



Politechnika Śląska
Wydział Automatyki, Elektroniki i Informatyki
Instytut Informatyki

ROZPRAWA DOKTORSKA

**SYSTEM WIZUALIZACJI I DIAGNOSTYKI PRACY URZĄDZEŃ
BAZUJĄCY NA BEZPRZEWODOWYJ SIECI CZUJNIKÓW
WIBROAKUSTYCZNYCH I METODACH EKSPLOKACJI DANYCH**

Autor: mgr inż. Krzysztof Szczyrba
Promotor: dr hab. Marek Sikora prof. Pol. Śl.
Promotor pomocniczy: dr inż. Łukasz Wróbel

Gliwice, 2023

SPIS TREŚCI

1. Wstęp	5
1.1. Struktura pracy	8
2. System monitorowania.....	11
2.1. Strategie utrzymania ruchu i koncepcja systemu monitorowania.....	11
2.2. Warstwa sprzętowa	17
2.3. Warstwa analityczno-raportująca.....	22
2.4. Analiza konkurencji	25
3. Warstwa sprzętowa	30
3.1. Czujniki	30
3.2. Infrastruktura odbiorcza	49
4. Warstwa programowa	54
4.1. Warstwa transportowa platformy ThingsBoard	56
4.2. Warstwa zarządzania.....	58
4.3. Repozytorium danych telemetrycznych.....	59
4.4. Wizualizacja danych	60
4.5. Silnik analityczny.....	62
5. Model diagnostyczny suwnicy bramowej.....	72
5.1. Opis przedmiotu monitorowania.....	72
5.2. Procedura diagnostyczna.....	76
6. Model diagnostyczny kruszarki węgla.....	90
6.1. Opis przedmiotu monitorowania.....	90
6.2. Metoda.....	93
6.3. Eksperymenty.....	99
6.4. Wyniki.....	105
6.5. Objaśnialność decyzji.....	111
6.6. Praktyczna procedura diagnostyczna	114
7. Podsumowanie	117
BIBLIOGRAFIA	123
SPIS ILUSTRACJI.....	133

1. Wstęp

Produkcja przemysłowa odbywa się w warunkach silnej konkurencji. Rynek oczekuje od producentów dostarczania wysokiej jakości produktów w możliwie krótkim czasie, za jak najniższą cenę. Istotnym elementem wpływającym na konkurencyjność procesu produkcyjnego jest dbałość o stan techniczny parku maszynowego wykorzystywanego w procesie wytwarzania dóbr. Brak takiej dbałości może prowadzić do awarii maszyn, czego konsekwencją są przestoje linii produkcyjnych. W takim przypadku przedsiębiorstwo ponosi koszty związane z usunięciem awarii oraz straty będące następstwem wstrzymania cyklu produkcyjnego. W większości zakładów produkcyjnych powoływana jest specjalna komórka odpowiedzialna za ten element: tzw. dział utrzymania ruchu. Głównym zadaniem pracowników tego działu jest zapobieganie nieplanowanym przestojom linii produkcyjnych. Realizacja tego celu wymaga szeregu działań koncentrujących się na monitorowaniu aktualnego stanu technicznego poszczególnych maszyn, przewidywaniu potencjalnych zdarzeń awaryjnych, identyfikacji źródeł usterek w razie ich wystąpienia, usuwania skutków awarii. Niezależnie od tego pracownicy służb utrzymania ruchu wykonują prace związane z szeroko pojętą profilaktyką, do których można zaliczyć regulacje, przeglądy, smarowania, uzupełnianie płynów technologicznych. Odpowiadają też za szeroko pojętą logistykę części zamiennych i materiałów eksploatacyjnych. Wszystkie te zadania realizowane są w ramach regularnych obchodów, cyklicznych bądź ciągłych pomiarów, doraźnych bądź planowych akcji remontowych. Muszą być one planowane z uwzględnieniem cyklu produkcyjnego przedsiębiorstwa, a także uwzględniać presję w kierunku zmniejszania kosztów osobowych tych działań przy jednoczesnym deficycie wyspecjalizowanej w tym zakresie kadry inżynierskiej na rynku pracy.

W tej sytuacji naturalną staje się potrzeba dążenia do poszukiwania narzędzi technicznych wspierających działania związane z utrzymaniem ruchu. Narzędzia takie powinno wspierać:

- monitorowanie bieżącego stanu technicznego poszczególnych maszyn ciągu technologicznego,
- uzyskiwanie wyprzedzających informacji o zagrożeniach związanych z uszkodzeniem poszczególnych elementów systemu,
- selekcję monitorowanych punktów systemu pod kątem potencjalnych zagrożeń awaryjnych,
- optymalizację planowania terminów akcji serwisowych i remontowych,
- optymalizację czasową i kosztową logistyki zakupów części zamiennych,
- ocenę jakości dokonywanych akcji serwisowych w zakresie samej usługi serwisowej oraz użytych części zamiennych,

- minimalizację personelu zaangażowanego w cykliczne obchody instalacji,
- podnoszenie jakości pracy personelu poprzez wspieranie procesu edukacji w zakresie podnoszenia kompetencji eksperckich.

Koncepcja takiego narzędzia musi także uwzględniać aspekty techniczne i organizacyjne związane z koniecznością jego wdrożenia na istniejącej instalacji przemysłowej. Spośród nich można wymienić:

- konieczność montażu na elementach linii technologicznych składającej się z elementów o różnym stopniu złożoności, wdrożonych w odmiennych okresach historii rozwoju zakładu,
- ograniczoną możliwość ingerencji w konstrukcję wybranych elementów maszyn wynikającą z ograniczeń zapisów umów gwarancyjnych i/lub wpływu na ich cechy funkcjonalne,
- ograniczenia ekonomiczne i techniczne budowy infrastruktury pomiarowej i transmisyjnej,
- pracochłonność obsługi infrastruktury systemu diagnostycznego w bilansie potencjalnych korzyści,
- politykę bezpieczeństwa informatycznego organizacji.

Dotychczas wsparcie informatyczne w wymienionych wyżej obszarach zapewniały systemy typu SCADA (ang. Supervisory Control And Data Acquisition) w zakresie akwizycji i prezentacji danych pochodzących z procesu oraz systemy typu CMMS (ang. Computerised Maintenance Management System) w zakresie zarządzania organizacją procesów w utrzymaniu ruchu. W większości przypadków gromadzą one dane z czujników i elementów wykonawczych systemów sterowania procesami technologicznymi. W szczególnym przypadku umożliwiają one rejestrację prezentowanych parametrów, umożliwiając w ten sposób ocenę przeszłych zdarzeń awaryjnych na podstawie danych historycznych. Jednak podstawowym zadaniem tych systemów było bieżące monitorowanie procesu.

W ramach czwartej rewolucji przemysłowej rozwijała się koncepcja Przemysłu 4.0 (ang. Industry 4.0) [1, 2], zgodnie z którą szczególny nacisk kładziony jest na szeroko pojętą cyfryzację przemysłu. Zgodnie z tą ideą dostęp do danych na temat produktu w dowolnym etapie cyklu życia ma być realizowany z dowolnego miejsca w czasie rzeczywistym. Wdrażanie koncepcji ułatwiał dostęp do coraz większej bazy czujników różnych wielkości fizycznych, pozwalających na pomiar różnych parametrów procesu. Dzięki temu stało się możliwe wdrażanie koncepcji internetu rzeczy (ang. internet of things IoT), według której przedmioty świata rzeczywistego mają swoje odwzorowanie w świecie wirtualnym [3–5].

W ostatnich latach poziom dojrzałości osiągnęły badania nad sztuczną inteligencją AI (ang. Artificial Intelligence). Coś, co do niedawna było ciekawostką w środowisku wdrożeń przemysłowych, jest dzisiaj z powodzeniem wdrażane w różnych sferach życia, także

w przemyśle [6, 7]. Na szczególną uwagę zasługuje jedna z głównych gałęzi AI - Uczenie Maszynowe ML (ang. Machine Learning), rozumiane jako obszar informatyki zajmujący się opracowywaniem metod pozwalającym na generalizację wiedzy, doświadczenia i danych [8]. Jako że istniejące systemy SCADA rejestrują duże ilości tych danych, naturalnym wydaje się możliwość wykorzystania algorytmów ML na potrzeby predykcyjnego utrzymania ruchu (ang. predictive maintenance – PdM). Nadrzędnym celem PdM jest informowanie operatorów i działów utrzymania o: niepożądanych trendach zmian monitorowanych parametrów procesu, niestandardowych zrachowaniach (stanach systemu), wreszcie o nadciągających awariach monitorowanych urządzeń i maszyn.

Celem niniejszej rozprawy jest przedstawienie kompletnego systemu diagnostyki maszyn obejmującego zarówno warstwę sprzętową (zapewniającą akwizycję danych pomiarowych) jak również warstwę programową (zapewniającą wizualizację danych oraz wdrażanie modeli PdM). Z założenia przedmiotem monitorowania systemu są węzły łożyskowe elementów maszyn wykonujących ruch obrotowy. W odróżnieniu od dostępnych na rynku systemów, rozwiązanie kompleksowo realizuje zadania z zakresu PdM z wykorzystaniem algorytmów ML – od pomiarów symptomów diagnostycznych, przez ich akwizycję i transmisję do nadrzędnego systemu komputerowego, po ich rejestrację, prezentację, analizę i wnioskowanie. W ramach prac przedstawiono założenia techniczne systemu i koncepcję jego budowy. W kolejnym kroku opisano budowę systemu opracowanego w firmie Somar S.A. przez zespół kierowany przez autora rozprawy w oparciu o tą koncepcję obejmujący:

- warstwę fizyczną złożoną z opracowanej w ramach projektu sieci bezprzewodowych czujników różnych wielkości fizycznych badających symptomy diagnostyczne instalacji,
- warstwę transmisji danych z tych czujników złożoną z sieci transceiverów radiowych oraz lokalnych stacji diagnostycznych komunikujących się z czujnikami i warstwą informatyczną systemu,
- warstwę programową systemu, w ramach której opracowano:
 - repozytorium danych telemetrycznych,
 - moduł analityczny przeznaczony do uruchamiania modeli diagnostycznych,
 - interaktywną platformę prezentacji surowych danych telemetrycznych oraz wyników działania algorytmów analitycznych.

W ramach prac zidentyfikowano podstawowe symptomy diagnostyczne, będące źródłem danych w postaci przyspieszeń drgań i temperatury oraz symptomy uzupełniające, niezbędne do tworzenia modeli diagnostycznych (między innymi prędkość obrotowa, pobór mocy, ciśnienie, itp.). Aspekty wdrożeniowe zdecydowały o zastosowaniu w zakresie pomiarowym technologii bezprzewodowych, w wyniku czego istotnym elementem badań okazały się aspekty oszczędzania energii ze źródeł zasilania.

Projekt części bazodanowej systemu wymagał dostosowania do akwizycji dużej ilości danych napływających online, często spełniających warunek big data.

Projekt modułu analitycznego systemu obejmował standardowe etapy zgodne z metodyką CRISP Data Mining, tj. akwizycję i oczyszczenie danych, opracowanie modeli diagnostycznych urządzenia, opracowanie metod i wskaźników śledzenia zmian parametrów urządzenia, monitorowanie jakości prognoz i aktualizacji modeli diagnostycznych.

W ramach realizacji rozprawy doktorskiej opracowano również dwie metody dedykowane do zadań PdM. Pierwsza metody dotyczy zastosowań analizy trendu, a druga identyfikacji wartości odstających. Wybór metod podyktowany był koniecznością realizacji konkretnych wdrożeń systemu (diagnostyki suwnicy bramowej oraz kruszarki węgla), ponadto metody te mogą być traktowane jako metody ogólnego użycia dla konkretnych podobnych wdrożeń. Dla obu podejść wytypowano zmienne diagnostyczne, opracowano procedury diagnostyczne i zaproponowano sposób prezentacji wyników działania tych procedur w postaci odpowiednich raportów diagnostycznych.

Prace opisane w niniejszej rozprawie zrealizowano w ramach ścieżki doktoratu wdrożeniowego. Realizując prace wdrożeniowe i badawcze starano się udowodnić następującą tezę główną:

Możliwe jest opracowanie bezprzewodowego systemu monitorowania drgań zapewniającego efektywną i długotrwałą pracę pozwalającą na monitorowanie maszyn i urządzeń. Mniejsza, niż jest to w systemach o zasilaniu ciągłym, ilość gromadzonych danych nadal pozwala na budowanie modeli diagnostycznych realizujących zadania predykcyjnego utrzymania ruchu.

Ze względu na wymagania techniczne i poszukiwanie przewagi konkurencyjnej nad innymi systemami monitorowania drgań, prace prowadzone również były w kierunku spełnienia następującej tezy pomocniczej:

Czujniki odpowiedzialne za gromadzenie danych dla modeli diagnostycznych realizujących zadania predykcyjnego utrzymania ruchu mogą być zasilane z ogniwa wtórnego wymienianego nie częściej niż raz do roku. Przy czym wymiary gabarytowe ogniwa stanowią nie więcej niż 10% wielkości czujnika.

1.1. Struktura pracy

W rozdziale drugim przedstawiono koncepcję przedmiotowego systemu monitorowania. Opisano w nim trzy podstawowe strategie utrzymania ruchu oraz uzasadniono, dlaczego system opracowany w ramach rozprawy wspiera strategie PdM.

Wytypowano podstawowe i uzupełniające parametry mierzone przez system traktowane jako symptomy diagnostyczne. Przedstawiono założenia całości systemu i koncepcję jego budowy ze szczególnym uwzględnieniem poszczególnych warstw: od sprzętowej odpowiedzialnej za pomiary, akwizycję i transmisję danych, po analityczno-raportującą. W ostatniej części rozdziału dokonano analizy dostępnych na rynku systemów realizujących podobne zadania.

