [70]. RCM koncentruje się na znalezieniu odpowiedzi na następujące pytania:

- Jakie są funkcje i związane z nimi pożądane standardy wydajności urządzenia w jego obecnym kontekście operacyjnym (funkcje)?
- Jakie zdarzenia mogą prowadzić do utraty zdolności realizacji funkcji (utrata funkcjonalności)?
- Co powoduje każdą z utrat funkcjonalności (tryby awarii)?
- Co się stanie, gdy wystąpi dana awaria (skutki awarii)?
- W jaki sposób awaria wpływa na cały proces (konsekwencje awarii)?
- Co należy zrobić, aby przewidzieć lub zapobiec awarii? (zadania proaktywne i ich planowanie)?
- Co należy zrobić, jeśli nie można zrealizować działań proaktywnych (działania doraźne)?

Metodę RCM można z powodzeniem zastosować do zarządzania utrzymaniem ruchu w dystrybucji energii elektrycznej. Autorzy pracy [71], uwzględniając koszty przestojów, zaprojektowali algorytm optymalizacyjny, który pozwolił na zmniejszenie kosztów całkowitych przy jednoczesnym zwiększeniu poziomu niezawodności. Inny przykład przedstawia instalację znajdującą się w Szwecji, gdzie zbadano kompleksowe ramy do wdrożenia RCM, w tym stosunek kosztów do korzyści dla krytycznych urządzeń rozdzielni energii [72]. W obszarze odnawialnych źródeł energii analiza zastosowania RCM przeprowadzona dla krytycznych elementów turbin wiatrowych została przedstawiona w artykule [73], gdzie autorzy zwrócili uwagę na znaczenie standaryzowanego i zautomatyzowanego gromadzenia danych o awariach i konserwacji.

### 2.2.3 Analiza trybów i skutków awarii

Analiza trybów i skutków awarii (ang. *Failure mode and effect analysis*, FMEA) to metoda pozwalająca na identyfikację potencjalnych trybów awarii dla urządzenia lub procesu, oceny związanego z nią ryzyka, określania priorytetów dla zdarzeń, określania i realizacji działań korygujących w celu rozwiązania najbardziej istotnych problemów. FMEA wraz z RCM są ważnymi metodami pozwalającymi na planowanie i wdrażania programów proaktywnych opartych na podejściach prewencyjnych i predykcyjnych [74]. Analiza może być stosowana na wielu etapach cyklu życia produktu. W zależności od etapu rozwoju wyróżnia się następujące rodzaje analiz FMEA: systemową, projektową, procesową lub serwisową. Analiza FMEA polega na dekompozycji funkcjonalnej badanego obiektu (lub procesu) oraz zbiorczej analizie ilościowej i jakościowej [75]. Przykładowy arkusz analizy FMEA przedstawiono na rys. 2.5. Podstawowymi elementami arkusza są:

- Obiekt/Funkcja,
- Tryb awarii,
- Skutki awarii,
- Przyczyny awarii,
- Ocena wpływu,
- Zalecane działanie.

Obiekt/Funkcja	Tryb awarii	Skutki awarii	Dotkliwość	Przyczyny awarii	Prawdopodob.	Obecny system detekcji	Wykrywalność	Numer priorytetu ryzyka (RPN)	Zalecane działanie	Wyniki			
										Dotkliwość	Prawdopodob.	Wykrywalność	RPN
Zespół pompy - pompa	ograniczona wydajność	wyciek / niska wydajność	4	uszkodzony zawór	4	wizualna inspekcja	2	32		4	4	2	32
	ograniczona wydajność	przegrzewanie / wysoka temperatura	4	zanieczyszczony filtr	6	monitorowanie procesu	2	48		4	6	2	48
	brak pompowania wody	zatrzymanie produkcji	10	uszkodzone łożysko	1	monitorowanie procesu	4	40	okresowa kontrola drgań	10	1	2	20
Zespół pompy - silnik	brak pompowania wody	zatarcie silnika	10	niski poziom oleju	1	okresowe przeglądy	2	20		10	1	2	20
	brak pompowania wody	zatrzymanie produkcji	10	usterka elektryczna	2	okresowe przeglądy	8	160	częstsze przeglądy	10	2	4	80

Rysunek 2.5: Przykładowy arkusz analizy FMEA

Arkusz zawiera dwie kategorie analizowanych danych - jakościowe i ilościowe. Analiza jakościowa jest wykorzystywana do oceny ryzyka i ustalania priorytetów

działań naprawczych. Koncentruje się na możliwych usterkach, ich przyczynach i skutkach. Natomiast analiza ilościowa obejmuje analizę krytyczności dla każdego elementu w danym czasie pracy i określa niezawodność elementu związaną z każdym potencjalnym trybem awarii. Dla każdego trybu awarii ocenia się także prawdopodobieństwo, że dana część spowoduje awarię systemu. Aby ocenić wpływ zidentyfikowanych usterek, można zastosować metodę numeru priorytetu ryzyka (ang. *Risk priority number*, RPN). Metoda ta polega na określeniu następujących elementów:

- dotkliwości każdej z awarii (ang. *Severity*),
- prawdopodobieństwa wystąpienia (ang. *Occurence*),
- trudności wykrycia (ang. *Detection*).

RPN jest następnie obliczane jako:

$$RPN = \text{dotkliwość} \times \text{prawdopodobieństwo} \times \text{wykrywalność} \quad (2.2)$$

W przeglądzie literatury analiza FMEA została z powodzeniem zastosowana dla zespołu turbiny wiatrowej. W artykule [76] autorzy porównali ilościowe wyniki FMEA z rzeczywistymi wskaźnikami awarii wykazując istotną korelację wyników. Uzyskane wyniki i wnioski z pracy mogą być przydatne do projektowania turbin wiatrowych w przyszłości. Ponadto w artykule wskazano na oprogramowanie komputerowe wspomagające przetwarzanie danych i analizę FMEA [77, 78]. Wykonanie analizy FMEA może być łatwo skomputeryzowane i wykorzystane w trybie półautomatycznym przy użyciu systemów informatycznych. W kilku pracach [79, 80, 81], zaproponowano kodowanie struktury FMEA za pomocą sieci bayesowskiej. Uwzględnienie danych probabilistycznych pozwala na lepszą analizę ryzyka i stwarza możliwości dalszego przetwarzania informacji. Rozszerzenie analizy awarii poprzez zastosowanie metod eksploracji danych przedstawiono dla sygnałów rzeczywistych w studium przypadku dla elektrowni wodnej [82]. Autorzy rozszerzyli podstawową analizę FMEA o zastosowanie metod asocjacyjnych. Wiele prac poświęcono również automatycznemu generowaniu przeglądów FMEA

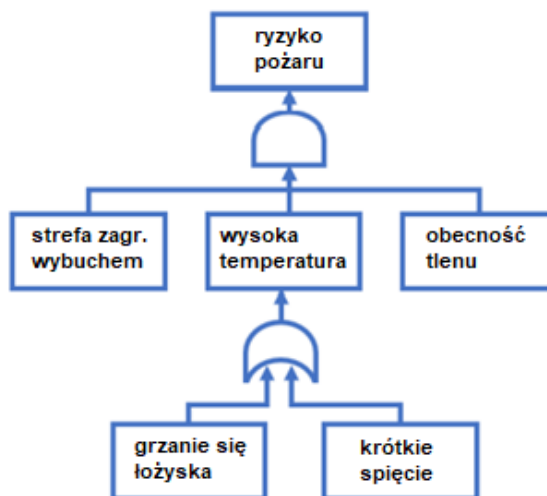
z wykorzystaniem danych historycznych oraz metod symulacyjnych, które pozwalają na przeprowadzenie tego procesu bez angażowania ekspertów [83, 84, 85]. Przykład zastosowania metod sztucznej inteligencji z wykorzystaniem techniki głębokiego uczenia w przemyśle lotniczym wykazał, że dokładność przewidywania usterek przewidywania usterek może oscylować wokół 95% [86].

#### 2.2.4 Analiza drzewa usterek

Analiza drzewa usterek (ang. *Fault tree analysis*, FTA) jest techniką wykorzystującą model logiczny przedstawiony w formie graficznej do opisanego zależności między wieloma zdarzeniami prowadzącymi do awarii. Tworzony diagram typu góra-dół składa się z dwóch rodzajów elementów: zdarzeń i bramek logicznych, które łączą się w celu zidentyfikowania przyczyny głównego niepożądanego zdarzenia, jak pokazano na rys. 2.6. Głównym celem analizy FTA jest zmniejszenie ryzyka awarii systemu na podstawie zidentyfikowanych przyczyn i ich prawdopodobieństwa. Ponadto, dzięki tej analizie można uzyskać poprawę wskaźników wydajności systemu. FTA może być przeprowadzona samodzielnie lub jako uzupełnienie analizy FMEA. Główne korzyści płynące z analizy FTA to:

- graficzna wizualizacja,
- możliwość określania zagrożenia zarówno dla pojedynczych elementów, jak i całego systemu,
- oszacowane prawdopodobieństwa wystąpienia dla każdej pierwotnej przyczyny usterki,
- ocena wpływu i ryzyka możliwych zmian w systemie,
- możliwość wyróżnienia komponentów krytycznych,
- identyfikacja możliwych ścieżek prowadzących do awarii,
- zdolność do przeprowadzania analizy jakościowej i ilościowej.

Niektóre przykłady w literaturze opisującej zastosowania analizy FTA w przemyśle obejmują analizę drzewa błędów dla transformatora energetycznego opartą na metodach analitycznych i diagnostyce termowizyjnej [87] lub obliczanie ryzyka powstania pożaru oraz wybuchu, łącząc informację płynącą z wiedzy eksperckiej oraz metod probabilistycznych [88]. Rozwój i rozszerzenia tej techniki wspierają



Rysunek 2.6: Drzewo usterek dla zdarzenia zagrożenia pożarem

narzędzia ułatwiające generowanie diagramów drzew błędów. Półautomatyczna budowa polega na translacji modelu zapisanego w językach reprezentujących przepływy, jak: SysML [89], UML [90], AADL [91] lub jest generowany na podstawie zdefiniowanego zestawu komponentów, tablic funkcyjnych lub tablic przejść [92, 93].

### 2.2.5 Analiza przyczyn źródłowych

Analiza przyczyn źródłowych (ang. *Root cause analysis*, RCA) jest techniką polegającą na przeprowadzeniu dogłębnej analizy w celu zidentyfikowania podstawowych przyczyn zaistniałej awarii oraz uniknięcia podobnych zdarzeń w przyszłości. Proces ten jest szeroko stosowany w przemyśle ze względu na złożoność systemów, w których powiązanie usterek z ich objawami nie jest łatwym zadaniem. Na przykładzie zatartego łożyska, najprostszym rozwiązaniem jest podejście korekcyjne, które ogranicza się do wymiany elementu na nowy. Analiza przyczyn źródłowych koncentruje się natomiast na znalezieniu przyczyny źródłowej, np. słabego smarowania, wycieku oleju, drgań, nieprawidłowego montażu itp. Co pozwala na zastosowanie działań zapobiegawczych, aby uniknąć podobnych sytuacji w przyszłości.



ści. Klasyczne metody wnioskowania opierają się na dedukcyjnej analizie opartej na wiedzy eksperckiej, w której można wykorzystać następujące techniki:

- 5WHYs (metoda pięciu pytań „dlaczego?”): metoda dedukcyjna polegająca na iteracyjnym zadawaniu pytań ”dlaczego” w odniesieniu do zaistniałej awarii. Przy prawidłowym sformułowaniu pytań i zachowaniu logiki przyczynowo-skutkowej metoda ta pozwala na analizę źródła usterki i poznanie jej przyczyn.
- Diagram szkieletowy (ang. *Fishbone*, zwany także diagramem Ishikawy): metoda służy do wizualizacji związków przyczynowo-skutkowych, pomagając w wizualny i ustrukturyzowany sposób odróżnić przyczyny od skutków danej awarii i podzielić skomplikowany problem na mniejsze części. Analizę rozpoczyna się od określenia wystąpienia zdarzenia (awarii lub wady), a następnie identyfikuje się wszystkie możliwe czynniki, które je spowodowały, kategoryzując grupy przyczyn. Typowy diagram podzielony na cztery kategorie (Człowiek, Maszyna, Metody, Materiały) przedstawiono na rys. 2.7
- Wykres Pareto: proste narzędzie, które w łatwy sposób kategoryzuje i wizualizuje dane na wykresie słupkowym. Stosując zasadę 80/20 (20% przyczyn powoduje 80% problemów), metoda ta umożliwia wyróżnienie tych przyczyn, które mają największy wpływ np. ilościowy lub finansowy.

Tradycyjna analiza przeprowadzana przez ekspertów jest zazwyczaj bardzo dokładna i wnikliwa. Jest ona jednak bardzo czasochłonna i wymaga posiadania wyczerpującej technicznej wiedzy branżowej, co w połączeniu ze złożonym systemem ogranicza możliwość powszechnego zastosowania tej metody. W praktyce analizuje się jedynie krytyczne usterki o dużym wpływie. Dlatego warto rozważyć zastosowanie metod eksploracji danych, które pozwalają zautomatyzować ten proces lub pomóc w jego znacznym uproszczeniu. Stosowane techniki wywodzą się z takich dziedzin, jak sztuczna inteligencja, sieci neuronowe, teoria grafów, statystyka, czy teoria automatów. Analizując różne algorytmy stosowane do analizy przyczyn źródłowych, autorzy jednego z artykułów przeglądowych [94] sklasyfikowali je jako:

- deterministyczne: oparte na zaprojektowanych regułach, na przykład implementacje drzew błędów (FTA), rejestry usterek, sieci Petriego,



Rysunek 2.7: Diagram Ishikawy przedstawiający skategoryzowane możliwe przyczyny awarii

- probabilistyczne - uwzględniające problem niepewności i wykorzystujące metody stochastyczne, w tym sieci bayesowskie, ukryte modele Markowa, drzewa decyzyjne lub logikę rozmytą.

Modele analityczne charakteryzują się różnymi właściwościami i działaniem w zależności od celu ich stosowania. Celem analizy może być wykrycie pierwotnej przyczyny na podstawie objawów, przy użyciu algorytmów zdolnych do detekcji, klasyfikacja lub grupowanie zdarzeń występujących jednocześnie. Analiza przyczyn źródłowych może także dostarczać dodatkowych informacji, dotyczących klasy pierwotnych przyczyn na podstawie objawów oraz pozwala pogłębić ich naturę, pochodzenie i powiązane z nimi zdarzenia.

## 2.3 Zaawansowana analityka wspierająca procesy utrzymaniowe

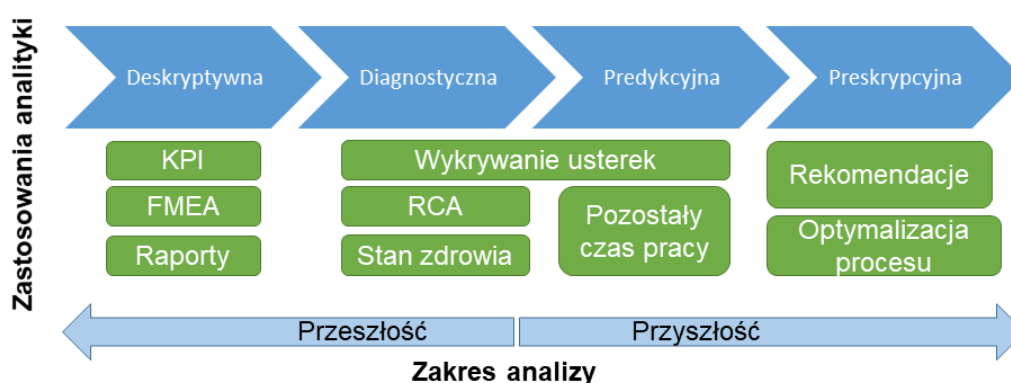
W niniejszym rozdziale przedstawiono przykłady wykorzystania różnego rodzaju zbiorów danych i technik analitycznych w celu uzyskania wsparcia procesów w obszarze utrzymania ruchu. Przedstawione metody zostały skategoryzowane pod względem stopnia skomplikowania i celu jaki realizują oraz umożliwiają dokładny opis zdarzeń przeszłych, bieżącej sytuacji, a także przewidywanie wyników

w przyszłości oraz symulację i optymalizację oczekiwanych rezultatów.

### 2.3.1 Złożoność i zakres analizy

Rozwijająca się cyfryzacja zbiorów danych oraz techniczne możliwości ich przetwarzania w czasie rzeczywistym pozwalają na wykorzystanie technik automatyzacji i wnioskowania do wspomagania tradycyjnych procesów utrzymania ruchu. Wdrożenie systemów eksploracji danych daje niewątpliwe korzyści dla procesów wspierających produkcję, ale też wymaga zaangażowania określonych zasobów i w zależności od realizowanego zagadnienia powoduje konieczność ich zapewnienia na różnych poziomach, m.in.:

- infrastruktury IT (repozytoria danych, chmura obliczeniowa),
- wiedzy eksperckiej (wiedza branżowa, analizy danych),
- dostępności danych historycznych.



Rysunek 2.8: Złożoność i zakres analizy danych

W zależności od złożoności analizy oraz kontekstu czasowego wyniku, możemy wyróżnić następujące rodzaje analiz, jak pokazano na rys. 2.8:

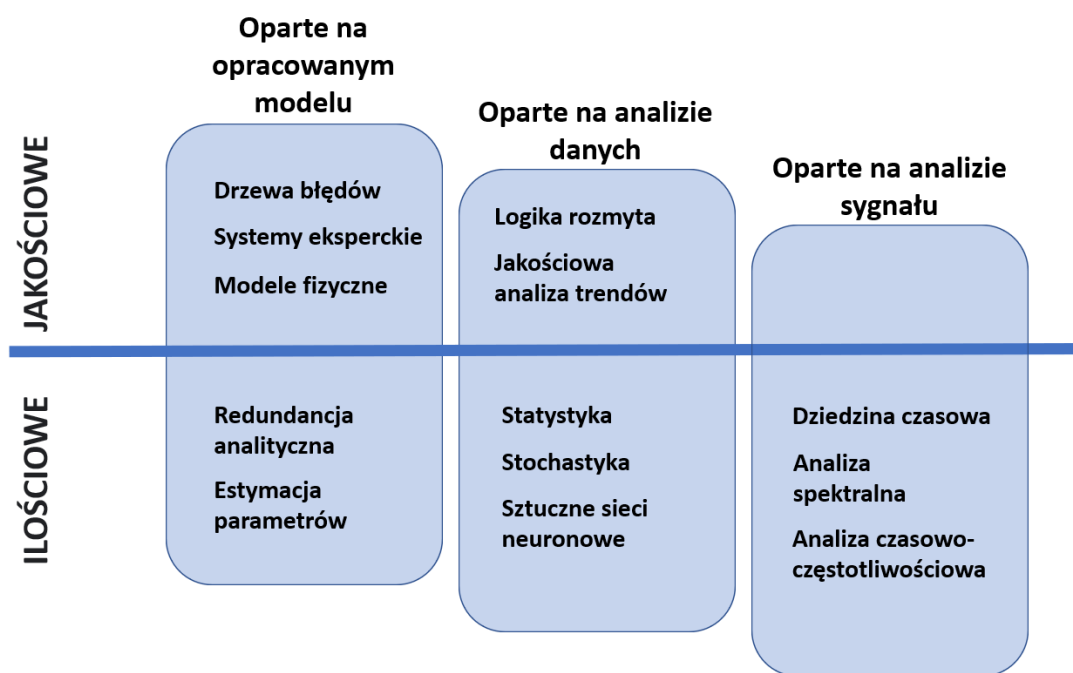
- Analiza deskryptywna - odpowiada na pytanie "co się stało?". Jest to zbiór technik i metod wykorzystywanych do interpretacji danych historycznych

w celu lepszego zrozumienia zaszłych zdarzeń oraz określenia metryk służących do oceny i porównania poszczególnych okresów czasowych. Przykładem może być obliczanie współczynników, takich jak: średniego czasu do awarii (ang. *Mean time to failure*, MTTF) dla urządzenia lub instalacji. Do zadań analitycznych stosuje się narzędzia, takie jak raporty, metryki, KPI (ang. *Key performance indicator*) lub wykresy, wykorzystując głównie statystykę, agregację danych oraz techniki wizualizacji.

- Analiza diagnostyczna - odpowiada na pytanie "dlaczego tak się stało?". Wykorzystuje techniki z obszaru eksploracji danych w celu określenia przyczyn aktualnego stanu. W obszarze utrzymania ruchu analiza deskryptywna jest stosowana przede wszystkim w zadaniach pozwalających na określenie przyczyn źródłowych usterki. Wykorzystywane narzędzia w tej grupie są uzupełniane przez metody i produkty wspierające eksplorację danych.
- Analiza predykcyjna - odpowiada na pytanie "co się stanie?". Rodzaj analizy, w której wykorzystuje się zarówno narzędzia statystyczne, jak i uczenie maszynowe do przewidywania wyników w przyszłości. W kontekście procesów utrzymaniowych rozwijającym się obszarem jest tutaj predykcyjne utrzymanie ruchu (ang. *Predictive maintenance*), otwierające nowe możliwości, które dzięki wykorzystaniu zaawansowanych technologii informatycznych pozwala na zbieranie, integrację i analizę danych online. Techniki predykcyjne koncentrują się na wykrywaniu przyszłych awarii oraz określaniu szacowanego pozostałego okresu użytkowania (określając przewidywany czasu do wystąpienia awarii).
- Analiza preskrypcyjna – angażuje zaawansowane techniki symulacyjne i optymalizacyjne, które analizują możliwe scenariusze dla różnych ścieżek decyzyjnych na podstawie wyników predykcji i wybierają optymalne rozwiązanie zgodnie z przypisaną funkcją celu. Wykorzystuje się tu techniki związane ze sztuczną inteligencją, optymalizacją i metody symulacji do wspomaganie podejmowania decyzji w czasie rzeczywistym. Przykładem może być algorytm, który steruje pracą maszyny w taki sposób, aby przedłużyć jej pozostały okres użytkowania do najbliższego planowanego przestoju.

## 2.3.2 Klasyfikacja metod prognozowania stanu technicznego urządzeń

Metody wykrywania i diagnozowania awarii można sklasyfikować ze względu na przyjęte podejście, wykorzystywane zasoby oraz stosowane techniki. Najczęściej metody są pogrupowane ze względu na przyjęte podejście - wyróżniamy tutaj podejścia oparte na analizie danych (ang. *Data-driven*) oraz podejścia oparte na opracowanym modelu (ang. *Model-driven*). Niektórzy autorzy wyróżniają również podgrupy, jak np. metody oparte na wiedzy, analizie sygnału lub probabilistyczne. Zgodnie z taksonomią przyjętą w literaturze i biorąc pod uwagę charakterystykę opisanych modeli, zaproponowano klasyfikację dwuwymiarową, jak przedstawiono na rys. 2.9.



Rysunek 2.9: Klasyfikacja metod prognostycznych w obszarze predykcyjnego utrzymania ruchu

Ze względu na rodzaj wykorzystywanej informacji oraz sposób projektowania modelu prognostycznego metody prognozowania stanu technicznego urządzeń możemy podzielić na:

- Oparte na opracowanym modelu - grupa technik opartych na modelach wymaga, aby system był zaprojektowany w taki sposób, aby zakodować wiedzę ekspercką oraz zachodzące zjawiska w postaci cyfrowej. Model przeważnie jest projektowany w sposób deterministyczny, np. przy użyciu równań i modelowania matematycznego, tak aby odtworzyć zachowanie systemu. Podejścia te są czasem określane jako białe skrzynki (ang. *White box*), gdzie zależności między wejściami i wyjściami są starannie zaprojektowane i przewidywalne.
- Oparte na analizie danych - podejścia wykorzystujące duże zestawy danych historycznych oraz techniki, takie jak uczenie maszynowe do tworzenia reguł wnioskowania. Zwyczajowo modele utworzone tą techniką - szczególnie przy wykorzystaniu sztucznych sieci neuronowych - są nazywane czarnymi skrzynkami (ang. *Black box*) ze względu na ograniczony wgląd w strukturę i mechanizmy modelu. Proces projektowania opiera się na starannej selekcji danych treningowych i wyborze odpowiedniej architektury przy procesie uczenia. Wymagają one znacznie mniejszej wiedzy branżowej kosztem nieco większego wkładu analityka zajmującego się przetwarzaniem danych.
- Oparte na analizie sygnału - grupa metod bardzo zbliżonych do tradycyjnie stosowanych metod diagnostycznych. Opierają się one na założeniu, że w mierzonym sygnale (oraz jego cechach statystycznych) odzwierciedlają się stany awaryjne urządzenia. Stosowane techniki opierają się na badaniu pojedynczego sygnału lub pomiaru, wykorzystując techniki eksploracji danych (ekstrakcja cech) oraz dekompozycji/transformacji badanego sygnału.

Ze względu na charakter danych przetwarzanych przez model oraz wzajemne relacje pomiędzy danymi, metody prognozowania stanu technicznego możemy podzielić na:

- Metody ilościowe - podejścia ilościowe koncentrują się na określeniu relacji między wejściem a wyjściem systemu. Metody z tej grupy odpowiadają na pytanie "ile?", determinując tym samym rodzaj przetwarzanych danych do wartości liczbowych. Opierają się na metodach matematycznych, staty-

stycznych lub stochastycznych uwzględniając potencjalną niepewność wyników.

- Metody jakościowe - w modelach jakościowych relacje w systemie są wyrażone przez jakościowe funkcje poszczególnych części systemu, przeważnie sformułowanych w postaci grafów, przepływów lub reguł typu "IF - THEN". Metody jakościowe odpowiadają na pytania: "co?", "jak?", "dlaczego?". Istotą metod z tej grupy jest lepsze poznanie charakteru badanego zjawiska, skupiając się przede wszystkim na zadaniach detekcji i klasyfikacji zdarzeń.

### 2.3.3 Metody oparte na opracowanym modelu

Metody oparte na opracowanych modelach polegają głównie na wiedzy eksperckiej, dzięki czemu tworzony system jest przejrzysty, jasny i dobrze odzwierciedlający intencje projektanta. Poniżej przedstawiono niektóre z technik kwalifikujące się do tej kategorii wraz z ich opisem i przykładami zastosowania w zadaniach wykrywania usterek.

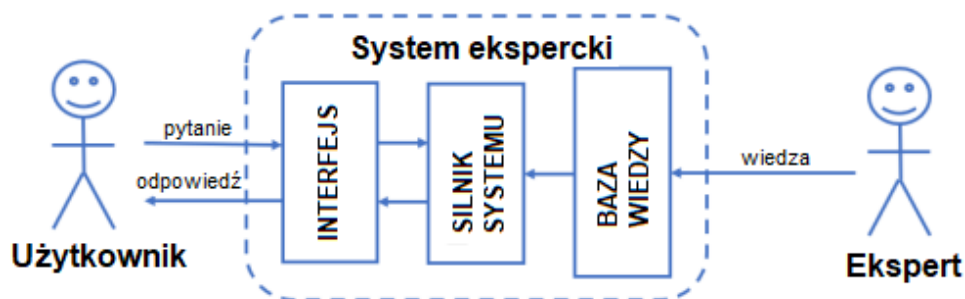
#### Drzewa błędów

Drzewo błędów (ang. *Fault tree*) przedstawia strukturę przepływu przyczynowo-skutkowego w postaci wizualnego diagramu. Zastosowanie tej metody jest przejrzyste i czytelne dla odbiorcy. Metoda daje możliwość opisanie zdarzeń (np. blokada zaworu, zwarcie), które trudno przedstawić za pomocą metod ilościowych opartych na samych pomiarach [95]. Drzewa błędów są z powodzeniem stosowane zarówno w obszarze bezpieczeństwa i higieny pracy, jak i optymalizacji niezawodności. W opracowaniu Vesely i in. [95] przedstawiają zastosowanie drzew błędów, które w połączeniu z technikami logiki rozmytej pozwalają na obliczenie prawdopodobieństwa wystąpienia poszczególnych zdarzeń (usterek). W ten sposób metoda zostaje uzupełniona o elementy ilościowe pozwalające na obliczenie prawdopodobieństwa zdarzeń. Drzewa błędów rozszerzone o teorię zbiorów rozmytych zostały również zastosowane w branżach: petrochemicznej [96] oraz górniczej [97] do zarządzania ryzykiem związanym z występowaniem pożarów i wybuchów. Tradycy-

cyjna analiza przyczyn źródłowych z wykorzystaniem drzew błędów i diagramów Ishikawy została zastosowana dla turbiny gazowej w jednej z elektrowni. Dzięki uwzględnieniu prawdopodobieństwa i potencjalnych kosztów, autorzy pracy [98] byli w stanie usprawnić proces projektowy oraz wspierać planowanie działań prewencyjnych.

## Systemy eksperckie

Ideą systemu eksperckiego jest zakodowanie wiedzy ekspertów branżowych w postaci algorytmów i struktur, tak aby proces wnioskowania mógł być zautomatyzowany, np. przez program komputerowy. Schemat systemu ekspertowego pokazano na rys. 2.10.



Rysunek 2.10: Schemat ideowy systemu eksperckiego

Użytkownik komunikuje się z systemem za pomocą interfejsu. Może to być typowa aplikacja komputerowa, aplikacja mobilna, specjalistyczne okulary pracujące w trybie rzeczywistości rozszerzonej [99, 100] lub wirtualnego asystenta [101]. Baza wiedzy to ustrukturyzowane repozytorium dokumentacji, rozwiązań i doświadczeń, zasilane i stale aktualizowane przez specjalistów z danej dziedziny. Na podstawie przeglądu dostępnych technik [102, 103], możemy wyróżnić następujące główne techniki stosowane w systemach eksperckich:

- systemy oparte na regułach (ang. *Rule based*) - polegają na kodowaniu logiki działania w postaci zdań warunkowych np. JEŻELI-TO. Technika ta umożli-



liwia kodyfikację zapisów instrukcji obsługi, np. JEŻELI *temperatura łożyska przekroczy z góry określony próg*, TO *wyślij powiadomienie*.

- wnioskowanie oparte na przykładach (ang. *Case-based reasoning*) - polega na wykorzystaniu bazy wiedzy, gdzie na podstawie podobnych wcześniejszych przypadków dostarczane są rozwiązania dla bieżącego problemu.
- sieci neuronowe i algorytmy ewolucyjne - to dwa podejścia wykorzystujące techniki tzw. miękkich obliczeń (ang. *Soft computing*), które na etapie wnioskowania stosują algorytmy oparte np. na sztucznych sieciach neuronowych lub algorytmach genetycznych [104], zamiast jawnych reguł logicznych.
- logika rozmyta - podejście, które opiera się na teorii zbiorów rozmytych i umożliwia uwzględnienie niepewności we wnioskowaniu. Wykorzystuje metody statystyczne i probabilistyczne w celu odzwierciedlenia ludzkiego sposobu podejmowania decyzji. W porównaniu ze standardowymi regułami JEŻELI -> TO, reguły rozmyte zawierają wyrażenia, które są oparte na zbiorach rozmytych:

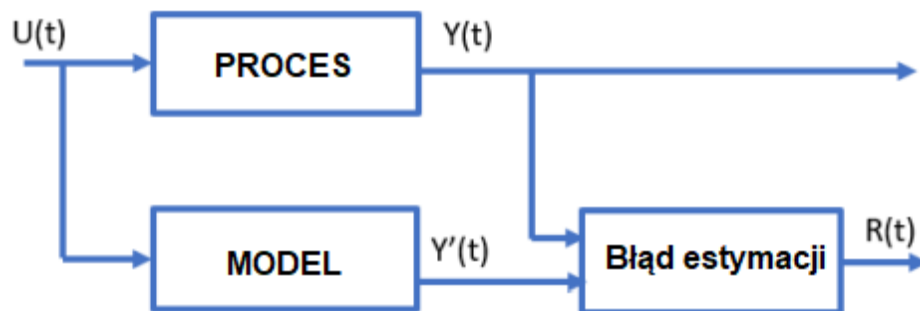
**JEŻELI** (*T jest Wysokie*) i (*T rośnie*) **TO** *wyślij powiadomienie*

- projektowanie obiektowe - skupia się na przechowywaniu procedur i danych w postaci klas i hierarchii. Obiekty (instancje klas) przechowują wartości, tekst, grafikę, diagramy oraz wszelkie informacje funkcjonalne. Metoda ta pozwala na modelowanie faktów i relacji za pomocą trzech pojęć: abstrakcyjnego typowania danych, dziedziczenia oraz tożsamości obiektu.

### Analityczna redundancja

Jedną z najczęściej stosowanych metod wykrywania błędów i anomalii opartą na modelu analitycznym jest redundancja analityczna [105]. Metoda ta polega na modelowaniu badanego procesu i śledzeniu różnicy pomiędzy rzeczywistą wartością wyjściową ( $Y$ ) a wartością oszacowaną ( $Y'$ ). Uzyskana różnica, zwana również residuum, jest następnie analizowana w celu prawidłowej diagnozy błędu. Uproszczony przebieg tej metody pokazano na rys. 2.11. Model może być fizyczną kopią

urządzenia (redundancja sprzętowa) lub wyrażeniem matematycznym (deterministycznym lub statystycznym), które opisuje badaną wartość na podstawie zależności między zmiennymi procesowymi. W zależności od charakteru analizowanego zbioru danych wyróżnia się dwa rodzaje redundancji. Redundancja bezpośrednia analizuje zależności pomiędzy skorelowanymi chwilowymi wyjściami czujników, natomiast redundancja czasowa szacuje wartości oparte na wyjściach czujników i wejściach elementów wykonawczych w przedziale czasu.



Rysunek 2.11: Schemat blokowy zastosowania analitycznej redundancji

W ramach tego podejścia wyróżnia się najczęściej trzy rodzaje technik:

- Obserwator (ang. *Observer*) - technika polega na porównywaniu wartości zmierzonych z wartościami oszacowanymi na podstawie modeli matematycznych dla każdego z sygnałów opisujących urządzenie. Stany wewnętrzne są reprezentowane przez relację między wejściem, a wyjściem. W prawidłowo działającym systemie różnice (residua) powinny oscylować wokół zera, natomiast pojawienie się znaczących wartości różnic powinno wskazywać stany awaryjne. Metody należące do tej grupy pierwotnie opierały się na metodzie Luenbergera [106, 107] lub filtrze Kalmana [108, 109].
- Estymacja parametrów (ang. *Parameter estimation*) - zakłada, że usterka wpływa na parametry systemu (które niekoniecznie są pomiarami). Technika ta polega na badaniu zmian monitorowanych parametrów w dziedzinie czasu,

np. poprzez porównanie ich z warunkami wzorcowymi dla zdrowego systemu lub śledzenie zmian charakterystyk w czasie [110].

- Przestrzeń parzystości (ang. *Parity space*) - jest techniką podobną do techniki opartej na obserwatorze, ale jej istotą jest uzyskanie wektora różnic poprzez porównanie zgodności wyników generowanych przez modele cyfrowe z pomiarami (wyjściami czujników) lub wejściami elementów wykonawczych (aktywatorami) [111, 112]. Identyfikację błędów dla czujników można zrealizować poprzez zaprojektowanie relacji, tak aby wartości poszczególnych reszt były powiązane z konkretnymi czujnikami. Podobnie, w przypadku identyfikacji uszkodzeń elementów aktywnych, można zastosować przekształcenia przestrzeni parzystości, tak aby wyniki niezerowe jednoznacznie wskazywały źródło usterki. Przykładami takiego podejścia są: relacja parzystości pojedynczego urządzenia [113] lub ortogonalne równania parzystości [114, 115].

#### 2.3.4 Metody oparte na analizie danych

Metody oparte na analizie danych wykorzystują dostępne zasoby danych, w tym obszerne repozytoria danych historycznych do modelowania procesów i tworzenia mechanizmów wnioskowania. Metody przedstawione w tej grupie wykorzystują zaawansowaną analitykę, w tym techniki eksploracji danych, takie jak uczenie maszynowe czy metody statystyczne. Głównymi czynnikami pozwalającymi na osiągnięcie oczekiwanych rezultatów są tu jakość danych treningowych, zdolność do przetwarzania dużej liczby danych, w tym danych strumieniowych, oraz umiejętności analityczne poparte wiedzą branżową. Spektrum metod stosowanych w tej kategorii obejmuje wykorzystanie metod, m.in. takich jak przedstawione w niniejszym podrozdziale.

#### Systemy rozmyte

Techniki oparte na logice rozmytej są często zaliczane do kategorii systemów eksperckich. Charakterystyczną cechą i niewątpliwie dodatkową zaletą tych metod jest stosowanie technik ilościowych w projektowanych regułach, co jest zaletą przy zastosowaniu w systemach dynamicznych. Istotą systemów rozmytych jest prze-

kształcenie wektora danych wejściowych w zbiór rozmyty i zastosowanie reguł rozmytych do wnioskowania na wzór zbliżony do funkcjonowania rozumowania ludzkiego [116]. Oznacza to, że dyskretne dane wejściowe, jak np. "PRAWDA"/"FAŁSZ", mogą być przekształcane w stany pośrednie zgodnie z regułą uwzględniającą wpływ innych zmiennych lub historię zmian. Projektowanie systemu rozmytego wymaga wysiłku, aby włączyć wiedzę ekspercką do reguł rozmytych, które są tworzone w celu poprawy działania całego systemu. Wiedza może tutaj być czerpana zarówno z doświadczenia ekspertów, jak i z danych historycznych, dlatego technika ta jest również stosowana zarówno w połączeniu z systemami eksperckimi, jak i metodami statystycznymi. Logika rozmyta znajduje również szerokie zastosowanie w systemach sterowania ze względu na szybkość i łatwość do zrozumienia mechanizm działania.


### Jakościowa analiza trendów

Jakościowa analiza trendów (ang. *Quality trend analysis*, QTA) opiera się na analizie szeregów czasowych poprzez wyodrębnienie charakterystycznych cech z zaobserwowanych wzorców. W wielu przypadkach sekwencja zidentyfikowanych kształtów mierzonych sygnałów odzwierciedla istotne zdarzenia wpływające na proces technologiczny. Technika ta polega na podzieleniu szeregu czasowego na odcinki (segmentacji) w taki sposób, że koniec jednego z nich jest początkiem następnego. Każdemu odcinkowi jest przypisywany stan zależny od pochodnej sygnału: rosnący (+), malejący (-) lub stały (0) [117].

Przykład segmentacji przedstawiony został na rys. 2.12. Analiza sygnału tą metodą składa się z dwóch etapów:

- Ekstrakcji wzorców trendu - przekształcenia serii danych we wzorce trendów. Można tu wykorzystać takie metody, jak transformacja falkowa [118], sieci neuronowe [119] lub ukryte modele Markowa [120, 121].
- Analizy wzorców trendów - na podstawie charakterystyki sekwencji trendów uzyskuje się cechy jakościowe, które służą do klasyfikacji charakterystycznych zdarzeń w procesie.

Ta grupa metod może być wykorzystywana do wspomagania operatora w analizie danych procesowych, automatycznie wykrywając fluktuacje przed wystąpie-



Rysunek 2.12: Przykład segmentacji sygnału w metodzie QTA

niem awarii [122], może być również stosowana do monitorowania skuteczności pętli sterowania procesem w systemach automatyki przemysłowej [123].

### Metody statystyczne

W zadaniach wykrywania i diagnozowania usterek podejścia statystyczne koncentrują się na rozpoznawaniu wzorców na podstawie cech wyodrębnionych za pomocą różnych metod statystycznych. W niniejszym punkcie przedstawiono niektóre z często stosowanych technik obejmujące: analizę głównych składowych (ang. *Principal component analysis*, PCA), regresja metodą cząstkowych najmniejszych kwadratów (ang. *Partial least squares*, PLS), metody autoregresji i maszyny wektorów wspierających (ang. *Support vector machines*, SVM).

- PCA (ang. *Principal components analysis*) - jest jedną z najczęściej stosowanych technik. Przekształca ona wektor danych wejściowych w celu zmniejszenia jego wymiarowości przy minimalnej utracie informacji. W wyniku transformacji uzyskuje się zredukowany zbiór cech reprezentujących stan badanego systemu, co znacząco upraszcza analizę i dalsze obliczenia. Metody oparte na PCA są często stosowane w procesie wstępnego przetwarzania danych, w tym również w branży energetycznej, zwiększając możliwości diagnostyczne zaprojektowanego systemu i zmniejszając przy tym liczbę fałszywych

alarmów [124, 125, 126].

- PLS (ang. *Partial least squares*) - jest metodą statystyczną, która znajduje zależności między cechami w modelu regresji liniowej rzutowanym na nową przestrzeń projekcji. Przykładem wykorzystania technik opartych o PLS i PCA w praktyce - jest zadanie wykrywania blokad młynów węglowych [127]. PLS zastosowano również w monitorowaniu wydajności procesów produkcyjnych. Wykorzystując dane historyczne z systemów sterowania procesami, można oszacować sprawność turbiny gazowej [128], miary jakościowe sprawności cieplnej oraz emisji NOx i SOx [129].
- SVM (ang. *Support vector machines*) - jest techniką uczenia nadzorowanego, która może być stosowana zarówno do zadań klasyfikacji, jak i regresji. Metoda polega na znalezieniu granicy decyzyjnej w przestrzeni za pomocą funkcji transformacji (zwanej jądrem), która mapuje przykłady między dwiema (lub więcej) klasami tak, aby zachować jak największą granicę (margines) pomiędzy tymi klasami. Metoda ta jest szeroko stosowana w wykrywaniu uszkodzeń, na przykład, zastosowano ją do wykrywania awarii urządzeń w elektrowniach cieplnych [130] i turbinach wiatrowych [131].

## Metody stochastyczne

Podejścia stochastyczne obejmują metody ilościowe, które tworzą warunkowe modele probabilistyczne. Grupa ta obejmuje algorytmy, które diagnozują i przewidują stany (awaryjne i bezawaryjne) zdefiniowane na podstawie wskazań pomiarowych i obliczonych prawdopodobieństw. Metody przeważnie opierają się na teorii Bayesa, według której prawdopodobieństwo warunkowe  $P$  zdarzenia  $A$ , pod warunkiem, że zaszło zdarzenie  $B$ , jest określane zgodnie ze wzorem:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)} \quad (2.3)$$

Sieć bayesowska może być reprezentacją systemu przedstawioną za pomocą grafu skierowanego z węzłami reprezentującymi zmienne losowe i stany, które odzwierciedlają związek przyczynowo skutkowy dla przewidywanych awarii [132].

Algorytmy stochastyczne, mimo że są klasyfikowane jako oparte na analizie danych, nie zawsze wymagają obszernego i kompletnego zbioru danych. Do określenia rozkładu prawdopodobieństwa zazwyczaj wystarczy znalezienie niewielkiego, aczkolwiek reprezentatywnego podzbioru. Struktury i algorytmy są w tej metodzie czytelne i przejrzyste. Często jednak wymagają one dużego wkładu pracy przygotowawczej na przykład w postaci analiz FMEA (opisanych w sekcji 2.2.3) lub RCA (opisanych w sekcji 2.2.5) w celu stworzenia niezbędnych struktur do zaimplementowania. Metody oparte na sieciach bayesowskich są często łączone z innymi metodami w celu podniesienia jakości obliczeń. Mogą to być na przykład:

- Filtry cząsteczkowe (ang. *Particle filters*) - metoda ta wykorzystuje częściowy zbiór danych do oszacowania stanu systemu. Model jest zasilany losowymi próbkami (cząstkami) migrującymi w grupach w celu oszacowania rozkładu całego układu [133]. Metoda ta może być stosowana do modelowania nieliniowych charakterystyk systemu z różnymi rodzajami szumów.
- Filtr Kalmana - jest estymatorem stanu działającym na układzie dynamicznym z gaussowskim rozkładem szumu. Stan jest szacowany na podstawie serii bieżących obserwacji (mogą one być niekompletne) oraz ostatniego stanu systemu. Jest to algorytm wydajny obliczeniowo, głównie gdy jest stosowany do systemów liniowych. Technika jest z powodzeniem stosowana również w przypadku nieliniowych relacji wejścia-wyjścia.
- Modele Markowa - reprezentują system, w którym poszczególne stany odzwierciedlają obserwowalne zdarzenia lub warunki. Przewidywany stan zależy od sekwencji poprzednich stanów. Rozszerzeniem tych modeli są ukryte modele Markowa (ang. *Hidden markov models*), w których proces jest kodowany w postaci ukrytych łańcuchów w przypadku, gdy model nie jest trywialny do opisania. Za pomocą modeli Markowa można modelować zarówno zdarzenia w kontekście analizy szeregu czasowego, jak i relacji poszczególnych cech. Wadą tej metody jest wysoka złożoność obliczeniowa.

## Sztuczne sieci neuronowe

Sztuczne sieci neuronowe (ang. *Artificial neural networks*) znajdują wiele zastosowań analitycznych, w tym również zadania związane z wykrywaniem i diagnozowaniem usterek [134]. Istnieją różne rodzaje sieci neuronowych, które możemy podzielić na podstawie przyjętej architektury lub wyznaczonego realizowanego celu. Tworzenie modelu sieci oparte jest na metodzie uczenia maszynowego, które polega na dostosowywaniu parametrów/wag elementów sieci neuronowej w sekwencyjnym procesie uczenia na podstawie dużej liczby danych treningowych. Stworzenie modelu nie wymaga znacznego zaangażowania wiedzy eksperta, ale wymaga posiadania dużego reprezentatywnego zbioru danych i specjalistycznej wiedzy w zakresie inżynierii danych i procesu trenowania modelu. Strategie uczenia dzielą się na nadzorowane i nienadzorowane. Uczenie nienadzorowane polega na dostosowaniu sieci do danych szkoleniowych, np. sieć reprezentuje stan systemu w bezawaryjnym okresie i śledzi odchylenia od tego stanu w przypadku pracy. Uczenie nadzorowane wymaga etykietowania danych w zbiorze treningowym i zwykle wymaga dużej liczby danych treningowych. Rodzaj sieci ANN można podzielić na kategorie ze względu na przyjętą architekturę, funkcje celu i metodę uczenia. Biorąc pod uwagę charakter danych wyjściowych, sieci ANN mogą wykonywać następujące zadania:

- Detekcję - gdy wyjściem jest binarna wartość prawda/fałsz. Są one wykorzystywane przy wykrywaniu określonych zdarzeń [135, 136] lub anomalii [137, 138].
- Klasyfikację - proces kategoryzacji danych w sposób, który odzwierciedla relacje w zbiorze treningowym poprzez przypisanie określonej etykiety (konkretna usterka, stan zdrowia). Przykładem może być klasyfikacja stanu awarii w turbinie wiatrowej [139].
- Regresję - generuje na wyjściu wartość ciągłą, zwykle jest to residuum lub miara stanu zdrowia urządzenia. Metoda ta ma szeroki zakres zastosowań, od analizy trendów do przewidywania pozostałego okresu użytkowania.
- Grupowanie - jest metodą wykorzystującą technikę uczenia nienadzorowanego. Oznacza to, że zbiór treningowy nie wymaga etykietowania. Na pod-



stawie zbioru treningowego dane są grupowane lub szeregowane. Metoda ta jest wykorzystywana w szczególności do wykrywania anomalii. Na przykład, Rakhshani i in. w artykule [140] grupują stany zdrowia kotła w elektrowni i wykorzystują sieci ANN do przewidywania awarii.

Klasyczną architekturą sieci neuronowej jest sieć typu feed-forward, której typowymi przedstawicielami są: sieć typu MLP (ang. *Multi layer perceptron* - perceptron wielowarstwowy) oraz sieć typu RBF (ang. *Radial basis function* - radialna funkcja bazowa). Sieci te składają się z warstwy wejściowej, opcjonalnych warstw ukrytych oraz warstwy wyjściowej. Dane wejściowe mogą być danymi liczbowymi, zakresami lub kategoriami. Zbiór danych wejściowych jest często przetwarzany za pomocą algorytmu selekcji cech (w celu wyodrębnienia najbardziej istotnych cech) lub redukcji wymiarowości (np. przy użyciu analizy składowych głównych [141]). Warto tutaj nadmienić, iż proces selekcji cech nie jest wymagany dla większości z architektur tzw. głębokiego uczenia, tj. posiadających bardziej złożone struktury i warstwy ukryte. Przykładem może być wykorzystanie konwolucyjnej sieci neuronowej (ang. *Convolutional neural network*, CNN). Janssens i in. [142] stosując sieć typu CNN uzyskali znacznie lepsze wyniki w porównaniu do metody lasu losowego z ręczną inżynierią cech, wykazując przy tym oszczędność czasu na wstępnym przetwarzaniu danych. Często stosowanym modelem, zwłaszcza w wykrywaniu anomalii, jest auto-encoder. Zasada działania auto-encodera polega na uczeniu się reprezentacji systemu w sposób nienadzorowany poprzez rekonstrukcję sygnału wyjściowego na podstawie sygnału wejściowego poprzez stratną kompresję w warstwach ukrytych. Naturalnym zastosowaniem sieci jest odszumianie sygnału [143], co czyni tę metodę użyteczną jako etap wstępnego przetwarzania również dla wielu innych zastosowań [144]. Auto-encoder może być również wykorzystywany do wykrywania anomalii poprzez generowanie residuów z różnic między wektorami wejściowym i wyjściowym [145, 146, 147, 148, 149]. Istotną architekturą stosowaną często w obszarze wykrywania i identyfikacji uszkodzeń są rekurencyjne sieci neuronowe (ang. *Recurrent neural network*, RNN). Cechą charakterystyczną sieci RNN są połączenia wsteczne (rekurencyjne) z dalszych warstw (nie występujące w sieciach typu feed-forward). Ten typ sieci jest przeznaczony do analizy danych sekwencyjnych w szeregach czasowych. Podgrupą dla tego typu sieci są sieci

typu LSTM (ang. *Long short-term memory*), które dzięki zastosowaniu tzw. bramek zapominających pozwalają na analizę długich sekwencji szeregów czasowych. Technika ta została z powodzeniem zastosowana do wykrywania awarii elementów maszyn wirujących, takich jak łożyska [150], silników [151], czy turbin wiatrowych [152].

### 2.3.5 Metody oparte na analizie sygnałów

Modele wykrywania awarii oparte na analizie sygnałów koncentrują się na badaniu charakterystyk i cech mierzonego pojedynczego sygnału i porównują je z parametrami wzorcowymi uzyskanymi dla prawidłowo działającego systemu. Alternatywnie, badane są zmiany owych cech w czasie. Prosty schemat wykrywania i identyfikacji awarii na podstawie analizy sygnałów przedstawiono na rys. 2.13. Potencjalne usterki są odzwierciedlone w szeregach czasowych mierzonych sygnałów lub w ich widmie, co umożliwia zarówno wykrywanie anomalii, jak i klasyfikację konkretnych usterek. Podejście to jest szeroko stosowane w tradycyjnych urządzeniach służących do monitorowania i diagnostyki. Typowe zastosowania obejmują analizę sygnałów, takich jak drgania [153], sygnały akustyczne lub prądowe [154, 56].



Rysunek 2.13: Schemat ideowy metody wykrywania awarii opartej na analizie sygnału

W zależności od zastosowanego podejścia, algorytmów przetwarzania sygnałów

oraz metod ekstrakcji cech, wyróżniamy następujące grupy metod analizy sygnału [155, 156], opisane w szczególności w poniższych sekcjach.

### Metody analizy czasowej

Metody te operują bezpośrednio na surowych sygnałach pomiarowych, analizując ich statystyki jak: średnie, trendy, wartości min/max, odchylenie standardowe itp. W tej grupie można znaleźć techniki związane z analizą szeregów czasowych, takie jak sumy skumulowane (ang. *Cumulative sum*, CUSUM), wykładniczo ważona średnia krocząca (ang. *Exponentially weighted moving average*, EWMA) [157], dopasowanie auto-regresyjne lub śledzenie błędu średnio-kwadratowego [158]. Celem tego podejścia jest wyznaczenie wskaźników statystycznych, które umożliwiają porównanie bieżących odczytów ze stanem wzorcowym. Przykładem zastosowania może być tutaj wykrywanie usterek przekładni planetarnej, gdzie na etapie selekcji sygnałów zastosowano analizę wskaźników statystycznych [159]. Współczynnik błędu średnio-kwadratowego jest często stosowany w metodach analizy czasowej jako miara energii drgań, która bezpośrednio świadczy o stanie technicznym urządzenia. Zdecydowaną zaletą tych metod jest możliwość bezpośredniej oceny degradacji systemu, nieskomplikowane obliczenia i przejrzystość. Bardziej złożone zadania, takie jak określenie źródła anomalii lub klasyfikacja uszkodzeń wymagają zastosowania innych metod, np. opartych na analizie częstotliwości.

### Metody analizy częstotliwości

Jest to popularna grupa metod diagnostycznych dla urządzeń obrotowych i elektrycznych. Metody te przedstawiają mierzone szybkozmienne przebiegi w dziedzinie częstotliwości i opierają się na identyfikacji anomalii widocznych w pasmach częstotliwości, przy których występują typowe uszkodzenia. Widmo sygnału można uzyskać za pomocą dekompozycji, na przykład metodą szybkiej transformaty Fouriera, która rozkłada przebieg na sumę sinusoid o różnych częstotliwościach. Najczęściej stosowanym pomiarem przy diagnostyce urządzeń są wibracje, szczególnie w przypadku łożysk i przekładni, natomiast w przypadku silników i urządzeń elektrycznych można wykorzystać pomiary elektryczne i metody analizy sygnatur prądowych (ang. *Motor current signature analysis*, MCSA) [49]. Przy-

kładem zastosowania analizy widmowej jest analiza drgań dla łożysk przekładni [160], która pozwala na śledzenie postępu stanu degradacji; uzyskane wyniki były skorelowane z wynikami przeglądów okresowych. W przypadku analizy sygnałów elektrycznych, analizę częstotliwości prądu i demodulację amplitudy wykorzystano do wykrywania uszkodzeń łożysk w turbinach wiatrowych [161]. Alternatywne wykorzystanie analizy prądu elektrycznego zapewnia dodatkowe korzyści ekonomiczne w przypadku braku możliwości monitorowania drgań na bieżąco. Główną zaletą analizy częstotliwościowej jest jej zdolność zlokalizowania uszkodzonego elementu systemu. Jednakże główną wadą jest niezdolność do identyfikacji źródła degradacji w przypadku układu niestacjonarnego, na co remedium może być zastosowanie metod analizy czasowo-częstotliwościowej.

### Metody analizy czasowo-częstotliwościowej

Ta grupa metod umożliwia ekstrakcję cech zarówno w dziedzinie czasowej, jak i widmowej. Wykorzystuje ona narzędzia transformacyjne do dekomponowania sygnału i wydobywania informacji o cechach zawartych w sygnałach niestacjonarnych [162]. W obszarze konserwacji predykcyjnej możemy wykorzystać następujące techniki z tej grupy:

- Krótkookresowa transformata Fouriera (ang. *Short-time Fourier transform*, STFT) - dostarcza informacji zarówno w dziedzinie czasowej, jak i spektralnej, śledząc zmiany częstotliwości w funkcji czasu. Obliczanie transformaty Fouriera w kolejnych przedziałach czasowych sprawia, że metoda ta jest skomplikowana obliczeniowo. Wykorzystując współczynniki uzyskane metodą STFT, autorzy [163] zaproponowali prostą regułę decyzyjną do wykrywania uszkodzeń łożysk.
- Rozkład Wignera-Villego (ang. *Wigner-Ville distribution*, WVD) - zapewnia lepszą rozdzielczość czasowo-częstotliwościową przy niższym koszcie obliczeniowym w porównaniu z krótkookresową transformatą Fouriera. Wadą metody jest występowanie zakłóceń międzyokresowych, utrudniających interpretację wyników.
- Transformata falkowa (ang. *Wavelet transform*, WT) - jest bardzo popularną

metodą przetwarzania sygnałów, często wykorzystywaną także w wykrywaniu uszkodzeń [164, 165]. Transformaty WT rozwinęły się z klasycznych metod ciągłej transformaty falkowej i dyskretnej transformaty falkowej. Do zalet stosowania WT należy zaliczyć uzyskanie wysokiej rozdzielczości adaptacyjnej oraz możliwość pracy w dziedzinie sygnałów niestacjonarnych.

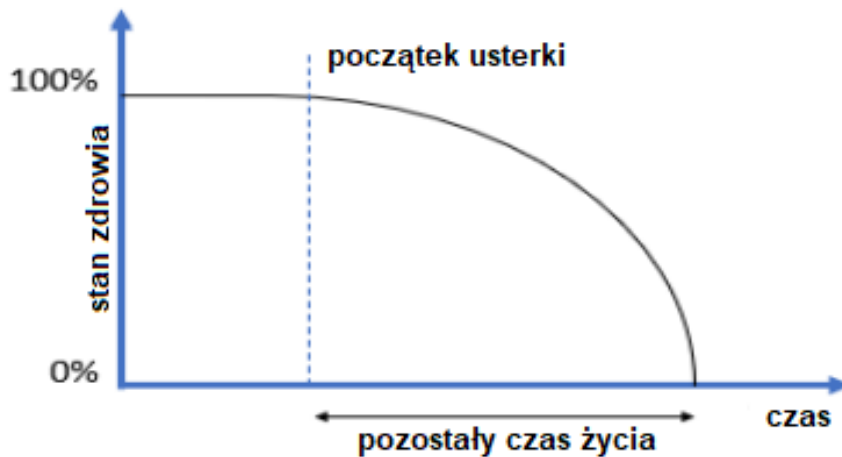
- Transformata Hilberta-Huanga - polega na dekompozycji sygnału zgodnie z metodologią empirycznej dekompozycji trybów pracy na tzw. wewnętrzne funkcje trybów, a następnie wyznaczeniu widma Hilberta. Transformata Hilberta-Huanga jest najbardziej adaptacyjną metodą dla sygnałów niestacjonarnych i nieliniowych.

### 2.3.6 Określanie pozostałego czasu bezawaryjnej pracy

Opisane we wcześniejszych sekcjach metody pozwalają wykrywać stany awaryjne i określać stan aktualnej kondycji urządzenia. Rozszerzeniem tej analizy jest przewidywanie szacowanego czasu wystąpienia spodziewanej awarii oraz charakterystyki degradacji dla trybu awaryjnego maszyny. Wskaźnik pozostałego czasu bezawaryjnej pracy (ang. *Remaining useful life*, RUL) mierzy czas od chwili obecnej do chwili kiedy szacujemy, że wystąpi całkowita utrata funkcjonalności w wyniku awarii, jak pokazano na rys. 2.14.

Czas RUL można oszacować wykorzystując jeden lub więcej wskaźników zdrowia (lub degradacji) przy czym bardzo istotna jest ich zmienność w czasie. Wiele metod i algorytmów stosowanych w tym przypadku jest zbieżnych z tymi stosowanymi w diagnostyce i wykrywaniu uszkodzeń. Główna różnica polega na tym, że w przypadku RUL zdarzenia są przewidywane w przyszłości z uwzględnieniem konkretnego czasu wystąpienia usterki, co wymaga przyjęcia pewnych przedziałów ufności i niepewności, względem przewidywanych wartości. Jakość danego indeksu zdrowia, a tym samym możliwość zastosowania w zadaniu szacowania RUL jest określana przez następujące cechy i właściwości [166, 167]:

- Monotoniczność - to zdolność do utrzymania stałego wzrostu lub spadku wskaźnika zdrowia w trakcie kolejnych cykli, np. postępujące zużycie przy braku konserwacji i ciągłej eksploatacji.



Rysunek 2.14: Estymowany czas bezawaryjnej pracy na podstawie stanu urządzenia

- **Stabilność** - określa zdolność metryki do zadań predykcyjnych pod względem odporności na szumy i stopnia niepewności wyników. Stabilność skutkuje wygładzoną charakterystyką RUL.
- **Tendycyjność** - jest miarą korelacji między tempem degradacji a czasem (cyklem).
- **Rozpoznawalność** - umożliwia klasyfikację zdefiniowanych trybów awaryjnych na podstawie charakterystyki wskaźników stanu zdrowia.
- **Spójność** - jest to współczynnik zgodności wskaźników stanu zdrowia uzyskanych różnymi metodami.

Obliczenie szacowanego pozostałego okresu użytkowania RUL wymaga kompleksowych danych o bieżącym stanie urządzenia i klasyfikacji potencjalnych trybów awaryjnych. Poprawna identyfikacja zdarzenia, które inicjuje daną awarię, pozwala określić pozostały okres użytkowania poprzez ekstrapolację stopnia degradacji i obliczenie czasu, w którym nastąpi przekroczenie progu, dla którego urządzenie będzie musiało zostać wyłączone. Alternatywnie, można dokonać analizy historycznych zapisów i wziąć pod uwagę rozkład w czasie wskaźnika zdrowia urządzenia

operującego w trybie "praca do awarii". Najczęściej stosowane podejście do szacowania RUL zakłada:

- utworzenie modeli degradacji dla poszczególnych trybów awarii,
- identyfikację aktualnego wskaźnika zdrowia lub trybów awarii,
- oszacowanie pozostałego okresu użytkowania poprzez kompilację informacji o aktualnym stanie w kontekście funkcji gęstości prawdopodobieństwa dla określonych cykli degradacji.

Klasyfikacja technik zaproponowana w pracach [168], [166] obejmuje następujące podejścia:

- Oparte na wiedzy - metody oparte na wiedzy dziedzinowej, zbiorach danych historycznych oraz automatyzacji procesu umożliwiającej kodowanie wiedzy, np. w postaci algorytmów lub reguł w systemach eksperckich. Tego typu systemy są łatwe do zrozumienia i zaprojektowania. Ograniczeniem są funkcjonalność określona przez wiedzę ekspertów oraz wysiłek włożony w zaprojektowanie systemu.
- Statystyczne i stochastyczne - metody statystyczne polegają na analizie bieżących i przeszłych obserwacji w celu przewidywania przyszłych stanów. Metody te są najczęściej oparte na analizie szeregów czasowych i nie wymagają dużej liczby danych historycznych. Do charakterystycznych metod stosowanych w tym obszarze należą:
  - Modele autoregresyjne, które pozwalają na oszacowanie parametru skorelowanego z RUL poprzez analizę szeregów czasowych. Stosowane modele zakładają monotoniczność i liniowość szacowanej wartości w odniesieniu do danych z przeszłości. Techniki stosowane w tym obszarze są najczęściej oparte na obliczeniach związanych z średnią kroczącą: ARMA (ang. *Autoregressive moving average*), ARIMA (ang. *Autoregressive integrated moving average*) lub ARMAX (ang. *Autoregressive moving average with exogenous input*).

- Modele Markowa, które zakładają, że procesy degradacji maszyn są zawarte w skończonej przestrzeni stanów. Definiując prawdopodobieństwa łączące te stany, można oszacować prawdopodobieństwo przewidywanych awarii. Wartości predykcji zależą od kolejności ostatnio odczytanych w analizowanym szeregu czasowym.
- Proporcjonalne modele zagrożenia (ang. *Proportional hazards model*, PHM), które opierają się na modelu przetrwania zaproponowanym przez Davida Coxa [169]. W modelach PHM uwzględnia się wpływ wielu czynników na szacowany wynik. Głównymi składnikami czynników funkcji zagrożenia  $\lambda(t)$  są: bazowa funkcja zagrożenia  $\lambda_0$ , która opisuje stopień degradacji w kolejnych cyklach oraz funkcja kowariancji  $\exp(\beta \times X)$ , która opisuje wpływ ( $\beta$ ) na współczynnik zagrożenia wystąpienia zdarzeń warunkowych ( $X$ ):

$$\lambda(t) = \lambda_0(t) \times \exp(\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n). \quad (2.4)$$

- Uczenie maszynowe - metody wymagające najczęściej pracy z dużym zbiorem danych historycznych, gdzie wkład pracy analityka jest bardziej znaczący niż eksperta technicznego. Dzięki tym technikom możliwe jest obliczanie wartości RUL bezpośrednio z pomiarów, ale ostateczny wynik jest silnie uzależniony od wybranej metody i jakości danych treningowych. Słabą stroną tych metod jest brak wglądu w mechanizm działania "modelu czarnej skrzynki".
- Modelowanie zjawisk fizycznych - technika ta obejmuje obliczanie pozostałego okresu użytkowania sprzętu na podstawie modelu matematycznego odzwierciedlającego zachowanie procesu lub zjawiska. Wymaga wysokiego poziomu wiedzy specjalistycznej do utworzenia modelu i zakodowania charakterystyk degradacji. Tego typu podejście zwykle zapewnia doskonałe i zrozumiałe wyniki. Ze względu na dużą pracochłonność jest ono stosowane w szczególnych przypadkach (tj. dla konkretnego zjawiska, np. grubości ścianki kotła, postępującej korozji itp.). Popularnym trendem, również w dziedzinie konserwacji predykcyjnej, jest opracowywanie cyfrowych duplikatów urządzeń lub całych instalacji, zwanych bliźniakami cyfrowymi



(ang. *Digital twin*). Przykładowo Aivaliotis i in. [170] przedstawili metodologię symulacji urządzeń na podstawie danych empirycznych i obliczeń dotyczących pozostałego okresu użytkowania.

## 2.4 Wykaz artykułów podejmujących podobną tematykę

W tabeli 2.1 przedstawiono zbiór prac przeglądowych o tematyce najbardziej zbliżonej do tej podejmowanej w niniejszej pracy doktorskiej. Przegląd literatury obejmował prace poświęcone rozwiązaniom wspierającym predykcje utrzymania ruchu w przemyśle. Z uwagi na szeroki obszar tematyczny przyjęto następujące uproszczone kryteria porównania:

- Strategia - wpływ prezentowanych treści na procesy zarządzania, np. formułowanie strategii lub potencjalną zmianę obecnych procesów.
- Metody - przedstawia szczegółowy opis i kategoryzację metod i algorytmów, uwzględniając ich zastosowanie, źródła danych, zalety i wady.
- Diagnostyka - zawiera opis metod i zastosowań w takich obszarach, jak wykrywanie i identyfikacja błędów, rozpoznawanie wzorców i analiza przyczyn źródłowych.
- Predykcja - obejmuje metody i zastosowania w takich obszarach, jak predykcje zarządzanie zdrowiem, pozostały okres użytkowania.
- Preskrypcja - opisuje zaawansowane aplikacje analityczne w obszarze preskrypcji, w tym techniki, takie jak symulacja, cyfrowy bliźniak, optymalizacja procesów.
- Obszar - branża objęta przeglądem.

Tabela 2.1: Powiązane artykuły koncentrujące się na tematyce predykcyjnego utrzymania ruchu w przemyśle (w tym w energetyce)

Artykuł	Rok	Strategia	Metody	Diagnostyka	Predykcyjna	Preskrypcja	Obszar	Opis
Sikorska i in. [168]	2011	○	●	●	●	○	Przemysł	Kompleksowy przegląd metod związanych z szacowaniem RUL. Klasyfikacja algorytmów oraz przedstawienie ich mocnych i słabych stron w celu ułatwienia wyboru odpowiedniego modelu dla konkretnego przypadku użycia.
Gao i in. [156, 171]	2015	○	●	●	○	○	Przemysł	Przegląd technik wykrywania usterek. Klasyfikacja metod jako opartych na modelu, opartych na analizie sygnału i opartych na analizie wiedzy.
Sole i in. [94]	2017	●	●	●	○	○	Przemysł	Przegląd problemów związanych z analizą przyczyn źródłowych (RCA), ze szczególnym uwzględnieniem aspektów związanych z wymaganiami, wydajnością i skalowalnością.
Diez-Olivan i in. [172]	2019	○	○	●	●	●	Przemysł	Przegląd zastosowań algorytmów predykcyjnych opartych na analizie danych w przemyśle w ramach paradygmatu I4.0 (klasyfikacja metod jako: deskrypcyjne, predykcyjne i preskrypcyjne)
Carvalho i in. [173]	2019	●	●	●	○	○	Przemysł	Przegląd metod uczenia maszynowego stosowanych w konserwacji predykcyjnej. Koncentruje się na stosowanych metodach, urządzeniach i potrzebnych źródłach danych.
Zhang i in. [174]	2019	○	●	●	○	○	Przemysł	Koncentruje się na metodach PdM opartych na analizie danych i ich zastosowaniach.
Saufi i in. [175]	2019	○	●	●	○	○	Urządzenia wirnikowe	Przegląd metod wykrywania i diagnozowania uszkodzeń opartych na głębokim uczeniu.
Merkt [176]	2019	●	●	●	○	○	Przemysł	Przegląd metod predykcyjnych opartych na analizie danych z podkreśleniem wad i zalet oraz wskazaniem obszarów możliwych zastosowań.
Alcacer i Cruz-Machado [177]	2019	●	○	○	○	●	Przemysł	Przegląd zastosowań technologii I4.0 pod kątem możliwości i wykorzystania w środowiskach produkcyjnych.
Ngarayana in. [178]	2019	●	●	●	●	○	Energetyka	Przegląd modeli, metod i strategii optymalizacji utrzymania ruchu w elektrowni jądrowej. Porównanie badań naukowych z rzeczywistymi zastosowaniami.
Soualhi i in. [179]	2019	○	●	●	○	○	Przemysł	Przegląd metod diagnostycznych stosowanych do wykrywania i identyfikacji uszkodzeń. Klasyfikacja metod jako opartych na modelu, opartych na analizie danych i hybrydowych.
Cinar i in. [180]	2020	○	●	●	○	○	Przemysł	Przegląd zastosowań ML w PdM. Klasyfikuje prace na podstawie metod, źródeł danych, urządzeń wykorzystywanych do pozyskiwania danych oraz rozmiaru danych.
Chao i in. [181]	2020	●	○	●	●	○	Energetyka	Przegląd zastosowań sztucznej inteligencji skategoryzowanych pod kątem typowych scenariuszy w elektrowni jądrowej; porusza problem interakcji człowiek-maszyna.
Fausing i in. [182]	2020	●	●	●	○	○	Energetyka	Przegląd artykułów z dziedziny PdM ze szczególnym uwzględnieniem systemów pomp w elektrowniach.
Zonta i in. [183]	2020	○	●	●	○	○	Przemysł	Systematyczny przegląd literatury na temat PdM w przemyśle. Kategoryzacja metod, standardów i zastosowań. Omówienie ograniczeń i wyzwań związanych z PdM.

○: nie badane ●: wspomniane ●: zbadane

## Rozdział 3

# Techniki badawcze oraz metody wykrywania usterek

W niniejszym rozdziale przedstawiona została metodologia badań oraz wykorzystane metody i algorytmy przy opracowanych eksperymentach i obliczeniach. Szczególna uwaga została skupiona na autorskich rozwiązaniach z obszaru eksploracji danych, pozwalających na realizację postawionych celów projektowych i badawczych. Poza algorytmami i metodami opisane zostały również narzędzia informatyczne, za pomocą których realizowano obliczenia oraz wizualizowano wyniki części badawczej.

### 3.1 Metody i techniki badawcze

Prowadzone w ramach niniejszej rozprawy badania i prace badawcze nad opracowaniem skutecznych metod predykcyjnego wykrywania usterek urządzeń pracujących w elektrowni realizowane były głównie metodą indukcyjną. W ramach tego podejścia eksperymenty były przeprowadzane z wykorzystaniem metod symulacji komputerowej, wykorzystującej zaprojektowane modele analityczne oraz opracowane algorytmy przewidujące stany awaryjne na tle rzeczywistych historycznych danych pomiarowych oraz odnotowanych zdarzeń. Podstawową techniką badawczą było przeprowadzenie eksperymentów polegające na zastosowaniu różnych algorytmów uczenia maszynowego oraz parametryzacji zmiennych wejściowych, takich

jak: parametry (współczynniki) modelu, wielkość zbiorów treningowych, czy sposobów przetwarzania danych (w tym eksploracji i selekcji cech), których wyniki jako obiekt obserwacji były podstawą do oceny testowanego rozwiązania.

Wykorzystując opracowane modele, zebrane dane oraz uzyskane wyniki przeprowadzono weryfikację postawionych tez oraz znaleziono odpowiedzi na zadane w problemie badawczym pytania. Na początkowym etapie badań zastosowano metodę studium przypadku w celu lepszego zrozumienia danego procesu oraz kompleksowej analizy zaistniałych usterek krytycznych.

### 3.1.1 Studium przypadku

Zastosowanie metody studium przypadku pozwala na dogłębną analizę oraz poznanie charakteru badanego zjawiska. Studium przypadku jest w porównaniu z innymi metodami badawczymi bogatsze pod względem liczby możliwych do zastosowania technik i narzędzi pozwalających na pozyskiwanie i analizę danych, co predestynuje tę metodę do stosowania w początkowej fazie eksploracji danych (w szczególności zrozumienia badanych procesów i zrozumienia danych). Metoda korzysta z wielu źródeł danych typowych dla metod zarówno ilościowych, jak i jakościowych. Obiektem analiz mogą być zatem operacyjne dane historyczne, rejestry zdarzeń, raporty, wywiady lub ankiety. Z uwagi na brak metodologicznych ograniczeń, studium przypadku było pierwszą metodą zastosowaną w celu analizy dostępnych źródeł danych oraz przyczyn awarii krytycznych dla pierwszego badanego urządzenia - zespołu pomp zasilających pracujących w Elektrowni Łaziska w Łaziskach Górnych. Kompleksowa analiza procesu i dostępnych danych pozwoliła na późniejsze rozpoczęcie prac nad docelowym modelem wykrywającym usterki. W ramach studium przypadku przeanalizowano dane i dokumentację dostępną w różnych systemach informatycznych i produkcyjnych, jak np.:

- historyczne dane procesowe urządzenia (pomiarzy i sygnały sterujące),
- dane o usterkach w systemie planowania zasobów przedsiębiorstwa (ERP),
- odnotowane zdarzenia w rejestrze operatorskim (prowadzonym ręcznie),
- raporty zespołów badających skutki awarii,

- wyniki okresowych badań diagnostycznych (wibroakustyka),
- wywiady i konsultacje z pracownikami odpowiedzialnymi za eksploatację i remonty.

W kontekście prowadzonych badań, studium przypadku miało następujące cele:

- analizę deskrypcyjną obejmującą znalezienie korelacji między danymi oraz ograniczenie liczby źródeł danych do analizy poprzez wykorzystanie metod wizualizacji i eksploracji danych;
- wybór odpowiedniego podejścia pozwalającego na analizę predykcyjną mającą na celu zaprojektowanie modelu analitycznego umożliwiającego wykrywanie z wyprzedzeniem usterek dla tego urządzenia.

Zastosowanie metody studium przypadku jest uzasadnione faktem rzadkiego występowania awarii w analizowanych urządzeniach. Analizowane zdarzenia miały charakter unikalny, zarówno pod względem natury zdarzenia, jak i występowania na innych urządzeniach.

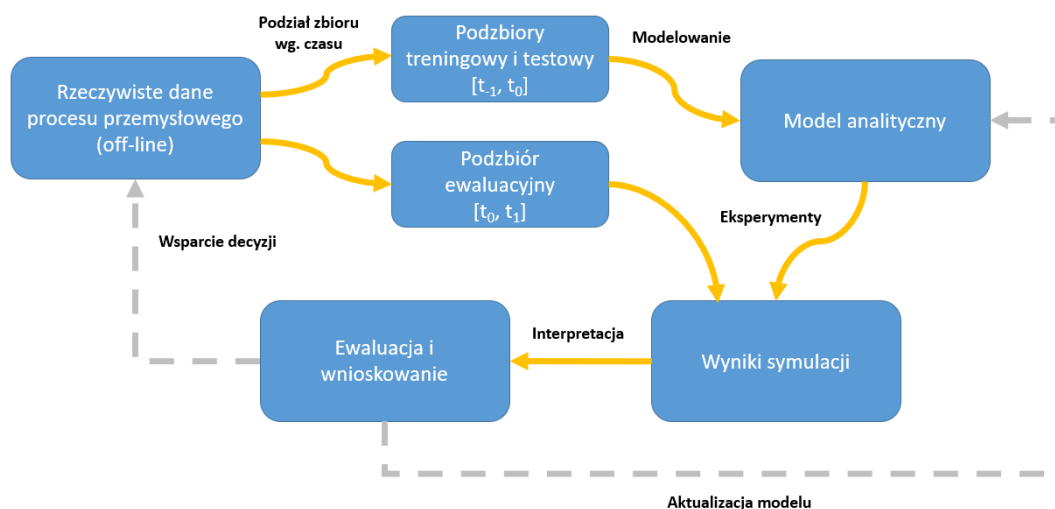
### 3.1.2 Metody symulacji komputerowej

Symulacje komputerowe są podgrupą metod ilościowych znajdującą zastosowania przy rozwiązywaniu różnych problemów decyzyjnych. Niewątpliwą zaletą stosowanej metody jest brak konieczności wdrażania rozwiązań i prowadzenia eksperymentów w środowisku fizycznym, co znacznie obniża koszty badań oraz przyspiesza ich realizację.

Schemat blokowy procesu symulacji przedstawiono na rys. 3.1. Symulacja ma na celu zebranie odpowiedzi zwracanych przez model wykrywający usterki w dynamicznie zmieniających się warunkach pracy. Elementem odzwierciedlającym fizyczne urządzenie oraz symulowany proces są dane procesowe urządzenia zebrane off-line oraz informacje o usterekach dla analizowanego okresu czasu.

Analizowane dane mają charakter szeregów czasowych i na podstawie czasu są one dzielone na następujące grupy:

- zbiór treningowy i testowy  $[t_{-1}, t_0]$  - służą do utworzenia i oceny modelu analitycznego aktualnego dla chwili  $t_0$  (bieżący czas w scenariuszu symulacji).



Rysunek 3.1: Schemat blokowy procesu symulacji eksperymentów

Zbiór treningowy służy do wytrenowania modelu, natomiast zbiór testowy do oceny parametrów jakościowych modelu. Podział zakresu  $[t_{-1}, t_0]$  na zbiory treningowy i testowy był realizowany w jednym z dwóch wariantów:

- zbiór treningowy stanowiło 80% najstarszych próbek  $[t_{-1}, t_x]$ , natomiast zbiór testowy 20% najnowszych  $(t_x, t_0]$ . Ten wariant był stosowany w przypadku eksperymentów na pompach zasilających;
  - ocena modelu metodą walidacji krzyżowej, gdzie zbiór był dzielony na 5 rozłącznych części (nielosowych). W ramach 5-krotnej iteracji zebrane wyniki obejmowały cały zakres  $[t_{-1}, t_0]$
- zbiór ewaluacyjny  $(t_0, t_1]$  - zbiór, za pomocą którego badamy zdolności detekcyjne modelu. Poprzez manipulowanie danymi wejściowymi z czasu przyszłego względem chwili  $t_0$ , symulujemy zachowanie modelu w quasi rzeczywistych warunkach.