W drugim rozdziale pracy skoncentrowano się na opisie warstwy sprzętowej systemu. W pierwszej części opisu przedstawiono zaprojektowane na potrzeby systemu czujniki bezprzewodowe. Jako podstawowy przedstawiono bezprzewodowy czujnik drgań i temperatury, jako uzupełniające – czujniki ciśnienia, natężenia prądu, wilgotności i prędkości obrotowej. Następnie dokonano analizy bilansu energetycznego czujników, istotnego ze względu na konieczność oszczędzania energii z baterijnego źródła zasilania. Opisano szczegółowo mechanizmy sprzętowe i programowe zastosowane w celu redukcji poziomu pobieranej mocy ze źródła zasilania. W kolejnych podrozdziałach opisano zastosowaną infrastrukturę odbiorczą. Przedstawiono budowę zaprojektowanych na potrzeby systemu transceiverów radiowych odpowiedzialnych za komunikację radiową z czujnikami bezprzewodowymi oraz zaprezentowane lokalne stacje diagnostyczne, pozwalające dodatkowo na lokalną prezentację wyników pomiarów. Omówiono protokoły komunikacyjne zaimplementowane w kanale radiowym do komunikacji z czujnikami oraz w sieci Ethernet, do komunikacji z warstwą przetwarzania danych.

W rozdziale czwartym przedstawiono opis warstwy programowej systemu. Przewidziano główne zadania warstwy programowej oraz cechy umożliwiające ich realizację. Następnie opisano jak poszczególne bloki architektury realizują poszczególne wymagania. Przedstawiono budowę bramy IoT implementującą warstwę transportową systemu. Opisano warstwę zarządzania odpowiedzialną za zarządzanie repozytorium danych telemetrycznych i reguły przetwarzania tych danych. W kolejnym podrozdziale omówiono architekturę modułu analitycznego, ze szczególnym uwzględnieniem analitycznej bazy danych oraz części ML, odpowiedzialnej za uruchamianie procedur diagnostycznych realizowanych w oparciu o algorytmy uczenia maszynowego. Opisano również powłokę interfejsu użytkownika realizującą dostęp do plansz wizualizacyjnych, paneli administracyjnych oraz raportów analitycznych.

W rozdziale piątym i szóstym przedstawiono opracowane i wdrożone w ramach doktoratu metody analityczne. Jako pierwsze zaprezentowano podejście do PdM w oparciu o analizy trendowe. Opisano sposób wyboru odpowiedniej zmiennej diagnostycznej, zaproponowano procedurę diagnostyczną opartą o analizę zmienności trendu tej zmiennej oraz sposób prezentacji wyników działania tej procedury w postaci odpowiedniego raportu. Metoda wiąże się z konkretnym wdrożeniem systemu PdM,

którego celem była diagnostyka suwnicy bramowej przeznaczonej do transportu surówki do pieców konwertorowych huty stali. Wybór metody bazującej na trendach podyktowany był wymaganiami klienta, który w swoim systemie SCADA prowadził już proste analizy trendów dla kluczowych z monitorowanych parametrów suwnicy.

Drugą prezentowaną z przedstawionych metod analitycznych jest metoda bazująca na analizie wartości odstających. Także dla tej metody zaproponowano procedurę selekcji cech, model diagnostyczny i model korekcyjny. W oparciu o model diagnostyczny zaproponowano procedurę diagnostyczną. Dla raportu analitycznego prezentującego wyniki działania tej procedury przygotowano moduł objaśnialności prognoz, pozwalający na wskazanie cech najważniejszych z punktu widzenia bieżącej diagnostyki. Metodę zastosowano w systemie monitorowania kruszarek węgla pracujących w ciągu transportu paliwa do kotła fluidalnego elektrowni węglowej.

W obu przypadkach przedstawiono monitorowane obiekty, zdefiniowano problem diagnostyczny, zaprezentowano wdrożony układ pomiarowy, opisano pozyskane zbiory danych, opisano procedury diagnostyczne oraz przebieg eksperymentów.

W ostatnim rozdziale podsumowano wyniki badań przeprowadzonych w ramach rozprawy i zaproponowano dalsze kroki.

Podziękowania

Autor rozprawy składa serdeczne podziękowania kolegom z firmy Somar S.A. oraz zespołowi z Politechniki Śląskiej za wsparcie w realizacji prac nad projektem i wdrożeniem niniejszego systemu diagnostyki maszyn. Bez Waszego udziału i wsparcia nie byłaby możliwa realizacja tego przedsięwzięcia. Szczególne podziękowania składam prezesowi firmy Somar S.A. w osobie Juranda Sobczyka za możliwość publikacji wyników prac w rozprawie oraz promotorowi dr. hab. Markowi Sikorze, za udzielone wsparcie i wykazaną cierpliwość w trakcie prac.

2. System monitorowania

2.1. Strategie utrzymania ruchu i koncepcja systemu monitorowania

Problem utrzymania ruchu jest przedmiotem badań na pograniczu dyscyplin zarządzania i inżynierii produkcji oraz mechaniki [9–11]. Środowisko naukowe i technicy zajmujący się tym tematem wyróżniają zazwyczaj trzy generacje strategii utrzymania ruchu.

Najprostsze i najmniej korzystne z ekonomicznego punktu widzenia są strategie reaktywne. Przykładem takiego podejścia jest obsługa awaryjna (ang. breakdown maintenance – BM) [10]. Zgodnie z tą strategią maszyny eksploatuje się do momentu ich uszkodzenia, po czym następuje faza serwisu. Z oczywistych powodów strategia ta generuje duże straty dla przedsiębiorstw. Straty te związane są między innymi z nieplanowanymi przestojami.

Bardziej zaawansowane są strategie prewencyjne, zaliczane do strategii drugiej generacji. Przykładem tej klasy strategii jest konserwacja profilaktyczna (ang. preventive maintenance – PM). Polegają one na cyklicznej obsłudze maszyny. Zgodnie z tą strategią określa się bezpieczne okresy eksploatacji podzespołów, a po ich przekroczeniu dokonuje się prewencyjnych remontów. W zakresie tych działań mieszczą się zarówno okresowe wymiany płynów technologicznych takich jak smary, oleje jak i okresowe działania czyszczenia, wymiany podzespołów oraz regulacje parametrów ruchowych. Przykładem z życia codziennego jest eksploatacja samochodu: instrukcja obsługi nakazuje po przekroczeniu zadanego przebiegu wymianę oleju, rozrządu, klocków hamulcowych itd.

Reprezentantem najbardziej zaawansowanej technicznie strategii trzeciej generacji jest konserwacja predykcyjna (ang. predictive maintenance – PdM). Głównym jej celem jest prognozowanie momentu, w którym urządzenie prawdopodobnie ulegnie awarii na bazie rzeczywistych warunków pracy [4, 12–15]. Zgodnie z tą strategią urządzenie wyposaża się w czujniki monitorujące kluczowe z punktu widzenia diagnostyki, parametry pracy podzespołów. Czujniki te monitorują tzw. symptomy diagnostyczne i na ich podstawie dokonują diagnozy bieżącej kondycji urządzenia oraz starają się prognozować stan techniczny urządzenia w przyszłości.

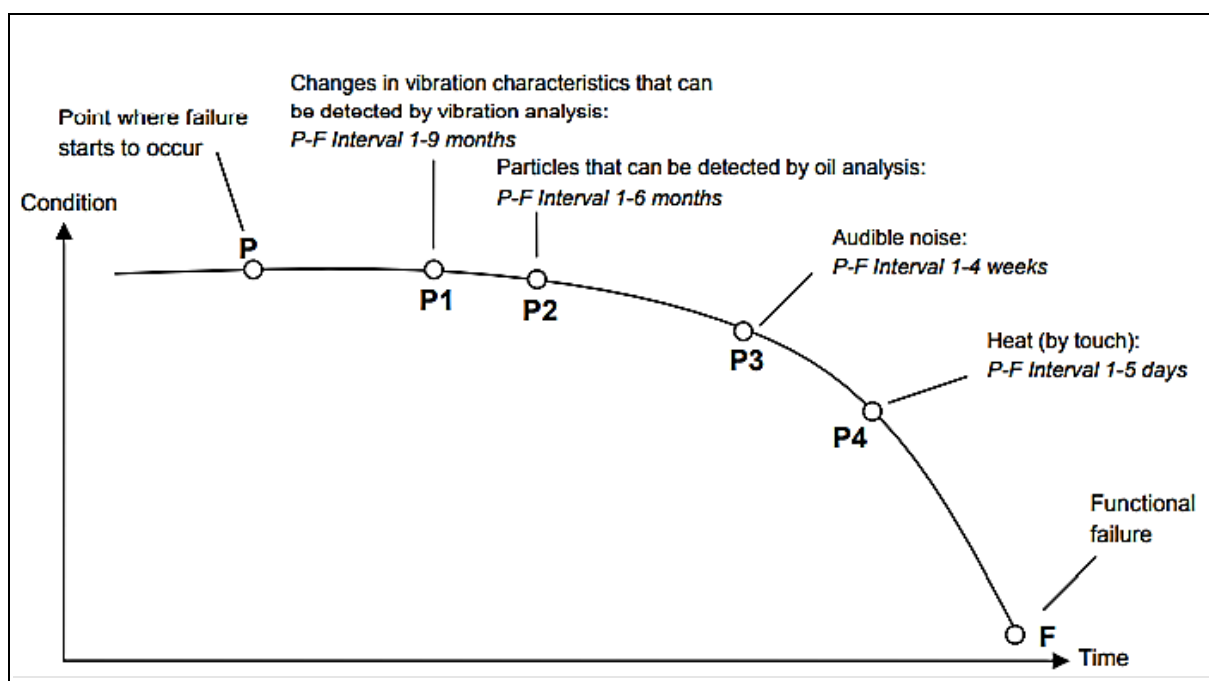
Badania naukowe i praktyka wdrożeniowa podkreślają zalety stosowania strategii PdM w zakresie efektywnego wykorzystania dostępnego parku maszynowego przedsiębiorstw [10–12, 16]. Stosowanie tej strategii pozwala przede wszystkim na uzyskiwanie wyprzedzających informacji o uszkodzaniu elementów nadzorowanych maszyn. Pozwala to na optymalizację planowania terminów serwisu i remontów [4, 13, 14, 17, 18] – remonty mogą być przeprowadzane w trakcie planowanych przestojów bez zakłócania cyklu produkcyjnego. Wyprzedzająca informacja o uszkodzeniu pozwala na zatrzymanie procesu

zużycia elementu we wczesnej fazie powstawania usterki. Przekłada się to na redukcję kosztów naprawy oraz na zmniejszenie liczby awarii, zwiększając dostępność maszyny dla procesu produkcyjnego. Efektem ubocznym stosowania strategii PdM jest uzyskanie obszernej informacji na temat stanu technicznego monitorowanego obiektu. Zarządzanie tą informacją pozwala na skoncentrowanie uwagi służb utrzymania ruchu na wybranych elementach systemu poprzez uzyskanie selektywnej i wiarygodnej informacji o punktach stwarzających ryzyko uszkodzeń. Docelowo pozwala to na redukcję kosztów działu utrzymania ruchu poprzez zmniejszenie liczby osób zaangażowanych w zadania diagnostyki instalacji [19]. Jest to szczególnie istotne dla służb odpowiedzialnych za organizację i zarządzanie działami utrzymania ruchu w przedsiębiorstwach (naciski na ograniczanie kosztów zatrudnienia, deficyt osób z kompetencjami diagnostycznymi na rynku pracy, wymiana pokoleniowa załóg powiązana z koniecznością eksploatacji wiekowych instalacji technicznych). Dodatkowo dane te są szczególnie wartościowe dla producenta monitorowanej maszyny, który może dzięki temu zestawić założone w projekcie warunki pracy z rzeczywistymi. Pozwala to na doskonalenie projektu w kierunku poprawy parametrów wydajnościowych i niezawodnościowych kolejnych wersji maszyn.

Kolejna przewaga strategii PdM ujawnia się w kontekście zarządzania procesem planowania zakupu części zamiennych. Strategie reaktywne zwiększają koszty magazynowania potencjalnie potrzebnych części zamiennych lub prowadzą do wzrostu kosztów zatrzymania procesu o dodatkowy czas dostawy tych części. Wada ta jest pozornie eliminowana w przypadku stosowania strategii prewencyjnych, jednak w tym przypadku pojawia się problem kosztów wymiany prewencyjnej [16], nie zawsze uzasadnionej rzeczywistym stanem technicznym. Wiedza o stanie technicznym obiektu oraz prognoza jego przyszłego stanu, uzyskiwana dzięki stosowaniu strategii predykcyjnych, pozwala podjęcie decyzji zakupowej uwzględniającej możliwości logistyczne dostawcy i bieżący plan produkcyjny. Jednocześnie możliwa jest natychmiastowa weryfikacja jakości i skuteczności przeprowadzonych czynności remontowych, w tym weryfikacja jakości zastosowanych części zamiennych.

Kluczowym w stosowaniu strategii predykcyjnych jest dobór monitorowanych symptomów diagnostycznych, tak by ich wektor poprawnie odwzorowywał stan techniczny obiektu. Ważnym też aspektem jest selekcja parametrów pozwalających na monitorowanie uszkodzenia we wczesnej fazie jego powstawania.

Pomocna w tym zadaniu okazuje się wielokrotnie przywoływana w badaniach [20–23] krzywa P-F (ang. Potential to Functional Failure) (Rys. 1).



Rys. 1 Krzywa PF (ang. Potential to Functional Failure) [23].