Pojedynczy eksperyment polega zatem na obserwacji i rejestrowaniu wyników modelu predykcyjnego (poziom odchylenia/błąd, powiadomienie o usterece) w odpowiedzi na zmiany parametrów wejściowych w kolejnych iteracjach czasowych,

jakimi są parametry procesowe i sterujące np. napięcie zasilania, ustawienie przełożenia, ustawienie zaworu, temperatura oleju itp.

Ewaluacja wyników w scenariuszu symulacji analitycznej polega na powiązaniu występowania powiadomienia ostrzegającego przed zbliżającą się usterką w danym czasie z rzeczywistością odnotowanymi zdarzeniami. Należy tutaj zwrócić uwagę na fakt, iż w założeniu model predykcyjny powinien być w stanie wykrywać usterki z dużym wyprzedzeniem, przez co stwierdzenie, iż wcześniejsze powiadomienie prawdopodobnie wykryło późniejszą usterkę wymaga pewnej interpretacji lub zastosowania pewnych założonych schematów przy wnioskowaniu (np. założenie, iż symptomy usterki są widoczne na 2 tygodnie przed wystąpieniem lub zachowanie ciągłości stanu alarmowego od czasu pojawienia się powiadomienia o usterce do faktycznego odnotowania usterki).

Ewaluacja systemu predykcyjnego w schemacie symulacyjnym pozwala zarówno na kompleksową ocenę właściwości detekcyjnych w postaci np. macierzy pomyłek, krzywej ROC, jak i na wyzwalanie czynności aktualizacji modelu w ramach analizowanego zbioru (jako sposób zapobiegania zjawisku dryfu koncepcji (ang. *Concept drift*)).

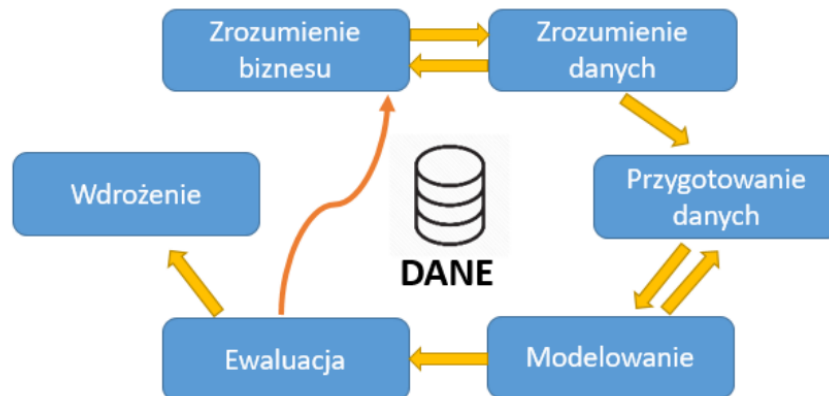
### 3.1.3 Proces eksploracji danych

W procesie eksploracji danych wykorzystana została metodologia CRISP-DM (ang. *Cross-industry standard process for data mining*), której podstawowe kroki przedstawiono na rys. 3.2.

Z uwagi na uniwersalny charakter metodologii, była ona stosowana w przypadku realizacji kolejnych problemów badawczych oraz analizy kolejnych urządzeń.

#### Zrozumienie uwarunkowań biznesowych

Etap zrozumienia uwarunkowań biznesowych koncentruje się na prawidłowym zdefiniowaniu celów projektu i zrozumieniu wymagań biznesowych odbiorców. Czynności typowe dla tego etapu w większości zostały zrealizowane na etapie definiowania i uzgadniania tematu oraz celów niniejszej pracy doktorskiej. W przypadku prac badawczych poniższe czynności typowe dla procesu zarządzania projektem



Rysunek 3.2: Metodologia CRISP-DM

pozwalają na uzyskanie zbieżności prowadzonych prac badawczych z wyznaczonymi celami przedsiębiorstwa:

- zdefiniowanie celów - wyznaczenie efektów, jakie mają być osiągnięte z perspektywy korzyści dla przedsiębiorstwa. W przypadku niniejszego projektu jest to przede wszystkim zaprojektowanie systemu wspierającego proces zarządzania pracami konserwacyjnymi poprzez mechanizmy pozwalające z wyprzedzeniem wykrywać usterek i awarie;
- ocena sytuacji - weryfikuje dostępność zasobów, danych względem postawionych wymagań dla projektu. Definiuje niezbędne zasoby do wykonania zadania;
- zdefiniowanie celów analitycznych - określenie celów z punktu widzenia procesu eksploracji danych. W przypadku niniejszej pracy, były to kryteria jakościowe modeli analitycznych (dokładność, czułość modeli klasyfikujących oraz średnie błędy dla modeli regresji);
- zaplanowanie projektu - stworzenie harmonogramu prac, zdefiniowanie potrzebnych zasobów i utworzonych produktów.



## Zrozumienie danych

Faza zrozumienia danych obejmuje działania związane z identyfikowaniem i analizą potencjalnych źródeł danych służących to realizacji założonych celów. Fazę możemy dekomponować na następujące kroki:

- gromadzenie danych - pozyskanie niezbędnych danych oraz wstępne ich przetworzenie. W kontekście realizowanego projektu wykonane czynności polegały na pozyskaniu i kompilacji danych procesowych z systemów automatyki przemysłowej oraz pozyskaniu informacji o czynnościach serwisowych wykonywanych na badanym urządzeniu (informacje o usterkach, remonty, dzienniki operatorskie);
- analiza danych - zbadanie danych, określenie ich formatu oraz zakresu wartości jakie przyjmują;
- eksploracja danych - analiza deskryptywna pozwalająca na analizę statystyczną oraz znalezienie zależności między danymi. Na tym etapie wykorzystano techniki do wizualizacji, jak histogram, wykres punktowy; a także techniki statystyczne, jak analiza korelacji Pearsona, analiza głównych składowych (PCA);
- weryfikacja jakości danych - na tym etapie dokonano oceny i selekcji danych do dalszej obróbki pod względem ich kompletności oraz wiarygodności.

## Przygotowanie danych

W tym kroku realizowane są zadania związane z przygotowaniem zbiorów danych do późniejszego modelowania, obejmujące czynności, takie jak:

- selekcja danych - wybór zbiorów danych wykorzystanych do analizy na podstawie wcześniejszej analizy i istniejących korelacji. Na tym etapie odfiltrowywano dane w kolumnach (atrybuty) uwzględniając zakresy, które nie były przydatne dla modelu;
- czyszczenie danych - podstawowymi realizowanymi zadaniami były tutaj odseparowanie usterek o niskim priorytecie lub niewiarygodnych parametrach

(np. trwające bardzo długo), uzupełnienie brakujących danych procesowych poprzez uśrednienie lub przypisanie wartości zerowej oraz odrzucenie pomiarów niewiarygodnych (przykładem mogą być pomiary z uszkodzonych czujników lub pomiary z czujników zainstalowanych w późniejszym czasie, które przez większość analizowanego okresu nie dostarczają przydatnych danych);

- ekstrakcja cech - polega na wyodrębnieniu lub uwzględnieniu dodatkowych atrybutów wynikających z podstawowego zbioru danych mogących mieć wpływ na jakość modelu predykcyjnego. Przykładami mogą być tutaj: dodanie atrybutu określającego czy bieżący dzień jest wolny czy roboczy, grupowanie danych ciągłych na zakresy lub kategoryzacja danych (liczbowych lub tekstowych). W realizowanych pracach badawczych takimi cechami były m.in.: określenie stanu pracy urządzenia na podstawie napięcia zasilającego, wstępne określenie stanu awaryjnego urządzenia, dodanie kroczących statystyk pomiarów, jak średnia, wartości maksymalne i minimalne czy wariancja;
- łączenie danych - zadanie polegające na łączeniu wielu zbiorów danych. Typowym przykładem powtarzającym się we wszystkich realizowanych zadaniach badawczych było łączenie informacji o usterkach z szeregiem czasowymi danych procesowych, gdzie wspólnym atrybutem łączącym był czas.

## Modelowanie

Na etapie modelowania tworzony i oceniany jest model predykcyjny. Proces modelowania realizowany jest w kolejnych iteracjach przybliżających z każdym krokiem właściwości jakościowe tworzonego modelu do oczekiwanych. Istotnymi aspektami tej fazy są:

- Wybór algorytmu - określenie metody adekwatnej do realizowanego zadania, mogą to być techniki regresji, sztuczne sieci neuronowe lub klasyfikatory. Wybór odpowiedniego modelu może być wynikiem kroku optymalizacyjnego.
- Zaprojektowanie procesu uczenia - polega na implementacji kroków pozwalających na zdefiniowanie podzbioru uczącego, testowego i walidacyjnego; ocenę modeli (mechanizm walidacji krzyżowej, obliczanie błędów); selekcję cech oraz optymalizację parametryczną.

- Budowanie modelu - tworzenie modelu na podstawie wybranego algorytmu w zaprojektowanym procesie uczenia.
- Ocena modelu - określenie jego właściwości predykcyjnych poprzez obliczenie błędów np. średniego błędu bezwzględnego w przypadku regresji lub macierzy pomyłek w przypadku klasyfikatorów.

## Ewaluacja

Ewaluacja modelu stanowi ocenę właściwości predykcyjnych w kontekście postawionych wymagań dla projektowanego systemu. Bardziej niż na ocenie współczynników jakościowych modelu skupia się na długoterminowej analizie zwracanych wyników w zestawieniu z zaistniałymi zdarzeniami. Ewaluacja stanowi wyznacznik determinujący przydatność zastosowania modelu w danym procesie. Miarami pozwalającymi ocenić model są przede wszystkim współczynniki oceniające zdolności klasyfikacyjne, jak dokładność, czułość, specyficzność. Zarówno na etapie ewaluacji systemu oraz przy porównywaniu wyników uzyskanych dla różnych modeli wykorzystano metryki takie, jak krzywa ROC (ang. *Receiver operating characteristic*) czy pole pod krzywą AUC (ang. *Area under curve*), pozwalające ocenić właściwości predykcji w perspektywie zmiennych parametrów modelu.

## Wdrożenie

Etap wdrożenia obejmuje zaplanowanie prac związanych z uruchomieniem i utrzymaniem rozwiązania w środowisku produkcyjnym. Obejmuje działania związane z:

- tworzeniem dokumentacji i instrukcji, zarówno dla użytkowników końcowych, jak i dokumentacji technicznej;
- opracowaniem procedur aktualizacji modelu i ewentualnych poprawek;
- analizą prac oraz utworzeniem rejestrów doświadczeń, w celu usprawnień podobnych projektów w przyszłości.

## 3.2 Narzędzia analizy i wizualizacji danych użyte w procesie implementacyjnym i przedwdrożeńowym

Postawione cele projektowe i badawcze wymagały pracy z dużymi zakresami danych oraz możliwości zastosowania różnych metod eksploracji danych na tych zbiorach danych. Przedstawione w niniejszym podrozdziale narzędzia w znaczący sposób ułatwiły badania dostarczając wachlarz funkcjonalności z obszaru przetwarzania i analizy danych. Istotnym aspektem w ujęciu zarówno badawczym, jak i praktycznym jest możliwość wizualizacji danych, jak i otrzymanych wyników.

### 3.2.1 KNIME

Algorytmy wykrywania anomalii w badanych urządzeniach (pompy zasilające, sprężarki natleniające) zostały zaprojektowane i zaimplementowane w środowisku KNIME [184]. KNIME jest platformą analityczną służącą do graficznego projektowania przepływów pracy związanych z przetwarzaniem i analizą danych. Platforma zawiera komponenty do przetwarzania danych, uczenia maszynowego, rozpoznawania wzorców i wizualizacji. Do tworzenia cyfrowych modeli głównie wykorzystywano wbudowane komponenty modelowania oparte o regresję. W przypadku konieczności skorzystania z bardziej zaawansowanych metod istnieje możliwość aplikacji algorytmów z innych środowisk, jak WEKA czy Python za pomocą dedykowanych rozszerzeń. Środowisko pozwala również na zaprojektowanie eksperymentów i symulacji za pomocą mechanizmów sterowania przepływem. Graficzna wizualizacja i intuicyjny interfejs sprawiają, iż cały proces nie wymaga posiadania dużej wiedzy z zakresu języków programowania. Istnieje możliwość produkcyjnego wykorzystania środowiska, opracowane modele mogą być zapisywane na etapie ich tworzenia (np. w formacie PMML - ang. *Predictive Model Markup Language*) i odczytywane przez instancję produkcyjną. Dzięki temu utworzone modele mogą być wdrażane w lokalnych środowiskach produkcyjnych oraz opartych o centra danych w chmurze obliczeniowej, co zwiększa możliwości wdrożeniowe produktów niniejszej pracy.

### 3.2.2 Power BI

Do zadań wizualizacji danych oraz wyników wykorzystano narzędzie PowerBI będące w pakiecie Microsoft Office. PowerBI jest narzędziem dedykowanym do tworzenia raportów dla danych ekonomicznych i produkcyjnych. Z uwagi na możliwość pracy z relatywnie dużymi zbiorami danych (kilkanaście GB), możliwość prezentowania szeregów czasowych oraz intuicyjny interfejs, narzędzie to bardzo dobrze nadaje się do zadań związanych z wizualizacją danych, do celów zarówno związanych z poznawaniem i eksploracją danych, jak i prezentacją wyników.

### 3.2.3 Python

Język Python wraz z pakietem Anaconda zostały wykorzystane do zadań wstępnego przygotowania danych wejściowych. Za pomocą skryptów w języku Python realizowane były operacje polegające na konsolidowaniu plików z danymi procesowymi z systemów automatyki przemysłowej, łączenie danych procesowych z danymi o usterkach, a także ekstrakcja cech. Z uwagi na brak w środowisku KNIME niektórych algorytmów, za pomocą języka Python zaimplementowano funkcje realizujące algorytmy ADWIN, CUSUM (opisane w sekcji 3.3.5) wykorzystane do niwelowania zjawiska dryfu koncepcji, a także funkcje operujące na szeregach czasowych i uzyskanych wynikach (np. test normalności, przetwarzanie i analiza wyników).

## 3.3 Opis opracowanych metod i algorytmów

Niniejsza sekcja przedstawia metody z obszaru eksploracji danych wykorzystane w celu zaprojektowania i realizacji proponowanego rozwiązania. Bazując na wcześniej przedstawionych podstawach teoretycznych z obszaru predykcyjnego utrzymania ruchu oraz opartych na analizie danych metod wykrywania usterek, zostały opracowane metody realizujące postawione cele badawcze.

### 3.3.1 Opracowane metody na tle uczenia maszynowego

Uczenie maszynowe (ang. *Machine learning*, ML) jest jedną z technik modelowania opartą na analizie danych często stosowaną w środowisku przemysłowym z uwagi na występowanie dużych zbiorów danych o usystematyzowanej formie. Spektrum stosowania modeli ML jest bardzo szerokie i specyficzne dla danego obszaru zastosowań. Algorytmy oparte na uczeniu maszynowym można ogólnie podzielić na dwie główne klasy:

- nadzorowane, gdzie informacje o występowaniu awarii są obecne w zbiorze danych treningowych, szeregi czasowe są etykietowane znacznikiem wystąpienia awarii lub rodzajem awarii,
- nienadzorowane, gdy dostępne są informacje dotyczące procesu produkcyjnego (wskazania czujników, sygnały sterujące), natomiast w zbiorze treningowym nie ma informacji o czasie wystąpienia usterki i jej rodzaju.

Podejścia nadzorowane wymagają dostępności zbioru danych postaci  $S = \{\mathbf{x}_i, y_i\}_{i=1}^n$ , gdzie para  $\{\mathbf{x}_i, y_i\}$  zawiera informacje związane z  $i$ -tą iteracją procesu. Wektor  $\mathbf{x}_i \in R^p$  zawiera informacje dotyczące  $p$  zmiennych związanych z dostępnymi informacjami o procesie [185]. W zależności od charakteru zmiennej wyjściowej  $y$  wyróżniamy: modele klasyfikacyjne (jeśli przewidywane są etykiety kategoryczne) oraz modele regresyjne (jeśli wyniki są wartościami ciągłymi). Uczenie nadzorowane jest z powodzeniem stosowane w dziedzinie konserwacji predykcyjnej do klasyfikacji usterek poprzez budowanie detektorów usterek. W literaturze przedmiotu detektory te opierają się na różnych technikach sztucznej inteligencji (AI), takich jak sieci neuronowe [186, 187], metodzie  $k$ -najbliższych sąsiadów [188], maszyny wektorów wspierających [189, 190] lub sieci Bayesowskie [191, 192], często z wykorzystaniem metod redukcji wymiarowości danych, takich jak analiza głównych składowych (PCA) [193, 194].

Tworzenie modeli w niniejszej pracy przebiegało głównie z wykorzystaniem metod regresji, które są grupą metod nadzorowanych. W przyjętym schemacie działania nadzorowana nauka modelu nie wymagała dużego wysiłku w kwestii etykietowania danych, gdyż jako etykiety wykorzystano wartości pomiarów dla danego znacznika czasowego.


### 3.3.2 Algorytm wykrywania anomalii wykorzystujący metodę regresji

W ramach niniejszej rozprawy opracowano algorytm pozwalający na wykrywanie z wyprzedzeniem usterek urządzeń na podstawie analizy generowanych przez nie danych procesowych. Opracowana metoda z uwagi na niewielką liczbę zarejestrowanych usterek krytycznych wykorzystuje mechanizm wykrywania anomalii, gdzie wykorzystano techniki regresji jako podstawę tworzenia modeli.

#### Ogólna koncepcja metody

Koncepcja algorytmu wykrywania anomalii zakładała utworzenie cyfrowego modelu każdego z sygnałów pochodzących z czujników podłączonych do urządzenia (czyli sygnałów opisujących stan tego urządzenia) oraz analizę różnic występujących pomiędzy wartościami rzeczywistymi (zmierzonymi) i wartościami oczekiwanymi sygnału (estymowanymi). Wartość oczekiwana jest estymowana na podstawie bieżących wskazań pozostałych czujników (z wyłączeniem czujnika, dla którego wartość estymujemy). Schemat działania odpowiada metodzie analitycznej redundancji opisanej w sekcji 2.3.3 i jest analogiczny do koncepcji pełnej rekonstrukcji sygnału (ang. *Full Signal ReConstruction*, FRSC) w metodzie modelowania tzw. "normalnego zachowania" przedstawionej w artykule [27]. Założono, że w czasie poprzedzającym zarejestrowaną usterkę różnica między wartościami estymowaną i rzeczywistą będzie rosła. Przykładowy wykres wartości szacowanych, rzeczywistych oraz ich różnicy dla pomiaru przepływu wody na wyjściu pompy pokazano na rys. 3.3. Na wykresie widać okres, w którym uszkodzony był zawór minimalnego przepływu, stąd widoczny był duży błąd predykcji. Predykcji dokonano z wykorzystaniem opracowanego modelu, przedstawionego w sekcji 3.3.3.

**Definicja 1** (Model sygnału). *Modelem sygnału w niniejszej pracy będziemy nazywać estymowaną wartość danego sygnału (pomiaru z czujnika) odwzorowaną na podstawie funkcji wartości pozostałych sygnałów z wyłączeniem sygnału, który jest estymowany oraz jego wartości historycznych.*



Rysunek 3.3: Wartości rzeczywista i estymowana dla pomiaru przepływu wody na wyjściu pompy oraz residuum

### Model wykorzystujący metodę regresji

Do tworzenia cyfrowych modeli poszczególnych sygnałów wykorzystano metodę regresji wielomianowej. Niewątpliwą zaletą algorytmów opartych na regresji wielomianowej jest szybkość obliczeń oraz przejrzystość. Innymi czynnikami decydującymi o wyborze metod opartych o regresję były zależności liniowe i wysoka korelacja między sygnałami z czujników zamontowanych na monitorowanych urządzeniach przemysłowych.

Dla zbioru wszystkich danych wejściowych, gdzie  $x = [x_1, x_2, x_3, \dots, x_m]$  jest wektorem pojedynczych pomiarów z  $m$  czujników, estymujemy wektor, o liczbie współrzędnych  $k'$ , wyników dla najbardziej skorelowanych sygnałów objętych monitoringiem, gdzie każda ze składowych jest rekonstrukcją danego sygnału będącą liniową funkcją wszystkich pozostałych zmiennych, tj,


$$\hat{x}_i = f_i(x) = \sum_{\substack{j=1 \\ j \neq i}}^m a_j^{(i)} x_j + a_0^{(i)} + \varepsilon^{(i)} \quad \forall i \in \{1, 2, \dots, k'\}, \quad k' \leq m, \quad (3.1)$$

gdzie  $\varepsilon^{(i)}$  jest wartością residuum dla  $i$ -tej estymacji, natomiast współczynniki  $a_j^{(i)}$  przyjmują wartości obliczone metodą najmniejszych błędów kwadratowych [195].



### 3.3.3 Proces tworzenia modelu

Schemat przedstawiony na rys. 3.4 ilustruje ogólny algorytm wykonywany podczas budowania modelu analitycznego dla zespołu pomp zasilających. W proponowanym algorytmie utworzono grupę modeli opisujących monitorowane urządzenie, dla których wyniki przedstawiane są w postaci znormalizowanej (jako wielokrotność błędu RMSE obliczoną na etapie uczenia modelu). Uwzględniając błąd maksymalny i wyznaczając różne progi alarmowe, usterki mogą być wykrywane na podstawie obserwowanych anomalii (można zaobserwować znaczne odchylenia wartości sygnału od oczekiwanej poprzedzające zarejestrowane awarie).



Rysunek 3.4: Schemat blokowy etapów działania algorytmu

#### Pozyskiwanie i wstępne przetwarzanie danych

W pierwszym kroku przepływu pracy wczytywany i wstępnie przetwarzany jest analizowany zestaw danych. W procesie czyszczenia poprawiane są wiersze, w których brakuje wartości (brakujące wartości ustawiane są na 0). Kolumny zawierające znaczniki czasu są przekonwertowane z formatu tekstowego na format daty. Odfiltrowane są zakresy danych kiedy urządzenie nie jest w stanie pracy. Jako próg działania przyjęto wartość prądu zasilania pompy równą 1[A], która wynikała z zakłóceń spowodowanych samoindukcją prądu przy wyłączonej pompie. Wartość progowa została określona jako dwukrotność bezwzględnej wartości szczytowej prądu samo-indukującego.

**Definicja 2** (Próg determinacji stanu pracy). *Próg determinacji stanu pracy  $\tau_1$  jest progiem, dla którego przyjmujemy czy pompa jest w stanie operacyjnym lub w stanie postoju:*

$$\tau_1 > 1[A] > 2 \times | \text{wartość szczytowa} |. \quad (3.2)$$

Analizowany zestaw danych dzielony jest na dwie części:

- Część treningową: obejmującą pewien okres czasu, np. 2013-2014. Wykorzystując dane z tej części zbioru tworzone są modele sygnałów. Dla przyjętego przedziału czasu w zależności od przyjętej długości okna treningowego  $\Delta T$ , zbiór mieścił się w zakresie  $[31-12-2013 - \Delta T, 31.12.2013]$ . W celu obliczenia jakości utworzonych modeli sygnałów zbiór treningowy jest dzielony w stosunku 80% (uczenie)/20% (testowanie).
- Część ewaluacyjną: obejmującą następujący okres czasu, np. 2014-2017. Na część testową nakładane są uzyskane wyniki predykcji oraz informacje o zarejestrowanych awariach z systemu ERP.

### Tworzenie grupy modeli

**Definicja 3** (Grupa modeli). *Grupą modeli  $\{f_i\}_{i=1}^k$  nazywamy zbiór modeli sygnałów reprezentujących dane urządzenie. Na grupę modeli składa się  $k$  modeli sygnałów, dla których uzyskano wymaganą jakość predykcji, z wszystkich  $m$  modeli sygnałów opisujących urządzenie.*

**Definicja 4** (Próg akceptacji modelu). *Progiem akceptacji modelu  $\tau_2$  nazywamy graniczną wartość współczynnika determinacji  $R^2$ , powyżej której model jest dodawany do grupy modeli.*

W procesie budowania modelu predykcyjnego urządzenia na podstawie zestawu danych procesowych o długości  $N$  (przedstawionym w Algorytmie 1) brany jest pod uwagę zestaw  $k$  sygnałów, dla których tworzone są modele sygnałów  $(x_1, \dots, x_k)$ , gdzie  $k \leq m$  ( $m$  to liczba wszystkich czujników). Dla każdego z tych sygnałów utworzony zostaje model sygnału wykorzystujący metodę regresji, który rekonstruuje ten sygnał na podstawie danych z pozostałych czujników zgodnie z równaniem 3.1.

Do celów wdrożeniowych utworzony model jest następnie zapisywany w formie Predictive Model Markup Language (PMML). W przedstawionym algorytmie 1 opisującym tworzenie grupy modeli przekazywanymi parametrami są: bieżący znacznik czasu  $T_0$ , długość okna czasowego zbioru treningowego  $\Delta T$ , zbiór  $k'$  wybranych sygnałów, próg determinacji stanu pracy  $\tau_1$ , próg współczynnika determinacji  $\tau_2$  oraz maksymalny stopień wielomianu dla zbudowanego modelu regresji. Mimo występowania  $m$  sygnałów opisujących urządzenie, modele tworzone są tylko dla ograniczonej liczby  $k' \leq m$  z nich, co jest spowodowane tym, iż nie wyznaczana jest funkcja regresji dla zmiennych sterujących (przyjmują one tylko dwie wartości: jeden (prawda) lub zero (fałsz)) oraz dla zmiennych słabo skorelowanych z pozostałymi, co powodowałoby duży błąd przy rekonstrukcji sygnału. Zmienne te mogą jednak dostarczyć dodatkowych informacji dla modelu, dlatego nie są pomijane przy wyznaczaniu funkcji regresji. Dla wszystkich  $i \in \{1, \dots, k'\}$  utworzonych modeli regresji  $f_i$ , obliczane są również współczynniki błędów  $Sc_i$ , obejmujące wartości średniego błędu bezwzględnego ( $MAE_i$ ), błędu średnio-kwadratowego ( $RMSE_i$ ) oraz współczynnika determinacji ( $R_i^2$ ), które wyznaczone są zgodnie z równaniami 3.3, 3.4, 3.5, 3.6. Porównanie wartości współczynnika determinacji  $R_i^2$  z wartością progową  $\tau_2$  jest regułą, która decyduje o tym, czy zaakceptować, czy odrzucić utworzony model sygnału dla danej grupy modeli. Wynikiem działania algorytmu tworzenia grupy modeli z eliminacją modeli o słabej jakości jest zestaw  $k \leq k' \leq m$  modeli sygnałów, które spełniają zadany warunek oraz zbiór współczynników błędów składający się z  $k$  wektorów błędów.

---

**Algorithm 1:** Tworzenie grupy modeli z eliminacją modeli o słabej jakości

---

**Data:**  $X, k', T_0, \Delta T, deg, \tau_1, \tau_2$   
**Result:** Modele regresji:  $\{f_i\}_{i=1}^k$ , współczynniki błędów:  $\{Sc_i\}_{i=1}^k, k \leq k'$   
 $f = \emptyset$ ; // pusty zbiór modeli  
 $X = [x_1, x_2, x_3, \dots, x_m] = \{x_{ij} : i \in \{1, \dots, m\}, j \in \{1, \dots, N\}\}$ ;  
 $X \leftarrow trim(X, [T_0 - \Delta T, T_0])$ ; // ustaw zakres zbioru uczącego X  
 $X \leftarrow filter(X, missingvalues, \tau_1)$ ; // Filtruj tylko czas operacji  
**for**  $i = 1 \dots k'$  **do**  
     $O_i = x_i$ ; // ustaw wektor wyjściowy wartości objaśnionych  
     $I_i = X/x_i$ ; // wyklucz zmienną objaśnianą  
    wyznacz model regresji  $f_i(x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_m)$  dla  $S_i = \{I_i, O_i\}$   
    wyznacz współczynniki błędów  $Sc_i = (MAE_i, RMSE_i, R_i^2)$  dla  
     $S_i = \{I_i, O_i\}$   
    **if**  $R_i^2 > \tau_2$  **then**  
        zapisz model  $f_i$  w formacie PMML;  
        zapisz współczynniki błędów  $Sc_i$ ;  
    **end**  
**end**

---

### Obliczanie współczynników błędów i ocena jakości modeli

W celu oceny jakości  $i$ -tego modelu  $f_i$  obliczono kilka współczynników, które pozwoliły zmierzyć różnice między wartościami obserwowanymi i szacowanymi, tj. średni błąd bezwzględny (MAE), błąd średniokwadratowy (MSE), średni błąd kwadratowy (RMSE) oraz współczynnik determinacji ( $R^2$ ):

$$MAE_i = \frac{1}{n} \sum_{j=1}^n |x_{ij} - \hat{x}_{ij}|, \quad (3.3)$$

$$MSE_i = \frac{1}{n} \sum_{j=1}^n (x_{ij} - \hat{x}_{ij})^2, \quad (3.4)$$

$$RMSE_i = \sqrt{\frac{1}{n} \sum_{j=1}^n (x_{ij} - \hat{x}_{ij})^2}, \quad (3.5)$$

$$R_i^2 = 1 - \frac{\sum_{j=1}^n (x_{ij} - \hat{x}_{ij})^2}{\sum_{j=1}^n (x_{ij} - \bar{x}_i)^2}, \quad (3.6)$$

gdzie  $x_{i1}, \dots, x_{in}$  są wartościami obserwowanymi,  $\hat{x}_{i1}, \dots, \hat{x}_{in}$  – to wartości przewidywane,  $\bar{x}_i$  – to średnia wartość  $i$ -tej zmiennej (estymacja dla  $i$ -tego czujnika dla  $i \in \{1, 2, \dots, k'\}$ ), a  $n$  to liczba analizowanych próbek w oknie czasowym  $\Delta T$ .

Współczynniki błędów obliczane są na etapie trenowania modelu, przy czym zbiór testowy (dla którego obliczane są współczynniki błędów) stanowi najnowsze 20% próbek.

W celu oceny jakości predykcyjnych pod kątem wykrywania usterek zastosowano miary bazujące na macierzy pomyłek. W macierzy pomyłek wyniki predykcji są etykietowane klasami w zależności od relacji otrzymanego wyniku względem wartości rzeczywistej, tak jak przedstawiono w tabeli 3.1.

Tabela 3.1: Macierz pomyłek

		Klasa rzeczywista	
		0	1
Klasa predykowana	0	Prawdziwie negatywna (TN)	Fałszywie negatywna (FN)
	1	Fałszywie pozytywna (FP)	Prawdziwie pozytywna (TP)

Macierz pomyłek przewiduje następujące możliwości zwracanych wyników predykcji względem zdarzeń rzeczywistych w kontekście wykrywania usterek:

- prawdziwie pozytywna (ang. *True positive*, TP) - model prawidłowo wykrył usterkę, która miała miejsce,
- prawdziwie negatywna (ang. *True negative*, TN) - model prawidłowo nie wykrył usterki, przy prawidłowym działaniu urządzenia,

- fałszywie pozytywna (ang. *False positive*, FP) - model błędnie wykrył usterkę, gdy w rzeczywistości nie wystąpiła (błąd pierwszego rodzaju),
- fałszywie negatywna (ang. *False negative*, FN) - model nie wykrył usterki w sytuacji, kiedy w rzeczywistości wystąpiła (błąd drugiego rodzaju).

Na podstawie tak sklasyfikowanych zdarzeń, w niniejszej pracy zastosowano następujące miary jakości predykcji usterek:

$$\text{Dokładność} = \frac{\sum TP + \sum TN}{\sum TP + \sum TN + \sum FP + \sum FN}, \quad (3.7)$$

$$\text{Czułość} = \frac{\sum TP}{\sum TP + \sum FN}, \quad (3.8)$$

$$\text{Swoistość} = \frac{\sum TN}{\sum FP + \sum TN}. \quad (3.9)$$

Miary dokładności (ang. *Accuracy*) i czułości (ang. *Sensitivity*) pozwalają określić zdolności detekcyjne modelu, natomiast miara swoistości (ang. *Specificity*) akcentuje tendencje modelu do generowania fałszywych alarmów.

Graficzną prezentacją jakości klasyfikatora jest krzywa ROC (ang. *Receiver Operating Characteristic*) przedstawiająca relację między wartościami czułości i swoistości dla wybranych parametrów modelu. Jako mierzalną wartość oceniającą całościowo model na podstawie krzywej ROC jest przestrzeń pod krzywą ROC zwana AUC (ang. *Area under curve*). Idealną wartością miary AUC jest wartość 1.

### Przetwarzanie i standaryzacja wyników

Ponieważ bezwzględna różnica między wartościami obserwowanymi i przewidywanymi dla różnych sygnałów nie jest miarą, którą można byłoby wykorzystać do porównania poziomu wartości błędów między sygnałami rzeczywistym i estymowanym, aby znormalizować wyniki wprowadzono współczynnik znormalizowanego błędu względnego *NRE* (ang. *Normalized relative error*) do określenia stopnia odchylenia dla  $i$ -tej zmiennej w zbiorze danych ( $i \in \{1, 2, \dots, k\}$ ).

**Definicja 5** (Znormalizowany błąd względny). *Znormalizowany błąd względny jest ilorzem modułu błędu estymacji pomniejszonego o średni błąd bezwzględny określony dla zbioru treningowego względem średniego odchylenia standardowego również określonego dla zbioru treningowego:*

$$NRE_i = \frac{|x_i(t) - \hat{x}_i(t)| - MAE_i}{RMSE_i}, \quad (3.10)$$

gdzie  $x_i(t)$  i  $\hat{x}_i(t)$  to wartość bieżąca i jej estymacja uzyskana za pomocą funkcji regresji ( $t \in (T_0, T_0 + \Delta T)$ ).

Wybierając zmienną o maksymalnej wartości  $NRE_{max}$  (zwanej *maksymalnym znormalizowanym błędem względnym*), można zidentyfikować sygnał, który prawdopodobnie wskazuje na przyczynę nadchodzącej awarii.

**Definicja 6** (Maksymalny znormalizowany błąd względny). *Maksymalny znormalizowany błąd względny jest maksymalną wartością spośród wszystkich współczynników  $NRE$  obliczonych dla wszystkich modeli  $f_i$  dla danego znacznika czasowego w obrębie danej grupy modeli wskazujący jednocześnie na indeks modelu sygnału będący prawdopodobnym źródłem potencjalnej usterki.*

$$NRE_{max} = \max(NRE_1, NRE_2, \dots, NRE_k). \quad (3.11)$$

Ten etap pozwala na znalezienie sygnału wskazującego prawdopodobne źródło anomalii spośród wszystkich sygnałów opisujących urządzenie. Następuje tutaj identyfikacja potencjalnego źródła usterki. Na przykład, jeżeli maksymalny znormalizowany błąd względny wskazuje na pomiar przepływu wody na wyjściu pompy, wtedy możliwą przyczyną usterki jest wyciek lub uszkodzony zawór. Podobnie, jeżeli wartość  $NRE_{max}$  wskazuje na pomiar temperatury konkretnego łożyska, możliwą przyczyną jest uszkodzenie (lub korozja), czego symptomem jest podwyższona temperatura.

### Wyzwalanie alarmów i wizualizacja

Do wizualizacji wyników stworzonego modelu na potrzeby analizy wykorzystano oprogramowanie PowerBI, które pozwala na łatwą i szybką prezentację danych, w tym również szeregów czasowych. Nanosząc progi ostrzegawcze i alarmowe

na osie wyników możliwa jest wizualne określenie czasu, kiedy zaproponowany algorytm wyśle powiadomienie o potencjalnym zagrożeniu. Próg ostrzegawczy (alarm pierwszego stopnia) proporcjonalny do wartości  $RMSE$ , został ustalony na wartość trzy:

$$NRE_{max} > 3 \Rightarrow \text{Alarm pierwszego stopnia}, \quad (3.12)$$

natomiast awaria (alarm drugiego stopnia) była sygnalizowana, jeśli  $NRE_{max}$  osiągnął wartość sześć:

$$NRE_{max} > 6 \Rightarrow \text{Alarm drugiego stopnia}. \quad (3.13)$$

Wartość progu ostrzegawczego została ustalona na trzy zakładając, iż dystrybucja błędów ma rozkład zbliżony do normalnego  $N(0, 1)$ . Zastosowanie reguły trzech sigm [196] oznaczałoby, że 99,73% wartości mieści się w tym przedziale. W przypadku zmiennych o rozkładzie innym niż normalny, zgodnie z nierównością Czebyszewa, co najmniej 88,8% przypadków powinno mieścić się w prawidłowo obliczonych przedziałach w zakresie trzech sigm.


### 3.3.4 Parametryzacja modelu i procesu uczenia

Jednym z celów pracy jest opracowanie algorytmów i modeli z ograniczonym wykorzystaniem wiedzy eksperckiej, zarówno w kwestii wiedzy branżowej, jak i wiedzy analitycznej. Dla rozwiązania tak zdefiniowanego zadania opracowano szereg metod pozwalających na automatyzację procesu tworzenia modeli, co pozwala na wdrożenie opracowanego algorytmu dla różnych urządzeń pracujących w różnych środowiskach. Szczególnie istotnym krokiem w procesie tworzenia modelu jest jego parametryzacja pod względem ustalenia współczynników modelu oraz zbioru cech wejściowych, co ma istotne znaczenie dla jakości zwracanych wyników.

#### Wstępne przetwarzanie i gromadzenie danych

Wstępne przetwarzanie danych polega na wstępnej selekcji cech ( $m$  sygnałów opisujących urządzenie) dla tworzonego modelu predykcyjnego. Na tym etapie dokonujemy wyboru grupy pomiarów, które wejdą w skład zbioru treningowego mo-





Rysunek 3.5: Przykład notacji KKS

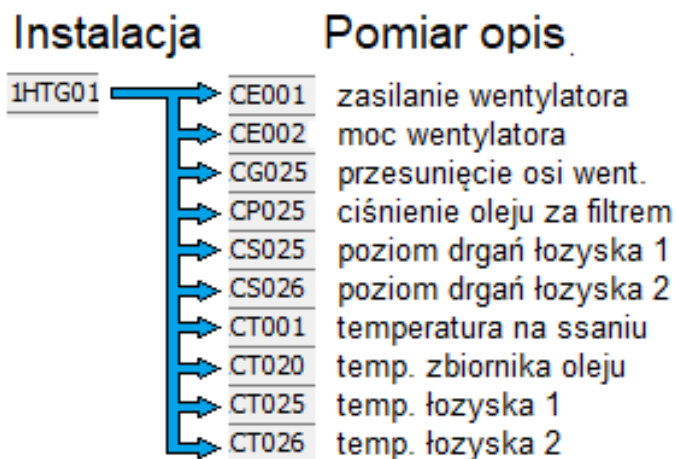
delu. W przypadku pojedynczego zadania predykcji możemy łatwo określić grupę jednostek miar związanych z urządzeniem (np. korzystając z dokumentacji technicznej). Jednak w przypadku tworzenia wielu modeli predykcyjnych do objęcia monitoringiem całej instalacji zawierającej dziesiątki tysięcy punktów pomiarowych, praca nie jest już trywialna. W tym przypadku pomocny jest sposób kodowania KKS.

Metoda notacji KKS (niem. *Kraftwerk-Kennzeichen-System*) pozwala na łatwe wyodrębnienie wszystkich podzespołów związanych z urządzeniem nadrzędnym. Przykładowy kod w notacji przedstawiono na rys. 3.5. W ten sposób można znacznie ograniczyć zbiór potencjalnych sygnałów wejściowych do dalszej analizy (np. analizy korelacji, optymalizacji parametrycznej itp.). System kodowania KKS został wprowadzony na potrzeby uzyskania jednolitego systemu oznaczeń urządzeń i instalacji w elektrowniach. System oznaczeń został po raz pierwszy opublikowany w 1978 roku i jest efektem współpracy wielu firm i branż. Stanowi obecnie podstawę dla oznaczania obiektów i ich podzespołów w elektrowniach.

Analizując system kodowania urządzeń i sygnałów (KKS) na rys. 3.6 przedstawiono propozycję metody automatycznej akwizycji danych pomiarowych powiązanych z danym urządzeniem. Zastosowana metoda upraszcza znacząco proces wstępnego przetwarzania danych szczególnie w przypadku pracy na dużych zbiorach danych (ang. *Big Data*).

### Automatyzacja procesu etykietowania i selekcji danych

W celu utworzenia modelu będącego analityczną rekonstrukcją konkretnego sygnału istotną kwestią jest wyznaczenie wzorcowego zbioru danych treningowych,



Rysunek 3.6: Hierarchia kodowania kodowania KKS

kiedy urządzenie jest w dobrej kondycji. Aby wyodrębnić ze zbioru danych wejściowych okresy, w których występowały awarie, i wytrenować model predykcyjny na poprawnych danych, konieczne jest etykietowanie rekordów znacznikami o występowaniu awarii. Informacje o występowaniu usterek są potrzebne do wyodrębnienia zbioru treningowego w procesie uczenia modelu oraz do późniejszej ewaluacji i wizualizacji wyników w zbiorze testowym. Analiza wpływu usterek jest czasochłonna i wymaga wiedzy inżynierskiej, aby odpowiednio sklasyfikować zdarzenia. Dlatego uproszczono proces etykietowania w taki sposób, aby automatycznie oznaczać zbiór danych na podstawie dat rejestracji usterek i zakończenia naprawy. Do zbioru treningowego dodana została kolumna zawierająca dane typu prawda lub fałsz, aby wskazać, czy urządzenie było w danym momencie (przypuszczalnie) w stanie awarii, jak pokazano na rys. 3.7. Dane wejściowe są filtrowane na podstawie priorytetu, aby wyizolować mniej znaczące zdarzenia, takie jak prace serwisowe, w tym wymiana oleju lub przeglądy okresowe. Automatyzacja procesu etykietowania wymaga ustandaryzowanego sposobu rejestrowania prac serwisowych i dobrej jakości danych. Jednakże, ewentualne błędy przy wprowadzonych danych mogą być kompensowane przez wielkość zbioru treningowego, zakładając ich marginalny wpływ na jakość algorytmu. Automatyczne etykietowanie na podstawie danych z rejestrów usterek znacząco przyspiesza czas przygotowania danych w procesie tworzenia modelu.

Timestamp	Signal 1	Signal 2	...	Signal m	Label
2017-01-01	0,15	2,74		-0,03	ok
2017-01-02	0,15	2,74		-0,03	failure
2017-01-03	0,15	2,74		-0,03	failure
2017-01-04	0,15	2,74		-0,03	failure
2017-01-05	0,15	2,74		-0,03	failure
2017-01-06	0,15	2,74		-0,03	failure
2017-01-07	0,15	2,74		-0,03	failure
2017-01-08	0,15	2,74		-0,03	failure
2017-01-09	0,15	2,74		-0,03	failure
2017-01-10	0,15	2,74		-0,03	failure
2017-01-11	0,15	2,74		-0,03	failure
2017-01-12	0,15	2,74		-0,03	failure
2017-01-13	0,15	2,74		-0,03	ok
2017-01-14	0,15	2,74		-0,03	ok
2017-01-15	0,15	2,74		-0,03	ok
2017-01-16	0,15	2,74		-0,03	ok
2017-01-17	0,15	2,74		-0,03	ok
2017-01-18	0,15	2,74		-0,03	ok
2017-01-19	0,15	2,74		-0,03	ok
2017-01-20	0,15	2,74		-0,03	ok
2017-01-21	0,15	2,74		-0,03	failure
2017-01-22	0,15	2,74		-0,03	failure
2017-01-23	0,15	2,74		-0,03	failure
2017-01-24	0,15	2,74		-0,03	failure
2017-01-25	0,15	2,74		-0,03	failure
2017-01-26	0,15	2,74		-0,03	failure
2017-01-27	0,15	2,74		-0,03	failure
2017-01-28	0,15	2,73		-0,03	failure
2017-01-29	0,15	2,70		-0,03	failure
2017-01-30	0,15	2,66		-0,03	failure
2017-01-31	0,15	2,62		-0,03	failure
2017-02-01	0,15	2,58		-0,03	ok
2017-02-02	0,15	2,55		-0,03	ok
2017-02-03	0,15	2,58		-0,03	ok

StartDate	EndDate	Description	Priority
2015-04-26	2015-05-03	oil leakage	3
2015-12-02	2015-12-09	max. vibrations	1
2016-01-03	2016-01-10	increased vibrations	2
2016-01-07	2016-01-14	increased vibrations	2
2016-01-14	2016-01-21	oil temperature exceeded	1
2017-01-02	2017-01-12	increased vibrations	2
2017-01-21	2017-01-31	increased vibrations	2

Rysunek 3.7: Automatyczne etykietowanie danych na podstawie zapisów w rejestrze usterek

W celu zautomatyzowania procesu etykietowania danych utworzono dodatkowy krok na etapie przetwarzania danych wejściowych pozwalający na łatwe etykietowanie szeregów czasowych oraz klasyfikację występujących zdarzeń. Rozwiązanie łączy ze sobą dane z systemów sterowania z systemem zarządzania majątkiem i zleceniami roboczymi.

### 3.3.5 Zjawisko dryfu koncepcji - detekcja i sposoby zapobiegania

#### Zjawisko dryfu koncepcji


Zjawisko dryfu koncepcji (ang. *Concept drift*) w analityce predykcyjnej związane jest ze zmianą w perspektywie czasu właściwości statystycznych procesu lub obiektu, który jest przedmiotem predykcji, co ma wpływ na jakość uzyskiwanych wyników przez utworzony model [197]. Wpływ czynników zewnętrznych, remonty, wymiana podzespołów, zmieniające się warunki pracy mają istotny wpływ na charakterystykę systemu co sprawia, że zmiany w funkcjonowaniu modelu pre-

dykcyjnego są nieuchronne. Zmiany widoczne w przebiegach szeregów czasowych procesów technologicznych odzwierciedlają się w rozkładzie danych i całej strukturze danych wejściowych modelu predykcyjnego. Istotnym czynnikiem wpływającym na utratę zdolności predykcyjnych są zmiany w relacjach pomiędzy zmiennymi modelu [198, 199], w przypadku opracowanego algorytmu zmiany w tych relacjach mają bezpośredni wpływ na jakość estymowanych wartości przez modele regresji, co w przypadku znaczących błędów powoduje generowanie fałszywych alarmów. Na rys. 3.8 przedstawiono różne formy, jakie może przybierać dryf koncepcji. Zmiany mogą zachodzić:

- Gwałtownie - co jest charakterystyczne dla nagłej zmiany stanu urządzenia. W kontekście zdarzeń serwisowych takie zmiany mogą wystąpić po naprawie lub wymianie istotnego elementu instalacji.
- Przyrostowo - w tym przypadku zmiany są zbliżone do liniowych, dryft przyrostowy może być objawem zużycia podzespołów, np. rosnącego ciepła łożysk lub parowania sprawności chłodziw. Podobne czynniki mogą powodować dryf stopniowy.
- Stopniowo - zmiany przybierają postać stopniowej deregulacji. Przyczyny mogą być te same co przy dryfcie przyrostowym. W tym przypadku bardziej prawdopodobne jest, że wpływ na to mają stopniowe zmiany na wejściu lub pojawienie się nowych czynników nieuwzględnionych w zbiorze treningowym.
- Rekurencyjnie - może to być typowy przykład usterki lub czynnika, który został zniwelowany. Zmiana stanu wskazuje na zbliżającą się (i trwającą) awarię, natomiast powrót do stanu początkowego następuje po usunięciu awarii. Ten przypadek, w węższym zakresie czasu, może również wskazywać na anomalie (np. uszkodzenie czujnika) lub stany rozruchu/wyłączenia.

### **Metody zapobiegania zjawisku dryfu koncepcji**

Klasyfikacja grup metod przeciwdziałania zjawisku dryfu koncepcji, przedstawiona została na rys. 3.9. Podejście wykorzystujące zarządzanie danymi obejmuje

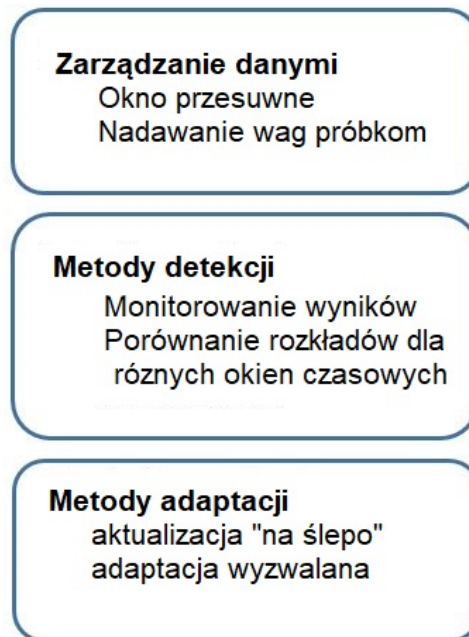


Rysunek 3.8: Rodzaje dryfu koncepcji

metody związane z selekcją i nadawaniem wag próbkom wejściowym w zbiorze treningowym. Jednym z wykorzystywanych mechanizmów jest tutaj zastosowanie okna czasowego dla zbioru argumentów przedstawianych w postaci szeregów czasowych. Metody detekcji obejmują techniki i mechanizmy służące do wykrywania zjawiska dryfu koncepcji. Dwa główne podejścia są związane z monitorowaniem wskaźników wydajności modelu oraz monitorowaniem rozkładów danych wyjściowych dla dwóch różnych okien czasowych (dłuższego i krótszego). Metody adaptacyjne polegają na douczeniu lub odświeżeniu modelu na podstawie nowych lub bardziej aktualnych danych.

### Koncepcja rozwiązania wykorzystująca metody detekcji

W niniejszej sekcji przedstawiono techniki i mechanizmy detekcji zjawiska dryfu koncepcji, szczegółowo opisując algorytmy zaimplementowane w badaniach wraz z opisem zastosowanych modyfikacji własnych. Metody pozwalające na detekcję



Rysunek 3.9: Główne podejścia służące do niwelowania zjawiska dryfu koncepcji

dryfu koncepcji można sklasyfikować jako [200]:

- metody wykorzystujące analizę sekwencyjną,
- metody wykorzystujące wykresy kontrolne,
- metody bazujące na różnicach między dwoma rozkładami,
- metody heurystyczne.

Mechanizmy detekcji dryfu są wykorzystywane do wykrywania zmian w wynikach zwracanych przez model predykcyjny, po których należy odświeżyć model. Można zastosować to podejście, mając pewność co do charakteru zmiany - czy jest to chwilowa usterka, czy też trwała zmiana w stanie urządzenia. Wykrywanie zjawiska dryfu koncepcji w szeregach czasowych może być zrealizowane poprzez wykorzystanie algorytmu sum skumulowanych.

**Algorytm sum skumulowanych** (ang. *Cumulative sum*, CUSUM) jest algorytmem opublikowanym w latach 50-tych XX wieku [201], z uwagi na swoje właściwości stosowany jest z powodzeniem do dnia dzisiejszego. Jest on zwykle używany

do wykrywania zmian w szeregach czasowych. Celem algorytmu jest podniesienie alarmu, gdy średnia wartość wejściowa jest znacznie większa od zera. Danymi wejściowymi algorytmu CUSUM może być dowolna wartość, dla której wykrywamy zmienność w czasie. W przypadku rozpatrywanym w niniejszej rozprawie będzie to błąd estymacji modelu danego sygnału ( $\varepsilon^{(i)}$  we wzorze 3.1). Algorytm opiera się na następujących równaniach 3.14:

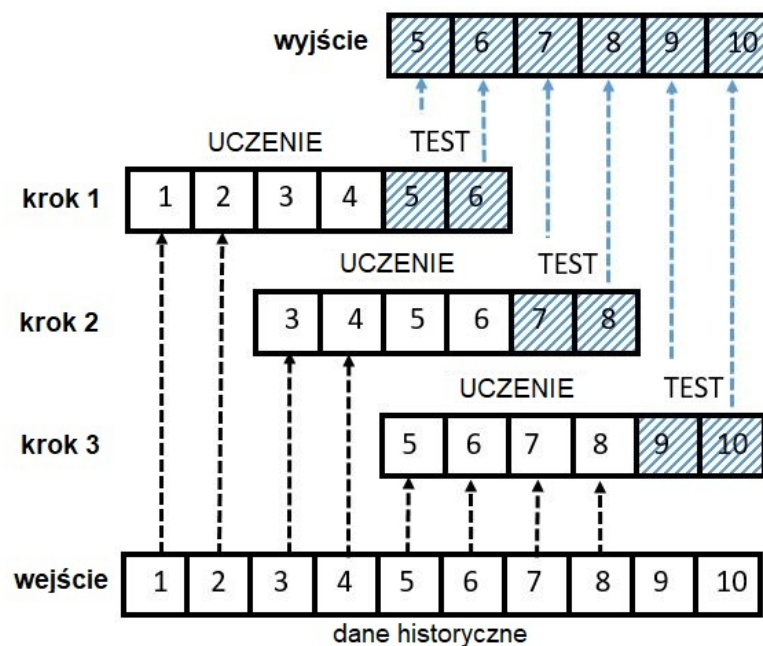
$$\begin{aligned} g_0 &= 0, \\ g_t &= \max(0, g_{t-1} + (r_t - v)), \end{aligned} \tag{3.14}$$

gdzie  $r_t$  jest aktualnie obserwowaną wartością,  $v$  jest dopuszczalną wielkością zmiany, a  $t$  jest aktualnym czasem. Gdy wartość  $g_t$  przekroczy ustalony próg  $\lambda$ , wyzwalany jest alarm, a wartość  $g_t$  ustawiana jest na zero. Przedstawiona formuła wykrywa tylko alarmy dla wartości dodatnich, co w prowadzonych eksperymentach jest wystarczającą własnością. Jeśli jednak konieczne byłoby wykrywanie zmian dla wartości ujemnych, operator "max" można zamienić na "min". Algorytm CUSUM nie jest skomplikowany i może z powodzeniem efektywnie obliczeniowo działać na strumieniach danych. Dokładność algorytmu zależy od właściwego ustawienia parametrów i wartości  $v$ . Ustawione progi mają wpływ na szybkość wykrywania (jak długo trwa stan anomalii) i tym samym liczbę generowanych fałszywych alarmów, przy czym większa czułość i szybkość wykrywania przekłada się na większą liczbę fałszywych alarmów. W kontekście przeprowadzonych badań algorytm ten służy do odfiltrowania stałych lub wolno rosnących błędów wynikających z pogorszenia właściwości predykcyjnych modelu (czyli domyślnie dryfu koncepcji) od wykrywania gwałtownych zmian (domyślnie awarii). Powyższa właściwość algorytmu sprawia, iż jego zastosowaniem w aspekcie prowadzonych prac nie jest wykrywanie dryfu koncepcji, a detekcja nagłych zmian oznaczających potencjalne awarie. Algorytm CUSUM można stosować jako mechanizm służący do wyzwalania alarmów niezależnie od algorytmów przedstawionych w dalszej części rozdziału.

### Rozwiązania wykorzystujące metody adaptacyjne

Metody w tej grupie skupiają się wokół adaptacji modelu, czyli procesu okresowej aktualizacji modelu na podstawie aktualnych danych. Można wyróżnić dwa rodzaje podejść: "na ślepo" i "w sposób informowany":

- Metody aktualizacji "na ślepo" (ang. *Blind window*) odświeżają model w cyklicznych krokach za pomocą najnowszych danych w regularnych odstępach czasu nie zwracając uwagi na to, czy nastąpiły zmiany w jakości predykcji dla badanego modelu (zob. rys. 3.10). W celu optymalizacji metody można nadawać wagi poszczególnym próbkom w zbiorze treningowym (selektywnie lub na podstawie czasu) lub dostosowywać rozmiar okna treningowego (liczba próbek w zbiorze treningowym).
- Metody informowane (ang. *Informed methods*) uruchamiają aktualizację modelu tylko wtedy, gdy wykryto zmianę. Współpracują one z modelem wykrywania.



Rysunek 3.10: Metoda adaptacji modelu "na ślepo"



**Algorytm okna adaptacyjnego (ang. *Adaptive window*, ADWIN)** to algorytm, który można wykorzystać do wykrywania zmian w szeregu czasowym, a także do estymowania wartości przy użyciu okna kroczącego o adaptacyjnym rozmiarze [202, 203]. W przeciwieństwie do tradycyjnego okna przesuwne, ADWIN dostosowuje długość okna w taki sposób, aby średnie wartości cząstkowe wewnątrz okna wyjściowego nie różniły się znacząco od średniej wartości próbek dla całego okna. W wyniku działania algorytmu otrzymujemy podzbiór najbardziej aktualnych elementów o spójnych wartościach średnich, co odbywa się poprzez usunięcie najstarszych fragmentów, jeśli ich średnie różnią się od pozostałych części okna. Parametrami dla algorytmu są: współczynnik ufności  $\delta \in (0, 1)$  oraz sekwencja danych w szeregu czasowym  $S$ , składająca się z próbek  $x_t \in S$  w chwili  $t$ . Algorytm wykorzystuje przesuwne okno  $W$  gdzie najnowsze dane (najbliższe bieżącej chwili) są najbardziej aktualne. Główna idea algorytmu jest następująca: gdy dwa "dostatecznie duże" podzbiory okna  $W$  wykazują "dostatecznie różne" średnie, można stwierdzić, że wyniki zwracane przez model dla tych dwóch okresów są różne i starsza część okna jest odrzucana [197]. Progi "dostatecznie duże" i "dostatecznie różne" są definiowane przez statystykę Hoeffdinga, która sprawdza, czy średnia z dwóch podzbiorów jest większa od progu  $\epsilon_{cut}$ , określonego następującym wzorem 3.15:

$$\epsilon_{cut} = \sqrt{\frac{1}{2m_h} * \ln \frac{4|W|}{\delta}}, \quad (3.15)$$

gdzie  $|W|$  oznacza długość okna  $W$ , natomiast  $m_h$  jest średnią harmoniczną długości dwóch sąsiednich podzbiorów  $|W_0|$  i  $|W_1|$ , obliczaną w sposób przedstawiony w równaniu 3.16:

$$m_h = \left( \frac{1}{|W_0|} + \frac{1}{|W_1|} \right)^{-1}. \quad (3.16)$$

Pseudokod algorytmu ADWIN jest przedstawiony w Algorytmie 2. Przyjmuje się, że  $\hat{\mu}_W$  oznacza średnią próbek zawartych w  $W$ ,  $n$  jest długością okna  $W$ , a  $n_0$  i  $n_1$  są długościami odpowiednio  $W_0$  i  $W_1$  tak, że  $n = n_0 + n_1$ .

**Algorithm 2:** Algorytm adaptacyjnego okna (ADWIN)

---

**Wejście:**  $\delta$  : przedział ufności;  
 Inicjalizacja okna  $W$ ;  
**foreach**  $t > 0$  **do**  
    $W \leftarrow W \cup \{x_t\}$ ;  
   **repeat**  
     | Odrzuć elementy z końca okna  $W$ ;  
   **until**  $|\widehat{\mu}_{W_0} - \widehat{\mu}_{W_1}| \geq \epsilon_{cut}$   
     wykonuj dla każdego podziału  $W$  takiego, że  $W = W_0 \cup W_1$ ;  
**end**  
**Wyjście:**  $\widehat{\mu}_W, n_0$


---

Algorytm może być stosowany na dwa sposoby:

- do wykrywania nagłych zmian: ADWIN zmniejsza okno tylko wtedy, gdy wykryto znaczącą zmianę,
- do szacowania wartości w szeregach czasowych: przewidywaną wartością jest średnia krocząca obliczona dla okna czasowego od ostatniej znaczącej zmiany, bez najstarszych wartości z inną średnią.

Algorytm ADWIN automatycznie wykrywa zmiany i dostosowuje się do nich. Parametrem, który należy ustawić, jest wartość ufności, określająca, jak dokładne powinny być wyniki obliczeń. Przykład dopasowywania długości okna pokazano na rys. 3.11.

Aby poprawić właściwości predykcyjne opracowanego algorytmu wykrywającego usterek istotną kwestią jest dobranie odpowiedniej długości okna treningowego w procesie uczenia modelu. Algorytm ADWIN może służyć podobnie jak przedstawiony w sekcji 3.3.5 algorytm CUSUM do wykrywania nagłych zmian, przy czym istotnym elementem charakterystycznym tego algorytmu jest możliwość określenia długości okna  $W$  od ostatniej znaczącej zmiany. Ta właściwość algorytmu może być wykorzystana do określania długości zbioru treningowego w celu dopasowania jego rozmiaru, analizując wartości odchylenia błędów predykcji. Niestety algorytm ADWIN wymaga parametryzacji przedziału ufności  $\delta$  mającego wpływ na współczynnik odcięcia  $\epsilon_{cut}$ . Wyznaczenie prawidłowego parametru jest kluczowe dla prawidłowego działania algorytmu i jest sporym wyzwaniem



Rysunek 3.11: Adaptacyjne dostosowanie długości okna w zależności od zmian sygnału wejściowego w algorytmie ADWIN

w przypadku jego zastosowania dla przebiegów wynikowych z różnych modeli sygnałów. W związku z trudnością wyznaczenia odpowiedniego parametru  $\delta$  algorytm ADWIN został zmodyfikowany w taki sposób, aby w ramach z góry ustalonego odpowiednio dużego przedziału znajdował największą zmianę.

### Zmodyfikowany algorytm adaptacyjnego okna (MSC-ADWIN)

W przeprowadzonych badaniach algorytm adaptacyjnego okna (ADWIN) został zmodyfikowany w taki sposób, aby określał optymalną wielkość zbioru treningowego, tzn. wyznaczał długość okna treningowego operując na wynikach predykcji zwróconych przez model, rozpoczynając od najnowszych wyników do momentu, w którym wystąpiła najbardziej znacząca zmiana. Zmodyfikowany w ten sposób algorytm realizujący powyższe zadanie został nazwany MSC-ADWIN (ang. *Most significant change-Adwin*). W założeniach, modyfikacja ta w połączeniu z opisaną w poprzednim rozdziale adaptacją "na ślepo", powinna poprawić jakość predykcji, gdyż zbiór treningowy będzie oparty na spójnych danych. W zmodyfikowanym algorytmie MSC-ADWIN nie wyznaczamy progu odcięcia, ponieważ w rozpatrywanych przypadkach rozkład zmiennych jest nieprzewidywalny (zwłaszcza w przypadku awarii lub remontu). Wykorzystujemy natomiast jedną z właściwości algorytmu ADWIN, jaką jest precyzyjne określenie momentu, w którym wystąpiła największa zmiana. W każdym kroku przesunięcia "ślepego" okna dzielimy zbiór na  $p$  części (w prowadzonych eksperymentach po 5000 próbek). Liczba

próbek (tj. 5000) została ustalona na podstawie wcześniejszych eksperymentów dotyczących minimalnej długości okna treningowego, z których wynika, że przy tej liczbie próbek błąd predykcji się stabilizuje (nie zmniejsza się znacząco przy zwiększaniu liczby próbek). Taki pojedynczy podzbiór odpowiadający krokowi minimalnego przesunięcia nazywać będziemy minimalnym podzbiorem cząstkowym.

**Definicja 7** (Minimalny podzbiór cząstkowy). *Minimalnym podzbiorem cząstkowym nazywany spójne okno danych zawierające ustaloną liczbę próbek pozwalającą na dostatecznie efektywną realizację procesu uczenia modelu predykcyjnego.*

Podział danych wejściowych na podzbiory cząstkowe ma na celu uniknięcie sytuacji, w której zbyt wcześnie wykryta zmiana uniemożliwi skuteczne wytrenowanie modelu oraz generalizację wyników poprzez analizę wartości średnich, mając na celu odfiltrowanie chwilowych wartości szczytowych i stanów nieustalonych. Średnie wartości próbek wewnątrz przedziałów będących wielokrotnościami minimalnego podzbioru cząstkowego nazywać będziemy średnimi wartościami cząstkowymi.

Pseudokod algorytmu MSC-ADWIN przedstawiono w Algorytmie 3, zakładając, że zbiór danych wejściowych  $W$  jest posortowany w porządku malejącym według znaczników czasu, a  $m_h$  jest średnią harmoniczną długości dwóch sąsiednich podzbiorów (okien danych  $W_0$  i  $W_1$ ).

**Definicja 8** (Średnie wartości cząstkowe). *Średnimi wartościami cząstkowymi  $\hat{\mu}_{W_0}$  i  $\hat{\mu}_{W_1}$  nazywamy średnie wartości próbek wewnątrz okna przesuwne  $W$ , obliczone dla przedziałów będących wielokrotnością minimalnego podzbioru cząstkowego (step).*

**Definicja 9** (Adaptacyjne okno przesuwne). *Jako adaptacyjne okno przesuwne należy rozumieć dopasowaną wielkość zbioru treningowego treningowego przy cyklicznej aktualizacji modelu predykcyjnego realizowanej przez zmodyfikowany algorytm MSC-ADWIN bazujący na analizie średnich wartości cząstkowych.*

Przykład działania algorytmu MSC-ADWIN w kolejnych iteracjach przedstawia rys. 3.12. Analizowany szereg czasowy stanowi zbiór sześciu próbek [0,8; 0,8; 0,4; 0,4; 0,4; 0,4]. Badany przebieg zmienia skokowo wartość w chwili  $t=1000$ .


**Algorithm 3:** Zmodyfikowany algorytm MSC-ADWIN

---

**Input** :  $W$  : zbiór danych wejściowych;  
            $step$  : rozmiar minimalnego podzbioru cząstkowego;  
 Set  $i_{max} := 0$ ;  $res_{max} := 0$ ;  $p := \lfloor |W|/step \rfloor$ ;  
**for**  $i \leftarrow 1$  **to**  $p$  **do**  
   –Obliczam średnie wartości cząstkowe–  
    $\widehat{\mu}_{W_0} :=$  average of the range[1 :  $i$ ];  
    $\widehat{\mu}_{W_1} :=$  average of the range[ $i + 1$  :  $p$ ];  
   oblicz  $m_h$  wg. wzoru 3.16  
   **if**  $|\widehat{\mu}_{W_0} - \widehat{\mu}_{W_1}| * m_h > res_{max}$  **then**  
      $i_{max} := i$ ;  
      $res_{max} := |\widehat{\mu}_{W_0} - \widehat{\mu}_{W_1}| * m_h$ ;  
   **end**  
**end**  
**Output:**  $i_{max} * step$

---

W przedstawionym przykładzie algorytm MSC-ADWIN obliczając w każdej iteracji średnie wartości cząstkowe  $\widehat{\mu}_{W_0}$  i  $\widehat{\mu}_{W_1}$  z uwzględnieniem średniej harmoniczej  $m_h$  prawidłowo określił miejsce największej zmiany w przebiegu (maksymalną wartość zaznaczono kolorem żółtym w tabeli). Zakładając, że chwila  $t=3000$  jest czasem najbardziej aktualnym, adaptacyjne okno przesuwne będzie w tym przypadku stanowił zbiór  $W_1 \in [0, 4; 0, 4; 0, 4; 0, 4]$ .



iteracja	$W_0$	$W_1$	$\mu_{w_0}$	$\mu_{w_1}$	$ W_0 $	$ W_1 $	$m_h$	$ \mu_{w_0} - \mu_{w_1}  * m_h$
1	[0,8]	[0,8; 0,4; 0,4; 0,4; 0,4]	0,8	0,48	1	5	0,83	0,2656
2	[0,8; 0,8]	[0,4; 0,4; 0,4; 0,4]	0,8	0,4	2	4	1,33	<b>0,532</b>
3	[0,8; 0,8; 0,4]	[0,4; 0,4; 0,4]	0,66	0,4	3	3	1,5	0,39
4	[0,8; 0,8; 0,4; 0,4]	[0,4; 0,4]	0,6	0,4	4	2	1,33	0,266
5	[0,8; 0,8; 0,4; 0,4; 0,4]	[0,4]	0,56	0,4	5	1	0,83	0,1328

Rysunek 3.12: Ilustracja działania algorytmu MSC-ADWIN w kolejnych iteracjach dla modelowego przykładu zmiany w szeregu czasowym

# Rozdział 4

## Wyniki badań

Niniejszy rozdział przedstawia wyniki eksperymentów, które przeprowadzono z wykorzystaniem opracowanych algorytmów i metod, które zostały przedstawione w rozdziale 3. Wszystkie obliczenia wykonano z wykorzystaniem rzeczywistych historycznych danych pomiarowych dotyczących badanych urządzeń przemysłowych w Elektrowni Jaworzno III oraz Elektrowni Łaziska. Dane historyczne służyły zarówno do uczenia modeli predykcyjnych oraz do ewaluacji wyników, jak opisano w sekcji 3.1.2. Kolejność przedstawianych wyników odpowiada sekwencji badań, dając sukcesywnie odpowiedzi na kolejne zagadnienia badawcze oraz zgłębiając naturę badanego przedmiotu. Całość badań podzielona jest na trzy etapy, w których:

1. Oceniana jest jakość predykcyjna zaproponowanego algorytmu wykrywającego usterki.
2. Implementowane są elementy pozwalające na automatyzację procesu tworzenia modeli oraz dobór parametrów modelu.
3. Zaproponowany jest mechanizm cyklicznej aktualizacji modelu w kontekście zjawiska dryfu koncepcji.

## 4.1 Algorytm wykrywający ustereki wykorzystujący metodę regresji na podstawie zaobserwowanych anomalii

W niniejszej sekcji przedstawione zostały wyniki badań przedstawiających zdolności predykcyjne opracowanego modelu pozwalającego na wczesne wykrywanie usterek w sytuacji ograniczonej liczby zarejestrowanych podobnych zdarzeń w przeszłości oraz zmiennych warunków pracy. Model predykcyjny został zaimplementowany zgodnie z koncepcją przedstawioną w sekcji 3.3.2 oraz algorytmem opisanym w sekcji 3.3.3. Przedstawiony algorytm został opracowany opierając się na literaturze podejmującej tematykę z obszaru predykcyjnego utrzymania ruchu. Zastosowane metody bazują na metodach regresji oraz koncepcji redundancji analitycznej. Uzyskane wyniki wraz z obszernym opisem i odniesieniami do literatury zostały opublikowane na łamach czasopisma *Sensors* (Core A)[204].

### 4.1.1 Koncepcja studium przypadku

Problemem badawczym rozpatrywanym w niniejszej części jest znalezienie modelu pozwalającego na wykrywanie rzadkich usterek o istotnym znaczeniu mogących powodować postój urządzenia. Studium przypadku obejmuje analizę pracy zespoły pomp zasilających w okresie 2013-2017, dla których odnotowano dwa przypadki wystąpienia usterek krytycznych, powodujących wyłączenie urządzenia i w efekcie postój całego bloku energetycznego.

Studium przypadku obejmuje analizę dostępnych informacji w danym okresie obejmujących dane procesowe urządzenia oraz rejestry usterek, w celu znalezienia odpowiedzi na pytania:

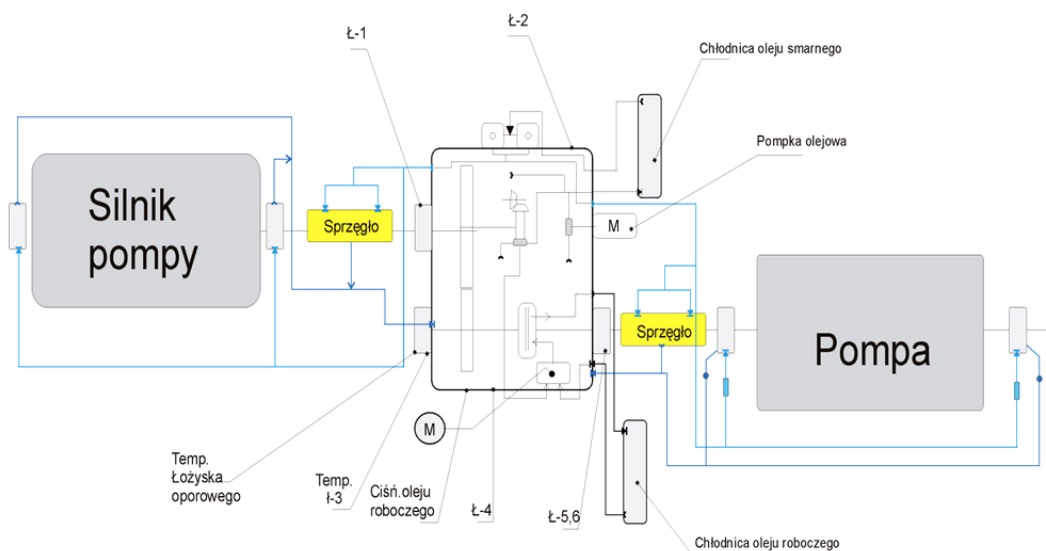
- Czy możliwym było wcześniejsze wykrycie złego stanu urządzenia i uniknięcie awarii krytycznych urządzenia?
- W jakim horyzoncie czasowym możliwe jest ewentualne wykrywanie podobnych usterek?
- Czy możliwa jest identyfikacja miejsca lub rodzaju ustereki?



## 4.1.2 Przedmiot badań

Przedmiotem badań dla studium przypadku był jeden z zespołów pomp zasilających blok energetyczny. Pompy zasilające są przeznaczone do zasilania wodą kotłów parowych bloków energetycznych o dużej mocy. Schemat zespołu pompowego będącego przedmiotem badań przedstawiono na rys. 4.1. Zespół składa się z trzech podstawowych komponentów:


- pompy zasilającej typu HD 150x8
- przekładniowego sprzęgła regulacyjnego (hydrokinetycznego) Voith'a typu R17K
- silnika elektrycznego typu SVJd142th.



Rysunek 4.1: Schemat zespołu pomp zasilających

Kocioł parowy jest zasilany przez trzy zespoły pompowe. Aby zapewnić pracę w warunkach nominalnych, dwie pompy muszą pracować równolegle. Z uwagi na proces technologiczny wymagający ciągłego zaopatrywania kotła w wodę, system pomp należy traktować jako instalację krytyczną, której awaria może skutkować przerwą w produkcji energii. W celu zapewnienia ciągłości działania, jedna

z pomp pełni funkcję rezerwową i jest uruchamiana automatycznie w przypadku awarii którejs z pracujących pomp. W przypadku pracy bezawaryjnej harmonogram pracy powinien zapewniać zrównoważone obciążenie wszystkich pomp. Zespół pompowy jest narażony na awarie typowe dla maszyn wirnikowych i elektrycznych, jak uszkodzenia łożysk, wycieki wody/oleju oraz awarie elektryczne [205, 206]. Aby zapobiec awariom, pompa jest regularnie sprawdzana podczas cyklicznych inspekcji oraz poddawana okresowym przeglądom diagnostycznym (np. pomiar drgań) w szerszym horyzoncie czasowym. Większość prac kontrolnych polega na wizualnej inspekcji urządzenia oraz odczytywaniu i interpretowaniu pomiarów z aparatury pomiarowej widocznej na rys. 4.2.



Rysunek 4.2: Przedmiot badań - 3-stopniowa pompa zasilająca typu Voith'a

### 4.1.3 Audyt i analiza danych

Analizowane dane obejmowały informacje o zarejestrowanych awariach pochodzące z systemów informatycznych oraz dane operacyjne urządzenia pozyskane z repozytorium danych procesowych z sieci automatyki przemysłowej. W bada-

nym okresie odnotowano dwie poważne usterki, które były powodem postoju całego bloku energetycznego, zapisy o tych awariach wraz z podaniem przyczyn odnotowano w systemie ewidencji postoju bloków, ich treść przedstawiono w tabeli 4.1.

Tabela 4.1: Awarie krytyczne odnotowane w badanym okresie

Urządzenie	Agregat pompy zasilającej PZ3 - turbospół TG12	Agregat pompy zasilającej PZ3 - turbospół TG12
Data rejestracji awarii	26.10.2015	07.08.2017
Opis usterki/awarii	Drgania i dymienie z łożyska wewnętrznego silnika napędowego pompy.	Podwyższona temperatura łożyska nr 4 przekładni VOITH.
Przyczyna	Opadnięcie fundamentu przekładni VOITH (brak współosiowości wałów przekładni i silnika, wytopienie stopu łożyskowego łożyska wewnętrznego silnika).	Uszkodzenie stopu łożyskowego panewki łożyska nr 4.
Data przywrócenia urządzenia do eksploatacji	14.01.2016	08.09.2017

Innym źródłem danych o awariach był system typu planowania zasobami przedsiębiorstwa (ERP), w którym w celach logistycznych i rozliczeniowych rejestrowane są wszystkie zlecenia serwisowe, eksploatacyjne i remontowe. Dla badanego obiektu w okresie 2013-2017 zarejestrowano ponad 300 zdarzeń. W analizowanym zbiorze zarejestrowane awarie przeplatają się z mniejszymi usterkami oraz czynnościami eksploatacyjnymi, jak np. wymiana oleju. W celu ograniczenia analizowanego zbioru oraz potrzeby etykietowania danych wyodrębnione zostało około 70 usterek o średnim lub wysokim priorytecie, które skategoryzowano w następujący sposób:

- awaria chłodnicy, 15 incydentów,
- czyszczenie filtra oleju, 15 incydentów,

- usterki łożysk, 2 incydenty (awarie krytyczne),
- wycieki oleju, 19 incydentów,
- wycieki wody, 8 incydentów.

Wykorzystane w badaniach dane procesowe zostały pozyskane w trybie offline z systemu PGIM (ang. *Power Generation Information Manager*) [207]. System PGIM stanowi repozytorium danych dla sygnałów z rozproszonego systemu sterowania (ang. *Distributed control system*, DCS) sterującego urządzeniami w elektrowni. Dane obejmowały m.in. odczyty temperatury z różnych czujników umieszczonych na monitorowanym agregacie pompowym (np. z łożysk), ciśnienia oleju, wartości natężenia prądu elektrycznego oraz nastawy parametrów pracy. Opis wszystkich sygnałów przedstawiono w tabeli 4.2. Zakres danych obejmował okres od stycznia 2013 r. do sierpnia 2017 r. z okresem próbkowania wynoszącym jedną minutę.