Krzywa ta prezentuje typowy dla większości maszyn wykonujących ruch o charakterze obrotowym proces rozwoju uszkodzenia od punktu P definiowanego jako punkt, w którym powstaje uszkodzenie, do punktu F, gdzie mamy do czynienia z uszkodzeniem funkcjonalnym całego zespołu maszyny. Krzywa wskazuje kolejność ujawnianych symptomów diagnostycznych, zgodnie z którą pierwsze pojawiają się drgania, później zmiany fizykochemiczne oleju, następnie hałas, a w końcowej fazie uszkodzenia wzrost temperatury.

Reprezentatywnym potwierdzeniem charakteru tej krzywej są modele procesu degradacji łożysk - kluczowych elementów maszyn, odpowiedzialnych za przenoszenie ruchu obrotowego. Ich uszkodzenia odpowiadają za większość awarii układów napędowych [24, 25]. Badania wyróżniają trzy kolejne fazy degradacji łożyska [25, 26]: szumową, drganiową oraz termiczną. Faza szumowa rozpoczyna się już w chwili oddania nowego łożyska do eksploatacji, charakteryzuje się występowaniem drgań o charakterze szumu szerokopasmowego o niskiej amplitudzie (100-200 mg). Za drgania te odpowiadają mikrouszkodzenia i mikropęknięcia. W końcowej fazie szumowej, wraz z ze zwiększaniem się liczby makro uszkodzeń na tle szumu pasmowego pojawiają się impulsy drgań o wartościach do 4 g. Łożysko przechodzi do kolejnej drganiowej fazy uszkodzenia. W tej fazie mikropęknięcia są dominowane przez ubytki masowe bieżni łożyska, drgania nabierają impulsowego charakteru dobrze widocznego w widmie w postaci szeregu wartości harmonicznych względem podstawowej częstotliwości obrotowej łożyska. W analizie czasowej przebiegu drganiowego objawia się to wzrostem wartości szczytowych przy

niezmiennej wartości skutecznej, średniokwadratowej (ang. Root Mean Square – RMS) [27]. Faza ta jest określana jako faza przed-awaryjna. Dalsza eksploatacja łożyska prowadzi do fazy termicznej. W tej fazie ubytki i deformacje powodują wzrost oporów ruchu. Tarcie elementów łożyska powoduje istotny wzrost temperatury, który w krótkim czasie prowadzi do zmian właściwości fizycznych węzła łożyskowego i całego zespołu obrotowego.

Z rozważań tych należy wyciągnąć następujące wnioski:

- system diagnostyczny powinien rekomendować wymianę łożyska w końcowej fazie szumowej, bądź początkowej fazie drganiowej,
- kluczowym symptomem diagnostycznym w przypadku maszyn wykonujących ruch o charakterze obrotowym są drgania.

Wobec powyższego, zdecydowano, że podstawowym parametrem monitorowanym w ramach systemu diagnostyki maszyn wykonujących ruch o charakterze obrotowym będą drgania mechaniczne. Zdecydowano o zaprojektowaniu szeregu czujników drgań pozwalających na pomiar drgań o różnym charakterze (pasmo, amplituda) oraz z różną dokładnością. Nie oznacza to, że vibracje staną się jedynym monitorowanym parametrem, ale pozostałe parametry będą pełniły funkcje uzupełniające. Pozwoli to, między innymi, na potwierdzenie diagnozy (np. przejście łożyska do fazy termicznej), zawężenie miejsca uszkodzenia (drgania mogą się przenosić po konstrukcji maszyny na sąsiednie elementy), określenie warunków pracy (np. poziomu obciążenia) czy warunków środowiskowych (temperatura otoczenia, wilgotność).

Projektując system szczególnie nacisk położono na aspekty wdrożeniowe, a w szczególności na możliwość zabudowy systemu na już istniejących i eksploatowanych instalacjach. Użytkownicy takich obiektów często wskazują na trudności związane z montażem i utrzymaniem dodatkowych instalacji kablowych na elementach eksploatowanych maszyn, dyskwalifikując rozwiązania oparte na czujnikach przewodowych. Akcentowany jest problem uciążliwości związanych z usuwaniem uszkodzeń linii transmisyjnych i zasilających. Wskazywany jest również brak możliwości montażu takich rozwiązań dla ruchomych podzespołów maszyn (w tym wirujących). Z tego powodu zdecydowano o stosowaniu czujników bezprzewodowych. Zaletą tego rozwiązania jest również możliwość uniezależnienia się od systemu zasilania i sterowania poszczególnych zespołów. Integracja z tymi systemami, w szczególności, gdy nie były one projektowane z założeniami obsługi funkcji diagnostycznych, zwykle byłaby skomplikowana i nieefektywna. W skrajnych przypadkach mogłaby zakłócać funkcje bezpieczeństwa maszyny.

Decyzja ta wymaga zaakceptowania wad systemu bezprzewodowego, które wynikają głównie z faktu ograniczonych zasobów zasilania urządzeń odpowiedzialnych za akwizycję

danych pomiarowych, co prowadzi do redukcji ich funkcjonalności. Przykładami takich ograniczeń są między innymi:

- ograniczona częstość gromadzenia danych przez punkty pomiarowe, często połączona ze zmienną częstotliwością ich akwizycji,
- ograniczony rozmiar bloków danych podlegających transmisji do warstwy analitycznej,
- brak możliwości implementacji algorytmów złożonych obliczeniowo: np. szybkiej transformaty Fouriera (ang. Fast Fourier Transform FFT).

Sz szczególnie istotne jest ostatnie z wymienionych wyżej ograniczeń. Klasyczne podejście diagnostyki węzłów łożyskowych maszyn wirujących polega na analizie amplitud drgań w poszczególnych częstotliwościach jego widma [28]. Jednak wymaga to wyznaczenia takiego widma na podstawie spróbkowanego przebiegu czasowego (np. z zastosowaniem algorytmu FFT). Takie obliczenia mogłyby być dokonane bezpośrednio w czujniku, są jednak kosztowne energetycznie. Drugą możliwością jest przeniesienie tych obliczeń do warstwy wyższej systemu, lecz wymaga to kosztownej czasowo i energetycznie operacji przesłania wszystkich wartości spróbkowanego przebiegu.

Wybór technik bezprzewodowych implikuje konieczność rozwiązania problemów zasilania i komunikacji z czujnikami. Stan techniki pozwala na rozwiązanie problemów zasilania czujników bezprzewodowych przez zastosowanie chemicznych źródeł energii (baterie, akumulatory) lub przez wykorzystanie metod pozyskiwanie energii ze źródeł wolno dostępnych (techniki Energy harvesting) takich jak światło, wiatr, drgania, ruch, ciepło, itp. Mimo oczywistych zalet tych rozwiązań (niezależność energetyczna, bezobsługowość, brak odpadów) zdecydowano się na zastosowanie źródeł chemicznych. Głównymi powodami tej decyzji była konieczność wyboru rozwiązania dostosowanego do możliwie szerokiej gamy aplikacji - problematyczne było wskazanie alternatywnego, wystarczająco efektywnego źródła energii, dostępnego jednocześnie przy każdej potencjalnej aplikacji.

Przy założeniu bezprzewodowości czujników, naturalnym rozwiązaniem problemów ich komunikacji z warstwą analityczną systemu jest zastosowanie transmisji radiowej. Potencjalnie możliwe jest zastosowanie optycznych technik transmisji danych, jednak w tym przypadku środowisko pracy urządzeń - zapylenie, duża wilgotność skutecznie ogranicza zasięg takiej komunikacji.

Dopełnieniem warstwy akwizycji danych systemu monitorowania jest infrastruktura odbiorcza. Głównym zadaniem urządzeń wchodzących w skład tej warstwy jest odbiór danych z czujników i ich przekazanie do warstwy gromadzenia i przetwarzania. Oprócz tego, urządzenia te odpowiadają za konfigurację parametrów czujników (parametry torów pomiarowych, komunikacji), zarządzanie oprogramowaniem wbudowanym firmware czujników (w tym funkcja bootloadera), diagnostykę sieci czujników.

Przedstawione rozważania pozwalają na podsumowanie koncepcji systemu diagnostyki poprzez sformułowanie następujących wymagań dla warstwy sprzętowej systemu:

- system ma wspierać strategię PdM,
- podstawowym symptomem diagnostycznym ma być poziom drgań mechanicznych, uzupełniony o wartość temperatury,
- system może być uzupełniony o pomiar innych wielkości celem identyfikacji kontekstu pracy urządzenia,
- pomiar symptomów diagnostycznych ma się odbywać z zastosowaniem czujników bezprzewodowych, zasilanych bateryjnie, komunikujących się drogą radiową,
- nie jest konieczne, by system dokonywał analizy widmowej mierzonych wielkości,
- algorytmy działania czujników muszą uwzględniać aspekt energooszczędności, wymiana baterii w czujnikach powinna odbywać się nie częściej niż raz do roku,
- warstwa akwizycji danych powinna umożliwiać dwustronną komunikację radiową z czujnikami.

Uzupełnieniem warstwy sprzętowej systemu jest jego warstwa programowa, która powinna:

- zapewnić komunikację z urządzeniami odpowiedzialnymi za akwizycję danych protokołem zoptymalizowanym na transmisję danych telemetrycznych, zapewniającym możliwość ich szyfrowania,
- rejestrować pozyskane dane w repozytorium bazodanowym,
- umożliwiać wdrażanie systemu zarówno w sieciach lokalnych (izolowanych) jak i w wariantach chmurowych,
- umożliwiać uruchamianie procedur diagnostycznych silnika analitycznego, korzystającego z bibliotek analitycznych platform uczenia maszynowego (ang. Machine Learning) różnych dostawców,
- umożliwiać prezentację surowych danych oraz wyników działania silnika analitycznego użytkownikowi końcowemu,
- zapewniać jednoczesny i autoryzowany dostęp dla wielu użytkowników jednocześnie, z wykorzystaniem terminali pracujących pod kontrolą różnych systemów operacyjnych.

Schemat blokowy architektury systemu uwzględniający wymagania przedstawione w koncepcji prezentuje Rys. 2.

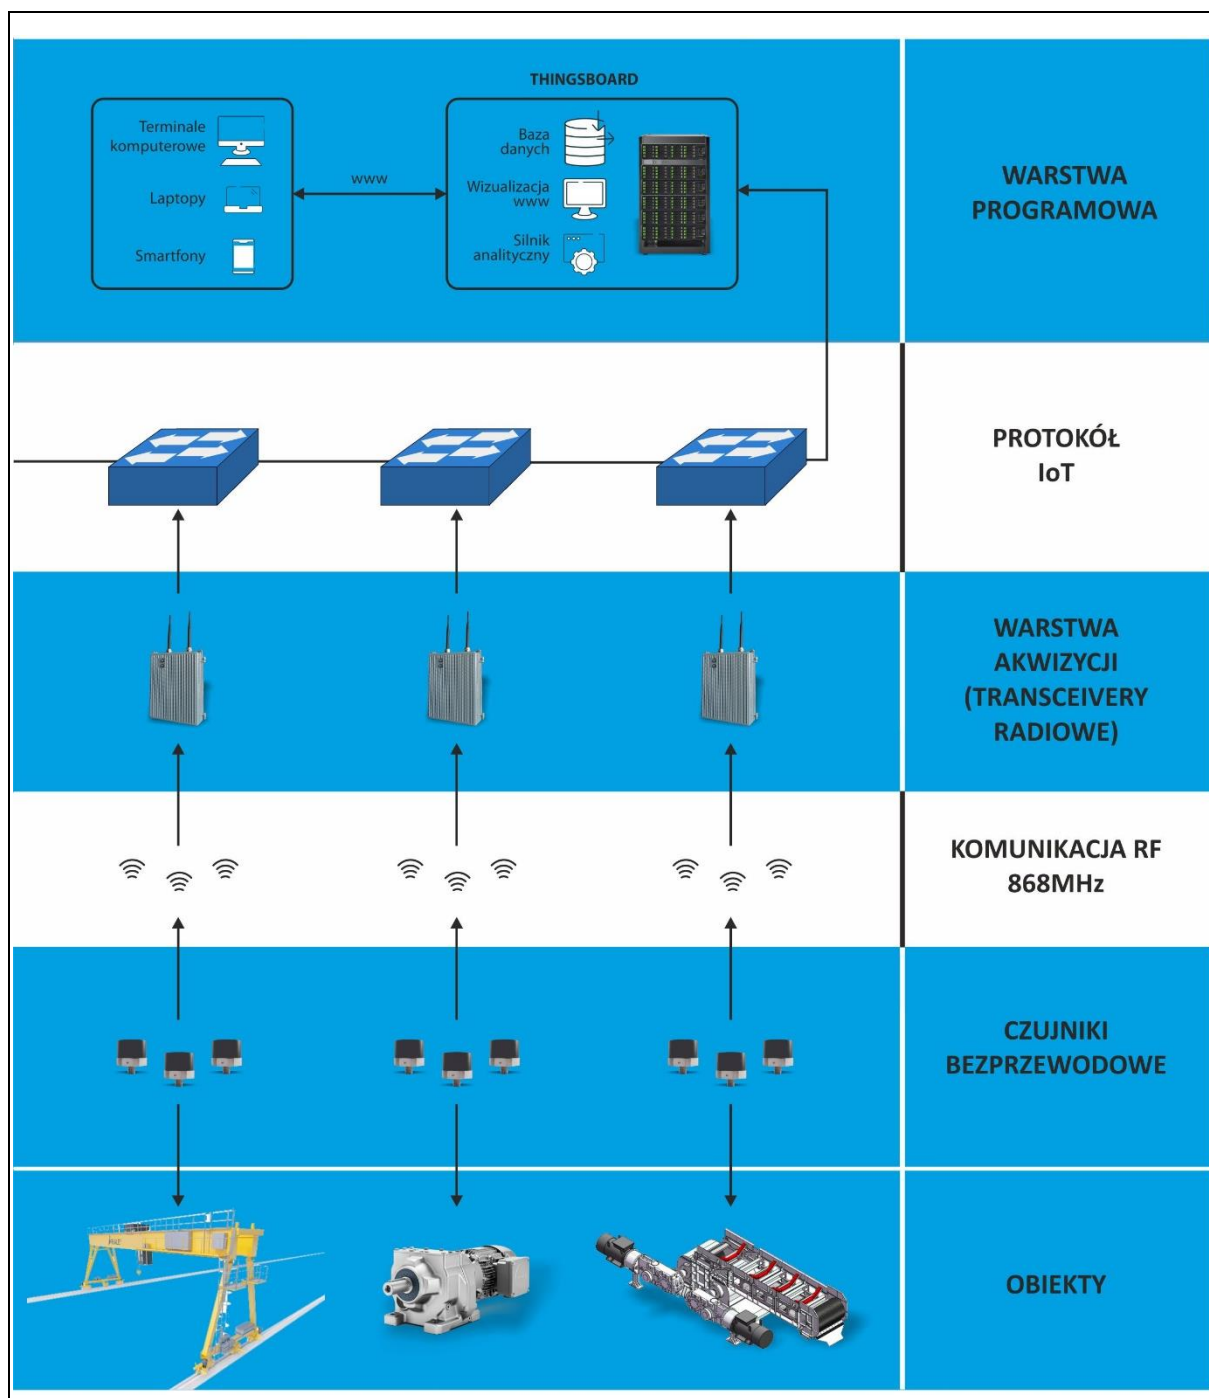


Rys. 2 Schemat blokowy architektury systemu.