Na etapie czyszczenia danych odfiltrowane zostały kolumny z wartościami stałymi lub bez wartości (nie używane pomiary). Liczba analizowanych wierszy ograniczona została to stanu pracy pompy, tzn. przy analizie nie uwzględniano rekordów, dla których wartość zasilania (pomiar 12LAC30CE001) była mniejsza niż 1[A], czyli urządzenie było wyłączone. W ramach analizy deskryptywnej danych procesowych przeanalizowano statystyki dla badanych pomiarów, takie jak wartości minimalne, maksymalne, średnie, odchylenia standardowe itp. Istotną cechą zbioru danych jest występowanie znaczących korelacji pomiędzy poszczególnymi grupami sygnałów. Współczynniki korelacji Pearsona obliczone dla każdej pary kolumn przedstawiono na rys. 4.3. Za wyjątkiem pomiaru ciśnienia oleju (12MGV30CP002) oraz wartości nastaw pompy (12MGV30AP001, 12LAC30AA001), każda wartość była silnie skorelowana z co najmniej jednym innym pomiarem. Największe zależności zaobserwowano dla grup pomiarów:

- prąd zasilania, przepływ wody, temperatury podzespołów silnika,
- temperatura łożysk nr 1-6 oraz temperatur oleju smarowego przed chłodnicą,
- ciśnienie wody zasilającej i temperatura dyszy tłocznej.


Tabela 4.2: Opis sygnałów procesowych pompy zasilającej

Kod pomiaru	Jedn.	Min	Max	Śr.	Opis
12MGA30CT001 XQ50	°C	0	150	45,0	temp. uzwojenia stojana silnika
12MGA30CT002 XQ50	°C	0	150	45,2	temperatura żelaza silnika
12MGA30CT003 XQ50	°C	0	150	34,8	temp. pow. przed silnikiem
12MGA30CT004 XQ50	°C	0	150	47,9	temp. pow. za silnikiem
12LAC30CE001 XQ50	A	0	400	217	prąd zasilający
12MGD30CT001 XQ50	°C	0	100	54,9	temp. łożyska 1
12MGD30CT002 XQ50	°C	0	100	57,9	temp. łożyska 2
12MGD30CT003 XQ50	°C	0	100	58,4	temp. łożyska 3
12MGD30CT004 XQ50	°C	0	100	60,7	temp. łożyska 4
12MGD30CT005 XQ50	°C	0	100	69,3	temp. łożyska 5-6
12MGD30CT006 XQ50	°C	0	100	56,2	temp. łożyska oporowego
12LAC30CG101 XQ50	%	0	100	53,4	ustawienie sprzęgła
12MGV30CT001 XQ50	°C	0	100	81,1	temp. ol. smarnego przed chłodnicą
12MGV30CT002 XQ50	°C	0	100	84,3	temp. ol. roboczego za chłodnicą
12MGV30CT003 XQ50	°C	0	150	111	temp. ol. roboczego przed chłodnicą
12MGV30CP002 XQ50	MPa	0	1	0,56	ciśnienie ol. smarnego
12LAC30CF901 XQ50	t/h	0	450	246	przepływ wody
12LAC30CP002 XQ50	MPa	0	25	14,0	ciśnienie wody na wyjściu
12LAC30CP003 XQ50	MPa	0	4	0,66	ciśnienie wody na wejściu
12LAC30CT001 XQ50	°C	0	400	148	temp. dyszy wylotowej
12MGV30AP001 XB01	T/F	0	1	-	ustawienie zaworu oleju
12LAC30AA001 XB01	T/F	0	1	-	ustawienie zaworu minimalnego przepływu

#### 4.1.4 Opis eksperymentu

Ze względu na niepewność danych dotyczących awarii (prawidłowy priorytet, daty rozpoczęcia i zakończenia) i ograniczony dostęp do wiedzy eksperckiej docelowo zaprojektowany został system wykrywania anomalii bez użycia technik klasyfikacji, bazując na technikach związanych z regresją. Zastosowaną metodę przedstawiono w sekcji 3.3.2. Metoda polega na utworzeniu analitycznego modelu wykorzystującego metodę regresji, na podstawie wzorcowego okresu czasu, gdzie model był uczony rzeczywistymi wartościami estymowanego sygnału. W związku z tym z procesu uczenia wyłączono informacje o usterkach i awariach, które były wykorzystane dopiero w procesie ewaluacji.

Zbiorem danych treningowych dla utworzonego modelu regresji był zbiór danych historycznych z okna czasowego o ustalonej długości poprzedzającego ana-



Rysunek 4.3: Korelacje pomiędzy sygnałami pomiarowymi pompy

lizowany okres. Długość okna była dostosowywana w zależności od rodzaju eksperymentu. Zbiór wyników zawierał odpowiedź modelu dla bieżącego znacznika czasu lub w bardziej rozbudowanej formie, było to okno czasowe zawierające ostatecznie wyniki, co umożliwiało analizę danych statystycznych, jak trendy i wartości średnich. Wielkość zastosowanego zbioru treningowego miała wpływ na charakterystykę wyników. Im większy był ten zbiór, tym mniejszy był błąd estymacji. Istotnym problemem wynikłym podczas eksperymentów było określenie wielkości zbioru uczącego, zbiór treningowy powinien być wystarczająco duży, aby można było wykryć zdarzenia rozłożone w czasie, na przykład stopniową degradację łożyska lub rosnący wyciek. Z drugiej strony, model powinien być w stanie uzyskać wiarygodne wyniki w sytuacjach, kiedy wymagane jest odświeżenie modelu,


np. po remontach kapitalnych, gdy zbiór treningowy nie jest zbyt obszerny, a maszyna może zmienić swoją charakterystykę pracy.

#### 4.1.5 Wyniki badań eksperymentalnych

W niniejszej sekcji przedstawiono wyniki działania algorytmu wykrywającego usterki na podstawie zaobserwowanych anomalii. Przedstawione wyniki obejmują analizę graficzną wyników predykcji na tle zarejestrowanych zdarzeń historycznych, badanie jakości modelu w zależności od wielkości zbioru uczącego, wyniki predykcji usterek na tle metod wykorzystujących klasyfikację. Wyniki eksperymentów pozwalają na określenie przydatności metody przy zastosowaniach w warunkach produkcyjnych oraz określenie zakresu usterek, które mogą być wykrywane przez zaproponowany algorytm.

##### Graficzna analiza wyników

Analizując różnice między wartością rzeczywistą, a wartością szacunkową poszczególnych sygnałów można zauważyć znaczące odchylenia w okresach poprzedzających czas kiedy zarejestrowano awarie urządzenia. W niniejszym punkcie przeanalizowane zostaną wyniki uzyskane z wykorzystaniem opracowanej grupy modeli regresji dla sygnałów pomiarowych (wynikami są odchylenia od wartości oczekiwanej) na tle znaczących awarii zarejestrowanych w danym okresie (wszystkie wykryte awarie są szczegółowo opisane w dalszej części pracy, w tabeli 4.5 i widoczne również na rys. 4.9). W pierwszym przykładzie (awaria F2) pokazanym na rys. 4.4 zaobserwowano stopniowy spadek wydajności pompy spowodowany nieuszczelnnością zaworu minimalnego przepływu. Zawór minimalnego przepływu służy do ochrony pompy przed zatarciem podczas rozruchu i pracy z niską prędkością. Usterka zaworu powodowała nieuszczelnność i pracę pompy z mniejszą wydajnością. W szczytowym punkcie strata wydajności wynosiła nawet ponad 30% (ponad 100 ton na minutę). Awaria została zarejestrowana w dniu 16 marca 2015 roku, po czym nastąpiły czynności serwisowe. Stosując zaproponowany próg alarmowy (opisany w sekcji 3.3.3) jako trzy odchylenia standardowe ( $3 \times RMSE$ ), można byłoby wykryć to zdarzenie trzy miesiące wcześniej.



Rysunek 4.4: Różnica między rzeczywistą, a szacunkową wartością pomiaru dla przepływu wody.


Drugi przykład (awaria F3) dotyczy nagłego wzrostu odchylenia temperatury łożyska. Anomalia ta wystąpiła po okresie przestoju urządzenia. Przyczyną awarii był brak współosiowości wałów przekładni i silnika oraz stopienie się stopu łożyska. Widocznymi skutkami awarii były drgania i dym wydobywający się z łożyska. Różnice w temperaturach łożyska w czasie przed wystąpieniem tej awarii pokazano na rys. 4.5. Kolejne awarie oznaczone symbolami F4 i F5 na rys. 4.9 są najprawdopodobniej wynikiem degradacji i zanieczyszczenia spowodowanego usterką F3 (słaby przepływ wody chłodzącej przez chłodnicę oraz wyciek oleju z wału zewnętrznego łożyska silnika).

Trzeci przykład (F6) i druga analizowana awaria krytyczna widoczna na rys. 4.6 przedstawia uszkodzenie stopu łożyska, które spowodowało wzrost temperatury łożyska. Podobnie jak w poprzednim przykładzie, znaczącą zmianę charakterystyki pracy układu zaobserwowano po dłuższym przestoju. W tym przypadku tendencję wzrostową krzywej odchylenia można zaobserwować na kilka dni przed awarią.


### Wpływ wielkości zbioru okna uczonego na jakość predykcji awarii

Aby zapewnić zadowalającą jakość modelu i dokonać jego oceny, przeprowadzono szereg eksperymentów mających na celu dobór odpowiednich parametrów, takich jak stopień wielomianu w modelu regresji, czy długość okna czasowego okre-



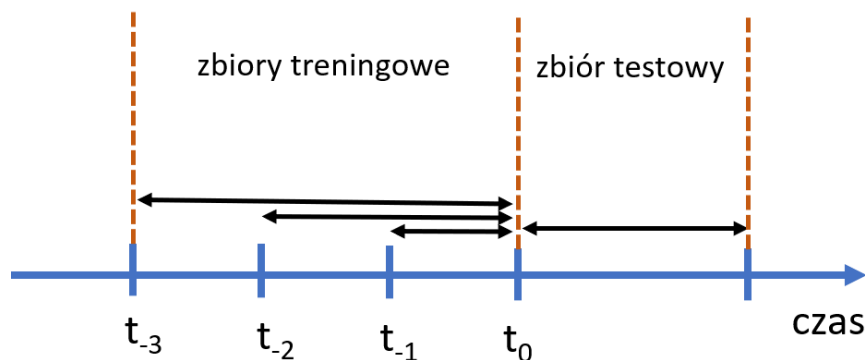


Rysunek 4.5: Różnica między rzeczywistą a szacunkową wartością łożyska nr 1.



Rysunek 4.6: Różnica między rzeczywistą a szacunkową wartością łożyska nr 4.

śląjącego wielkość zbioru uczącego. Eksperymenty przeprowadzono na tym samym zbiorze testowym, przy czym parametryzowano długość okna czasowego w zbiorze treningowym, jak przedstawiono na rys. 4.7. Natomiast miarami dokładności modelu są współczynnik determinacji ( $R^2$ ) oraz średnia procentowa wartość średniego błędu bezwzględnego ( $\%MAE$ ).




Rysunek 4.7: Zbiory treningowe i testowe w eksperymencie

Długość przedziału czasowego ma bezpośredni wpływ na liczbę kroków obliczeniowych przy tworzeniu modelu. Wyniki pokazane na rys. 4.8 przedstawiają procentową wartość średniego błędu bezwzględnego  $\%MAE$  w zależności od wielkości zbioru danych treningowych wyrażonej w dniach (jeden dzień to 1440 odczytów). Analizując wykres można wywnioskować, że im większa liczba próbek, tym błąd jest mniejszy, przy czym zadowalającą jakość uzyskuje się już przy tygodniowym zbiorze uczącym. Po 20 dniach poziom błędów  $\%MAE$  i  $R^2$  stabilizuje się. Na potrzeby dalszych obliczeń ustalono 30-dniowe okno czasowe, które jest kompromisem pomiędzy stabilnymi wartościami  $\%MAE$  i  $R^2$ , a krótkim czasem uczenia. Ustalenie minimalnego zbioru uczącego ma znaczący wpływ na możliwość szybkiego dopasowania modelu w krótkim czasie po poważnych naprawach lub dłuższych przestojach.

### Efektywność różnych metod regresji przy odwzorowywaniu sygnału

W badaniach eksperymentalnych zweryfikowano również jakość predykcji dla różnych metod regresji zastosowanych do budowy modeli sygnałów. Badania



Rysunek 4.8: Średni błąd bezwzględny  $\%MAE$  i współczynnik determinacji  $R^2$  w zależności od długości okna czasowego.

przeprowadzono z wykorzystaniem 30-dniowego zbioru treningowego oraz 3-miesięcznego zbioru testowego. Zbiory treningowy i testowy były takie same dla wszystkich badanych wariantów.

Tabela 4.3 przedstawia wyniki uzyskane w zależności od zastosowanej metody regresji. Wyniki uzyskane przez poszczególne algorytmy są porównywalne, najlepsze jednak dopasowanie uzyskano dla regresji liniowej. W przypadku zwiększania stopnia wielomianu regresji wielomianowej zaobserwowano spadek dokładności modelu (tj. wyższą wartość błędy  $\%MAE$ ).

Szczegółowe wyniki uzyskane dla każdego z modelowanych sygnałów dla algorytmu regresji liniowej przedstawiono w tabeli 4.4.

### Normalizacja i wizualizacja wyników

Działanie algorytmu nie skupia się jedynie na wykryciu anomalii w przebiegach sygnałów procesowych, ale wskazuje też konkretny pomiar, dla którego występuje


Tabela 4.3: Dokładność wybranych metod regresji

Metoda	MAE	$R^2$
drzewo regresji	1,17%	0,8683
drzewa regresji wspomagane gradientem	1,95%	0,8725
regresja liniowa	1,04%	0,8818
regresja wielomianowa 2st	1,12%	0,7941
regresja wielomianowa 3st	1,09%	0,8383
regresja wielomianowa 4st	1,24%	0,7069
regresja wielomianowa 5st	1,22%	0,4599

Tabela 4.4: Współczynniki błędów uzyskane przez modele predykcyjne dla poszczególnych sygnałów przy zastosowaniu regresji liniowej

Model	MAE	$R^2$
przepływ wody	1,53%	0,9669
ciśn. oleju smarnego	1,10%	0,2429
temp. żelaza silnika	0,08%	0,9975
temp. łożyska oporowego	2,49%	0,8401
temp. łożyska 1	0,89%	0,9788
temp. łożyska 2	0,48%	0,9914
temp. łożyska 3	1,03%	0,9707
temp. łożyska 4	1,32%	0,9204
temp. łożyska 5-6	1,09%	0,961
temp. oleju smarnego przed chłodnicą	1,68%	0,817
temp. oleju smarnego za chłodnicą	0,88%	0,9171
temp. powietrza przed silnikiem	0,82%	0,8662
temp. uzwojenia stojana silnika	0,15%	0,9936
średnia	1,04%	0,8818

największe odchylenie, co jest symptomem potencjalnie zbliżającej się usterki urządzenia (lub uszkodzenia aparatury pomiarowej). Proponowana metoda normalizacji wyników poprzez wprowadzenie współczynnika  $NRE$  pozwala na wstępną interpretację i priorytetyzację wyników dla odbiorcy końcowego. Wyniki działania algorytmu przy zastosowaniu 30-dniowego okna treningowego dla całego pozostałego okresu przedstawiono na rys. 4.9. Symbolami F1-F6 oznaczono wykryte (przewidywane) awarie urządzeń, które rzeczywiście wystąpiły w okresie monitorowania. Dwie poziome linie w kolorze pomarańczowym i czerwonym reprezentują odpowiednio pierwszy i drugi poziom alarmowy, zgodnie z opisem we wzorach (3.12)



Rysunek 4.9: Znormalizowany błąd względny ( $NRE$ ) z identyfikacją źródła awarii

i (3.13). Wszystkie wykryte awarie są opisane bardziej szczegółowo w tabeli 4.5. Kolor linii na wykresie wskazuje sygnał, dla którego występuje największe odchylenie względne ( $NRE_{max}$ ). Współczynnik błędu  $NRE$  jest obliczany zgodnie z równaniem (3.10).

Zastosowany algorytm jest bardzo wrażliwy na zdarzenia związane z awariami czujników. Uszkodzenie jednego z czujników ma istotny wpływ na wyniki uzyskane z modeli regresji dla sygnałów zebranych z całego urządzenia. Zakłócony sygnał ma negatywny wpływ na jakość wyników zarówno ze względu na zakłócenie procesu treningowego, jak i prezentacji wyników. W przypadku wizualizacji zły pomiar powoduje, że prezentacja i interpretacja wyników może być niewłaściwa. Natomiast podczas procesu uczenia błąd pomiaru powoduje obliczanie niższych wag współczynników, co ma znaczący wpływ na jakość modelu. W celu poprawy jakości modelu, w procesie czyszczenia danych należy rozważyć wykluczenie sygnałów, w przypadku których wystąpiły błędne pomiary z uszkodzonego czujnika poprzez zastosowanie etapu wstępnej estymacji na zbiorze treningowym.

Usterki krytyczne (F3 i F6) są znacząco akcentowane na tle okresów bezawaryjnej pracy oraz mniej znaczących usterek. Wysoki poziom odchylenia odnoto-

Tabela 4.5: Awarie i czas ich zarejestrowania.

Id	Opis	Czas rejestr.	Pocz. usterki	Źródło
F1	Nieprawidłowy pomiar temperatury oleju smarowego przed chłodnicą	25.12.2013	27.11.2013	temp. oleju smar.
F2	Nieszczelność zaworu minimalnego przepływu	27.02.2015	06.01.2015	przepływ wody
F3	Wibracje i dymienie z wewnętrznego łożyska silnika pompy	14.01.2016	26.10.2015	temp. łoż. 1
F4	Wyciek oleju z wału z zewnętrznego łożyska silnika	03.02.2016	18.01.2016	temp. oleju smar.
F5	Słaby przepływ wody chłodzącej przez chłodnicę	08.04.2016	30.03.2016	temp. łoż. 1
F6	Zwiększona temperatura łożyska nr 4 przekładni VOITH	07.08.2017	22.05.2017	temp. łoż. 4

wywany jest również w przypadkach uszkodzenia opomiarowania lub odłączenia czujnika (F1).

### Porównanie wyników z innymi metodami

W celu porównania uzyskanych wyników z innymi algorytmami opisanymi w literaturze pokrewnej, utworzono modele oparte na drzewach decyzyjnych i klasyfikatorach opartych na sztucznych sieciach neuronowych typu MLP (ang. multi-layer perceptron). W obu przypadkach eksperymenty przeprowadzono, dostarczając surowe dane, dodając etap ekstrakcji cech oraz opcjonalnie krok redukcji wymiarowości za pomocą algorytmu PCA. Ekstrakcja cech polegała na obliczeniu dodatkowych zmiennych dla każdego sygnału wejściowego przy użyciu takich funkcji, jak kurtoza, skośność, odchylenie standardowe, minimum, maksimum, wariancja i średnia. Do zbioru danych przypisano etykiety informujące o wystąpieniu awarii dla każdej próbki. Eksperymenty przeprowadzono z wykorzystaniem techniki 10-krotnej walidacji krzyżowej. Zbiór danych został podzielony na 10 równych części, przy czym obliczenia były wykonywane w pętli, gdzie jedna część stanowiła zbiór testowy, a pozostałe 9 części - zbiór treningowy.

Wyniki eksperymentu zawierające takie metryki ewaluacyjne, jak dokładność,

pole powierzchni pod krzywą (AUC), czułość i specyficzność, przedstawiono w tabeli 4.6.

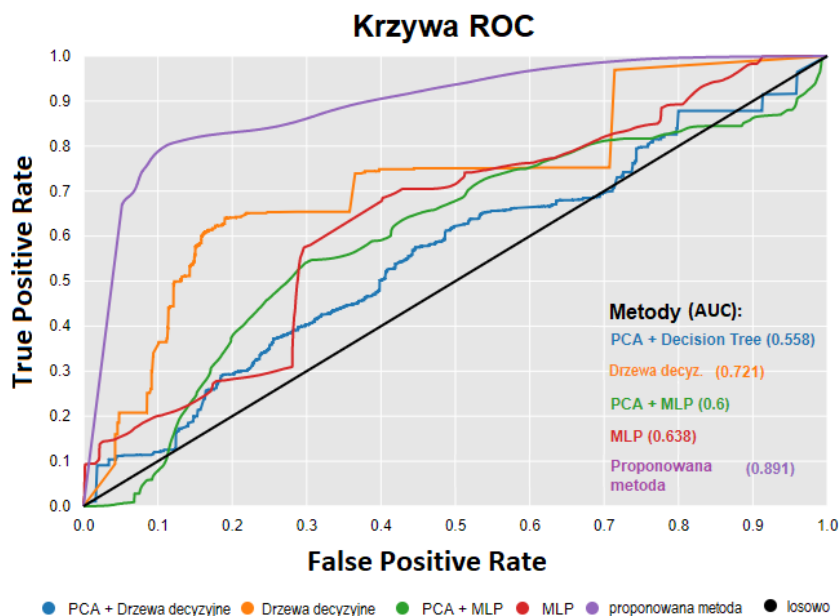
Tabela 4.6: Jakość klasyfikacji algorytmów

	Dokładność	AUC	Czułość	Swoistość
Proponowana metoda	0,86	0,89	0,67	0,95
Drzewa decyzyjne	0,76	0,72	0,58	0,85
PCA + Drzewa decyz.	0,59	0,56	0,43	0,67
MLP	0,67	0,64	0,2	0,90
PCA + MLP	0,65	0,60	0,37	0,79

Krzywe ROC (ang. *Receiver Operating Characteristics*) przedstawione na rys. 4.10 wizualizują wydajność proponowanego modelu w porównaniu z innymi metodami. Jakość modelu jest określana na podstawie wartości pola pod powierzchnią krzywej - AUC (ang. *Area Under Curve*). AUC przyjmuje wartości z przedziału od 0 do 1, gdzie 1 oznacza wynik możliwie najlepszy.

## Wnioski

Zaobserwowane wyniki potwierdziły przydatność zastosowanego algorytmu do zadania wykrywania usterek. Znacząca korelacja pomiędzy sygnałami wejściowymi umożliwiła modelom wykorzystującym regresję wychwycenie nietypowych zdarzeń. Metoda ta była jednak również bardzo wrażliwa na wszelkie zmiany zachodzące w badanym systemie, zwłaszcza w sytuacjach, gdy jeden z czujników uległ awarii. Z drugiej strony zaletą algorytmu była możliwość przewidywania poważnych awarii na długo przed ich rzeczywistym wystąpieniem oraz identyfikacja sygnału, który wskazywał na potencjalne źródło zdarzenia awaryjnego. Umożliwiło to wykrycie źródeł nadchodzących awarii w symulowanym środowisku z dużym wyprzedzeniem. Jedną z możliwości optymalizacji modelu mogłoby być dodanie



Rysunek 4.10: Krzywe ROC dla proponowanej metody oraz innych metod klasyfikacji.

kroku do przetwarzania wstępnego dla określenia stanu urządzenia. W eksperymencie do określenia, czy urządzenie jest w trybie pracy, czy jest wyłączone, wykorzystano techniki oparte na regułach. W celu ograniczenia liczby wyników fałszywie dodatnich można rozważyć wstępną kategoryzację stanu dla każdego sygnału, w tym przestoju, rozruchu, pracy i uszkodzenia. W porównaniu z innymi metodami przedstawionymi w literaturze pokrewnej zaletą prezentowanej metody była możliwość jej zastosowania w przypadku niewystarczającej liczby danych opisujących przewidywane zdarzenia tylko na podstawie danych procesowych. Ze względu na swoją prostotę algorytm działał bardzo szybko i nie wymagał dużych nakładów sprzętowych. Na podstawie uzyskanych wyników możliwe jest udoskonalenie algorytmu poprzez dodanie poziomu klasyfikacji, w którym obliczone wartości odchyień są jednym z wejść klasyfikatora. Algorytm można również wykorzystać na etapie czyszczenia i przygotowania danych w celu usunięcia nieprawidłowych danych ze zbioru (tj. pomiarów z uszkodzonych czujników oraz z okresów, w których maszyna pracowała w stanie awarii).

Przeprowadzony eksperyment potwierdził możliwość wykrywania z wyprzedze-



niem stanów awaryjnych obejmujących przede wszystkim usterki krytyczne i awarie czujników. Zastosowanie zaawansowanych metod statystycznych w połączeniu ze zdobytą wiedzą ekspercką pozwoliło na:

- Wykorzystanie danych z systemów technologicznych do celów innych niż były pierwotnie przeznaczone. Dane wykorzystywane do nadzoru procesu produkcji wykorzystano do diagnostyki i predykcji stanów awaryjnych.
- Wykrywanie zdarzeń (usterek) bez zastosowania dodatkowego opomiarowania. W przypadku usterek krytycznych spowodowanych nadmiernymi wibracjami, możliwe było ich wykrycie jedynie za pomocą analizy pomiarów temperatury.
- Normalizację wartości odchyleń pozwalającą na identyfikację źródła zbliżającej się usterki. Wskazanie pomiaru, dla którego występuje największa relatywna anomalia pozwala na wstępną diagnozę możliwej usterki (np. uszkodzenie czujnika, wyciek, podwyższona temperatura) i wskazanie prawdopodobnego miejsca wystąpienia (np. łożysko, silnik).

## **4.2 Strojenie modelu oraz przenaszalność rozwiązania**

Jak pokazały wyniki badań przedstawione w poprzednim rozdziale, opracowane podejście bazujące na wykrywaniu anomalii dzięki grupie modeli regresji potrafi skutecznie wykrywać awarie dla zespołu pomp zasilających typu Voith. W trakcie badań pojawiło się jednak pytanie - czy zastosowany algorytm będzie równie skuteczny dla predykcji usterek innego urządzenia i w jaki sposób usprawnić proces wdrażania rozwiązania w innym środowisku? Powyższe zagadnienia stały się przedmiotem badań w niniejszym rozdziale.

### **4.2.1 Koncepcja eksperymentu**

Celem badawczym realizowanym na tym etapie jest sprawdzenie uniwersalności wypracowanego algorytmu pod kątem przeniesienia i uruchomienia go na innym

urządzeniu, przy czym celami drugorzędnymi było wprowadzenie dodatkowych kroków parametryzujących model podczas procesu uczenia oraz automatyzacja procesu tworzenia modelu. Dodatkowymi elementami, o których mowa są wykorzystanie systemu kodowania KKS w procesie zbierania danych, zastosowanie zautomatyzowanego przepływu danych oraz metod optymalizacji parametrycznej.

Aby udowodnić możliwość przenoszenia prezentowanego rozwiązania na inne urządzenia, wykorzystujemy algorytm zastosowany wcześniej dla predykcji usterek pomp zasilających [13] do analizy danych pochodzących ze sprężarek natleniających. Eksperymenty przeprowadzono na rzeczywistych danych z czujników monitorujących wybrane sprężarki natleniające, które są podzespołami instalacji odsiarczania spalin w elektrowni.

#### 4.2.2 Przedmiot badań

Sprężarki natleniające są urządzeniami wykorzystywanymi w procesie produkcji gipsu z dwutlenku siarki, będącego ubocznym efektem spalania węgla. Z punktu widzenia budowy, architektury instalacji i zasady działania, urządzenia te są bardzo zbliżone do pomp zasilających. Instalacja odsiarczania spalin wykorzystuje 3 absorbery, w ramach których pracuje 7 sprężarek (po 2 sprężarki w ramach dwóch absorberów (o kodach KKS: 1HT\*, 2HT\*) jednego dostawcy i 3 sprężarki w ramach absorbera innego dostawcy (o kodach KKS: 3HT\*).

Sprężarki pracują naprzemiennie (przez około 30%-50% czasu, jeśli instalacja nie jest odstawiona) w ramach absorberów, co zapewnia ciągłość procesu w razie usterki jednego z nich. Absorbery poddawane są częstym przeglądom technicznym i remontom, przez co liczba odnotowanych zdarzeń awaryjnych jest niewielka. Średnio jest to kilka zdarzeń na urządzenie w całym badanym okresie.

#### 4.2.3 Audyt i analiza danych

Dane wykorzystane w eksperymencie pochodziły z systemu monitoringu dwóch sprężarek natleniających z instalacji odsiarczania spalin. Każde z tych urządzeń jest opisane dziesięcioma parametrami obejmującymi: moc, temperaturę łożysk, drgania, ciśnienie oleju. Listę danych procesowych wraz z opisem przedstawiono


w tabeli 4.7. Parametry te są pomiarami pochodzącymi z czujników umieszczonych na urządzeniu i są przechowywane w repozytorium danych procesowych. Analizowane dane procesowe obejmują okres od stycznia 2017 do maja 2019, w którym sprężarki pracowały przez około jedną trzecią tego czasu. Dane pozyskano w postaci wsadowej dla dwóch sprężarek oznaczonych jako 1HTG01 i 2HTG01. Dla pozostałych sprężarek nie odnotowano znaczących awarii lub nie pracowały one (remont, rezerwa) w badanym okresie.

Tabela 4.7: Opis analizowanych sygnałów procesowych sprężarki

Kod pomiaru	Jedn.	Min	Max	Śr.	Std. dev.	Opis
1HTG01CE001	A	0	38,1	32,1	0,56	Zasilanie wentylatora 1
1HTG01CE002	kW	0	347	320	4,81	Moc wentylatora 1
1HTG01CG025	mm	-0,04	0,013	-0.035	0,02	Przesunięcie osiowe went.
1HTG01CP025	bar	0,65	1,39	1,16	0,035	Ciśn. za filtrem oleju
1HTG01CS025	um	0	45,3	23,3	7,47	Poziom drgań 1
1HTG01CS026	um	0	44,2	26,69	7,74	Poziom drgań 2
1HTG01CT001	°C	0	41,2	25,1	5,19	Temp. strony ssącej
1HTG01CT020	°C	0	79,4	60,8	5,09	Temp. zbiornika oleju
1HTG01CT025	°C	0	79,4	60,1	4,31	Temperatura łożyska 1
1HTG01CT026	°C	0	83,1	66,7	4,34	Temperatura łożyska 2

Analizując współczynnik korelacji Pearsona przedstawiony na rys. 4.11 dla poszczególnych sygnałów, można wyróżnić grupy silnie skorelowanych sygnałów. Istnienie silnych korelacji (tzn. o wartościach bliskich 1 lub -1) oznacza, że pomiędzy różnymi zmiennymi istnieją znaczące zależności i uzasadnia to zastosowanie modelu regresji do przewidywania anomalii podobnie, jak w przypadku pomp zasilających.

Odnutowane w analizowanym okresie zdarzenia obejmują zarówno mniejsze usterki, awarie, jak i remonty. Liczba wszystkich zdarzeń wynosiła około 45, liczby w podziale na kategorie przedstawiono w tabeli 4.8.



Rysunek 4.11: Macierz korelacji Pearsona pomiędzy sygnałami zebranymi dla sprężarki natleniającej

Tabela 4.8: Zdarzenia serwisowe odnotowane dla sprężarek natleniających w analizowanym okresie

Urządzenie	2017	2018
1HTG01	9 zdarzeń, remont	brak zdarzeń
1HTG02	5 zdarzeń	brak zdarzeń
2HTG01	brak zdarzeń	6 zdarzeń, remont
2HTG02	remont	remont
3HTG01	10 zdarzeń	1 zdarzenie
3HTG02	2 zdarzenia	2 zdarzenia
3HTG03	9 zdarzeń	1 zdarzenie

#### 4.2.4 Opis eksperymentu

W ramach badań eksperymentalnych przeprowadzono szereg analiz pozwalających określić możliwości predykcyjne opracowanego algorytmu wykrywania usterek dla innego urządzenia. Przedmiotem badań był także wpływ na jakość predykcji dodatkowych kroków w procesie uczenia mających na celu dobór odpowiednich parametrów modelu oraz dobór cech wejściowych.

### **Parametryzacja modelu wykrywającego usterki i automatyzacja procesu tworzenia modelu**

W przypadku predykcji usterek dla agregatów sprężarek zasilających wykorzystano model wykrywający anomalie oparty na metodzie regresji opisany w sekcji 3.3.3. Nowymi elementami wprowadzonymi w tym eksperymencie było zautomatyzowanie procesu przygotowania i etykietowania danych na wstępnym etapie tworzenia modelu oraz parametryzacja modelu, co opisano w sekcji 3.3.4.

Krok parametryzacji w procesie uczenia modelu służy do dostosowania parametrów modelu na każdej iteracji w celu uzyskania najlepszych wyników (minimalizacji błędów RMSE, MAE), a jednocześnie uniknięcia sytuacji, w której model jest przetrenowany. Parametry, które dobieramy, to stopień wielomianu i zestaw cech wejściowych. Parametryzacja jest wykonywana w procesie walidacji krzyżowej, w której podzielono zbiór danych wejściowych na pięć równych części, a następnie wykonano obliczenia, gdzie w kolejnych iteracjach zmienia się zbiór testowy (jeden z pięciu), natomiast pozostała część zbioru służy to wytrenowania modelu.

### **Symulacja działania modelu predykcyjnego**

W odróżnieniu od poprzedniego eksperymentu badającego zdolność predykcyjną modelu dla pomp zasilających, w tym przypadku model był okresowo odświeżany w celu odzwierciedlenia sytuacji, w której co jakiś czas model należy uaktualniać. W celu symulacji okresowego uczenia modelu zastosowano metodę kroczącego okna w celu określenia zbioru uczącego i testowego dla pojedynczej iteracji. Schemat działania kroczącego okna jest analogiczny do metody adaptacji "na ślepo" przedstawionej na rys. 3.10. Zakładając długość zbioru uczącego na 2 tygodnie i długość zbioru testowego na 4 tygodnie, dla całego zbioru danych z lat 2013-2017 wykonano symulację okresowej aktualizacji modeli oraz zebrania odpowiedzi modelu z całego badanego zakresu danych.

#### **4.2.5 Wyniki**

Głównym celem eksperymentów była ocena wpływu opracowanych usprawnień na etapie tworzenia modelu oraz porównanie wyników predykcji przy zasto-

sowaniu algorytmu dla innych urządzeń. W przedmiotowym przypadku były to sprężarki natleniające. Wyniki przedstawiają wpływ modyfikacji parametrów na jakość predykcji modelu. Parametryzowanymi wielkościami były: stopień wielomianu modelu regresji, zbiór cech wejściowych oraz parametry zbioru uczącego. W kontekście oceny skuteczności algorytmu przy zastosowaniu dla innego urządzenia porównano otrzymane wyniki z tymi uzyskanymi dla zespołu pomp zasilających. Wyniki wraz z szczegółowym opisem eksperymentu oraz odniesieniami do literatury opublikowano w materiałach międzynarodowej konferencji *International Conference on Computational Science (ICCS, Core A)* [208].

### Selekcja cech i strojenie modelu

**Dopasowanie wielomianowe.** Wyniki uzyskane podczas parametryzacji stopnia wielomianu na 3-miesięcznym zbiorze testowym, przedstawiono w tabeli 4.9. W przypadku większości zmiennych najlepsze wyniki predykcji uzyskano przy niskim stopniu wielomianu. Im wyższy jest stopień wielomianu, tym model jest bardziej wrażliwy na zmiany w zbiorze danych wejściowych. W przypadku wyższych stopni wielomianu model predykcyjny ujawnia więcej nietypowych sytuacji, jednak działa bardzo niestabilnie i jest podatny na zakłócenia.

Tabela 4.9: Miary błędów ( $MSE$ ) w zależności od parametru stopnia wielomianu. Najlepsze wyniki oznaczono kolorem żółtym.

kod sygnału	stopień wielomianu				
	1	2	3	4	5
1HTG01CP025	0,0001	0,0002	0,0002	0,0002	0,0011
1HTG01CS025	2,7962	1,2322	1,8621	29,408	264,76
1HTG01CS026	2,6363	2,1789	2,9565	16,536	34,689
1HTG01CG025	0,00001	0,00001	0,00002	0,0001	0,0002
1HTG01CT025	0,0087	0,0111	0,0196	0,0286	0,1813
1HTG01CT026	0,0067	0,008	0,0173	0,0106	0,0281
1HTG01CT001	12,433	12,643	14,953	19,346	30,349
1HTG01CT020	0,0818	0,0745	0,0791	0,1373	1,1435
1HTG01CE001	0,1006	0,1084	0,1286	0,1659	3,1217
1HTG01CE002	8,0852	8,4233	8,0673	30,904	154,71


**Wybór cech.** W kolejnym kroku strojenia wybieramy optymalny zbiór cech wejściowych, aby zminimalizować błąd predykcji, a tym samym zmaksymalizować efektywność procesu predykcyjnego. Dzięki odpowiedniemu doborowi parametrów można zwiększyć dokładność modelu o około 20% (tzn. zmniejszyć błąd średnio-kwadratowy MSE średnio o 20%), co pokazano w tabeli 4.10. Do optymalizacji parametrycznej wykorzystano dwa algorytmy - eliminację wsteczną (ang. *Backward feature elimination*) i algorytm genetyczny. Zastosowanie obydwu metod optymalizacji dla przedstawianego urządzenia dało takie same wyniki jeśli chodzi o określenie optymalnego zbioru cech oraz poprawę dokładności predykcji. Czas obliczeń w przypadku zastosowania metody eliminacji wstecznej (29 785 kombinacji) w porównaniu z algorytmem genetycznym (27 535 kombinacji) był również podobny.

Tabela 4.10: Wyniki w postaci błędu średnio-kwadratowego ( $MSE$ ) uzyskane w efekcie wprowadzenia kroku optymalizacji selekcji cech.

kod sygnału	wszystkie cechy		eliminacja wsteczna		algorytm genetyczny		poprawa %
	liczba cech	MSE	liczba cech	MSE	liczba cech	MSE	
1HTG01CP025	9	0,0001	2	0,0001	2	0,0001	9,76%
1HTG01CS025	9	1,2322	7	1,0971	7	1,0971	12,3%
1HTG01CS026	9	2,1789	5	1,7033	5	1,7033	27,92%
1HTG01CG025	9	0,00001	3	0,00001	3	0,00001	57,77%
1HTG01CT025	9	0,0087	7	0,0073	7	0,0073	19,15%
1HTG01CT026	9	0,0067	6	0,0053	6	0,0053	26,18%
1HTG01CT001	9	12,433	4	10,352	4	10,352	20,09%
1HTG01CT020	9	0,0745	3	0,0499	3	0,0499	49%
1HTG01CE001	9	0,1006	7	0,099	7	0,099	1,58%
1HTG01CE002	9	8,067	3	4,8747	3	4,8747	65,49%

### Funkcja oceny i rozkład błędów

Podczas wykrywania anomalii jednym z czynników jakościowych oceniających działanie zbudowanego modelu predykcyjnego jest uzyskanie wysokiego współczynnika błędów dla okresu awarii (oraz czasu poprzedzającego awarię) w porównaniu z okresem normalnej pracy. W celu wizualizacji działania modelu



Rysunek 4.12: Rozkład odchyłeń dla stanu awaryjnego i prawidłowej pracy.

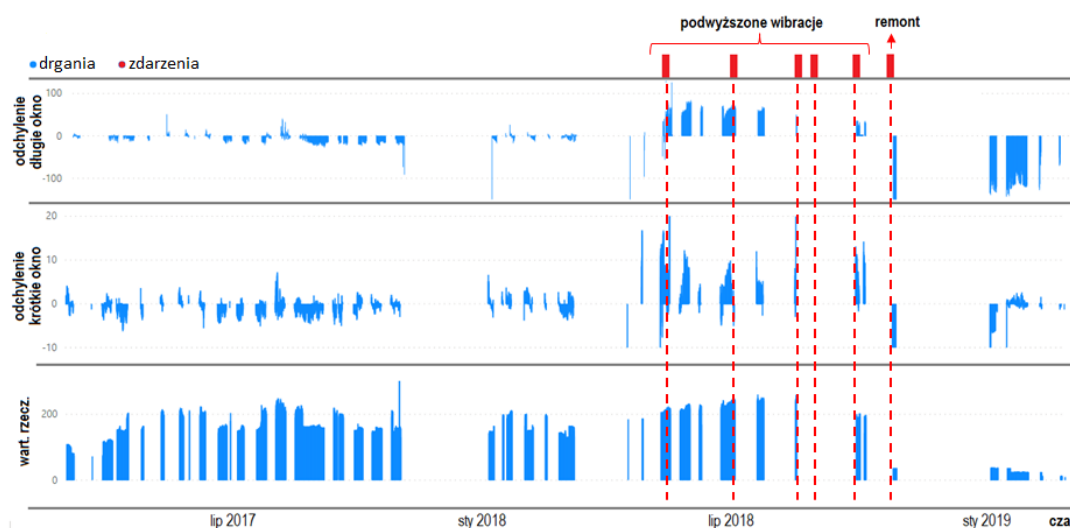
na rys. 4.12 przedstawiono przykład rozkład błędu (odchylenia od wartości rzeczywistej) dla sprężarki 2GHG01. Kolorem czerwonym oznaczono normalny stan pracy, natomiast kolorem niebieskim - stan awaryjny (podany okres został wydłużony o wcześniejsze dwa tygodnie, aby ocenić zdolność do wykrywania stanów przed awaryjnych). Na podstawie wizualnej analizy możemy wyznaczyć próg alarmowy, po przekroczeniu którego generowany będzie alarm, wtedy wyniki można by przedstawić w postaci macierzy pomyłek. Przy analizie wyników należy wziąć pod uwagę, iż symptomy awarii mogły być widoczne na dłużej niż założone 2 tygodnie wcześniej, co jest źródłem błędów pierwszego rodzaju (fałszywe alarmy). Podczas gdy histogram czerwony jest zbliżony do rozkładu normalnego ze średnią w okolicach wartości 0, histogram niebieski charakteryzuje się znaczną skośnością i przesunięciem średniej wartości błędu.

### Wpływ długości kroczącego okna czasowego na jakość predykcji

Podczas projektowania systemu predykcyjnego istotnym parametrem budowanego modelu predykcyjnego jest wielkość zbioru treningowego dla modelu, będącą w rzeczywistości okresem czasowym potrzebnym do wytrenowania modelu. Okno czasowe może wpływać na możliwości predykcyjne modelu. Dlatego w przeprowadzonych badaniach zbadany został również ten parametr. Na rys. 4.13 przed-



stawiono wizualne różnice w uzyskanych wynikach w zależności od zastosowanej długości okna czasowego. Dłuższe okna czasowe obejmujące szeroki zakres danych (tj. 3 miesiące) wolniej adaptują się do nagłych zmian, takich jak remont (w styczniu 2019 r. na rys. 4.13), ale wyraźnie pokazują rozbieżność między okresami awarii, a prawidłowym działaniem. W przypadku krótszych okien czasowych (1 miesiąc) model szybko dostosowuje się do zmienności środowiska, tzn. może się skorygować w czasie niedługim po remoncie. Z drugiej strony, w przypadku długotrwałej usterki, może on traktować usterkę jako stan prawidłowy. W związku z tym, dobór długości okna uczącego należy dostosować do wymaganej specyfiki działania algorytmu. Najprostszym z rozwiązań problemu jest stosowanie dwóch wariantów algorytmu, aktualizowanego krótkim i długim oknem. Niemniej jednak uzyskane wyniki nasuwają pytanie czy możliwym jest dobranie długości okna uczącego tak, aby jakość modelu była zadowalająca w każdym z przypadków?




Rysunek 4.13: Odchylenia od stanu przewidywanego drgań uzyskane dla długiego i krótkiego okna czasowego, wyznaczającego zbiór treningowy dla modelu.

### Jakość detekcji modelu


Wyniki badań przedstawione w dalszej części niniejszej sekcji obejmują wizualizację działania algorytmu na tle zarejestrowanych usterek. Algorytm wytrenowano

zarówno długim oknem uczącym (prognoza długoterminowa), jak i krótkim oknem uczącym (prognoza krótko terminowa).

**Prognoza długoterminowa.** W badanym okresie w rejestrach awarii odnotowano kilka istotnych usterek. W przypadku sprężarki 1HTG01 zgłaszanymi zdarzeniami były w lutym 2017 r. - uszkodzenie łożyska, a następnie stwierdzenie głośniejszej pracy urządzenia i drgań łożyska w wyniku czego w kwietniu 2017 r. przeprowadzono remont urządzenia. Po remoncie model prognostyczny nie wykazywał żadnych odchyień, mimo zgłoszeń zwiększonych drgań w okresie lipiec-sierpień. Analiza rzeczywistych pomiarów drgań nie wykazała żadnych nieprawidłowości w pracy urządzenia. Sprężarka 2HTG01 charakteryzowała się bezawaryjną pracą przez dłuższy okres do maja 2018 r., kiedy to odnotowano podwyższoną temperaturę oleju, a w kolejnych tygodniach pojawiło się kilka usterek związanych z podwyższonym poziomem drgań. Sprężarka została wyremontowana w październiku 2018 r. Wpływ remontu jest widoczny na wykresie na rys. 4.14 jako znaczne zmniejszenie wartości odchylenia (błędu). W przypadku obu sprężarek punkty awarii widoczne na rys. 4.14 jako zarejestrowane zdarzenia pokrywają się z większymi odchyleniami wskazanymi przez model predykcyjny dla badanej zmiennej, co świadczy o prawidłowym działaniu modelu.



Rysunek 4.14: Anomalie dla pomiarów drgań ze wskazaniem na osi czasu usterek i działań serwisowych.

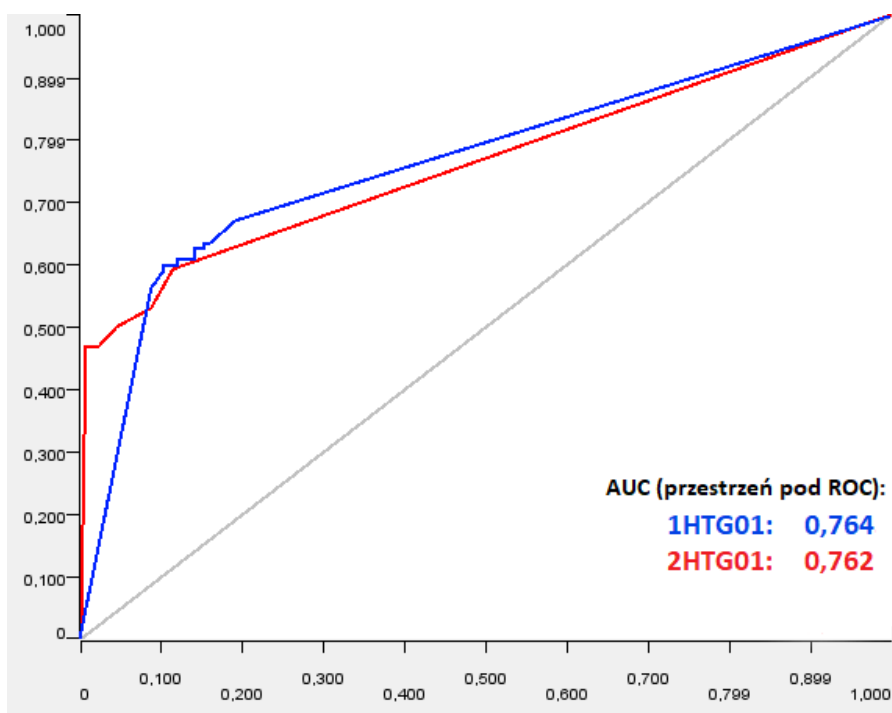


Rysunek 4.15: Odchylenie i rzeczywiste wskazanie dla ciśnienia oleju za filtrem przed awarią łożyska.

**Przewidywanie krótkoterminowe.** Jedną z awarii, która została zarejestrowana 23 lutego w sprężarce 1HTG01 (3 dni po wystąpieniu awarii), było uszkodzenie łożyska. Uszkodzenie nastąpiło w czasie, gdy zarejestrowano podwyższone poziomy drgań, co spowodowało konieczność przeprowadzenia kompleksowego remontu. Jednak już przed samą awarią można zauważyć znaczny wzrost odchylenia od wartości szacunkowych. Na około godzinę przed włączeniem urządzenia 20 lutego widoczny jest znaczny wzrost odchylenia. Fizyczny efekt zaobserwowanej awarii miał wpływ na rzeczywisty spadek ciśnienia za filtrem oleju, co widać na rys. 4.15. Awaria wymagająca postępu wystąpiła trzy dni później podczas kolejnego rozruchu sprężarki.

## Porównanie wyników

W celu porównania wyników predykcji usterek dla sprężarek obliczono wartości  $NRE$ , dzieląc wartość odchylenia przez lokalny błąd średnio-kwadratowy  $RMSE$  (równoważny odchyleniu standardowemu), a następnie odfiltrowano wartości, dla których odchylenie standardowe przekraczało wartość progową 6 (wyznaczoną doświadczalnie podczas eksperymentu z pompą zasilającą) przez mniej niż 15 minut. Oznacza to, że alarm dotyczący przewidywanej usterki wejściowej jest zgłaszany tylko wtedy, gdy wartość  $NRE > 6$  przez co najmniej 15 minut. Ten sam próg zastosowano do monitorowania stanu pomp zasilających kotły, uzyskując dobre jakościowo wyniki predykcji. Porównanie wyników uzyskanych dla badanych sprężarek w postaci pola pod krzywą ROC przedstawiono na rys. 4.16.



Rysunek 4.16: Krzywe ROC dla modeli predykcyjnych wykrywania anomalii zbudowanych dla sprężarek 1HTG01 i 2HTG02.

W tabeli 4.11 przedstawiono efektywność modeli predykcyjnych zbudowanych zarówno dla sprężarek 1HTG01 i 2HTG02 oraz dla pompy zasilającej, której wyniki przedstawiono w sekcji 4.1.5. Uzyskane wyniki dla sprężarek są nieco gorsze niż dla pompy. Warto jednak zauważyć, iż przy niewielkiej liczbie rzeczywistych usterek uzyskano dobry poziom swoistości, co przekłada się na niewielką liczbę wyników fałszywie dodatnich (błędów typu I). Czułość modelu prawdopodobnie można poprawić poprzez ulepszenie algorytmów generujących alarmy lub dalsze doskonalenie etapu strojenia.

Tabela 4.11: Wydajność modeli predykcyjnych zbudowanych dla różnych urządzeń w elektrowni.

	Dokładność	AUC	Czułość	Swoistość
Pompa zasilająca PZ3	0,86	0,89	0,67	0,95
Sprężarka 1HTG01	0,79	0,764	0,58	0,91
Sprężarka 2HTG01	0,93	0,762	0,47	0,98

## **Wnioski**

Uzyskane wyniki potwierdzają możliwość stosowania prezentowanej metody dla innych typów urządzeń znajdujących się w elektrowniach. Algorytm oparty na regresji, stosowany wcześniej do przewidywania awarii pomp zasilających kotły, został z powodzeniem zastosowany do sprężarek natleniających w instalacji odsiarczania spalin. Wyniki uzyskane dla sprężarek w porównaniu z pompami są minimalnie gorsze, aczkolwiek porównywalne. Fakt, iż uzyskano je przy użyciu prostych metod eksploracji danych i niewielkiemu wkładowi pracy analitycznej, zachęca do dalszych prac nad poprawą jakości modelu poprzez usprawnienie procesu inżynierii danych. Zaproponowany algorytm wzbogacono o metody automatyzacji selekcji cech, gromadzenia i grupowania danych wykorzystujące specyficzne kodowanie urządzeń i instalacji w energetyce.

Wprowadzone na etapie modelowania kroki strojenia parametrów modelu i selekcji cech poprawiają znacznie własności predykcyjne modelu. Warto przy tym zauważyć, iż redukcja zbioru cech powoduje również mniejsze zakłócenia wskazań powiązanych elementów przy wystąpieniu usterki jednego z nich, tzn. jeżeli statystycznie używamy mniej zmiennych do rekonstrukcji sygnału to przekłamanie jednej zmiennej w mniejszym stopniu ma wpływ na wyniki rekonstrukcji innych zmiennych (sygnałów).

Niewątpliwą zaletą algorytmu jest brak konieczności etykietowania danych w porównaniu z większością metod opartych na klasyfikacji. Etykietowanie danych w przedstawianej metodzie nie jest konieczne, gdyż oparta jest ona na algorytmach regresji. Jedynym zadaniem związanym z przygotowaniem danych w procesie przygotowania zbioru uczącego jest określenie wzorcowych (bezawaryjnych) okresów pracy, co pośrednio ma wpływ na uzyskane wyniki predykcji.

Zaproponowane kroki na etapie tworzenia modelu zgodnie z oczekiwaniami poprawiły jakość modelu i pozwoliły zachować jego wysokie zdolności predykcyjne. Najistotniejszym czynnikiem wnoszącym wartość dodaną jest usprawnienie procesu tworzenia i utrzymania modelu. Możliwość zautomatyzowania niektórych czynności projektowych i administracyjnych ogranicza pracochłonność i konieczność wykorzystania wiedzy eksperckiej z zakresu modelowania i eksploracji danych.

## 4.3 Aktualizacja modelu i przeciwdziałanie zjawisku dryfu koncepcji

Jak omówiono w sekcji 3.3.5 dryf koncepcji jest negatywnym zjawiskiem wpływającym na zdolności predykcyjne modeli, szczególnie w szerszym horyzoncie czasowym. W niniejszej sekcji przedstawione zostały wyniki zastosowania algorytmów operujących na szeregach czasowych, mających za zadanie wykrywanie i zapobieganie zjawisku dryfu koncepcji. Szczególnym problemem badawczym w tej części było odróżnienie zjawiska dryfu koncepcji od prawidłowego działania algorytmu wykrywającego usterki. Prezentowane wyniki zostały opublikowane w ramach artykułu opublikowanego na konferencji MASCOTS (Core A)[209].

### 4.3.1 Koncepcja studium przypadku

W niniejszej sekcji analizowane jest zjawisko dryfu koncepcji występujące w kontekście wyników predykcji zwracanych przez opracowany system diagnostyczny dla rzeczywistych danych pomiarowych pompy zasilającej. Celem na tym etapie badań było zbadanie opracowanych technik pozwalających na utrzymanie zdolności predykcyjnych modelu w perspektywie czasu oraz odróżnienie anomalii wywołanych usterką bądź awarią od sytuacji, w której model stracił własności predykcyjne (rozregulował się) i powinien być odświeżony. W części badawczej eksperymentalnie zweryfikowano algorytmy i techniki operujące na szeregach czasowych umożliwiające poprawę zdolności detekcyjnych modelu oraz pozwalające ograniczyć negatywne skutki zjawiska dryfu koncepcji. Podstawowym problemem badawczym było odróżnienie zjawiska dryfu koncepcji spowodowanego nieaktualnością modelu od sytuacji, w której odchylenie jest spowodowane zbliżającą się usterką. W założeniu opracowywana metoda miała na celu zapewnienie wymaganej dokładności modeli predykcyjnych poprzez automatyczną aktualizację oraz aplikację metod operujących na szeregach czasowych w celu poprawy jakości zwracanych wyników. Zaproponowane rozwiązania miały na celu usprawnienie prac analitycznych i administracyjnych w sytuacji, gdy istnieje wiele modeli obejmujących setki urządzeń i tysiące pomiarów działających w zmiennym środowisku.

### 4.3.2 Przedmiot badań

Zjawisko występowania dryfu koncepcji zostało przeanalizowane dla modelu opartego na regresji wykrywającego awarie jednej z pomp zasilających blok energetyczny w Elektrowni Łaziska w Łaziskach Górnych. Badanym obiektem była inna pompa niż przedstawiona w sekcji 4.1.2, architektura i schemat działania są jednak te same. Typowe awarie i czynności serwisowe podczas pracy pompy to wymiana filtra oleju, czyszczenie chłodnicy, wycieki wody i oleju, przegrzanie silnika i wylanie się oleju. Aby zapobiec awariom, pompa jest sprawdzana codziennie i poddawana przeglądowi diagnostycznym przez dłuższy czas. Zestaw danych wejściowych dla modelu prognostycznego zastosowanego w prowadzonych badaniach zawierał nieprzetworzone pomiary historyczne uzyskane w trybie offline z systemu PGIM (ang. *Power Generation Information Manager*). System PGIM jest repozytorium danych dla sygnałów z rozproszonego systemu sterowania (DCS) używanego w elektrowniach do sterowania procesem produkcji. Dane obejmują pomiary temperatury, ciśnienia, mocy, przepływu i wielu innych zmiennych z różnych czujników umieszczonych na monitorowanym zespole pompowym.

### 4.3.3 Audyt i analiza danych

Ze względu na względnie dużą liczbę pomiarów i występowanie istotnych korelacji sygnałów, prowadzone badania ograniczono do czterech reprezentatywnych sygnałów: ciśnienia wyjściowego wody, temperatury silnika, temperatury powietrza przed silnikiem oraz temperatury łożyska nr 5. Wybór tych sygnałów podyktowany był niewielkimi wzajemnymi korelacjami pomiędzy wartościami wybranych pomiarów (można je traktować jako sygnały reprezentatywne). Zakres danych obejmuje okres od stycznia 2013 do sierpnia 2017 r. z okresem próbkowania wynoszącym jedną minutę.

### 4.3.4 Opis eksperymentu

Zaprojektowane eksperymenty opierały się na zastosowaniu metod cyklicznego odświeżania modelu i weryfikacji ich wpływu na jakość predykcji. W wyniku badań porównane zostały wyniki otrzymane dla następujących wariantów aktualizacji:

- model stacjonarny, gdzie model jest raz wytrenowany i nie aktualizowany,
- aktualizacja "na ślepo", gdzie model jest aktualizowany w ustalonych stałych cyklach,
- aktualizacja "na ślepo" z wykorzystaniem autorskiego algorytmu MSC-ADWIN, gdzie model jest aktualizowany w ustalonych stałych cyklach, przy czym długość zbioru treningowego jest dopasowywana na podstawie analizy historycznych wyników predykcji.

Jako element przeciwdziałający zjawisku stopniowego dryfu koncepcji przetestowano działanie filtra CUSUM oraz przeanalizowano otrzymane wyniki w kontekście pokrywających się rzeczywistych odnotowanych zdarzeń.

#### 4.3.5 Wyniki

W trakcie prowadzonych badań zweryfikowano następujące zagadnienia:

- zidentyfikowano występowanie zjawiska dryfu koncepcji w wynikach działania opracowanego algorytmu,
- zbadano efektywność algorytmu CUSUM jako filtra wyników do celu wyzwalania alarmów,
- zweryfikowano skuteczność aktualizacji modelu za pomocą opracowanego algorytmu MSC-ADWIN na tle metod aktualizacji "na ślepo" oraz modelu nieaktualizowanego.

#### **Analiza zjawiska dryfu koncepcji na danych rzeczywistych**

Analizując wyniki jakie zwrócił model predykcyjny dla danych rzeczywistych uzyskanych za pomocą modelu stacjonarnego wytrenowanego na danych z 2013 r., można było zaobserwować wszystkie wcześniej wymienione typy dryfu koncepcji. Na rys. 4.17, 4.18 i 4.19 przedstawiono odchylenia (tj. średni błąd bezwzględny *MAE*) od wartości oczekiwanej dla wybranych sygnałów. Wyniki modelu zebrano dla zbioru testowego z okresu 2014-2017.




Na rys. 4.17 przedstawiono błąd predykcji dla temperatury oleju przed chłodnicą. Błąd ten sukcesywnie wzrasta w długim okresie czasu. W tym przypadku rzeczywiście odnotowanych było wiele zgłoszeń o podwyższonej temperaturze (temperatura łożyska utrzymywała się na wysokim poziomie przez cały okres 2013-2017) oraz o pracach konserwacyjnych związanych z tym łożyskiem. Przyczyną rosnącego odchylenia wartości szacowanej dla modelu stacjonarnego prawdopodobnie mógł być wpływ prac konserwacyjnych lub postępująca degradacja łożyska.

Na rys. 4.18 i 4.19 przedstawiono wyniki dla temperatury silnika i ciśnienia wyjściowego wody. W tych przypadkach można zaobserwować nagły, chwilowy wzrost błędów, co może być wyraźnym odzwierciedleniem zarejestrowanych w tym czasie awarii. Na późniejszym etapie, w wyniku zmian spowodowanych naprawami, pojawia się błąd oscylujący wokół stałej wartości. Sporadyczne przypadki powtarzających się dryfów mogą być również spowodowane zakłóceniami spowodowanymi usterkami innych części. Istotnym zagadnieniem jest możliwość odróżnienia dryfu koncepcji od wykrycia usterki (czyli prawidłowego zachowania algorytmu). Uwzględniając jedynie analizę przebiegu residuum  $\epsilon_i$  bardzo trudne, a wręcz niemożliwe jest odróżnienie przyczyn odchylenia np. awarii od zmiany warunków atmosferycznych. Jednym z rozwiązań jest przyjęcie, iż stały błąd utrzymujący się przez dłuższy okres czasu jest dryfem koncepcji zakładając, iż usterka powinna była być w tym czasie usunięta. Innym rozwiązaniem jest analiza ilości fałszywych alarmów generowanych przez algorytm. W tym przypadku w celu detekcji konieczna jest informacja zwrotna od eksperta w celu stwierdzenia czy alarm był fałszywy.

### **Porównanie wyników uzyskanych przez model stacjonarny oraz adaptacyjny**

Zaprojektowany eksperyment weryfikuje skuteczność różnych metod aktualizacji modelu (przedstawionych w rozdziale 3.3.5) oraz porównuje zdolności wykrywania usterek dla poszczególnych wariantów.


W przypadku modeli opartych na regresji, jakość modelu predykcyjnego określa się na podstawie zdolności do predykcji wartości, czego miarą są najczęściej współczynniki, takie jak średni błąd bezwzględny ( $MAE$ ), błąd średnio-kwadratowy



Rysunek 4.17: Przykład zjawiska dryfu koncepcji przy predykcji wartości temperatury oleju przed chłodnicą zaobserwowany dla stacjonarnego modelu predykcyjnego

( $RMSE$ ) lub współczynnik determinacji ( $R^2$ ). Dla systemów z obszaru predykcyjnego utrzymania ruchu bardziej istotną cechą projektowanego modelu niż odwzorowywanie sygnału jest zachowanie wymaganej zdolności do wykrywania anomalii. W przeprowadzonym eksperymencie porównano wyniki procesu predykcji awarii uzyskane dla różnych wariantów aktualizacji modelu oraz metody stacjonarnej (model nieaktualizowany). Badania eksperymentalne prowadzono dla różnych wariantów aktualizacji modeli predykcyjnych:

- Model stacjonarny, gdzie dane treningowe pochodziły z całego roku 2013, natomiast zbiór testowy zawierał dane z okresu 2014-2017.
- Modele adaptacyjne (aktualizacja "na ślepo"), które operowały na zbiorze danych z lat 2014-2017, który został podzielony na podzbiory po 160 tys. próbek każdy (około 40 000 próbek odpowiada miesięcowi ciągłej pracy). W pierwszym wariantcie zbiór treningowy obejmował pierwsze 120 000 próbek, a następne 40 000 próbek włączono do zbioru testowego (przesunięcie okna przy jednym cyklu aktualizacji modelu wynosiło 40 000). W drugim wariantcie użyto mniejszego zbioru treningowego (pierwsze 40 000 próbek), natomiast zbiór testowy był równy kolejnym 120 000 próbkom (przesunięcie




Rysunek 4.18: Dryf koncepcji przy predykcji temperatury silnika uzyskany dla stacjonarnego modelu predycyjnego

okna przy jednym cyklu aktualizacji modelu wynosiło 120 000).

- Model adaptacyjny z dostosowanym rozmiarem okna, w którym algorytm jest niemal identyczny, jak w przypadku modelu aktualizowanego "na ślepo", jednak w tym przypadku dodatkową funkcją jest dopasowanie długości okna treningowego do takiego rozmiaru, przy którym wykryto najbardziej znaczącą zmianę wyników predykcji aktualizowanego modelu. Zastosowanie dodatkowego kroku pozwoli na uzyskanie spójnego zbioru treningowego zawierającego najaktualniejsze dane. Długość okna jest wyznaczana z przedziału od 5 do 80 tysięcy próbek. Zastosowany zmodyfikowany algorytm MSC-ADWIN jest opisany w sekcji 3.3.5.

W tabeli 4.12 przedstawiono wyniki uzyskane dla modelu stacjonarnego, natomiast w tabeli 4.13 - wyniki dla modeli adaptacyjnych. Eksperymenty przeprowadzono dla modeli predycyjnych opracowanych dla sygnałów:

- $T_{engine}$  - temperatury silnika,
- $T_{air}$  - temperatury powietrza przed silnikiem,
- $T_{bearing}$  - temperatury łożyska,
- $P_{output}$  - ciśnienia wody na wyjściu.



Rysunek 4.19: Dryf koncepcji dla modelu stacjonarnego ciśnienia wody na wyjściu

Miarami wykorzystanymi do porównania jakości predykcji modeli były: średni błąd bezwzględny ( $MAE$ ) i błąd średnio-kwadratowy ( $RMSE$ ), gdzie symbole  $MAE$  i  $RMSE$  opisują parametry obliczone dla całego zbioru danych,  $MAE_0$  i  $RMSE_0$  - uzyskane wyniki dla części zbioru danych, dla której stwierdzono stan awaryjny,  $MAE_1$  i  $RMSE_1$  - uzyskane dla części zbioru danych dla stanu normalnej pracy. W celu określenia zdolności do wykrywania usterek/anomalii oznaczono zbiór danych znacznikami czasu, w których zarejestrowano zdarzenia serwisowe dla urządzenia. Następnie obliczono współczynniki  $RES_{MAE}$  i  $RES_{RMSE}$ , zgodnie z wzorami 4.1 i 4.2, które odnoszą się do stosunku wartości  $MAE$  i  $RMSE$  uzyskanych dla okresu awaryjnego do okresu bezawaryjnego:

$$RES_{MAE} = \frac{MAE_1}{MAE_0}, \quad (4.1)$$

$$RES_{RMSE} = \frac{RMSE_1}{RMSE_0}. \quad (4.2)$$

Współczynniki  $RES_{MAE}$  i  $RES_{RMSE}$  określają w sposób ilościowy jakość modelu predykcyjnego, w założeniu lepszy model będzie posiadał wyższy współczynnik z uwagi na odnotowany wyższy błąd w okresie awarii względem błędu w okresie

bezawaryjnym.

Analizując otrzymane wyniki, można zauważyć, że stosując model okresowego odświeżania z wykorzystaniem okna o stałym rozmiarze (wyniki przedstawiono w tabeli 4.13), uzyskuje się ogólnie niższy średni błąd bezwzględny ( $MAE$ ) w porównaniu do modelu statycznego (wyniki w tabeli 4.12), przy zachowaniu nieco mniejszych, ale nadal zadowalających współczynników  $RES_{MAE}$  i  $RES_{RMSE}$ . Porównując wyniki dla różnych wariantów okna przesuwne o stałym rozmiarze, można zauważyć, że stosując krótsze przesunięcie okna (porównując okno 160/120 z oknem 160/40), uzyskano lepsze parametry  $MAE$  i  $RMSE$ , ale znacznie gorsze parametry  $RES_{MAE}$  i  $RES_{RMSE}$ . Zastosowanie modelu adaptacyjnego z dostosowanym rozmiarem okna (poprzez zastosowanie algorytmu MSC-ADWIN) poprawia parametry  $RES_{MAE}$  i  $RES_{RMSE}$ , podczas gdy parametry  $MAE$  i  $RMSE$  pozostają na porównywalnym poziomie, jak w modelu adaptacyjnym aktualizowanym "na ślepo" w pierwszym wariancie (tj. rozmiar okna 160/120). Zastosowanie metody MSC-ADWIN dało najlepsze wyniki pod względem dopasowania modelu do celów wykrywania anomalii.

Tabela 4.12: Poziomy błędów przy zastosowaniu modeli statycznych

	$T_{engine}$	$T_{air}$	$T_{bearing}$	$P_{output}$
$MAE_0$	0,31	0,31	2,08	0,42
$RMSE_0$	0,43	0,45	2,35	0,54
$MAE_1$	2,36	1,81	7,40	0,47
$RMSE_1$	2,98	3,42	8,37	0,84
$MAE$	1,23	0,98	4,48	0,44
$RMSE$	2,02	2,32	5,88	0,69
$RES_{MAE}$	7,63	5,83	3,55	1,09
$RES_{RMSE}$	6,91	7,63	3,56	1,56

### Zastosowanie filtrowania CUSUM

Przedstawiony w sekcji 3.3.5 algorytm CUSUM służy do wykrywania zmian w szeregach czasowych. W kontekście zjawiska dryfu koncepcji odchylenie wartości błędu regresji  $\epsilon_i$  może być spowodowane zarówno nadchodzącą usterką, jak i innymi czynnikami (powodującymi powstanie dryfu koncepcji). Aby odróżnić zjawisko dryfu koncepcji od prawidłowego działania algorytmu predykcyjnego

Tabela 4.13: Poziomy błędów przy zastosowaniu modeli adaptacyjnych

Stały rozmiar okna 160/120				
	$T_{engine}$	$T_{air}$	$T_{bearing}$	$P_{output}$
$MAE_0$	0,28	0,24	0,85	0,25
$RMSE_0$	0,40	0,45	1,16	0,43
$MAE_1$	0,87	0,74	0,92	0,81
$RMSE_1$	2,49	2,95	1,53	0,59
$MAE$	0,91	0,86	0,95	0,85
$RMSE$	1,70	2,01	1,34	0,51
$RES_{MAE}$	5,04	4,40	1,33	1,55
$RES_{RMSE}$	6,31	7,33	1,32	1,39
Stały rozmiar okna 160/40				
	$T_{engine}$	$T_{air}$	$T_{bearing}$	$P_{output}$
$MAE_0$	0,33	0,45	1,26	0,29
$RMSE_0$	0,44	0,58	1,61	0,45
$MAE_1$	2,41	1,35	2,99	1,28
$RMSE_1$	3,58	2,40	4,41	1,66
$MAE$	1,27	0,86	2,04	0,74
$RMSE$	2,42	1,67	3,19	1,17
$RES_{MAE}$	7,21	3,02	2,36	4,32
$RES_{RMSE}$	6,91	7,63	3,56	1,56
Adaptacyjny rozmiar okna 160/(5-80)				
	$T_{engine}$	$T_{air}$	$T_{bearing}$	$P_{output}$
$MAE_0$	0,26	0,23	0,96	0,27
$RMSE_0$	0,35	0,38	1,25	0,41
$MAE_1$	1,26	1,19	1,66	0,46
$RMSE_1$	2,33	2,57	2,52	0,78
$MAE$	0,71	0,66	1,27	0,35
$RMSE$	1,59	1,75	1,93	0,60
$RES_{MAE}$	4,87	5,20	1,72	1,72
$RES_{RMSE}$	6,57	6,73	2,02	1,90

założono, iż stałe błędy pojawiające się w szerokim horyzoncie czasowym oznaczają dryf koncepcji, natomiast nagłe zmiany następujące w krótkim okresie (np. w ciągu ostatnich dwóch tygodni) oznaczają zbliżającą się usterkę.

Zastosowanie algorytmu CUSUM w założeniach powinno wyzwać alarmy na podstawie generowanych wyników poprzez filtrowanie stałej wartości błędu wynikającej z istnienia zjawiska dryfu koncepcji. Istotną kwestią jest odpowiedni

dobór parametrów określających wrażliwość algorytmu na zmiany. Aby dostosować algorytm do dynamicznie zmieniających się warunków parametr  $v$  określający próg zmian, które mają być wykryte nie był ustalany statycznie, a był obliczany na podstawie bieżącego kontekstu (najnowszych danych, przy czym długość okna na potrzeby realizacji zadania ustalono na 2 tygodnie). Parametr  $v$ , który był wykorzystany do tego zadania, składał się z ruchomej średniej i odchylenia standardowego z dwóch tygodni w oknie przesuwym:


$$v = AVG_{2\ weeks} + 3 \cdot ST\_DEV_{2\ weeks}. \quad (4.3)$$

Algorytm CUSUM został wykorzystany do analizy danych wyjściowych (błąd predykcji  $\epsilon_i$ ) dla modelu stacjonarnego (nieaktualizowanego).

Na rys. 4.20 przedstawiono wizualny wynik działania algorytmu na przykładzie modelu predykcji temperatury łożyska; w górnej części (oznaczonej literą a) znajdują się piki oznaczające wyzwolone alarmy, natomiast w dolnej części (oznaczonej literą b) poziom błędu predykcji. Analizując wykres, można stwierdzić, że zastosowanie filtra CUSUM rozwiązuje częściowo problem przyrostowego dryfu, poprzez odseparowanie stałej wolno zmiennej części błędu. W celu potwierdzenia tej teorii porównano punkty wystąpienia alarmu z prawdopodobnymi przyczynami, tj. zarejestrowanymi zdarzeniami serwisowymi w tym okresie. Wyniki badania przedstawiono w tabeli 4.14.

Zastosowanie algorytmu CUSUM w roli detektora nagłych zmian w wynikach modelu predykcyjnego dało dobre rezultaty. Miejsca kiedy wyzwolane są alarmy pokrywają się lub poprzedzają okresy odnotowanych zdarzeń serwisowych. Dzięki algorytmowi CUSUM możliwe jest poprawne działanie algorytmu predykcji bez konieczności częstego odświeżania modelu. Oznacza to, iż w przypadku zastosowania wariantów aktualizacji modelu "na ślepo" (zarówno ze stałą długością zbioru uczącego, jak i długością wynikającą z zastosowania algorytmu MSC-ADWIN) możliwe jest wydłużenie cykli odświeżania modelu. Inną zaletą wynikającą z właściwości algorytmu CUSUM jest generowanie alarmów w postaci pojedynczych pików, co ma istotny wpływ na czytelność wyników dla odbiorców końcowych. Zarównow przypadku prawidłowego wykrycia usterki, jak i fałszywego alarmu algorytm ogra-

nicza się do jednorazowego wyzwolenia alarmu (nie sygnalizując stanu alarmowego cały czas).



Rysunek 4.20: Przykład zastosowania filtra CUSUM dla danych wyjściowych modelu sygnału: a) alarmy wygenerowane poprzez zastosowanie algorytmu CUSUM na szeregu czasowym błędu  $\epsilon_i$  będącego wynikiem predykcji z użyciem modelu stacjonarnego, b) poziom błędu  $\epsilon_i$  wygenerowanego przez model predykcyjny dla estymacji temperatury łożyska nr 5.



Tabela 4.14: Alarmy wygenerowane po zastosowaniu algorytmu CUSUM oraz powiązane zdarzenia

Data	$P_{output}$	$T_{engine}$	$T_{air}$	$T_{bearing}$	Prawdopodobna przyczyna
2014-01-23	✓	✓	✓	✓	Uszkodzony pomiar temp. łożyska oporowego
2014-03-24				✓	Wyciek oleju między silnikiem, sprzęgłem
2014-06-26	✓				Nieznane
2014-07-19		✓	✓		Zanieczyszczona chłodnica
2014-08-11	✓	✓	✓		Wyciek z zaworu
2014-09-23				✓	Zanieczyszczona chłodnica
2015-04-25	✓	✓			Wyciek z zaworu bezpieczeństwa
2015-05-05		✓		✓	Zanieczyszczona chłodnica
2015-08-12	✓				Nieznane
2015-08-28			✓		Wyciek oleju
2015-10-05		✓	✓	✓	Remont silników elektrycznych
2015-11-10		✓			Podwyższone wibracje łożyska
2015-11-26				✓	Podwyższone wibracje łożyska
2015-12-02		✓			Podwyższone wibracje łożyska



# Rozdział 5

## Podsumowanie

### 5.1 Podsumowanie zrealizowanych prac

Postęp technologiczny otwiera nowe możliwości w przemyśle w zakresie wykorzystania analizy danych we wsparciu procesów produkcyjnych, uzupełniając w ten sposób korzyści płynące z istniejących systemów eksperckich oraz repozytoriów danych. Wspomniane możliwości są wyzwalane przez technologie pozwalające na pozyskiwanie i integrację danych (jak Big Data czy Internet Rzeczy) oraz techniki analityczne (uczenie maszynowe, metody statystyczne), umożliwiające wykorzystanie posiadanych zasobów do celów innych niż pierwotnie założono.

Przemysł energetyczny obfituje w liczne zbiory danych, szczególnie generowane maszynowo, których analiza pozwala na lepsze zrozumienie zachodzących zjawisk oraz istotnie wspiera proces poszukiwania nowych korzyści płynących z przetwarzania danych.

Temat przewodni pracy związany jest z zastosowaniem nowoczesnych technologii i rozwiązań opartych na uczeniu maszynowym i sztucznej inteligencji, do celów zwiększenia dyspozycyjności urządzeń energetycznych, realizowanego poprzez monitorowanie stanu zdrowia urządzeń na podstawie danych procesowych oraz wczesne wykrywanie stanów poprzedzających wystąpienie awarii.

Przedmiotem badań niniejszej pracy były zespoły pomp zasilających w Elektrowni Łaziska oraz sprężarki natleniające jednego z bloków energetycznych w Elektrowni Jaworzno III, dla których w badanym okresie analizowane były

historyczne dane procesowe z systemów sterowania pozyskane offline na tle zarejestrowanych zdarzeń i awarii.

Kompleksowy przegląd literatury pod kątem zastosowania predykcyjnego utrzymania ruchu oraz nowoczesnych technologii w energetyce ugruntował wiedzę w badanym obszarze. Analiza i klasyfikacja metod z obszaru wykrywania usterek oraz predykcyjnego utrzymania ruchu pozwoliły na wytyczenie prawidłowej ścieżki badań, natomiast przegląd zastosowań nowoczesnych technologii z pogranicza Przemysłu 4.0 pozwala na ich lepsze zrozumienie i ewentualną transformację istniejących procesów i procedur.

Prace badawcze skupiały się wokół obszaru predykcyjnego utrzymania ruchu, którego istotą jest zminimalizowanie liczby planowanych i nieplanowanych przestoju, poprzez ocenę stanu technicznego urządzenia oraz możliwość wykrywania z wyprzedzeniem usterek na podstawie danych procesowych.