2.2. Warstwa sprzętowa

Zgodnie z przedstawionymi wcześniej wymaganiami zaprojektowano architekturę systemu składającego się z warstwy sprzętowej i programowej. Architektura i zadania poszczególnych elementów zostały zaprezentowane w kolejnych podrozdziałach, a w dalszej części pracy zamieszczono opis szczegółowy.

Schemat blokowy ogólnej architektury systemu został przedstawiony na Rys. 3. Część sprzętową architektury reprezentują dolne warstwy schematu: czujniki bezprzewodowe oraz warstwa akwizycji.



Rys. 3 Architektura systemu.

2.2.1. Czujniki bezprzewodowe

Zgodnie z przedstawionymi wcześniej wymaganiami, za pozyskanie wartości odpowiadają zaprojektowane na potrzeby systemu bezprzewodowe czujniki drgań i temperatury. Czujniki montowane są bezpośrednio na elementach maszyn podlegających monitorowaniu. Sposób połączenia czujnika z obiektem zależy od lokalnych uwarunkowań technicznych i ekonomicznych. Najpewniejszym sposobem jest wkręcenie czujnika w odpowiednio przygotowany, gwintowany otwór. W tym przypadku następuje najlepsze

pod względem mechanicznym i termicznym sprzężenie czujnika z obiektem. Jednak nie zawsze jest możliwe wykonanie takiego otworu, często taka ingerencja w konstrukcję maszyny oznacza utratę gwarancji producenta. W takim przypadku stosuje się połączenie magnetyczne z zastosowaniem podstawki z wbudowanym silnym magnesem neodymowym lub klejone. Wszystkie typy czujników przygotowane są do pracy w trudnych warunkach środowiskowych, wykazując dużą odporność na zapylenie, zawilgocenie (stopień ochrony IP68) oraz udary temperaturowe. Mogą pracować w atmosferze zagrożonej wybuchem gazów i pyłów, także w strefach w których taka atmosfera występuje w sposób ciągły. Czujniki zasilane są bateryjnie z wykorzystaniem baterii litowo-chlorkowo tlenowych (Li-SOCl₂) o nominalnym napięciu 3,6 V i pojemności 1,2 Ah.

Głównym powodem zastosowania zasilania bateryjnego było uzyskanie rozwiązania w pełni autonomicznego, niewymagającego stosowania jakiegokolwiek infrastruktury kablowej. Konsekwencją takiego rozwiązania jest jednak konieczność okresowej wymiany baterii po ich wyczerpaniu. Trwałość baterii zależy z jednej strony od konstrukcji czujnika, która powinna uwzględniać wymagania energooszczędności, z drugiej strony od algorytmu pracy czujnika: - każda operacja związana z próbkowaniem sygnału mierzonego, obliczeniami i transmisją danych związane jest z wydatkiem energii. Konieczność częstej wymiany baterii zwiększa koszty eksploatacji systemu diagnostyki. Z rozmów przeprowadzonych z potencjalnymi użytkownikami systemu wynika, że akceptowalny czas pracy czujnika nie powinien być krótszy niż rok.

Podstawowym czujnikiem zastosowanym w systemie jest czujnik drgań i temperatury. Szczegółową budowę czujników przedstawiono w rozdziale 3.1. Pomiar drgań oparty jest o przetwornik akcelerometryczny wykonany w technologii MEMS (ang. Micro – Electro – Mechanical – Systems). Pozwala on na niezależne próbkowanie chwilowych wartości przyspieszeń niezależnie w trzech osiach. W podstawowej wersji czujnika częstotliwość próbkowania wynosi 5,3 kHz. Algorytm pracy czujnika determinowany jest koniecznością oszczędzania energii źródła zasilania. Dlatego przez większość czasu czujnik wprowadzany jest w tryb uśpienia (ang. sleep mode), w którym podtrzymywany jest wyłącznie układ zegarowy, pozwalający na jego wybudzenie w dyskretnych chwilach czasu. Czujnik po wybudzeniu próbkuje z zadaną częstotliwością wartości przyspieszeń w poszczególnych osiach, gromadząc odczyty w buforze RAM. Następnie wyznacza estymaty wartości maksymalnej oraz skutecznej q_{RMS} (ang. root mean square level - RMS) zbuforowanych danych. W kolejnym kroku dokonuje pomiaru temperatury, z wykorzystaniem przetwornika półprzewodnikowego oraz napięcia baterii. Następnie wymienione wcześniej parametry uzupełnione o unikalny numer identyfikacyjny czujnika są transmitowane drogą radiową w kanale pasma 868 MHz. W kolejnym kroku czujnik przełącza się w tryb odbioru na okres około 20 ms, w którym oczekuje na ewentualne komunikaty warstwy akwizycji danych.

Komunikaty te są wykorzystywane do ewentualnej parametryzacji czujnika. W przypadku braku takiej komunikacji przechodzi w stan uśpienia, w którym oczekuje kolejnego cyklu pomiarowego.

Pasmo komunikacji radiowej wybrano na podstawie badań prowadzonych w wyrobiskach podziemnych zakładów górniczych. Celem badań było uzyskanie maksymalnego zasięgu radiowego w zamkniętych pomieszczeniach o charakterze przemysłowym, w których montowane są elementy infrastruktury technicznej, wykonane ze stali, stanowiące przeszkodę na drodze propagacji fal elektromagnetycznych. W pomieszczeniach tych często pracują maszyny dużej mocy, zasilane przez przekształtniki częstotliwości, generujące zakłócenia elektromagnetyczne. Dodatkowo atmosfera może charakteryzować się dużą wilgotnością oraz obecnością pyłów przewodzących. W paśmie 2,4 GHz – atrakcyjnym ze względu na mnogość dostępnych na rynku rozwiązań technicznych – uzyskano komunikację wyłącznie przy widoczności optycznej anten nadajnika i odbiornika, zredukowanej dodatkowo przez wpływ wilgotności. Dalsze zasięgi uzyskiwano w przy częstotliwościach niższych: 145 MHz oraz 430 MHz. Wadą tych rozwiązań były jednak stosunkowo duże gabaryty anten oraz konieczność ich instalacji w pewnym oddaleniu od elementów stalowych. Docelowo najlepszym kompromisem okazało się pasmo 868 MHz, w którym uzyskano zasięgi komunikacji minimum 400 m w otwartej przestrzeni i minimum 100 m w pomieszczeniach o charakterze technicznym. W tym paśmie prowadzono również skuteczną komunikację z wykorzystaniem fal odbitych od elementów infrastruktury technicznej.

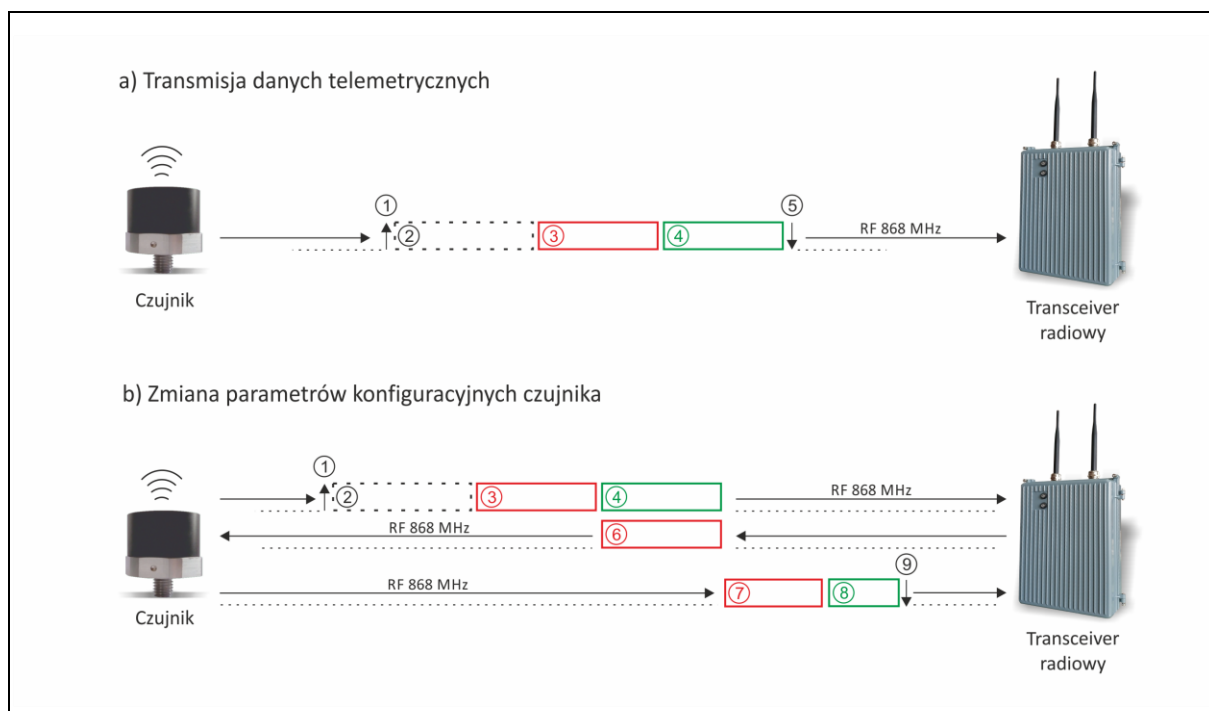
W systemie zastosowano również inne typy czujników, odpowiedzialne za pomiar innych wielkości fizycznych. Są to między innymi czujniki wilgotności, ciśnienia, natężenia prądu, prędkości obrotowej. Parametry mierzone przez te czujniki mają charakter uzupełniający, pozwalający na poznanie kontekstu pracy monitorowanego urządzenia, który może być istotny z punktu widzenia algorytmu predykcyjnego. Przykładowo wartość amplitudy drgań wężła łożyskowego zależy nie tylko od kondycji technicznej, ale również od innych czynników, w szczególności od aktualnego obciążenia maszyny.

2.2.2. *Transceivery radiowe*

Transceivery radiowe rozumiane jako połączenie nadajnika (ang. transmitter) oraz odbiornika (ang. receiver) stanowią elementy warstwy akwizycji danych. Ich podstawowym zadaniem jest odbiór radiowych ramek komunikacyjnych, zawierających między innymi wyniki pomiarów wielkości fizycznych dokonywanych przez warstwę czujników bezprzewodowych. Dane te są następnie przetwarzane i udostępniane warstwie programowej. Dodatkowym zadaniem transceiverów jest konfiguracja parametrów pracy czujników.

Transmisja danych odbywa się w paśmie 868 MHz z wykorzystaniem autorskiego protokołu transmisji. Przykładowe sesje komunikacyjne zaprezentowano na Rys. 4. Transceivery radiowe w sposób ciągły nasłuchują na kanale roboczym i nie mają fizycznej

możliwości inicjacji komunikacji z czujnikami. Czujniki wysyłają autonomicznie ramkę danych (3) po każdym cyklu pomiarowym(2). Pole danych ramki zawiera unikalny numer identyfikacyjny czujnika, napięcie baterii oraz wyniki pomiarów wykonywanych przez czujnik danego typu. Transceiver radiowy uzupełnia tę ramkę o wskaźnik siły sygnału radiowego RSSI (ang. Received Signal Strength Idication) z jaką ją odebrał i przekazuje do warstwy programowej systemu. W przypadku konieczności zmiany parametrów pracy czujnika (przykładowo zakresu pomiarowego, częstotliwości próbkowania, czasu między kolejnymi cyklami pomiarowymi, itp.), natychmiast po odebraniu danych, transceiver wysyła do czujnika żądanie zmiany parametrów (6). W tym przypadku sesja komunikacyjna kończy się po otrzymaniu potwierdzenia zmiany parametrów (7). W szczególnym przypadku (np. gdy żądanie dotyczy konieczności aktualizacji oprogramowania wbudowanego czujnika) dalsza komunikacja odbywa się na oddzielnym kanale radiowym, by nie zakłócać komunikacji z innymi czujnikami.