Ze względu na skomplikowane procesy technologiczne oraz ograniczony dostęp do wiedzy eksperckiej cele pracy koncentrowały się szczególnie na metodach modelowania niewymagających posiadania obszernej wiedzy eksperckiej, a pozwalających osiągnąć skalowalne rozwiązania spełniające zadane oczekiwania odnośnie wiarygodności modelu.

### **5.1.1 Autorski wkład badawczy**

Podczas realizacji rozprawy opracowano szereg rozwiązań implementujących postawione cele, których efektywność została zweryfikowana w części eksperymentalnej. W niniejszej sekcji wyszczególniono metody i algorytmy będące autorskimi rozwiązaniami lub posiadające istotny wkład własny.

#### **Redundancja analityczna wykorzystująca metody regresji**

Analizując dostępne dane procesowe opisujące pracę oraz odnotowane zdarzenia dla zespołu pomp zasilających blok energetyczny, opracowany został model analityczny realizujący zadanie wykrywania usterek w sytuacji ograniczonych informacjach o historycznych usterekach oraz przy zmiennych warunkach pracy. Utworzony algorytm bazuje na koncepcji wykrywania anomalii dla rejestrowanych przez czujniki wartości analogicznie do koncepcji redundancji analitycznej. Model

ten oparty jest na algorytmie regresji, który odwzorowuje wartość monitorowanego sygnału na podstawie istniejących korelacji i zależności z pozostałymi sygnałami. Zaproponowane podejście uzasadnia szybkość obliczeniowa metody w kontekście liczby analizowanych danych oraz istnienie kompleksowego opomiarowania urządzeń produkcyjnych, pozwalające na znalezienie licznych korelacji między sygnałami.

### **Opracowanie algorytmu wykrywającego usterki**

Opierając się na zaproponowanej koncepcji redundancji analitycznej wykorzystującej metody regresji opracowano proces tworzenia modelu wykrywającego usterki na podstawie danych procesowych z systemów sterujących. Modelowane sygnały były grupowane w celu powiązania pomiarów z danym urządzeniem oraz filtrowane pod względem jakości predykcji. Analizując relatywne odchylenia wartości estymowanych możliwe stało się wskazanie potencjalnego źródła awarii. Zaproponowany przepływ danych przy tworzeniu modeli obejmował czynności filtrowania i czyszczenia danych, sparametryzowane w taki sposób, aby cały proces łatwo można było odtworzyć.

### **Normalizacja i wizualizacja wyników**

Ze względu na wdrożeniowy charakter rozprawy i potencjalną grupę użytkowników końcowych istotnym zagadnieniem w pracy było przedstawienie wyników w sposób dla nich zrozumiały. W tym celu zaproponowano metodę normalizacji wyników oraz graficznej prezentacji najwyższego błędu (sygnału o największym relatywnym odchyleniu). W ten sposób potencjalna usterka jest identyfikowana w postaci wskazania potencjalnego źródła anomalii (czujnika generującego błąd).

Inną zaproponowaną metodą jest zastosowanie na strumieniu danych wyników algorytmu filtracji sum skumulowanych CUSUM w celu generowania powiadomień i alarmów. Metoda ta okazała się również skuteczna w przypadku przeciwdziałania zjawisku dryfu koncepcji.

## **Automatyzacja procesu inżynierii danych i parametryzacji modelu**

Analizując system kodowania urządzeń i sygnałów Kraftwerk-Kennzeichen System (KKS) zaproponowano metodę automatycznej akwizycji danych pomiarowych powiązanych z danym urządzeniem. Zastosowana metoda upraszcza znacząco proces wstępnego przetwarzania danych szczególnie w przypadku pracy na dużych zbiorach danych (Big Data).

W celu zautomatyzowania procesu etykietowania danych utworzono środowisko pozwalające na łatwe etykietowanie szeregów czasowych oraz klasyfikację występujących awarii. Rozwiązanie łączy ze sobą dane z systemów sterowania z systemem zarządzania majątkiem i zleceniami roboczymi.

Na etapie parametryzacji modelu dodano krok eksperymentalnego doboru parametru stopnia wielomianu oraz zbioru cech wejściowych dla każdego z modelowanych sygnałów. Badane metody (wsteczna eliminacja cech i algorytm genetyczny) w znaczący sposób poprawiały jakość modelu predykcji usterek.

Opracowanie i digitalizacja powyższych działań w założeniu pozwalają znacząco przyspieszyć proces wdrażania systemu dla nowych urządzeń, zachowując akceptowalne parametry jakościowe.

## **Zapobieganie zjawisku dryfu koncepcji**

W celu zniwelowania zjawiska dryfu koncepcji przeprowadzono modyfikacje symulujące działanie modelu w opcjach: statycznej oraz adaptacyjnej (cykliczne odświeżanie/douczenie). W celu usprawnienia procesu w algorytmie zastosowano metody z obszaru analizy szeregów czasowych: CUSUM oraz ADWIN. Zastosowanie algorytmu CUSUM jako filtru błędów estymacji sygnału dało bardzo dobre wyniki, w szczególności w przypadku zastosowania algorytmu razem z modelem statycznym (nieodświeżanym), gdzie spodziewane były wyniki o gorszej jakości. Algorytm CUSUM odfiltrowywał "stałą" część błędu, co przy odpowiednim dobraniu parametrów pozwoliło na zwiększenie jakości działania modelu poprzez zwiększenie czułości na nagłe zmiany stanu (błędu). Algorytm ADWIN został zmodyfikowany w taki sposób, aby wykrywać zmiany w zbiorze uczącym, w celu dobrania najbardziej spójnego zbioru uczącego w okresie począwszy od bieżącej chwili do maksymalnego rozmiaru okna.

### 5.1.2 Podsumowanie wyników badań

Główny problem badawczy podejmował wyzwanie utworzenia systemu wnioskowania pozwalającego na predycyjne wykrywanie usterek w urządzeniach energetycznych elektrowni węglowych. Specyfika pracy urządzeń energetycznych sprawia, iż potencjalne ustereki krytyczne mają charakter unikalny, a warunki i charakterystyka pracy systemu są bardzo zmienne.

Wobec powyższego problemu przeprowadzono szereg badań poświęconych zaprojektowaniu modelu analitycznego realizującego to zadanie oraz ewaluacji otrzymanych wyników. Specyfika systemów przemysłowych wiąże się z generowaniem w sposób maszynowy dużych rozmiarów danych, np. z czujników, systemów zabezpieczeń, czy elementów wykonawczych. Mnogość generowanych danych do analizy stanowi niewątpliwą zaletę względem potencjalnego stanowiska badawczego w laboratorium. Opierając się o tę zaletę zaproponowany został algorytm wykorzystujący efektywną obliczeniowo metodę regresji, który schematem działania (tj. wykrywania usterek) zbliżony jest do metody redundancji analitycznej. Występujące istotne korelacje pomiędzy sygnałami procesowymi sprawiły, iż zaproponowana metoda daje rezultaty o bardzo dobrej jakości. Natomiast oparcie głównego trzonu algorytmu o mechanizm wykrywający anomalie pozwolił na ograniczenie wpływu na wyniki niepewnych lub niekompletnych danych o awariach. Przeprowadzone badania na zespole pomp zasilających wykazały zdolność zaproponowanego modelu do wykrywania usterek krytycznych oraz innych zdarzeń mających wpływ na proces produkcyjny. Analiza otrzymanych wyników wykazała również, iż zaproponowane podejście bardzo dobrze nadaje się też do wykrywania awarii czujników oraz do procesu ich kalibracji. Innym zastosowaniem jest wykrywanie usterek mających wpływ na wydajność urządzenia. Takim przypadkiem było wykrycie rozszczelnienia zaworu zasilającego. Algorytm nie generował alarmów w przypadku pomniejszych usterek, jak wycieki oleju czy niewielkie wycieki wody, oraz przy okresowych czynnościach eksploatacyjnych, jak wymiana filtrów oleju. Porównanie wyników z innymi metodami opierającymi się na klasyfikacji dało satysfakcjonujące wyniki na korzyść opracowanego podejścia, przy czym dodatkowym atutem jest klarowny sposób działania i możliwość łatwej interpretacji wyników.

Oceniając wyniki działania zaproponowanego algorytmu dla zespołu pomp za-

silających, należy stwierdzić, że główna teza badawcza mówiąca iż:

**Teza 1:** *Zastosowanie metod redundancji analitycznej opartych na regresji operujących na dużych zbiorach danych z systemów przemysłowych pozwala na realizację zadania przewidywania awarii i usterek w sytuacji:*

- *ograniczonej liczby analizowanych cech i zdarzeń,*
- *zmiennych warunków pracy wynikających z częstych remontów i wpływu czynników zewnętrznych*

**została udowodniona.**

Charakter wdrożeniowy projektu oraz osadzenie rozwiązania w realiach produkcyjnych wymagają opracowania mechanizmów pozwalających na łatwe wdrożenie i późniejsze utrzymanie rozwiązania. Podążając ku tym celom realizowany był wątek badawczy poświęcony możliwościom przenoszenia rozwiązania oraz aktualizacji opracowanego modelu. Szereg przeprowadzonych badań nad różnymi sposobami aktualizacji modelu pozwalają na świadome dobranie strategii odświeżania do wymaganych parametrów jakościowych. Na szczególną uwagę zasługują wyniki uzyskane przy zastosowaniu autorskiej metody MSC-ADWIN opierającej się na zmodyfikowanym algorytmie okna adaptacyjnego. Wykorzystując właściwości algorytmu, na podstawie analizy średnich cząstkowych całego zbioru treningowego dopasowywany był rozmiar okna treningowego w taki sposób, aby docelowy zakres był jak najbardziej spójny pod względem stabilności przewidywanych wartości. Wyniki badań zrealizowanych dla sprężarek natleniających wykazały, iż zastosowanie zaproponowanej metody znacząco poprawia parametry jakościowe modelu regresji zachowując wysokie zdolności predykcyjne. Zastosowanie metody adaptacyjnego okna wraz z techniką cyklicznej aktualizacji modelu sprawia, iż utrzymanie modelu nie wymaga znaczącego wkładu pracy przez administratora lub analityka nadzorującego pracę systemu. Zaprezentowane wyniki poświadczają zasadność drugiej z tez badawczych niniejszej pracy, tj.:

**Teza 2:** *Algorytm adaptacyjnego okna przesuwonego oparty na analizie średnich wartości cząstkowych elementów tego okna pozwala zachować parametry jakościowe modelu predykcyjnego wykrywającego usterek, jednocześnie ograniczając potrzebę okresowej nadzorowanej aktualizacji modeli.*



Ważnym wątkiem w podjętych badaniach z projektowego punktu widzenia jest zapewnienie mechanizmów pozwalających na łatwe wdrożenie i utrzymanie modelu. Proces tworzenia modelu we wstępnej fazie eksperymentalnej obejmował ręcznie wykonywane czynności związane z parametryzacją i doбором cech. Parametry modelu były wyznaczone na podstawie dodatkowych eksperymentów lub wnioskowane na podstawie analizy deskryptywnej. Z uwagi na czasochłonność wspomnianego procesu inżynierii danych, a także konieczność posiadania specjalistycznej wiedzy eksperckiej, podjęto próby zautomatyzowania tego procesu.

Znając w praktyce wszystkie etapy tworzenia modelu dla zespołu pomp zasilających, te same kroki zostały odtworzone stosując zautomatyzowane przepływy danych dla dwóch agregatów sprężarek natleniających. Wprowadzone usprawnienia pozwalały na selekcję oraz filtrowanie cech dla zbioru treningowego oraz dostosowanie parametrów modelu. Zastosowane heurystyki pozwoliły na zbudowanie modelu wykazującego zbliżone właściwości predykcyjne w porównaniu z wcześniejszym eksperymentem (dotyczącym pomp zasilających). Porównanie wpływu kroku parametryzacji w ramach eksperymentów na sprężarkach zasilających, zgodnie z oczekiwaniami, dało znaczącą poprawę jakości predykcji. Automatyzacja procesu inżynierii danych wymaga od użytkowników wprowadzania dobrej jakości danych wykorzystywanych później do analizy (np. do etykietowania czasów usterek, postojów). Dane generowane maszynowo mają natomiast tę zaletę, iż mają stałą strukturę oraz są generowane w znaczących ilościach. Dzięki temu ewentualne braki lub pomyłki w danych z systemów informatycznych mogą być kompensowane dużą liczbą danych z systemów przemysłowych. Zastosowanie powyższych rozwiązań w zadaniu automatyzacji procesu budowania modeli w kontekście uzyskanych wyników dla agregatów sprężarek natleniających pozwala na potwierdzenie postawionej tezy:

**Teza 3:** *Proces inżynierii danych i tworzenia modeli predykcyjnych oparty na analizie danych generowanych maszynowo z urządzeń przemysłowych może zostać zautomatyzowany dla zastosowania względem nowych urządzeń, zachowując zbliżone zdolności predykcyjne*

## 5.2 Możliwe kierunki rozwoju

Na etapie prac związanych z wytrenowaniem modelu wydaje się być otwartym temat dalszej optymalizacji procesu predykcji możliwych awarii poprzez metody selekcji i ekstrakcji cech. Możliwym ulepszeniem systemu mogłoby być zastosowanie kilku modeli sygnałów w zależności od wykrytego stanu urządzenia (np. uruchamianie, praca, wyłączenie). Takie rozwiązanie bez wątpienia zwiększyłoby jakość odwzorowywania sygnału. Innym ulepszeniem w obszarze inżynierii danych mogłaby być selekcja zbioru treningowego w taki sposób, aby składał się on z potencjalnie bezawaryjnych okresów czasu na podstawie wstępnych wyników predykcji usterek. Takie usprawnienie mogłoby być zrealizowane poprzez analizę sygnałów procesowych z pewnego rodzaju sprzężeniem zwrotnym lub poprzez wnioskowanie na podstawie zarejestrowanych usterek. Proponowane ulepszenie zwiększyłoby zdolności predykcyjne modelu w kontekście wykrywania awarii.

Zakres predykcji obejmujący wykrywanie usterek krytycznych oraz awarii czujników jest wystarczający w kontekście niniejszej pracy, jednak istnieje możliwość uzupełnienia systemu o modele oparte na innych metodach (np. system eksperymentalny, klasyfikatory) zwiększające spektrum wykrywanych zdarzeń. W szczególności, istotnym uzupełnieniem proponowanej metody mogłaby być analiza trendów dla sygnałów nieskorelowanych z innymi. Przykładowo analiza ciśnienia oleju (pomiar słabo skorelowany z pozostałymi) powinna wskazywać na zanieczyszczenia filtrów w sytuacji, gdy wymagają one wymiany.

Zastosowanie algorytmów operujących na szeregach czasowych miało istotny wpływ na jakość generowanych przez model wyników. Potencjalnym elementem rozwoju jest niewątpliwie zastosowanie podobnych metod w celu przetworzenia lub interpretacji generowanych wyników na wyjściu modelu.

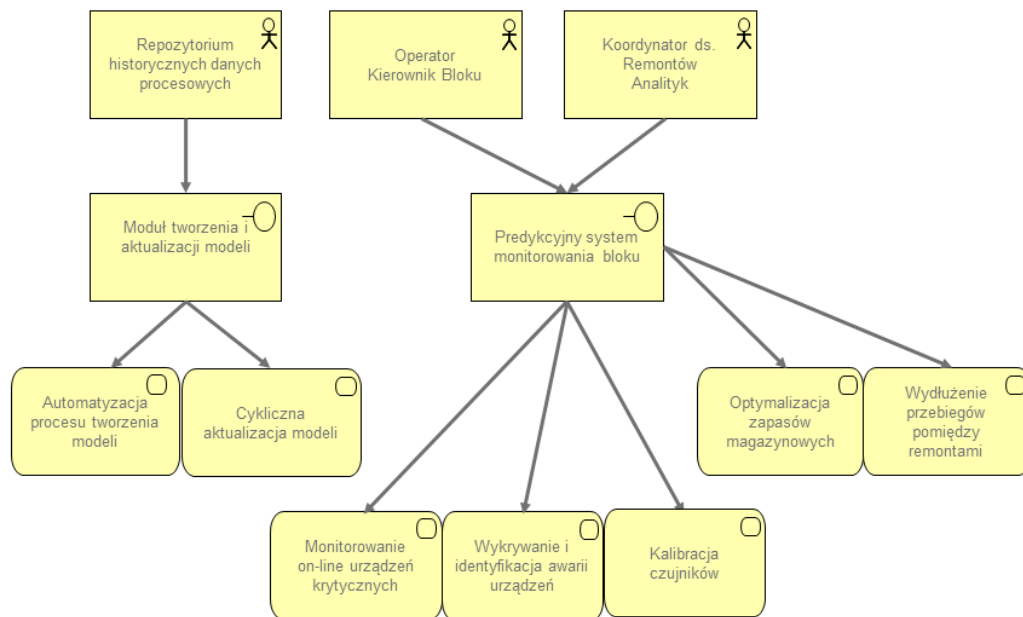
## 5.3 Aspekt wdrożeniowy

Przeprowadzone badania i prace rozwojowe pozwoliły na realizację projektu w formie potwierdzenia zasadności koncepcji (ang. *Proof of concept*), potwierdzającej potencjał wdrożeniowy opracowanej metody. Wytworzonymi produktami umożliwiającymi osadzenie projektu w środowisku produkcyjnym są:

- Moduł generujący modele predykcyjne dla urządzeń energetycznych, zasilany historycznymi danymi procesowymi oraz wsadowymi informacjami z systemów informatycznych o zaszłych awariach i usterkach. Przepływ pracy opracowany w środowisku KNIME może z łatwością zostać przeniesiony do języka programowania (np. Python) oraz do wersji serwerowej platformy KNIME, gdzie modele można przechowywać w formacie PMML.
- Moduł operujący na bieżących danych procesowych i przetwarzający wyniki zwracane przez utworzone modele.
- Interfejs użytkownika. Warstwa prezentacji jest bardzo istotnym elementem całego systemu. Na obecnym etapie projektowym w celach wizualizacji wyników wykorzystano oprogramowanie PowerBI.

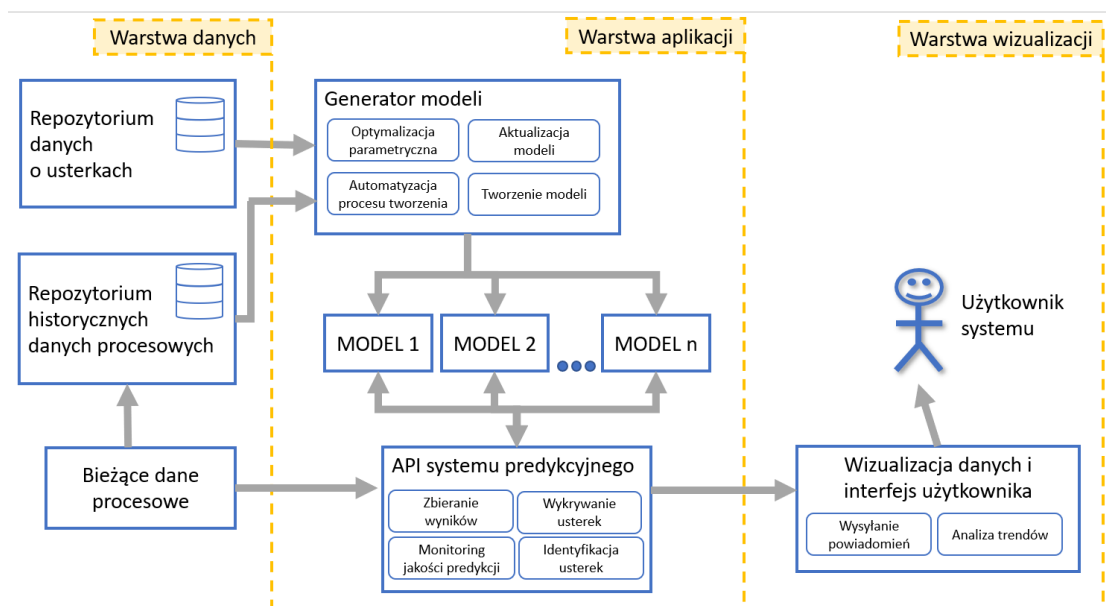
Zidentyfikowane korzyści dla przedsiębiorstwa płynące z zastosowanych rozwiązań z obszaru predykcyjnego utrzymania ruchu wyczerpująco opisano w części teoretycznej. W kontekście zakresu funkcjonalnego proponowanego systemu na rys. 5.1 zmapowano funkcje systemu na wspierane czynności techniczne. Z uwagi na duży potencjał analityczny rozwiązanie ma wiele przypadków użycia. Może być używane przez użytkowników nadzorujących pracę bloków energetycznych, gdzie główne zastosowanie to monitoring online urządzeń oraz powiadomienia o potencjalnych usterkach. Istotnym zastosowaniem może być również wykorzystanie systemu przez eksperta ds. remontów do zadań planistycznych i diagnostycznych. Przykładowymi zadaniami mogą być ujęcie oceny stanu technicznego urządzeń przy planowaniu remontów (wpływ na zwiększenie lub zmniejszenie zakresu prac) oraz ocena wpływu prac remontowych na parametry urządzenia. Realizację powyższych zadań ułatwia zrozumiały schemat działania metody opierający się na analizie odchyleń dla konkretnych sygnałów. W przypadku zmiany obserwowanych pomiarów, takich jak drgania czy temperatura, wartości te same w sobie określają zmianę stanu technicznego urządzenia (zwiększenie się poziomu wibracji lub temperatury np. łożyska świadczy o pogorszeniu stanu technicznego urządzenia).

Osadzenie powstałych elementów rozprawy w środowisku produkcyjnym wymaga dostosowania architektury systemu do wymagań bezpieczeństwa zgodnie



Rysunek 5.1: Architektura biznesowa rozwiązania

z wewnętrznymi i ustawowymi regulacjami. Innym warunkiem koniecznym jest powstanie bazy danych będącej repozytorium danych procesowych, dostępnych w sieci informatycznej. Propozycję koncepcji architektury rozwiązania z podziałem na warstwy danych, aplikacyjną i wizualizacji przedstawiono na rys. 5.2. Moduł tworzący modele predykcyjne zasilany jest danymi procesowymi z repozytorium oraz danymi o awariach. Wytworzone modele są wykorzystywane przez moduł produkcyjny, który w powtarzalnych cyklach pobiera wektor danych procesowych dla aktualnego znacznika czasowego i analizuje odpowiedź modelu predykcyjnego powiązanego z danym urządzeniem. Wyniki zwracane przez model są interpretowane i prezentowane w warstwie wizualizacji. Prezentacja i wizualizacja powinna pozwalać na analizę trendów, eksponować sytuacje awaryjne i wysyłać powiadomienia w postaci e-maili, sms-ów w przypadkach potencjalnych sytuacji awaryjnych.



Rysunek 5.2: Koncepcja architektury systemu uwzględniająca opracowane w trakcie realizacji rozprawy elementy środowiska predykcyjnego utrzymania ruchu

**Spis publikacji Autora**

1. Moleda Marek, Dariusz Mrozek. "Big data in power generation." International Conference: Beyond Databases, Architectures and Structures. Springer, Cham, 2019. Punktacja MNiSW: 15 pkt.
2. Moleda Marek, Alina Momot, Dariusz Mrozek. "Predictive maintenance of boiler feed water pumps using SCADA data." *Sensors* 20.2 (2020): 571. Punktacja MNiSW: 100 pkt. Impact Factor: 3.275
3. Moleda Marek, Alina Momot, Dariusz Mrozek. "Regression Methods for Detecting Anomalies in Flue Gas Desulphurization Installations in Coal-Fired Power Plants Based on Sensor Data." International Conference on Computational Science (ICCS). Springer, Cham, 2020. Punktacja MNiSW: 140 pkt.
4. Moleda, Marek, Alina Momot, Dariusz Mrozek. "Concept Drift and Avoiding its Negative Effects in Predictive Modeling of Failures of Electricity Production Units in Power Plants." 2020 28th International Symposium on Modeling, Analysis, and Simulation of Computer and Telecommunication Systems (MASCOTS). IEEE, 2020. Punktacja MNiSW: 140 pkt.
5. Moleda, Marek, Dariusz Mrozek, Weiping Ding. "Evolution of maintenance approaches towards smart power industry - a review". *Journal of Engineering Applications of Artificial Intelligence* (w trakcie recenzji). Punktacja MNiSW: 140 pkt. Impact Factor: 6.212

# Bibliografia

- [1] E. D. Chris Coleman, Satish Damodaran, “Predictive maintenance and the smart factory.” <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/process-and-operations/us-cons-predictive-maintenance.pdf>, 2017. Last accessed 15 Apr 2021.
- [2] S. Bradbury, B. Carpizo, M. Gentzel, D. Horah, and J. Thibert, “Digitally enabled reliability: Beyond predictive maintenance.” <https://www.mckinsey.com/business-functions/operations/our-insights/digitally-enabled-reliability-beyond-predictive-maintenance#>, 2018. Last accessed 15 Apr 2021.
- [3] IoT-analytics, “Industrial AI Market Report 2020-2025.” <https://iot-analytics.com/the-top-10-industrial-ai-use-cases/>, 2019. Last accessed 15 Apr 2021.
- [4] M. M. Mark Haarman, “Predictive Maintenance 4.0 Beyond the hype: PdM 4.0 delivers results.” <https://www.pwc.be/en/documents/20180926-pdm40-beyond-the-hype-report.pdf>, 2018. Last accessed 15 Apr 2021.
- [5] M. Moleda and D. Mrozek, “Big data in power generation,” in *International Conference: Beyond Databases, Architectures and Structures*, pp. 15–29, Springer, 2019.
- [6] Y. Chen, “Integrated and intelligent manufacturing: perspectives and enablers,” *Engineering*, vol. 3, no. 5, pp. 588–595, 2017.

- [7] “Maintenance - maintenance terminology,” standard EN13306, European Committee for Standardization, Brussels, 2010.
- [8] “Predictive Maintenance in Manufacturing Overview.” <https://docs.microsoft.com/en-us/previous-versions/azure/industry-marketing/manufacturing/predictive-maintenance-overview>. Last accessed 14 Apr 2021.
- [9] R. K. Mobley, *An introduction to predictive maintenance*. Oxford: Elsevier, 2002.
- [10] A. D. Carter, *Mechanical reliability*. Macmillan International Higher Education, 2016.
- [11] R. F. Stapelberg, *Handbook of reliability, availability, maintainability and safety in engineering design*. Springer Science & Business Media, 2009.
- [12] C. M. F. Lapa, C. M. N. Pereira, and M. P. de Barros, “A model for preventive maintenance planning by genetic algorithms based in cost and reliability,” *Reliability Engineering & System Safety*, vol. 91, no. 2, pp. 233–240, 2006.
- [13] C. R. Cassady and E. Kutanoglu, “Minimizing job tardiness using integrated preventive maintenance planning and production scheduling,” *IIE transactions*, vol. 35, no. 6, pp. 503–513, 2003.
- [14] C. R. Cassady and E. Kutanoglu, “Integrating preventive maintenance planning and production scheduling for a single machine,” *IEEE Transactions on reliability*, vol. 54, no. 2, pp. 304–309, 2005.
- [15] V. Radhakrishnan, M. Ramasamy, H. Zabiri, V. Do Thanh, N. Tahir, H. Mukhtar, M. Hamdi, and N. Ramli, “Heat exchanger fouling model and preventive maintenance scheduling tool,” *Applied Thermal Engineering*, vol. 27, no. 17-18, pp. 2791–2802, 2007.
- [16] T. E. Hidayanto, H. S. Nugroho, and M. M. Ardi, “Reliability analysis for preventive maintenance of salt crusher machine,” *International Journal of*



- 
- Mechanical Engineering and Robotics Research*, vol. 8, no. 2, pp. 297–303, 2019.
- [17] R.-Y. Kwak, A. Takakusagi, J.-Y. Sohn, S. Fujii, and B.-Y. Park, “Development of an optimal preventive maintenance model based on the reliability assessment for air-conditioning facilities in office buildings,” *Building and environment*, vol. 39, no. 10, pp. 1141–1156, 2004.
- [18] F. Carazas and G. de Souza, “Availability analysis of gas turbines used in power plants,” *International Journal of Thermodynamics*, vol. 12, no. 1, pp. 28–37, 2009.
- [19] Z. Tian, T. Jin, B. Wu, and F. Ding, “Condition based maintenance optimization for wind power generation systems under continuous monitoring,” *Renewable Energy*, vol. 36, no. 5, pp. 1502–1509, 2011.
- [20] W. Y. Yun and A. J. Endharta, “A preventive replacement policy based on system critical condition,” *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, vol. 230, no. 1, pp. 93–100, 2016.
- [21] A. Heng, A. C. Tan, J. Mathew, N. Montgomery, D. Banjevic, and A. K. Jardine, “Intelligent condition-based prediction of machinery reliability,” *Mechanical Systems and Signal Processing*, vol. 23, no. 5, pp. 1600–1614, 2009.
- [22] I. H. Afefy, “Reliability-centered maintenance methodology and application: a case study,” *Engineering*, vol. 2, no. 11, pp. 863–873, 2010.
- [23] M. Bevilacqua and M. Braglia, “The analytic hierarchy process applied to maintenance strategy selection,” *Reliability Engineering & System Safety*, vol. 70, no. 1, pp. 71–83, 2000.
- [24] L. Swanson, “Linking maintenance strategies to performance,” *International journal of production economics*, vol. 70, no. 3, pp. 237–244, 2001.
- [25] M. Nouri, B. K. Fussell, B. L. Ziniti, and E. Linder, “Real-time tool wear monitoring in milling using a cutting condition independent method,” *In-*

- ternational Journal of Machine Tools and Manufacture*, vol. 89, pp. 1–13, 2015.
- [26] C. Yang, J. Liu, Y. Zeng, and G. Xie, “Real-time condition monitoring and fault detection of components based on machine-learning reconstruction model,” *Renewable energy*, vol. 133, pp. 433–441, 2019.
- [27] J. Tautz-Weinert and S. J. Watson, “Using SCADA data for wind turbine condition monitoring—a review,” *IET Renewable Power Generation*, vol. 11, no. 4, pp. 382–394, 2016.
- [28] Y. Feng, Y. Qiu, C. J. Crabtree, H. Long, and P. J. Tavner, “Monitoring wind turbine gearboxes,” *Wind Energy*, vol. 16, no. 5, pp. 728–740, 2013.
- [29] Y. Qiu, Y. Feng, P. Tavner, P. Richardson, G. Erdos, and B. Chen, “Wind turbine SCADA alarm analysis for improving reliability,” *Wind Energy*, vol. 15, no. 8, pp. 951–966, 2012.
- [30] Y. Qiu, L. Chen, Y. Feng, and Y. Xu, “An approach of quantifying gear fatigue life for wind turbine gearboxes using supervisory control and data acquisition data,” *Energies*, vol. 10, no. 8, p. 1084, 2017.
- [31] Y. Qiu, Y. Feng, J. Sun, W. Zhang, and D. Infield, “Applying thermophysics for wind turbine drivetrain fault diagnosis using SCADA data,” *IET Renewable Power Generation*, vol. 10, no. 5, pp. 661–668, 2016.
- [32] G. Shen and T. Li, “Infrared thermography for high-temperature pressure pipe,” *Insight-Non-Destructive Testing and Condition Monitoring*, vol. 49, no. 3, pp. 151–153, 2007.
- [33] K. E. Cramer and W. P. Winfree, “Thermographic imaging of material loss in boiler water-wall tubing by application of scanning line source,” in *Non-destructive Evaluation of Highways, Utilities, and Pipelines IV*, vol. 3995, pp. 600–609, International Society for Optics and Photonics, 2000.
- [34] M. J. Ralph, “Power plant thermography—wide range of applications,” in *Information Proceedings*, vol. 135, 2004.

- 
- [35] S. Gallardo-Saavedra, L. Hernández-Callejo, and O. Duque-Perez, “Technological review of the instrumentation used in aerial thermographic inspection of photovoltaic plants,” *Renewable and Sustainable Energy Reviews*, vol. 93, pp. 566–579, 2018.
- [36] A. K. V. de Oliveira, M. Aghaei, and R. Rütther, “Aerial infrared thermography for low-cost and fast fault detection in utility-scale PV power plants,” *Solar Energy*, vol. 211, pp. 712–724, 2020.
- [37] G. Acciani, G. Simione, and S. Vergura, “Thermographic analysis of photovoltaic panels,” in *International Conference on Renewable Energies and Power Quality (ICREPQ’10)*, pp. 23–25, 2010.
- [38] D. Kim, J. Youn, and C. Kim, “Automatic fault recognition of photovoltaic modules based on statistical analysis of UAV thermography,” *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 42, p. 179, 2017.
- [39] M. Barrett and K. Williams, “Oil analysis,” *Materials Evaluation*, vol. 70, no. 1, pp. 32–40, 2012.
- [40] S. S. Kalligeros, “Predictive maintenance of hydraulic lifts through lubricating oil analysis,” *Machines*, vol. 2, no. 1, pp. 1–12, 2014.
- [41] H. Raposo, J. T. Farinha, I. Fonseca, and L. A. Ferreira, “Condition monitoring with prediction based on Diesel engine oil analysis: A case study for urban buses,” in *Actuators*, vol. 8, p. 14, Multidisciplinary Digital Publishing Institute, 2019.
- [42] H.-B. Jun, D. Kiritsis, M. Gambera, and P. Xirouchakis, “Predictive algorithm to determine the suitable time to change automotive engine oil,” *Computers & Industrial Engineering*, vol. 51, no. 4, pp. 671–683, 2006.
- [43] D. Scott and V. Westcott, “Predictive maintenance by ferrography,” *Wear*, vol. 44, no. 1, pp. 173–182, 1977.
- [44] R. J. Dalley, “An overview of ferrography and its use in maintenance,” in *Predictive Maintenance Seminar*, 16p, 1991.

- [45] R. S. Beebe and R. S. Beebe, *Predictive maintenance of pumps using condition monitoring*. Elsevier, 2004.
- [46] V. Saxena, N. Chowdhury, and S. Devendiran, “Assessment of gearbox fault detection using vibration signal analysis and acoustic emission technique,” *Journal of Mechanical and Civil Engineering*, vol. 7, no. 4, pp. 52–60, 2013.
- [47] S. Dudić, I. Ignjatović, D. Šešlija, V. Blagojević, and M. Stojiljković, “Leakage quantification of compressed air using ultrasound and infrared thermography,” *Measurement*, vol. 45, no. 7, pp. 1689–1694, 2012.
- [48] J. Murovec, L. Čurović, T. Novaković, and J. Prezelj, “Psychoacoustic approach for cavitation detection in centrifugal pumps,” *Applied Acoustics*, vol. 165, p. 107323, 2020.
- [49] S. Nandi, H. A. Toliyat, and X. Li, “Condition monitoring and fault diagnosis of electrical motors—a review,” *IEEE transactions on energy conversion*, vol. 20, no. 4, pp. 719–729, 2005.
- [50] C. Lanham, “Understanding the tests that are recommended for electric motor predictive maintenance,” *Baker Instrument Company*, 2002.
- [51] D. Miljković, “Brief review of motor current signature analysis,” *HDKBR Info magazin*, vol. 5, no. 1, pp. 14–26, 2015.
- [52] E. L. Bonaldi, L. E. d. L. de Oliveira, J. G. B. da Silva, G. Lambert-Torres, and L. E. B. da Silva, “Predictive maintenance by electrical signature analysis to induction motors,” in *Induction Motors-Modelling and Control*, In-techOpen, 2012.
- [53] W. T. Thomson, R. J. Gilmore, *et al.*, “Motor current signature analysis to detect faults in induction motor drives-fundamentals, data interpretation, and industrial case histories,” in *Proceedings of the 32nd turbomachinery Symposium*, Texas A&M University. Turbomachinery Laboratories, 2003.
- [54] D. Granda, W. G. Aguilar, D. Arcos-Aviles, and D. Sotomayor, “Broken bar diagnosis for squirrel cage induction motors using frequency analysis based

- 
- on MCSA and continuous wavelet transform,” *Mathematical and Computational Applications*, vol. 22, no. 2, p. 30, 2017.
- [55] S. Guedidi, S. Zouzou, W. Laala, M. Sahraoui, and K. Yahia, “Broken bar fault diagnosis of induction motors using MCSA and neural network,” in *8th IEEE Symposium on Diagnostics for Electrical Machines, Power Electronics & Drives*, pp. 632–637, IEEE, 2011.
- [56] M. E. H. Benbouzid, “A review of induction motors signature analysis as a medium for faults detection,” *IEEE transactions on industrial electronics*, vol. 47, no. 5, pp. 984–993, 2000.
- [57] A. Singhal and M. A. Khandekar, “Bearing fault detection in induction motor using motor current signature analysis,” *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 2, no. 7, pp. 3258–3264, 2013.
- [58] J. Cameron, W. Thomson, and A. Dow, “Vibration and current monitoring for detecting airgap eccentricity in large induction motors,” in *IEE Proceedings B (Electric Power Applications)*, vol. 133, pp. 155–163, IET, 1986.
- [59] Q. S. Al-Sabbagh and H. E. Alwan, “Detection of static air-gap eccentricity in three phase induction motor by using artificial neural network (ANN),” *Journal of Engineering*, vol. 15, no. 4, 2009.
- [60] G. M. Joksimovic and J. Penman, “The detection of inter-turn short circuits in the stator windings of operating motors,” *IEEE Transactions on Industrial electronics*, vol. 47, no. 5, pp. 1078–1084, 2000.
- [61] A. Stavrou, H. G. Sedding, and J. Penman, “Current monitoring for detecting inter-turn short circuits in induction motors,” *IEEE Transactions on energy conversion*, vol. 16, no. 1, pp. 32–37, 2001.
- [62] H. Eschen, T. Kötter, R. Rodeck, M. Harnisch, and T. Schüppstuhl, “Augmented and virtual reality for inspection and maintenance processes in the aviation industry,” *Procedia manufacturing*, vol. 19, pp. 156–163, 2018.

- [63] C. Legner, C. Nolte, and N. Urbach, “Evaluating mobile business applications in service and maintenance processes: results of a quantitative-empirical study,” 2011.
- [64] Y.-C. Lin, Y.-C. Su, N.-H. Lo, W.-F. Cheung, and Y.-P. Chen, “Application of mobile RFID-based safety inspection management at construction jobsite,” in *Radio Frequency Identification from System to Applications*, IntechOpen, 2013.
- [65] A. K. Jardine and A. H. Tsang, *Maintenance, replacement, and reliability: theory and applications*. CRC press, 2013.
- [66] “Smartlean page.” <https://smartlean.pl/5s/>. Last accessed 5 april 2022.
- [67] “inzynierjakosci page.” <https://inzynierjakosci.pl/2017/11/5-why-opis-przyklad-darmowy-formularz/>. Last accessed 14 april 2022.
- [68] “Kaizen on Leancenter page.” <https://leancenter.pl/bazawiedzy/kaizen>. Last accessed 11 april 2022.
- [69] J. Moubray, *Reliability-centered maintenance*. Oxford: Industrial Press Inc., 2001.
- [70] J. Woodhouse, “Combining the best bits of RCM, RBI, TPM, TQM, Six-Sigma and other ‘solutions’,” *J. Woodhouse.-The Woodhouse Partnership Ltd.-2003*, 2001.
- [71] H. Mirsaedi, A. Fereidunian, S. M. Mohammadi-Hosseininejad, and H. Lesani, “Electricity distribution system maintenance budgeting: A reliability-centered approach,” *IEEE transactions on power delivery*, vol. 33, no. 4, pp. 1599–1610, 2017.
- [72] P. Dehghanian, M. Fotuhi-Firuzabad, F. Aminifar, and R. Billinton, “A comprehensive scheme for reliability centered maintenance in power distribution systems—Part I: Methodology,” *IEEE Transactions on Power Delivery*, vol. 28, no. 2, pp. 761–770, 2013.