Rys. 4 Fazy komunikacji radiowej czujników z Transceiverami: 1 – wybudzenie czujnika, 2 – cykl pomiarowy, 3 – transmisja wyników pomiarów, 4 – tryb nasłuchu radiowego, 5 – wejście w tryb uśpienia, 6 – żądanie zmiany parametrów konfiguracyjnych czujnika, 7 – potwierdzenie zmiany parametrów, 8 – tryb nasłuchu radiowego, 9 – wejście w tryb uśpienia.

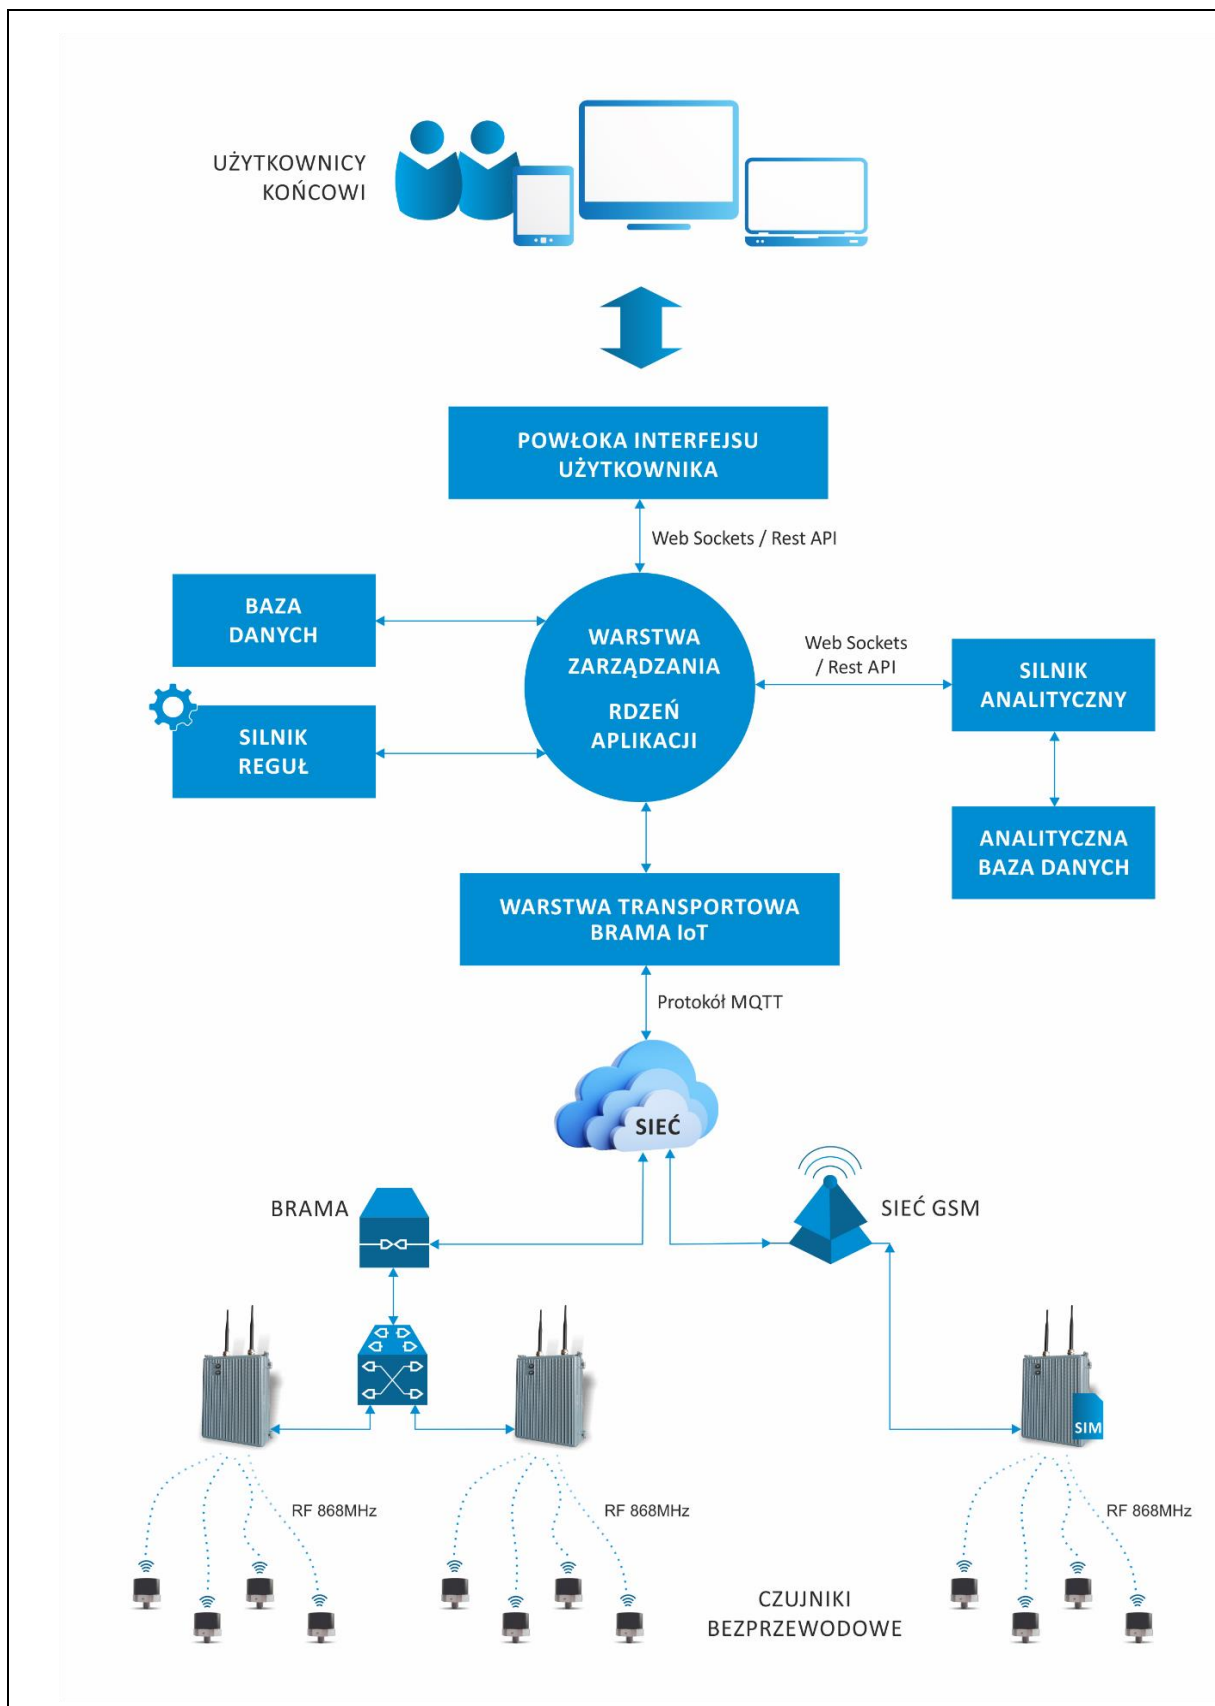
Transceivery radiowe komunikują się z warstwą programową systemu z wykorzystaniem sieci Ethernet. Elementem składowym transceivera jest switch ethernetowy obsługujący standard PoE (ang. Power over Ehtenet). Pozwala to pobór zasilania transceivera z poprzedzającego węzła sieci oraz przekazanie zasilania do węzłów kolejnych. Opcjonalnie poszczególne węzły odbiorcze mogą być zasilane zewnętrznym źródłem napięcia.

W szczególnym przypadku, transceiver może być wyposażony w modem sieci GPRS, w tym przypadku transmisja danych do warstwy programowej odbywa się z wykorzystaniem sieci komórkowej GSM. Konfiguracja transceivera odbywa się za pośrednictwem plików XML zamieszczanych w zdefiniowanych folderach wewnętrznego serwera FTP. W podobny sposób można dokonać aktualizacji oprogramowania wbudowanego firmware transceivera.

2.3. Warstwa analityczno-raportująca

Zagospodarowaniem danych wygenerowanych w wyniku działania części sprzętowej systemu zajmuje się warstwa analityczno-raportująca. Jej elementy odpowiadają za rejestrowanie tych danych w repozytoriach bazodanowych, ich analizę dokonywaną w ramach procedur diagnostycznych, prezentowanie danych surowych oraz wyników analiz użytkownikowi końcowemu.

Ogólny schemat architektury analityczno-raportującej został przedstawiony na Rys. 5.



Rys. 5 Schemat ogólny architektury systemu.

Jak wspomniano wcześniej, źródłem danych telemetrycznych są czujniki bezprzewodowe. Wyniki ich pomiarów trafiają do transceiverów radiowych z wykorzystaniem łącza radiowego na częstotliwości 868 MHz. Wszystkie transceivery łączą się z warstwą programową z wykorzystaniem sieci Ethernet. Może to być sieć lokalna (LAN) lub rozległa (WAN) – zależnie od wymagań bezpieczeństwa poszczególnych aplikacji. W przypadku sieci WAN, możliwe jest, by pewne węzły komunikowały się poprzez sieć GSM.

Warstwę programową systemu oparto o platformę ThingsBoard [29] (ozn. ThB). O jej wyborze zdecydowały cechy takie jak skalowalność, możliwość wdrażania w wariantach lokalnych i chmurowych, bezpieczeństwo oraz możliwość integracji z rozwiązaniami firm trzecich. Szczególnie ważna była ostatnia cecha, dzięki której możliwe było zintegrowanie platformy z autorskim rozwiązaniem silnika analitycznego systemu. Szerszy opis warstwy zamieszczono w rozdziale 4 niniejszej pracy. Poniżej opisano podstawowe bloki funkcjonalne warstwy.

Interfejsem danych telemetrycznych warstwy programowej jest brama IoT. Pozwala ona na komunikację z urządzeniami końcowymi, realizowaną z wykorzystaniem szerokiej gamy interfejsów przemysłowych takich jak Modbus, CAN, FTP, ODBC, OPC-UA oraz MQTT. Do komunikacji z transceiverami radiowymi wykorzystano MQTT [30], w tym celu stosowany jest element bramy IoT platformy, pełniący funkcję tzw. brokera MQTT. Dane telemetryczne wypracowane przez czujniki bezprzewodowe są grupowane w transceiverach bezprzewodowych i udostępniane w postaci wiadomości (ang. message) MQTT w tematach telemetrycznych subskrybowanych przez brokera platformy. Dane te są następnie kolejgowane i deponowane w telemetrycznej bazie danych platformy. W szczególnym przypadku mogą być one wstępnie przetwarzane przez silnik reguł.

Istotnym elementem warstwy programowej systemu jest silnik analityczny. Jego głównym zadaniem jest uruchamianie modeli diagnostycznych, które tworzone są przez analityków danych na podstawie danych historycznych. Odpowiada on również za ich konfigurację, testowanie, cykliczne uruchamianie oraz przygotowanie wyników działania. W ramach silnika funkcjonuje również środowisko pozwalające na przygotowanie nowych modeli diagnostycznych. Silnik analityczny szerzej omówiono w rozdziale 4.5. Za uruchamianie modeli diagnostycznych w ramach silnika analitycznego odpowiada platforma MLFlow[31]. Dane wejściowe oraz pośrednie (dot. m.in. parametrów modeli, czasu stosowania konkretnego modelu etc.) oraz wypracowane prognozy przechowywane są w tabelach analitycznej bazy danych. Baza ta zawiera informacje na temat danych konfiguracyjnych modeli, danych konfiguracyjnych obiektów podlegających „prognozowaniu” oraz parametrów prognoz. Przechowywane tam są również informacje o danych treningowych i walidacyjnych, na których były trenowane i optymalizowane

modele diagnostyczne. Wymiana danych pomiędzy silnikiem analitycznym a rdzeniem platformy ThB odbywa się z wykorzystaniem interfejsów REST API.

Prezentacja wyników działania modeli odbywa się już z wykorzystaniem pulpitów menadżerskich (tzw. dashboard'ów) tworzonych w ramach platformy ThB. Mają one postać interaktywnych raportów analitycznych. Sama warstwa wizualizacji umożliwia również dostęp do surowych danych telemetrycznych. Prezentuje je w postaci licznych kontroltek, różnego rodzaju wykresów, tabel skomponowanych w intuicyjne plansze wizualizacyjne.

Powłoka interfejsu użytkownika działa w oparciu o przeglądarkę internetową.

2.4. Analiza konkurencji

W dobie rewolucji przemysłowej określanej przez ekspertów Przemysłem 4.0 postępuje integracja pomiędzy fizycznymi i cyfrowymi systemami środowisk produkcyjnych [15]. Efektem ubocznym tego zjawiska jest fakt gromadzenia dużej ilości danych procesowych, pochodzących z szerokiej gamy czujników montowanych na urządzeniach w różnych sektorach zakładów przemysłowych [32]. Dane te mogą być i są wykorzystywane przy wdrażaniu strategii PdM. W pracach [15, 33] podsumowano najczęściej stosowane algorytmy ML stosowane do rozwiązywania problemów PdM w przemyśle. Wśród najczęściej wymienianych są maszyny wektorów podpierających (ang. support vector machines SVM), lasy losowe (ang. random forests RF), sztuczne sieci neuronowe (ang. artificial neural networks ANN).