- 
- [73] K. Fischer, F. Besnard, and L. Bertling, “Reliability-centered maintenance for wind turbines based on statistical analysis and practical experience,” *IEEE Transactions on Energy Conversion*, vol. 27, no. 1, pp. 184–195, 2011.
- [74] H. Dzulyadain, E. Budiasih, and F. T. D. Atmaji, “Proposed maintenance policy using reliability centered maintenance (RCM) method with fmeca analysis: A case study of automotive industry,” in *IOP Conference Series: Materials Science and Engineering*, vol. 1034, p. 012111, IOP Publishing, 2021.
- [75] D. H. Stamatis, *Failure mode and effect analysis: FMEA from theory to execution*. Quality Press, 2003.
- [76] H. Arabian-Hoseynabadi, H. Oraee, and P. Tavner, “Failure modes and effects analysis (FMEA) for wind turbines,” *International Journal of Electrical Power & Energy Systems*, vol. 32, no. 7, pp. 817–824, 2010.
- [77] “ReliaSoft XFMEA software.” <https://www.reliasoft.com/products/xfmea-failure-mode-effects-analysis-fmea-software>. Last accessed 20 Apr 2021.
- [78] “Reliability Workbench software, Isograph.” <https://www.isograph.com/software/reliability-workbench/fmeca-software/>. Last accessed 20 Apr 2021.
- [79] P. Weber, G. Medina-Oliva, C. Simon, and B. Iung, “Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas,” *Engineering Applications of Artificial Intelligence*, vol. 25, no. 4, pp. 671–682, 2012.
- [80] S. Rastayesh, S. Bahrebar, F. Blaabjerg, D. Zhou, H. Wang, and J. Dalsgaard Sørensen, “A system engineering approach using FMEA and Bayesian Network for risk analysis—a case study,” *Sustainability*, vol. 12, no. 1, p. 77, 2020.

- [81] A. García and E. Gilabert, “Mapping FMEA into Bayesian Networks.,” *International Journal of Performability Engineering*, vol. 7, no. 6, pp. 525–537, 2011.
- [82] S. Antomarioni, M. M. Bellinello, M. Bevilacqua, F. E. Ciarapica, R. F. da Silva, and G. F. M. de Souza, “A data-driven approach to extend failure analysis: A framework development and a case study on a hydroelectric power plant,” *Energies*, vol. 13, no. 23, p. 6400, 2020.
- [83] M. Walker, Y. Papadopoulos, D. Parker, H. Lönn, M. Törngren, D. Chen, R. Johansson, and A. Sandberg, “Semi-automatic FMEA supporting complex systems with combinations and sequences of failures,” *SAE International Journal of Passenger Cars-Mechanical Systems*, vol. 2, no. 2009-01-0738, pp. 791–802, 2009.
- [84] N. Hughes, E. Chou, C. J. Price, M. H. Lee, *et al.*, “Automating mechanical FMEA using functional models.,” in *FLAIRS Conference*, pp. 394–398, 1999.
- [85] N. Snooke and C. Price, “Model-driven automated software FMEA,” in *2011 Proceedings-Annual Reliability and Maintainability Symposium*, pp. 1–6, IEEE, 2011.
- [86] M.-A. Filz, J. E. B. Langner, C. Herrmann, and S. Thiede, “Data-driven failure mode and effect analysis (FMEA) to enhance maintenance planning,” *Computers in Industry*, vol. 129, p. 103451, 2021.
- [87] Y. Wang, X. Li, J. Ma, and S. Li, “Fault diagnosis of power transformer based on fault-tree analysis (FTA),” in *IOP Conference Series: Earth and Environmental Science*, vol. 64, p. 012099, IOP Publishing, 2017.
- [88] M. Yazdi, O. Korhan, and S. Daneshvar, “Application of fuzzy fault tree analysis based on modified fuzzy ahp and fuzzy topsis for fire and explosion in the process industry,” *International journal of occupational safety and ergonomics*, vol. 26, no. 2, pp. 319–335, 2020.



- 
- [89] B. Alshboul, D. C. Petriu, *et al.*, “Automatic derivation of fault tree models from sysml models for safety analysis,” *Journal of Software Engineering and Applications*, vol. 11, no. 05, pp. 204–222, 2018.
- [90] C. E. Dickerson, R. Roslan, and S. Ji, “A formal transformation method for automated fault tree generation from a UML activity model,” *IEEE Transactions on Reliability*, vol. 67, no. 3, pp. 1219–1236, 2018.
- [91] P. Feiler and J. Delange, “Automated fault tree analysis from aadl models,” *ACM SIGAda Ada Letters*, vol. 36, no. 2, pp. 39–46, 2017.
- [92] A. Majdara and T. Wakabayashi, “A new approach for computer-aided fault tree generation,” in *2009 3rd Annual IEEE Systems Conference*, pp. 308–312, IEEE, 2009.
- [93] A. Venceslau, R. Lima, L. A. Guedes, and I. Silva, “Ontology for computer-aided fault tree synthesis,” in *Proceedings of the 2014 IEEE Emerging Technology and Factory Automation (ETFA)*, pp. 1–4, IEEE, 2014.
- [94] M. Solé, V. Muntés-Mulero, A. I. Rana, and G. Estrada, “Survey on models and techniques for root-cause analysis,” *arXiv preprint arXiv:1701.08546*, 2017.
- [95] W. E. Vesely, F. F. Goldberg, N. H. Roberts, and D. F. Haasl, “Fault tree handbook,” tech. rep., Nuclear Regulatory Commission Washington DC, 1981.
- [96] S. M. Lavasani, A. Zendegani, and M. Celik, “An extension to fuzzy fault tree analysis (FFTA) application in petrochemical process industry,” *Process Safety and Environmental Protection*, vol. 93, pp. 75–88, 2015.
- [97] S. Shi, B. Jiang, and X. Meng, “Assessment of gas and dust explosion in coal mines by means of fuzzy fault tree analysis,” *International Journal of Mining Science and Technology*, vol. 28, no. 6, pp. 991–998, 2018.
- [98] A. Sarkar, S. C. Panja, and D. Das, “Fault tree analysis of rukhia gas turbine power plant,” *HKIE Transactions*, vol. 22, no. 1, pp. 32–56, 2015.

- [99] A. Syberfeldt, O. Danielsson, M. Holm, and L. Wang, “Dynamic operator instructions based on augmented reality and rule-based expert systems,” *Procedia Cirp*, vol. 41, pp. 346–351, 2016.
- [100] W. Friedrich, D. Jahn, and L. Schmidt, “Arvika-augmented reality for development, production and service.,” in *ISMAR*, vol. 2, pp. 3–4, Citeseer, 2002.
- [101] J. Cerezo, J. Kubelka, R. Robbes, and A. Bergel, “Building an expert recommender chatbot,” in *2019 IEEE/ACM 1st International Workshop on Bots in Software Engineering (BotSE)*, pp. 59–63, IEEE, 2019.
- [102] S.-H. Liao, “Expert system methodologies and applications—a decade review from 1995 to 2004,” *Expert systems with applications*, vol. 28, no. 1, pp. 93–103, 2005.
- [103] S. Leo Kumar, “Knowledge-based expert system in manufacturing planning: state-of-the-art review,” *International Journal of Production Research*, vol. 57, no. 15-16, pp. 4766–4790, 2019.
- [104] S. Motlaghi, F. Jalali, and M. N. Ahmadabadi, “An expert system design for a crude oil distillation column with the neural networks model and the process optimization using genetic algorithm framework,” *Expert systems with applications*, vol. 35, no. 4, pp. 1540–1545, 2008.
- [105] R. Isermann, “Process fault detection based on modeling and estimation methods—a survey,” *Automatica*, vol. 20, no. 4, pp. 387–404, 1984.
- [106] M. A. Eissa, M. S. Ahmed, R. Darwish, and A. Bassiuny, “Improved fuzzy Luenberger observer-based fault detection for bldc motor,” in *2015 Tenth International Conference on Computer Engineering & Systems (ICCES)*, pp. 167–174, IEEE, 2015.
- [107] P. Jain, L. Jian, J. Poon, C. Spanos, S. R. Sanders, J.-X. Xu, and S. K. Panda, “A Luenberger observer-based fault detection and identification scheme for photovoltaic dc-dc converters,” in *IECON 2017-43rd Annual Conference of the IEEE Industrial Electronics Society*, pp. 5015–5020, IEEE, 2017.

- 
- [108] S. Razvarz, R. Jafari, and A. Gegov, “Leakage detection in pipeline based on second order extended Kalman filter observer,” in *Flow Modelling and Control in Pipeline Systems*, pp. 161–174, Springer, 2021.
- [109] K. Reif and R. Unbehauen, “The extended Kalman filter as an exponential observer for nonlinear systems,” *IEEE Transactions on Signal processing*, vol. 47, no. 8, pp. 2324–2328, 1999.
- [110] R. Isermann, “Fault diagnosis of machines via parameter estimation and knowledge processing—tutorial paper,” *Automatica*, vol. 29, no. 4, pp. 815–835, 1993.
- [111] R. J. Patton and J. Chen, “A review of parity space approaches to fault diagnosis,” *IFAC Proceedings Volumes*, vol. 24, no. 6, pp. 65–81, 1991.
- [112] E. Chow and A. Willsky, “Analytical redundancy and the design of robust failure detection systems,” *IEEE Transactions on automatic control*, vol. 29, no. 7, pp. 603–614, 1984.
- [113] M.-A. Massoumnia and W. E. V. Velde, “Generating parity relations for detecting and identifying control system component failures,” *Journal of Guidance, Control, and Dynamics*, vol. 11, no. 1, pp. 60–65, 1988.
- [114] J. Gertler and D. Singer, “A new structural framework for parity equation-based failure detection and isolation,” *Automatica*, vol. 26, no. 2, pp. 381–388, 1990.
- [115] J. Gertler, Q. Luo, K. Anderson, and X. Fang, “Diagnosis of plant failures using orthogonal parity equations,” *IFAC Proceedings Volumes*, vol. 23, no. 8, pp. 361–366, 1990.
- [116] Z. Gao, C. Cecati, and S. X. Ding, “A survey of fault diagnosis and fault-tolerant techniques—Part II: Fault diagnosis with knowledge-based and hybrid/active approaches,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 6, pp. 3768–3774, 2015.

- [117] K. Villez, “Qualitative path estimation: A fast and reliable algorithm for qualitative trend analysis,” *AIChE Journal*, vol. 61, no. 5, pp. 1535–1546, 2015.
- [118] F. Flehmig, R. Watzdorf, and W. Marquardt, “Identification of trends in process measurements using the wavelet transform,” *Computers & chemical engineering*, vol. 22, pp. S491–S496, 1998.
- [119] R. Rengaswamy and V. Venkatasubramanian, “A syntactic pattern-recognition approach for process monitoring and fault diagnosis,” *Engineering Applications of Artificial Intelligence*, vol. 8, no. 1, pp. 35–51, 1995.
- [120] N. Sammaknejad, B. Huang, A. Fatehi, Y. Miao, F. Xu, and A. Espejo, “Adaptive monitoring of the process operation based on symbolic episode representation and hidden Markov models with application toward an oil sand primary separation,” *Computers & chemical engineering*, vol. 71, pp. 281–297, 2014.
- [121] J. C. Wong, K. A. McDonald, and A. Palazoglu, “Classification of process trends based on fuzzified symbolic representation and hidden Markov models,” *Journal of Process Control*, vol. 8, no. 5-6, pp. 395–408, 1998.
- [122] F. Yamanaka and T. Nishiya, “Application of the intelligent alarm system for the plant operation,” *Computers & chemical engineering*, vol. 21, pp. S625–S630, 1997.
- [123] R. Rengaswamy, T. Hägglund, and V. Venkatasubramanian, “A qualitative shape analysis formalism for monitoring control loop performance,” *Engineering Applications of Artificial Intelligence*, vol. 14, no. 1, pp. 23–33, 2001.
- [124] M. B. Shams, H. Budman, and T. Duever, “Fault detection, identification and diagnosis using CUSUM based PCA,” *Chemical Engineering Science*, vol. 66, no. 20, pp. 4488–4498, 2011.
- [125] W. Li, M. Peng, and Q. Wang, “Improved PCA method for sensor fault detection and isolation in a nuclear power plant,” *Nuclear Engineering and Technology*, vol. 51, no. 1, pp. 146–154, 2019.

- 
- [126] W. Li, M. Peng, and Q. Wang, "Fault identification in PCA method during sensor condition monitoring in a nuclear power plant," *Annals of Nuclear Energy*, vol. 121, pp. 135–145, 2018.
- [127] P. F. Odgaard, B. Lin, and S. B. Jorgensen, "Observer and data-driven-model-based fault detection in power plant coal mills," *IEEE Transactions on Energy Conversion*, vol. 23, no. 2, pp. 659–668, 2008.
- [128] F. Chu, F. Wang, X. Wang, and S. Zhang, "A kernel partial least squares method for gas turbine power plant performance prediction," in *2012 24th Chinese Control and Decision Conference (CCDC)*, pp. 3170–3174, IEEE, 2012.
- [129] J. Ritchie and D. Flynn, "Partial least squares for power plant performance monitoring," *IFAC Proceedings Volumes*, vol. 36, no. 20, pp. 243–248, 2003.
- [130] K.-Y. Chen, L.-S. Chen, M.-C. Chen, and C.-L. Lee, "Using SVM based method for equipment fault detection in a thermal power plant," *Computers in industry*, vol. 62, no. 1, pp. 42–50, 2011.
- [131] P. Santos, L. F. Villa, A. Reñones, A. Bustillo, and J. Maudes, "An SVM-based solution for fault detection in wind turbines," *Sensors*, vol. 15, no. 3, pp. 5627–5648, 2015.
- [132] H. Langseth and L. Portinale, "Applications of bayesian networks in reliability analysis," in *Bayesian Network Technologies: Applications and Graphical Models*, pp. 84–102, IGI Global, 2007.
- [133] J. V. Candy, *Bayesian signal processing: classical, modern, and particle filtering methods*, vol. 54. John Wiley & Sons, 2016.
- [134] S. Haykin and N. Network, "A comprehensive foundation," *Neural networks*, vol. 2, no. 2004, p. 41, 2004.
- [135] M. Schlechtingen and I. F. Santos, "Comparative analysis of neural network and regression based condition monitoring approaches for wind turbine fault detection," *Mechanical systems and signal processing*, vol. 25, no. 5, pp. 1849–1875, 2011.

- [136] D. Benazzouz, S. Benammar, S. Adjerid, *et al.*, “Fault detection and isolation based on neural networks case study: steam turbine,” *Energy and Power Engineering*, vol. 3, no. 4, pp. 513–516, 2011.
- [137] Z. Tang, Z. Chen, Y. Bao, and H. Li, “Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring,” *Structural Control and Health Monitoring*, vol. 26, no. 1, p. e2296, 2019.
- [138] M. De Benedetti, F. Leonardi, F. Messina, C. Santoro, and A. Vasilakos, “Anomaly detection and predictive maintenance for photovoltaic systems,” *Neurocomputing*, vol. 310, pp. 59–68, 2018.
- [139] N. Fadzail and S. M. Zali, “Fault detection and classification in wind turbine by using artificial neural network,” *International Journal of Power Electronics and Drive Systems*, vol. 10, no. 3, p. 1687, 2019.
- [140] E. Rakhshani, I. Sariri, and K. Rouzbehi, “Application of data mining on fault detection and prediction in boiler of power plant using artificial neural network,” in *2009 International Conference on Power Engineering, Energy and Electrical Drives*, pp. 473–478, IEEE, 2009.
- [141] X. Deng, X. Tian, and S. Chen, “Modified kernel Principal Component Analysis based on local structure analysis and its application to nonlinear process fault diagnosis,” *Chemometrics and Intelligent Laboratory Systems*, vol. 127, pp. 195–209, 2013.
- [142] O. Janssens, V. Slavkovikj, B. Vervisch, K. Stockman, M. Loccufier, S. Verstockt, R. Van de Walle, and S. Van Hoecke, “Convolutional neural network based fault detection for rotating machinery,” *Journal of Sound and Vibration*, vol. 377, pp. 331–345, 2016.
- [143] V. Zilvan, A. Ramdan, E. Suryawati, R. B. S. Kusumo, D. Krisnandi, and H. F. Pardede, “Denoising convolutional variational autoencoders-based feature learning for automatic detection of plant diseases,” in *2019 3rd International Conference on Informatics and Computational Sciences (ICICoS)*, pp. 1–6, IEEE, 2019.

- 
- [144] P. Park, P. D. Marco, H. Shin, and J. Bang, “Fault detection and diagnosis using combined autoencoder and long short-term memory network,” *Sensors*, vol. 19, no. 21, p. 4612, 2019.
- [145] D. Y. Oh and I. D. Yun, “Residual error based anomaly detection using auto-encoder in SMD machine sound,” *Sensors*, vol. 18, no. 5, p. 1308, 2018.
- [146] E. Principi, D. Rossetti, S. Squartini, and F. Piazza, “Unsupervised electric motor fault detection by using deep autoencoders,” *IEEE/CAA Journal of Automatica Sinica*, vol. 6, no. 2, pp. 441–451, 2019.
- [147] T. Tagawa, Y. Tadokoro, and T. Yairi, “Structured denoising autoencoder for fault detection and analysis,” in *Asian Conference on Machine Learning*, pp. 96–111, PMLR, 2015.
- [148] X. Wu, G. Jiang, X. Wang, P. Xie, and X. Li, “A multi-level-denoising autoencoder approach for wind turbine fault detection,” *IEEE Access*, vol. 7, pp. 59376–59387, 2019.
- [149] Y. Qi, C. Shen, D. Wang, J. Shi, X. Jiang, and Z. Zhu, “Stacked sparse autoencoder-based deep network for fault diagnosis of rotating machinery,” *IEEE Access*, vol. 5, pp. 15066–15079, 2017.
- [150] H. Shi, L. Guo, S. Tan, and X. Bai, “Rolling bearing initial fault detection using long short-term memory recurrent network,” *IEEE Access*, vol. 7, pp. 171559–171569, 2019.
- [151] H. C. Cho, J. Knowles, M. S. Fadali, and K. S. Lee, “Fault detection and isolation of induction motors using recurrent neural networks and dynamic Bayesian modeling,” *IEEE Transactions on Control Systems Technology*, vol. 18, no. 2, pp. 430–437, 2009.
- [152] L. Xiang, P. Wang, X. Yang, A. Hu, and H. Su, “Fault detection of wind turbine based on SCADA data analysis using cnn and lstm with attention mechanism,” *Measurement*, vol. 175, p. 109094, 2021.

- [153] L. Hong and J. S. Dhupia, “A time domain approach to diagnose gearbox fault based on measured vibration signals,” *Journal of Sound and Vibration*, vol. 333, no. 7, pp. 2164–2180, 2014.
- [154] U.-P. Chong *et al.*, “Signal model-based fault detection and diagnosis for induction motors using features of vibration signal in two-dimension domain,” *Strojniški vestnik*, vol. 57, no. 9, pp. 655–666, 2011.
- [155] A. Soualhi, Y. Hawwari, K. Medjaher, G. Clerc, R. Hubert, and F. Guillet, “PHM survey: implementation of signal processing methods for monitoring bearings and gearboxes,” *International Journal of Prognostics and Health Management*, vol. 9, no. 2, p. 0, 2018.
- [156] Z. Gao, C. Cecati, and S. X. Ding, “A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches,” *IEEE transactions on industrial electronics*, vol. 62, no. 6, pp. 3757–3767, 2015.
- [157] J. S. Hunter, “The exponentially weighted moving average,” *Journal of quality technology*, vol. 18, no. 4, pp. 203–210, 1986.
- [158] B. Wu, A. Saxena, T. S. Khawaja, R. Patrick, G. Vachtsevanos, and P. Sparis, “An approach to fault diagnosis of helicopter planetary gears,” in *Proceedings AUTOTESTCON 2004*, pp. 475–481, IEEE, 2004.
- [159] K. Feng, K. Wang, M. Zhang, Q. Ni, and M. J. Zuo, “A diagnostic signal selection scheme for planetary gearbox vibration monitoring under non-stationary operational conditions,” *Measurement Science and Technology*, vol. 28, no. 3, p. 035003, 2017.
- [160] L. C. K. Reuben and D. Mba, “Bearing time-to-failure estimation using spectral analysis features,” *Structural health monitoring*, vol. 13, no. 2, pp. 219–230, 2014.
- [161] X. Gong and W. Qiao, “Bearing fault diagnosis for direct-drive wind turbines via current-demodulated signals,” *IEEE Transactions on Industrial Electronics*, vol. 60, no. 8, pp. 3419–3428, 2013.



- 
- [162] E. Sejdić, I. Djurović, and J. Jiang, “Time–frequency feature representation using energy concentration: An overview of recent advances,” *Digital signal processing*, vol. 19, no. 1, pp. 153–183, 2009.
- [163] M. Cocconcelli, R. Zimroz, R. Rubini, and W. Bartelmus, “STFT based approach for ball bearing fault detection in a varying speed motor,” in *Condition Monitoring of Machinery in Non-Stationary Operations*, pp. 41–50, Springer, 2012.
- [164] Z. Peng and F. Chu, “Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography,” *Mechanical systems and signal processing*, vol. 18, no. 2, pp. 199–221, 2004.
- [165] A. G. Rehorn, E. Sejdić, and J. Jiang, “Fault diagnosis in machine tools using selective regional correlation,” *Mechanical Systems and Signal Processing*, vol. 20, no. 5, pp. 1221–1238, 2006.
- [166] Y. Lei, N. Li, L. Guo, N. Li, T. Yan, and J. Lin, “Machinery health prognostics: A systematic review from data acquisition to rul prediction,” *Mechanical systems and signal processing*, vol. 104, pp. 799–834, 2018.
- [167] F. Camci, K. Medjaher, N. Zerhouni, and P. Nectoux, “Feature evaluation for effective bearing prognostics,” *Quality and reliability engineering international*, vol. 29, no. 4, pp. 477–486, 2013.
- [168] J. Sikorska, M. Hodkiewicz, and L. Ma, “Prognostic modelling options for remaining useful life estimation by industry,” *Mechanical systems and signal processing*, vol. 25, no. 5, pp. 1803–1836, 2011.
- [169] D. R. Cox, “Regression models and life-tables,” *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 34, no. 2, pp. 187–202, 1972.
- [170] P. Aivaliotis, K. Georgoulas, and G. Chryssolouris, “The use of digital twin for predictive maintenance in manufacturing,” *International Journal of Computer Integrated Manufacturing*, vol. 32, no. 11, pp. 1067–1080, 2019.

- [171] Z. Gao, C. Cecati, and S. X. Ding, “A survey of fault diagnosis and fault-tolerant techniques—Part II: Fault diagnosis with knowledge-based and hybrid/active approaches,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 6, pp. 3768–3774, 2015.
- [172] A. Diez-Olivan, J. Del Ser, D. Galar, and B. Sierra, “Data fusion and machine learning for industrial prognosis: Trends and perspectives towards Industry 4.0,” *Information Fusion*, vol. 50, pp. 92–111, 2019.
- [173] T. P. Carvalho, F. A. Soares, R. Vita, R. d. P. Francisco, J. P. Basto, and S. G. Alcalá, “A systematic literature review of machine learning methods applied to predictive maintenance,” *Computers & Industrial Engineering*, vol. 137, p. 106024, 2019.
- [174] W. Zhang, D. Yang, and H. Wang, “Data-driven methods for predictive maintenance of industrial equipment: A survey,” *IEEE Systems Journal*, vol. 13, no. 3, pp. 2213–2227, 2019.
- [175] S. R. Saufi, Z. A. B. Ahmad, M. S. Leong, and M. H. Lim, “Challenges and opportunities of deep learning models for machinery fault detection and diagnosis: A review,” *IEEE Access*, vol. 7, pp. 122644–122662, 2019.
- [176] O. Merkt, “On the use of predictive models for improving the quality of industrial maintenance: An analytical literature review of maintenance strategies,” in *2019 Federated Conference on Computer Science and Information Systems (FedCSIS)*, pp. 693–704, IEEE, 2019.
- [177] V. Alcácer and V. Cruz-Machado, “Scanning the Industry 4.0: A literature review on technologies for manufacturing systems,” *Engineering science and technology, an international journal*, vol. 22, no. 3, pp. 899–919, 2019.
- [178] I. W. Ngarayana, K. Murakami, M. Suzuki, *et al.*, “Nuclear power plant maintenance optimisation: Models, methods & strategies,” in *Journal of Physics: Conference Series*, vol. 1198, p. 022005, IOP Publishing, 2019.
- [179] A. Soualhi, B. Elyousfi, Y. Hawwari, K. Medjaher, G. Clerc, R. Hubert, and F. Guillet, “PHM survey: Implementation of diagnostic methods for moni-

- 
- toring industrial systems,” *International Journal of Prognostics and Health Management*, vol. 10, no. 2, 2019.
- [180] Z. M. Çınar, A. Abdussalam Nuhu, Q. Zeeshan, O. Korhan, M. Asmael, and B. Safaei, “Machine learning in predictive maintenance towards sustainable smart manufacturing in Industry 4.0,” *Sustainability*, vol. 12, no. 19, p. 8211, 2020.
- [181] L. Chao, L. Jiafei, Z. Liming, G. Aicheng, F. Yipeng, Y. Jiangpeng, and L. Xiu, “Nuclear power plants with artificial intelligence in Industry 4.0 era: Top-level design and current applications—a systemic review,” *IEEE Access*, 2020.
- [182] J. Fausing Olesen and H. R. Shaker, “Predictive maintenance for pump systems and thermal power plants: State-of-the-art review, trends and challenges,” *Sensors*, vol. 20, no. 8, p. 2425, 2020.
- [183] T. Zonta, C. A. Da Costa, R. da Rosa Righi, M. J. de Lima, E. S. da Trindade, and G. P. Li, “Predictive maintenance in the industry 4.0: A systematic literature review,” *Computers & Industrial Engineering*, vol. 150, p. 106889, 2020.
- [184] “KNIME homepage.” <https://www.knime.com>. Last accessed 5 Nov 2019.
- [185] G. A. Susto, A. Schirru, S. Pampuri, S. McLoone, and A. Beghi, “Machine learning for predictive maintenance: A multiple classifier approach,” *IEEE Transactions on Industrial Informatics*, vol. 11, no. 3, pp. 812–820, 2014.
- [186] M. A. Awadallah and M. M. Morcos, “Application of AI tools in fault diagnosis of electrical machines and drives—an overview,” *IEEE Transactions on energy conversion*, vol. 18, no. 2, pp. 245–251, 2003.
- [187] M. Cococcioni, B. Lazzerini, and S. L. Volpi, “Robust diagnosis of rolling element bearings based on classification techniques,” *IEEE Transactions on Industrial Informatics*, vol. 9, no. 4, pp. 2256–2263, 2012.

- [188] J. Tian, C. Morillo, M. H. Azarian, and M. Pecht, "Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with k-nearest neighbor distance analysis," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 3, pp. 1793–1803, 2015.
- [189] P. Konar and P. Chattopadhyay, "Bearing fault detection of induction motor using wavelet and support vector machines (SVMs)," *Applied Soft Computing*, vol. 11, no. 6, pp. 4203–4211, 2011.
- [190] A. Rojas and A. K. Nandi, "Detection and classification of rolling-element bearing faults using support vector machines," in *2005 IEEE Workshop on Machine Learning for Signal Processing*, pp. 153–158, IEEE, 2005.
- [191] J. Qu, Z. Zhang, and T. Gong, "A novel intelligent method for mechanical fault diagnosis based on dual-tree complex wavelet packet transform and multiple classifier fusion," *Neurocomputing*, vol. 171, pp. 837–853, 2016.
- [192] J. Wu, C. Wu, S. Cao, S. W. Or, C. Deng, and X. Shao, "Degradation data-driven time-to-failure prognostics approach for rolling element bearings in electrical machines," *IEEE Transactions on Industrial Electronics*, vol. 66, no. 1, pp. 529–539, 2018.
- [193] A. Malhi and R. X. Gao, "PCA-based feature selection scheme for machine defect classification," *IEEE Transactions on Instrumentation and Measurement*, vol. 53, no. 6, pp. 1517–1525, 2004.
- [194] X. Zhang, R. Xu, C. Kwan, S. Y. Liang, Q. Xie, and L. Haynes, "An integrated approach to bearing fault diagnostics and prognostics," in *Proceedings of the 2005, American Control Conference, 2005.*, pp. 2750–2755, IEEE, 2005.
- [195] D. A. Freedman, *Statistical Models: Theory and Practice. Revised Edition*. New York: Cambridge University Press, 2009.
- [196] F. Pukelsheim, "The three sigma rule," *The American Statistician*, vol. 48, no. 2, pp. 88–91, 1994.
- [197] J. Gama, *Knowledge discovery from data streams*. Boca Raton, US: CRC Press, 2010.

- 
- [198] M. G. Kelly, D. J. Hand, and N. M. Adams, “The impact of changing populations on classifier performance,” in *Proceedings of the Fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '99, (New York, NY, USA), p. 367–371, Association for Computing Machinery, 1999.
- [199] J. Gao, W. Fan, J. Han, and P. S. Yu, *A General Framework for Mining Concept-Drifting Data Streams with Skewed Distributions*, pp. 3–14. 2007.
- [200] J. a. Gama, I. Žliobaitis, A. Bifet, M. Pechenizkiy, and A. Bouchachia, “A survey on concept drift adaptation,” *ACM Comput. Surv.*, vol. 46, Mar. 2014.
- [201] E. S. Page, “Continuous inspection schemes,” *Biometrika*, vol. 41, no. 1/2, pp. 100–115, 1954.
- [202] A. Bifet and R. Gavaldà, “Kalman filters and adaptive windows for learning in data streams,” in *Discovery Science* (L. Todorovski, N. Lavrač, and K. P. Jantke, eds.), (Berlin, Heidelberg), pp. 29–40, Springer Berlin Heidelberg, 2006.
- [203] A. Bifet and R. Gavaldà, *Learning from Time-Changing Data with Adaptive Windowing*, pp. 443–448. 2007.
- [204] M. Moleda, A. Momot, and D. Mrozek, “Predictive maintenance of boiler feed water pumps using SCADA data,” *Sensors*, vol. 20, no. 2, p. 571, 2020.
- [205] W. D. Marscher *et al.*, “Avoiding failures in centrifugal pumps,” in *Proceedings of the 19th International Pump Users Symposium*, Texas A&M University. Turbomachinery Laboratories, 2002.
- [206] L. Bachus and A. Custodio, *Know and understand centrifugal pumps*. Oxford, UK: Elsevier Science, 2003.
- [207] “PGIM product on vendor website.” <https://library.e.abb.com/public/8de8d0f13ed57bd0c12572650035aa0b/1KGD%20400132%20PGIM%205.0%20Leaflet.pdf>. Last accessed 28 Sep 2019.

- [208] M. Moleda, A. Momot, and D. Mrozek, “Regression methods for detecting anomalies in flue gas desulphurization installations in coal-fired power plants based on sensor data,” in *Computational Science – ICCS 2020* (V. V. Krzhizhanovskaya, G. Závodszky, M. H. Lees, J. J. Dongarra, P. M. A. Sloat, S. Brissos, and J. Teixeira, eds.), (Cham), pp. 316–329, Springer International Publishing, 2020.
- [209] M. Moleda, A. Momot, and D. Mrozek, “Concept drift and avoiding its negative effects in predictive modeling of failures of electricity production units in power plants,” in *2020 28th International Symposium on Modeling, Analysis, and Simulation of Computer and Telecommunication Systems (MASCOTS)*, pp. 1–7, IEEE, 2020.

# Spis rysunków

1.1	Klasyfikacja systemów w zakładzie przemysłowym . . . . .	8
2.1	Podstawowe strategie konserwacji . . . . .	16
2.2	Wykres "wann" (ang. <i>bathtub</i> ) wizualizujący prawdopodobieństwo wystąpienia awarii na wczesnych i późnych etapach eksploatacji . . .	19
2.3	Koszty naprawy w zależności od czasu wykrycia usterki . . . . .	20
2.4	Opłacalność wdrożenia predykcyjnego utrzymania ruchu . . . . .	21
2.5	Przykładowy arkusz analizy FMEA . . . . .	29
2.6	Drzewo usterek dla zdarzenia zagrożenia pożarem . . . . .	32
2.7	Diagram Ishikawy przedstawiający skategoryzowane możliwe przyczyny awarii . . . . .	34
2.8	Złożoność i zakres analizy danych . . . . .	35
2.9	Klasyfikacja metod prognostycznych w obszarze predykcyjnego utrzymania ruchu . . . . .	37
2.10	Schemat ideowy systemu eksperckiego . . . . .	40
2.11	Schemat blokowy zastosowania analitycznej redundancji . . . . .	42
2.12	Przykład segmentacji sygnału w metodzie QTA . . . . .	45
2.13	Schemat ideowy metody wykrywania awarii opartej na analizie sygnału . . . . .	50
2.14	Estymowany czas bezawaryjnej pracy na podstawie stanu urządzenia	54
3.1	Schemat blokowy procesu symulacji eksperymentów . . . . .	62
3.2	Metodologia CRISP-DM . . . . .	64
3.3	Wartości rzeczywista i estymowana dla pomiaru przepływu wody na wyjściu pompy oraz residuum . . . . .	72

---

3.4	Schemat blokowy etapów działania algorytmu . . . . .	73
3.5	Przykład notacji KKS . . . . .	81
3.6	Hierarchia kodowania kodowania KKS . . . . .	82
3.7	Automatyczne etykietowanie danych na podstawie zapisów w rejestrze usterek . . . . .	83
3.8	Rodzaje dryfu koncepcji . . . . .	85
3.9	Główne podejścia służące do niwelowania zjawiska dryfu koncepcji .	86
3.10	Metoda adaptacji modelu "na ślepo" . . . . .	88
3.11	Adaptacyjne dostosowanie długości okna w zależności od zmian sygnału wejściowego w algorytmie ADWIN . . . . .	91
3.12	Ilustracja działania algorytmu MSC-ADWIN w kolejnych iteracjach dla modelowego przykładu zmiany w szeregu czasowym . . . . .	94
4.1	Schemat zespołu pomp zasilających . . . . .	97
4.2	Przedmiot badań - 3-stopniowa pompa zasilająca typu Voith'a . . .	98
4.3	Korelacje pomiędzy sygnałami pomiarowymi pompy . . . . .	102
4.4	Różnica między rzeczywistą, a szacunkową wartością pomiaru dla przepływu wody. . . . .	104
4.5	Różnica między rzeczywistą a szacunkową wartością łożyska nr 1. .	105
4.6	Różnica między rzeczywistą a szacunkową wartością łożyska nr 4. .	105
4.7	Zbiory treningowe i testowe w eksperymencie . . . . .	106
4.8	Średni błąd bezwzględny $\%MAE$ i współczynnik determinacji $R^2$ w zależności od długości okna czasowego. . . . .	107
4.9	Znormalizowany błąd względny ( $NRE$ ) z identyfikacją źródła awarii	109
4.10	Krzywe ROC dla proponowanej metody oraz innych metod klasyfikacji. . . . .	112
4.11	Macierz korelacji Pearsona pomiędzy sygnałami zebranymi dla sprężarki natleniającej . . . . .	116
4.12	Rozkład odchyleń dla stanu awaryjnego i prawidłowej pracy. . . . .	120
4.13	Odchylenia od stanu przewidywanego drgań uzyskane dla długiego i krótkiego okna czasowego, wyznaczającego zbiór treningowy dla modelu. . . . .	121



---

4.14	Anomalie dla pomiarów drgań ze wskazaniem na osi czasu usterek i działań serwisowych. . . . .	122
4.15	Odchylenie i rzeczywiste wskazanie dla ciśnienia oleju za filtrem przed awarią łożyska. . . . .	123
4.16	Krzywe ROC dla modeli predykcyjnych wykrywania anomalii zbudowanych dla sprężarek 1HTG01 i 2HTG02. . . . .	124
4.17	Przykład zjawiska dryfu koncepcji przy predykcji wartości temperatury oleju przed chłodnicą zaobserwowany dla stacjonarnego modelu predykcyjnego . . . . .	130
4.18	Dryf koncepcji przy predykcji temperatury silnika uzyskany dla stacjonarnego modelu predykcyjnego . . . . .	131
4.19	Dryf koncepcji dla modelu stacjonarnego ciśnienia wody na wyjściu	132
4.20	Przykład zastosowania filtru CUSUM dla danych wyjściowych modelu sygnału: a) alarmy wygenerowane poprzez zastosowanie algorytmu CUSUM na szeregu czasowym błędu $\epsilon_i$ będącego wynikiem predykcji z użyciem modelu stacjonarnego, b) poziom błędu $\epsilon_i$ wygenerowanego przez model predykcyjny dla estymacji temperatury łożyska nr 5. . . . .	136
5.1	Architektura biznesowa rozwiązania . . . . .	148
5.2	Koncepcja architektury systemu uwzględniająca opracowane w trakcie realizacji rozprawy elementy środowiska predykcyjnego utrzymania ruchu . . . . .	149



# Spis tabel

2.1	Powiązane artykuły koncentrujące się na tematyce predykcijnego utrzymania ruchu w przemyśle (w tym w energetyce) . . . . .	58
3.1	Macierz pomyłek . . . . .	77
4.1	Awarie krytyczne odnotowane w badanym okresie . . . . .	99
4.2	Opis sygnałów procesowych pompy zasilającej . . . . .	101
4.3	Dokładność wybranych metod regresji . . . . .	108
4.4	Współczynniki błędów uzyskane przez modele predycyjne dla poszczególnych sygnałów przy zastosowaniu regresji liniowej . . . . .	108
4.5	Awarie i czas ich zarejestrowania. . . . .	110
4.6	Jakość klasyfikacji algorytmów . . . . .	111
4.7	Opis analizowanych sygnałów procesowych sprężarki . . . . .	115
4.8	Zdarzenia serwisowe odnotowane dla sprężarek natleniających w analizowanym okresie . . . . .	116
4.9	Miary błędów ( $MSE$ ) w zależności od parametru stopnia wielomianu. Najlepsze wyniki oznaczono kolorem żółtym. . . . .	118
4.10	Wyniki w postaci błędu średnio-kwadratowego ( $MSE$ ) uzyskane w efekcie wprowadzenia kroku optymalizacji selekcji cech. . . . .	119
4.11	Wydażność modeli predycyjnych zbudowanych dla różnych urządzeń w elektrowni. . . . .	124
4.12	Poziomy błędów przy zastosowaniu modeli statycznych . . . . .	133
4.13	Poziomy błędów przy zastosowaniu modeli adaptacyjnych . . . . .	134
4.14	Alarmy wygenerowane po zastosowaniu algorytmu CUSUM oraz powiązane zdarzenia . . . . .	137