W okresie ostatnich kilku lat znacząco rozwinęły się również zastosowania metod głębokiego uczenia do rozwiązywania zadań związanych z PdM [13, 15, 32–34] szczególnie rozwinęły się metody identyfikacji wartości odstających bazujące na idei uczenia głębokiego [35–37]. Zaletą tych metod jest duża czułość i specyficzność wykrywania potencjalnych awarii, jednakże wymagają one dużego zbioru danych treningowych co często uniemożliwia ich stosowanie w praktyce, gdyż problem tzw. zimnego startu stanowi barierę dla ich stosowania. W obszarach wizji komputerowej i przetwarzaniu języka naturalnego stosowany jest często paradygmat tzw. transfer learning – czyli stosowania pretrenowanej - na danych opisujących podobny problem - sieci neuronowej określonej architekturze. Niestety w odniesieniu do specyficznych obiektów technologicznych zastosowanie transfer learning jest trudne, według wiedzy autora nie opracowano do tej pory efektywnych architektur sieci dedykowanych np. do identyfikacji awarii (ogólnie identyfikacji przykładów wskazujących na awarię) w mocno niezbalansowanych zbiorach danych temporalnych.

W literaturze można znaleźć całą gamę publikacji dotyczących metod badawczych zastosowanych do rozwiązania konkretnych problemów związanych z PdM. Przykładowo w publikacjach [38–41] zaprezentowano wyniki badań nad zastosowaniem różnych algorytmów ML do monitorowania i prognozowania stanu technicznego obrabiarek

sterowanych numerycznie CNC z uwzględnieniem ich narzędzi. Autorzy publikacji [42–45] wykorzystywali algorytmy ML do procesów PdM w diagnostyce turbin wiatrowych, w publikacjach [46, 47] badano algorytmy ML w odniesieniu do problemów związanych z prognozowaniem stanu technicznego turbin gazowych, a w [48, 49] silników turbodrzutowych. Przedmiotem badań były także wentylatory [50, 51], pompy [52, 53], silniki elektryczne [54–56], czy same łożyska [57–59]. Cechy do algorytmów były generowane na podstawie rzeczywistych danych pozyskanych głównie z czujników drgań, aczkolwiek w niektórych przypadkach były uzupełniane o dane pochodzące z czujników akustycznych, czujników temperatury czy czujników ciśnienia.

Systemy komputerowe dedykowane do definiowania, monitorowania i prognozowania stanów diagnostycznych urządzeń można kategoryzować z różnych punktów widzenia. Jednym z takich sposobów jest ich podział na systemy szkieletowe [60] oraz dedykowane do konkretnego rozwiązania lub grupy rozwiązań (np. [61]). Metodyki realizacji zadań diagnostyki, utrzymania maszyn i urządzeń [62], predykcyjnego utrzymania ruchu [63, 64] czy diagnostyki uszkodzeń [65–67] pozwalają na coraz efektywniejsze wykorzystanie parku maszynowego będącego w zasobach przedsiębiorstw.

Opracowane modele ML dedykowane do rozwiązywania zadań PdM muszą pracować w sposób ciągły w wybranym obiekcie technologicznym. Często konieczne jest uruchamianie wielu modeli jednocześnie. Oczywiście jest, że konieczne jest również monitorowanie jakości działania modeli diagnostycznych i innych ich parametrów. Z praktycznego punktu widzenia nietrywialnym problemem staje się wybór odpowiedniej platformy pozwalającej na wdrażanie modeli ML (w szczególności modeli realizujących zadania PdM). W pracach [[68–70] zamieszczono porównania różnych platform analitycznych umożliwiających realizację tego typu zadania.

O ile poszczególne platformy nie wykazują dużych różnic pod względem wydajności obliczeń [68], o tyle różnią się pod względem metod dostępu do danych, metod czyszczenia danych, sposobu prezentacji wyników działania, stopnia automatyzacji uruchamiania metod ML, interfejsu użytkownika, sposobu licencjonowania.

Przykładem takiej platformy jest środowisko Alteryx Analytics [71, 72]. Oprogramowanie to jest zorientowane na użytkowników wdrażających aplikacje biznesowe i socjologiczne. Użytkowanie środowiska nie wymaga wysokich kompetencji w zakresie programowania: użytkownik wykorzystuje przygotowane komponenty interfejsu graficznego zestawiając je metodą „przeciągnij i upuść”. Autorzy oprogramowania akcentują zalety związane z łatwością obsługi, skróceniem czasu potrzebnego na przygotowanie danych do analiz i wysoką automatyzacją procesów analizy. Mocną stroną jest rozbudowany system wsparcia użytkownika. Recenzenci platformy postrzegają ją jednak jako narzędzie przeznaczone głównie do procesów przygotowania danych i wskazują na luki w zakresie

automatyzacji budowy i selekcji modeli, raportowania i wizualizacji [70]. Poważną wadą środowiska jest brak wsparcia dla systemów Linux i brak możliwości uruchamiania procesów na kilku maszynach.

Innym przykładem jest platforma KNIME [73, 74] udostępniana na licencji GPL przez uniwersytet w Konstancji. Użytkownik buduje w środowisku procesy realizujące algorytmy ML poprzez łączenie graficznych bloków funkcjonalnych, obejmujących zadania wszystkich etapów przetwarzania: od akwizycji danych po wizualizację wyników działania modeli. W szczególności dobrze radzi sobie z automatyzacją procesu projektowania i wdrażania modeli z uwzględnieniem automatycznego oczyszczania danych i generacji cech [70]. Platforma zapewnia integrację z innymi narzędziami analitycznymi opartymi o licencje otwarto-źródłowe takimi jak R, Python, Spark, Weka czy Keras. Środowisko jest bardzo wydajne i doskonale radzi sobie z dużymi zbiorami danych – także klasy Big Data.

Kolejnym przykładem platformy pozwalającej na tworzenie i uruchamianie projektów analitycznych opartych o algorytmy ML jest Databricks [75]. Platforma została opracowana w firmie o tej samej nazwie założonej przez twórców platformy programistycznej dla obliczeń rozproszonych Apache Spark i oparta na jej silniku. W 2018 roku w następstwie integracji platform Databricks i Microsoft Azure dostępna jest pod nazwą Azure Databricks [76]. Platforma jest przedstawiana jako zoptymalizowana pod względem wydajności i struktury do przetwarzania dużych zbiorów danych. Konsekwencją otwarto-źródłowego pochodzenia jest możliwość korzystania z popularnych bibliotek ML stworzonych w ramach projektów OpenSource takich jak MLFlow, TensorFlow, Pytorch, Keras, itp. stanowi kompletne środowisko do tworzenia i uruchamiania modeli ML.

Obserwuje się również tendencję to wyposażania platform analitycznych ogólnego przeznaczenia np. RapidMiner [77], SAS [78], MS Azure [79, 80] w komponenty dedykowane do realizacji procesów PdM.

W szczególności MS Azure oferuje zestaw narzędzi pozwalający na zastosowanie technologii IoT jako źródła danych dla architektur wykorzystujących uczenie maszynowe w aplikacjach wspierających między innymi procesy PdM czy wykrywania anomalii [81].

Pewne elementy rozwiązań PdM zaczynają również oferować producenci elementów warstwy sprzętowej (w tym rozwiązań IoT), systemów SCADA i CMSS. Przykładem jest niemiecka firma BeanAir oferująca system BeanScape bazujący na czujnikach wibroakustycznych własnej produkcji [82]. System ten oferuje standardową wizualizację i raportowanie spotykane w większości systemów klasy SCADA, jak również pewne elementy analizy danych (polegające głównie na analizie trendu i monitorowaniu przekroczeń progów alarmowych). Innym przykładem jest system Wimon Data Manager [83] produkcji ABB, bazujący na czujnikach wibroakustycznych własnej produkcji. Platforma ta realizuje zadania wizualizacji i analityki danych, pozwalając na automatyczne lub ręczne

zarządzanie gromadzeniem danych, analizą trendu monitorowanych wielkości, integrację z zewnętrznym systemem ABB Analyst [84]. Wspiera ona również powiadamianie realizowane na planszach diagnostycznych o przekroczeniu wcześniej zdefiniowanych progów alarmowych wielkości monitorowanych przez czujniki. Z kolei firma KCF Technology [85] jest producentem czujników wibroakustycznych dostarczających danych do systemu Machine Condition Monitoring Software. Aplikacja ta pozwala na śledzenie trendów zmian poszczególnych monitorowanych wielkości wraz z możliwością alarmowania za pośrednictwem komunikatów SMS lub email o przekroczeniach wcześniej zdefiniowanych progów. Aplikacja ta dostarcza również gotowe statystyczne opracowania dla analizy drgań. Kolejnym producentem czujników wibroakustycznych wspierających analizę wibroakustyczną jest firma AMC Vibro oferująca system AVE Care [86]. Podobnie jak we wcześniej przytoczonych przykładach, system tej firm pozwala na nadzór nad stanem technicznym maszyn w oparciu o przekroczenia progów ostrzegawczych i alarmowych zdefiniowanych dla poszczególnych punktów pomiarowych.

Przykładem firmy oferującej rozwiązania MES oraz CMMS z elementami PdM jest firma QUERIS [87]. Systemy te realizują zadania wspierania działów utrzymania ruchu w oparciu o dane pozyskiwane z zewnętrznych systemów SCADA.

Istnieją również firmy specjalizujące się tylko w rozwiązaniach programowych realizujących zadania PdM. W obrębie polskiego rynku warto wymienić krakowską firmę ReliaSol oferującą platformę analityki predykcyjnej RSIMS [88]. Silnik analityczny tej platformy wspiera zadania PdM w oparciu o już dostępne w systemach użytkowników dane pomiarowe i produkcyjne wdrażając metody uczenia maszynowego.

Ze względu na tematykę niniejszej rozprawy na szczególną uwagę zasługują prace, w których wejściowym sygnałem będącym podstawą diagnostyki, są drgania generowane przez pracujące urządzenie. W pracy [89] monitorowano zachowanie pompy nurnikowej w żurawiu samochodowym poprzez akwizycję jej drgań w trzech wymiarach. Znane były widma pracy urządzenia w stanie poprawnym oraz pięciu niepoprawnych stanach diagnostycznych. Do klasyfikacji bieżącego stanu pompy zastosowano techniki wnioskowania bayesowskiego, której parametry były strojone z wykorzystaniem algorytmu optymalizacji chmurą cząstek (ang. particle swarm optimization).

W pracy [90] przedstawiono rozwiązanie mające na celu wykrywanie uszkodzeń przekładni przenośnika taśmowego koparki w kopalni odkrywkowej. Dane wejściowe stanowiły cechy utworzone na podstawie zmian poziomu drgań oraz ich częstotliwości. Selekcja najbardziej istotnych cech odbywała się z wykorzystaniem samoorganizujących sieci neuronowych. Na podstawie wyniku grupowania zdefiniowano najbardziej znaczące sygnały z punktu widzenia dwóch uszkodzeń przekładni.

Do celu analizy danych, których źródłem są czujniki drgań, stosuje się również transformatę falkową. Przegląd zastosowań tej metodyki do diagnostyki urządzeń przedstawiono w [91, 92]. W szczególności metodę tę stosowano do wykrywania uszkodzeń wirnika silnika indukcyjnego [93], wykrywania uszkodzeń wyłączników wysokonapięciowych [94], czy też diagnostyki maszyn prądu stałego [95].

Przebiegi amplitudy drgań zazwyczaj nie są stacjonarne, z tego powodu do ich analizy stosuje się często tak zwaną kurtozę spektralną [96]. Metodę tę wykorzystano między innymi do wykrywania uszkodzeń zębów w przekładniach planetarnych turbin wiatrowych [97], czy też oceny stanu łożysk [98].

Kompleksowe ujęcie problematyki budowy modeli diagnostycznych na podstawie analizy drgań stanowi praca Samuela [99], w której przedstawiono wiele wariantów wykorzystania pomiarów drgań (począwszy od propozycji prostych wskaźników statystycznych w dziedzinie czasu i częstotliwości, poprzez transformację falkową, zastosowanie sieci neuronowych, aż po modelowanie matematyczne) do budowy modeli diagnostycznych urządzeń.

Bartelmus i inni w pracach [100, 101] podejmują z kolei temat uwzględniania podczas analizy drgań obciążenia, pod jakim w danej chwili pracuje urządzenie (np. przenośnik lub koparka kołowa). Wyodrębnienie składowej drgań wywołanych zmiennym obciążeniem urządzenia i odjęcie jej od oryginalnie zaobserwowanego szeregu drgań pozwala – w szczególnych przypadkach – na uzyskanie właściwych danych wejściowych dla procesu diagnostycznego.

Powyższy przegląd pokazuje, że zarówno z punktu widzenia metodycznego jak również produktowego (gotowe systemy) obserwujemy dynamiczny rozwój metod i systemów dedykowanych do realizacji zadań PdM.

Na tle konkurencji rozwiązanie opracowane w ramach realizowanej pracy doktorskiej charakteryzuje się kompleksowością (obejmuje warstwę sprzętową i programową, oferuje unikalny bezprzewodowy system akwizycji danych; zapewnia składowanie i wizualizację danych; zapewnia silnik i bazę analityczną – w tym zakresie bazuje na własnych rozwiązaniach oraz dojrzałych rozwiązaniach open source). System zawiera również dwie metody PdM bazujące na analizie trendu i identyfikacji wartości odstających. Jednak w ramach systemu można wdrażać – po dostosowaniu – dowolną metodę analityczną dedykowaną do realizacji zadań PdM.

3. Warstwa sprzętowa

3.1. Czujniki

3.1.1. Czujniki wibroakustyczne

Drganie lub ruchem drgającym nazywamy taki ruch, przy którym badana współrzędna na przemian zbliża się lub oddala od pewnej przeciętnej wartości [102]. Wartość ta jest zwykle określana punktem równowagi statycznej.

Typowym przykładem ruchu drgającego jest ruch harmoniczny prosty. Pozwala to na wykorzystanie jego równań do zdefiniowania podstawowych wielkości charakteryzujących ruch drgający. Przemieszczenie q w takim ruchu możemy opisać równaniem:

$$q = \hat{q} \sin(\omega t) \quad (1)$$

gdzie \hat{q} oznacza amplitudę, a ω częstość kątową ruchu. Z równania tego można wyznaczyć przebieg prędkości:

$$\dot{q} = \hat{q} \omega \cos(\omega t) \quad (2)$$

oraz przyspieszenie:

$$\ddot{q} = -\hat{q} \omega^2 \sin(\omega t) \quad (3)$$

Przytoczone równania wskazują, że pomiar jednej z wielkości jest wystarczający do wyznaczenia dwóch pozostałych: przebieg prędkości możemy uzyskać poprzez jednokrotne całkowanie zarejestrowanego przebiegu przyspieszenia, a przemieszczenie poprzez dwukrotne całkowanie tej funkcji.

Do opisu ilościowego drgań stosowane są następujące estymaty sygnałów [103]:

- wartość międzyszczytowa (peak-to-peak), definiowana jako różnica maksymalnych odchyłeń dodatnich i ujemnych,
- wartość szczytowa (peak), definiowana jako maksymalne odchylenie od punktu równowagi,
- wartość średnia q_{avr} (average level), definiowana jako całka wartości bezwzględnej funkcji w okresie T :

$$q_{avr} = \frac{1}{T} \int_0^T |q(t)| dt, \quad (4)$$

- wartość skuteczna q_{RMS} (root mean squer level RMS), definiowana wzorem:

$$q_{RMS} = \sqrt{\frac{1}{t_2 - t_1} \int_{t_2}^{t_1} [q(t) - q_{avr}]^2 dt}, \quad (5)$$

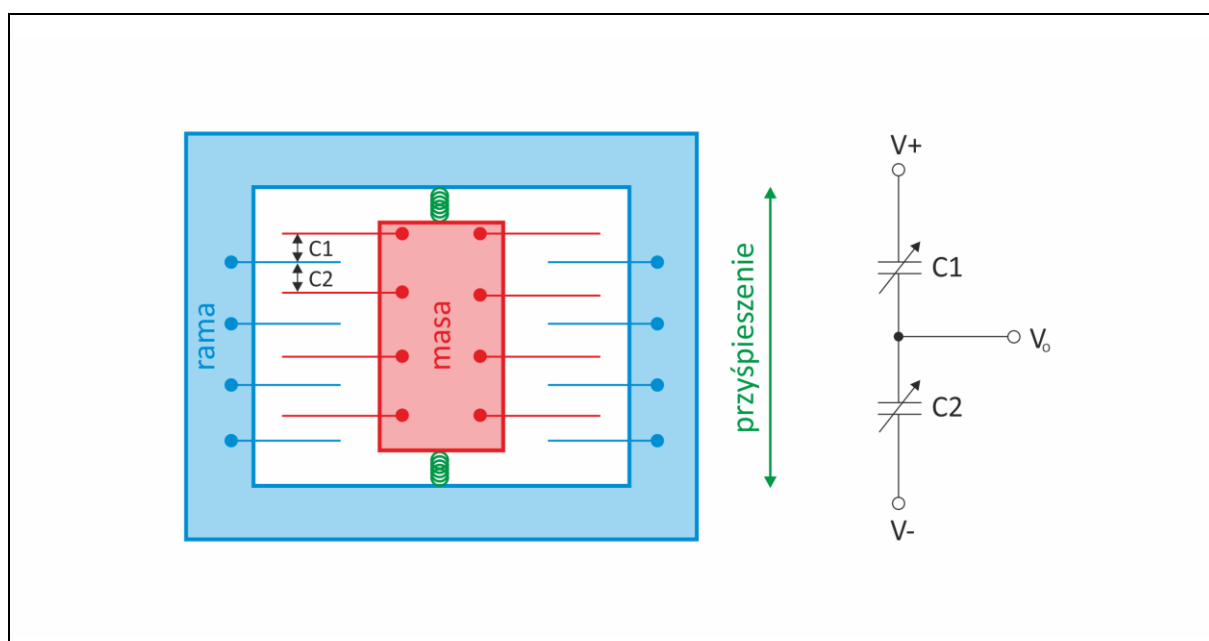
- który ulega uproszczeniu dla funkcji okresowych o okresie T :

$$q_{RMS} = \sqrt{\frac{1}{T} \int_0^T q^2(t) dt}, \quad (6)$$

- współczynnik maksymalnego przesterowania względem wartości skutecznej CR (ang. crest factor), określany jako stosunek wartości szczytowej sygnału do wartości skutecznej RMS.

W praktyce najczęściej mamy do czynienia z drgającym ruchem wypadkowym będącym superpozycją ruchów harmonicznym. Stąd do oceny drgań przydatną staje się analiza częstotliwościowa, której wynikiem jest postać widma amplitudowego. Do wyznaczenia takiego widma stosowana jest transformata Fouriera. Źródłem poszczególnych składowych widma są elementy maszyny wykonujące ruch obrotowy z różnymi prędkościami. Można wówczas przyporządkować każdej z prędkości obrotowej odpowiedni prążek widma i na tej podstawie identyfikować który element podzespołu ulega uszkodzeniu. Taka analiza jest jednak bardzo złożona: wymaga przede wszystkim opracowania dokładnego modelu dynamicznego maszyny. Model ten jest inny dla każdego typu czy nawet egzemplarza maszyny i wrażliwy na aktualne parametry pracy takie jak, obciążenie czy zmiana prędkości obrotowej. Algorytm FFT jest złożony obliczeniowo, a wynik obliczeń wymaga przesłania informacji o amplitudzie każdej częstotliwości składowej. W wielu przypadkach estymaty sygnałów takie jak wartość szczytowa czy wartość skuteczna są wystarczające do potrzeb diagnostyki.

Do pomiaru przyspieszeń wykorzystuje się trzy podstawowe rodzaje przetworników: MEMS, piezorezystancyjne i piezoelektryczne. Pierwszy z wymienionych rozpowszechnił się wraz z rozwojem technologii MEMS (Micro – Electro – Mechanical – Systems) - zintegrowanych urządzeń łączących elementy mechaniczne i elektryczne w strukturach o rozmiarach rzędu mikrometrów. Uproszczoną budowę akcelerometru zbudowanego w oparciu o tą technologię pokazuje Rys. 6.



Rys. 6 Uproszczona budowa akcelerometru MEMS.

Przetwornik bazuje na pomiarze zmian pojemności kondensatora grzebieniowego składającego się z masy zawieszanej na mikrosprężynkach pomiędzy jego okładzinami. Przemieszczająca się pod wpływem zewnętrznych przyspieszeń masa powoduje zmiany odległości pomiędzy okładzinami kondensatora, co skutkuje zmianami jego pojemności [104–106]. Do zalet tego typu przetworników należą niska cena, możliwość pomiaru przyspieszeń wolnozmiennych ze stałą włącznicą oraz miniaturowe rozmiary. Nie bez znaczenia jest również energooszczędność procesu pomiarowego bazującego na pomiarach pojemności, szczególnie w kontekście aplikacji bezprzewodowych. Wadą rozwiązania jest niskie w stosunku do innych technologii pasmo pomiarowe oraz mniejsza dokładność.

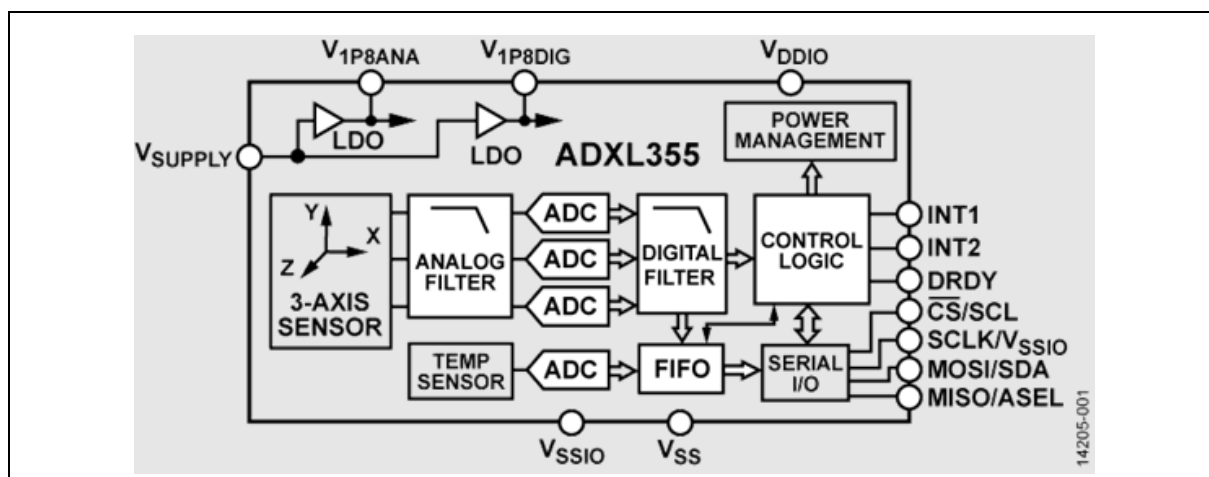
Akcelerometry piezorezystancyjne wykorzystują efekt stosowany między innymi w tensometrach. Zasada działania polega na pomiarze rezystancji materiału piezorezystancyjnego podlegającego odkształceniom na skutek działania zewnętrznej siły. Do zalet tych przetworników należą duże pasmo pomiarowe oraz możliwość pomiaru przyspieszeń o dużych amplitudach. Doskonale nadają się również do pomiaru przyspieszeń wolnozmiennych. Podstawową ich wadą jest zależność od zmian temperatury zewnętrznej - wymagają skomplikowanego procesu kompensacji termicznej oraz niska czułość.

Ostatniej wady pozbawione są akcelerometry piezoelektryczne. Wykorzystują one efekt powstawania napięcia elektrycznego wskutek zewnętrznych naprężeń. Zaletami tego typu przetworników są duża dokładność i duże pasmo pomiarowe – nawet kilkanaście kHz. Podstawową wadą jest wysoka cena. Nie nadają się one również do pomiaru przyspieszeń wolnozmiennych [107]. W praktyce dolna granica pasma pomiarowego to około 10Hz. Wymagają również kompensacji temperaturowej.

Wymienione wyżej przetworniki wymagają sprzężenia mechanicznego czujnika z obiektem mierzonym. Pomiar drgań, może jednak odbywać się również w sposób bezdotykowy. Niekoniecznie musi to być zaletą - taka metoda pomiaru wymaga montażu czujnika w odizolowanym wibracyjnie układzie odniesienia, co nie zawsze jest możliwe. Jednym z przykładów jest mikrofon dokonujący pomiarów w paśmie akustycznym. Zaletą tego typu pomiaru jest wysokie pasmo, wadą - bardzo mała dokładność pomiaru wartości bezwzględnych wibracji. W praktyce nadają się one do zgrubnej analizy widmowej drgań w zakresie wyższych częstotliwości. Klasycznymi przykładami przetworników bezdotykowych są czujniki przemieszczeń indukcyjne lub pojemnościowe [108], dziś praktycznie wypierane przez czujniki oparte o technologie laserowe lub wizyjne. Laserowe czujniki drgań opierają swoje działanie na analizie rozproszenia wiązki laserowej na powierzchni badanego elementu maszyny [109]. Wykorzystują one pomiar fluktuacji częstotliwości odbitej, modulowanej wiązki laserowej powstałych na ruchomej powierzchni w wyniku efektu Dooplera [110]. Na rynku dostępnych jest wiele odmian tego typu przetworników różniących się między sobą głównie szczegółami budowy części optycznej. Nowością na rynku są systemy wizyjne dokonujące pomiarów przemieszczeń metodami fotometrii obrazowej [111, 112]. Oprogramowanie takiego systemu dokonuje analizy przemieszczeń poszczególnych pikseli rejestrowanych przez matrycę przetwornika wizyjnego szybkiej kamery. Pozwala to na pomiar przemieszczeń wielu punktów naraz. Systemy te często wyposażane są w oprogramowanie ułatwiające identyfikację elementów drgających z amplitudą wskazującą na uszkodzenie poprzez wyróżnienie kolorem lub nienaturalne wzmocnienie przemieszczeń fragmentów obrazu [113].

Głównymi kryteriami doboru przetworników drgań przy tworzeniu systemu diagnostycznego opisywanego w niniejszej rozprawie były parametry pomiarowe istotne dla aplikacji (pasmo, spodziewane amplitudy drgań, parametry szumowe) oraz niski pobór mocy zasilania w całym cyklu pomiarowym. W związku z tym zdecydowano o stosowaniu akcelerometrów opartych o technologię MEMS w aplikacjach podstawowych oraz akcelerometrów piezoelektrycznych dla aplikacji wymagających pomiarów w szerszym paśmie częstotliwości.

Rys. 7 pokazuje schemat blokowy przetwornika akcelerometru opartego na układzie Analog Devices ADXL355.



Rys. 7 Schemat blokowy przetwornika ADXL 355 [114].

Układ jest przykładem mikro-elektromechanicznego systemu MEMS przeznaczony do pomiaru przyspieszeń w trzech osiach [114]. Wykazuje się ultraniskimi szumami ($22.5 \mu\text{g}/\text{Hz}^{0.5}$) oraz wysoką stabilnością długookresową przesunięcia 0g względem zmian temperatury ($0,15 \text{ mg}/^\circ\text{C}$). Zakres pomiarowy może być wybierany spośród wartości $\pm 2 \text{ g}$, $\pm 4 \text{ g}$ lub $\pm 8 \text{ g}$. Układ posiada trzy niezależne mikro kondensatory pomiarowe dla każdej z osi wyposażone w oddzielne, w pełni różnicowe tory pomiarowe co pozwala na minimalizację przesłuchów pomiędzy kanałami oraz dryftu i szumów. Sygnały pomiarowe są próbkowane z wykorzystaniem 20-bitowego przetwornika analogowo-cyfrowego typu $\Sigma\text{-}\Delta$. Częstotliwość próbkowania może być płynnie dobierana w zakresie 3,9 Hz - 4 kHz. Przetwornik posiada wbudowane filtry antyaliasingowe, umieszczone w każdym z trzech torów pomiarowych przed i za przetwornikiem analogowo-cyfrowym. Użytkownik może ustalać parametry tych filtrów. Komunikacja z układem nadrzędnym może się odbywać z wykorzystaniem standardu SPI lub I^2C . Istotnymi z punktu widzenia zasilania baterijnego są również parametry poboru mocy. Układ ADXL355 charakteryzuje się poborem prądu 200 μA w trybie pomiaru oraz 21 μA w trybie czuwania.

3.1.2. Czujniki temperatury

Mimo, że wzrost temperatury jest symptomem diagnostycznym występującym w końcowej fazie rozwoju uszkodzenia [25, 26], nie może on być pominięty w systemie diagnostycznym. Dlatego czujnik temperatury jest istotnym elementem systemu. Ważną kwestią jest poprawny dobór czujnika i przetwornika w kontekście wymagań stawianych przez aplikację.

W dużym uproszczeniu dostępne dzisiaj czujniki temperatury można podzielić na rozszerzalnościowe, przetworniki elektryczne oraz optyczne (bezkontaktowe).

Pierwsze z nich wykorzystują zjawisko rozszerzalności cieplnej materiału. Przykładem takich czujników są termometry bimetalowe, w których wykorzystuje się efekt odkształcenia

elementu składającego się z kompozytu dwóch metali (lub ich stopów) o skrajnie różnych parametrach rozszerzalności termicznej. Innym przykładem są termometry wykorzystujące zjawisko rozszerzalności cieplnej cieczy (termometry z kapilarą) lub gazów (termometry manometryczne). Wspólnymi cechami czujników rozszerzalnościowych są wysoka rozdzielczość, dokładność oraz stabilność i powtarzalność pomiarów. Do ich działania nie jest wymagane zewnętrzne zasilanie. Najczęściej są wykorzystywane jako przyrządy wzorcowe i laboratoryjne.

Termometry elektryczne wykorzystują zjawisko zmienności wybranej wielkości elektrycznej elementu względem temperatury. Wśród nich możemy wyróżnić czujniki termoelektryczne (tzw. termopary) oraz rezystancyjne i półprzewodnikowe. O powszechności ich stosowania w metrologii elektrycznej świadczy fakt, że poddane zostały normalizacji (EN-60584 oraz EN-60571). Przykładem popularnych termometrów rezystancyjnych są czujniki wykorzystujące zmianę rezystancji platyny (Pt) pod wpływem zmian temperatury. Najpopularniejsze konstrukcje tych czujników to Pt100 oraz Pt1000 których rezystancja znamionowa wynosi odpowiednio 100 Ω oraz 1000 Ω w temperaturze 0 °C. Charakterystyka rezystancji w funkcji temperatury oraz dokładność tych czujników jest znormalizowana (EN-60571). Najdokładniejsze z nich (klasa AA) dopuszczają odchyłkę temperatury 0,1 °C.


Przykładami termometrów optycznych są czujniki światłowodowe oraz czujniki pirometryczne. Pierwsze z nich wykorzystują efekt wpływu temperatury na współczynnik odbicia światłowodu. Przy współpracy z reflektometrem można w sposób precyzyjny wyznaczyć temperatury poszczególnych odcinków światłowodu. Czujniki pirometryczne bazują na detekcji promieniowania cieplnego obiektów głównie w paśmie podczerwieni. Główną ich zaletą jest bezkontaktowość pomiaru, co pozwala na umieszczenie czujnika w pewnym oddaleniu od obiektu oraz na izolację termiczną od obiektu. Obecnie czujniki te konstruowane są w postaci detektorów punktowych (pirometry) lub matrycowych (kamery termowizyjne). Istotnym elementem tych czujników jest układ ogniskowania promieniowania w detektorze wykonany w postaci soczewki lub układu soczewek. Materiał soczewki musi być w tym przypadku transparentny w paśmie optycznym detektora.

3.1.3. Czujniki pomocnicze

Wcześniej opisane czujniki drgań i temperatury pełnią w systemie diagnostyki funkcję podstawową, dostarczając informacji na temat symptomów diagnostycznych najbardziej istotnych z punktu widzenia oceny kondycji węzłów łożyskowych maszyn wykonujących ruch obrotowy. Jednakże, poziom drgań czy wartość temperatury nie tylko zależy od stopnia zużycia danego elementu, ale także od innych czynników, np. aktualnej prędkości obrotowej, stopnia obciążenia czy trybu pracy. W szczególnych przypadkach informacja na temat tych dodatkowych parametrów jest niezbędna do działania modelu diagnostycznego realizującego

zadania PdM. Z tych powodów, zaprojektowano dla systemu dodatkowe czujniki, pełniące funkcje pomocnicze, badające tzw. kontekst pracy urządzenia.


Przykładem takiego czujnika jest bezprzewodowy czujnik prędkości obrotowej. Pozwala on uwzględniać wzrost poziomu drgań danego węzła łożyskowego spowodowanego zmianą prędkości obrotowej. Do pomiaru tej wielkości wykorzystano efekt Halla, polegający na występowaniu różnicy potencjałów w przewodniku, w obecności pola magnetycznego. Głowicę czujnika wyposażono w przetwornik typu DRV5021A3 produkcji Texas Instruments wykrywający zmieniający stan wyjścia cyfrowego po przekroczeniu predefiniowanych wartości progowych natężenia pola magnetycznego w jakim znajduje się przetwornik. W celu zastosowania tego czujnika wymagane jest zamontowanie magnesu neodymowego na powierzchni bocznej elementu wykonującego ruch obrotowy. Fotografię czujnika wraz ze szkicem sposobu jego montażu pokazano na Rys. 8. Opracowany czujnik pozwala na pomiar prędkości obrotowej w zakresie 0-10000 obr/min z dokładnością do 100 obr/min.



Rys. 8 Bezprzewodowy czujnik prędkości obrotowej.


Kolejną wielkością pozwalającą na określenie kontekstu pracy maszyny jest czujnik natężenia prądu. Czujnik zamontowany na obwodzie zasilania silnika napędowego maszyny pozwala na ocenę jego aktualnego obciążenia. Jako że przyjęto w założeniach projektowych zasadę minimalnej ingerencji w konstrukcję monitorowanych obiektów, również ten czujnik zaprojektowano w oparciu o przetwornik Halla. W tym przypadku wykorzystano przetwornik typu ACS37612 produkcji Allegro Microsystems. Idea działania polega na pomiarze natężenia pola magnetycznego jakie powstaje wokół przewodu, w którym płynie prąd. Sonda czujnika (Rys. 9) jest mocowana do przewodu za pomocą opasek zaciskowych i połączona modułem bazowym zawierającym tor przetwarzania sygnału, mikrokontroler, transceiver radiowy pracujący w paśmie 868MHz oraz układ zasilania bateryjnego. Czujnik jest kalibrowany do pomiarów w zakresie 0-500A z dokładnością $\pm 25A$. Dokładność taka jest

wystarczająca do oceny stopnia obciążenia silników napędowych badanych układów mechanicznych zasilanych tym prądem.



Rys. 9 Sonda pomiarowa bezprzewodowego czujnika natężenia prądu.


Kolejnym czujnikiem dostarczającym uzupełniającej informacji diagnostycznej jest czujnik ciśnienia. W systemach wentylacji informacja o wartości podciśnienia w kanale wentylacyjnym może być skorelowana z aktualną prędkością wentylatora lub informować o zatorze w kanale wentylacyjnym. Innym przykładem jest diagnostyka pomp, gdzie ciśnienie pompowanego medium jest proporcjonalne do obciążenia pompy. W ramach projektu opracowano bezprzewodowy czujnik ciśnienia oparty na przetworniku typu MS5837 produkcji TE Connectivity wykonanym w technologii MEMS. Działanie przetwornika opiera się na pomiarze pojemności kondensatora utworzonego z części stałej czujnika i membrany zmieniającej swoje położenie pod wpływem zmian ciśnienia gazów naciskających na membranę. Zastosowany przetwornik charakteryzuje się wysoką liniowością, 24-bitową rozdzielczością i niskim poborem prądu. Czujnik mierzy ciśnienie absolutne w zakresie 300-1200 mbar z dokładnością ± 6 mbar. Dodatkowo wyposażono go w przetwornik pomiaru temperatury oparty o układ MCP9800 umożliwiający pomiar w zakresie $-55 \div +125$ °C.



Rys. 10 Bezprzewodowy czujnik ciśnienia i temperatury.

Ostatni z opracowanych w ramach projektu czujników pozwala ocenić wilgotność atmosfery w której pracują monitorowane maszyny. W pewnych przypadkach praca mechanizmów w obecności wilgotności może prowadzić do uszkodzeń spowodowanych korozją elementów maszyny. Pomiar wilgotności względnej zrealizowano w oparciu

o przetwornik typu SHT40 produkcji Sensiron. Realizuje on pomiar temperatury i wilgotności względnej, rozumianej jako stosunek ciśnienia cząstkowego pary wodnej zawartej w powietrzu do ciśnienia nasycenia, określającego maksymalne ciśnienie cząstkowe pary wodnej w danej temperaturze. Konstrukcyjnie jest on zbliżony do pozostałych czujników opracowanych w ramach sytemu. Główną różnicę stanowi przyłącze procesowe, zabezpieczone dodatkowymi filtrami (Rys. 11).



Rys. 11 Bezprzewodowy czujnik wilgotności i temperatury

Pomiar wilgotności względnej dokonywany jest w zakresie 0÷100%, a pomiar temperatury w zakresie $-40 \div +125$ °C.

3.1.4. Bilans energetyczny czujników

Kluczową kwestią z punktu widzenia eksploatacji systemu jest energooszczędność zastosowanych czujników bezprzewodowych. Zbyt duże zapotrzebowanie na energię zwiększa uciążliwość obsługi systemu ze względu na konieczność częstej wymiany baterii. Akceptowalnym czasem działania czujnika jest jeden rok.

Konieczność energooszczędności wpłynęła zarówno na decyzje związane z doбором komponentów sprzętowych czujnika jak i na algorytm jego działania. Po pierwsze, przy doborze elementów zwrócono uwagę na ich parametry poboru mocy w stanie aktywnym oraz w trybie tzw. uśpienia. Istotnym kryterium doboru elementów był czas osiągnięcia gotowości po załączeniu zasilania.


Dlatego też jednym z zadań realizowanych w ramach pacy było opracowanie strategii oszczędności energii warstwy akwizycji danych sytemu. Jako punkt wyjścia potraktowano pierwszą wersję czujnika drgań i temperatury typu WS-VT1 opracowaną w Somar S.A., stosowaną w klasycznych systemach pomiaru drgań i wdrożoną w kilkunastu aplikacjach. W ramach prac dokonano krytycznej analizy zastosowanych rozwiązań i wdrożono modyfikacje pozwalające na opracowanie strategii oszczędności energii. Wykorzystano tutaj doświadczenia zgromadzone w wynikach badań wydajności energetycznej czujników pracujących we wcześniej wdrożonych aplikacjach. Pozwoliło to na weryfikację przyjętych wcześniej prognoz tempa zużycia energii dokonanych na podstawie obliczeń projektowych.

Dokonano również krytycznej oceny konstrukcji mechanicznej czujnika pod kątem uciążliwości operacji związanych z fizyczną wymianą baterii.


3.1.4.1. Źródło zasilania

Wybór źródła zasilania determinowany był z jednej strony maksymalną pojemnością, z drugiej jego wymiarami i parametrami pozwalającymi na jej stosowanie w atmosferach zagrożonych wybuchem. Ze względu na ograniczenia aplikacyjne zdecydowano się na zastosowanie ogniwi pierwotnych, zakładając ich utylizację i wymianę na nowy egzemplarz po wyczerpaniu energii. Ważnym parametrem doboru była też powszechna i stabilna dostępność ogniwa na rynku międzynarodowym – zmiana typu ogniwa skutkuje koniecznością powtórzenia kosztownych badań certyfikacyjnych na zgodność z dyrektywami przeciwwybuchowymi.

Zdecydowano się na wybór baterii litowo chlorkowo tionylowej (Li-SOCl₂) typu LS 14250 produkcji Saft. O jej wyborze zdecydowały takie parametry jak stosunkowo wysoka gęstość energii – ogniwo o rozmiarze 1/2AA ma nominalną pojemność 1,2 Ah, niska waga (0,9 g) i gabaryty oraz budowa oceniona na zgodność z normą IEC 60079-11 zharmonizowaną z dyrektywą przeciwwybuchową. Nominalne napięcie baterii wynosi 3,6 V co pozwalało na jej bezpośrednie stosowanie w obwodzie zasilania czujnika bez konieczności budowy przetwornic napięcia. Istotnym ograniczeniem wnoszonym przez zastosowanie ogniwa jest maksymalna temperatura otoczenia T_a , wynosząca +85 °C.



Rys. 12 Charakterystyka rozładowania ogniwa LS 14250 w temperaturze pokojowej [115].

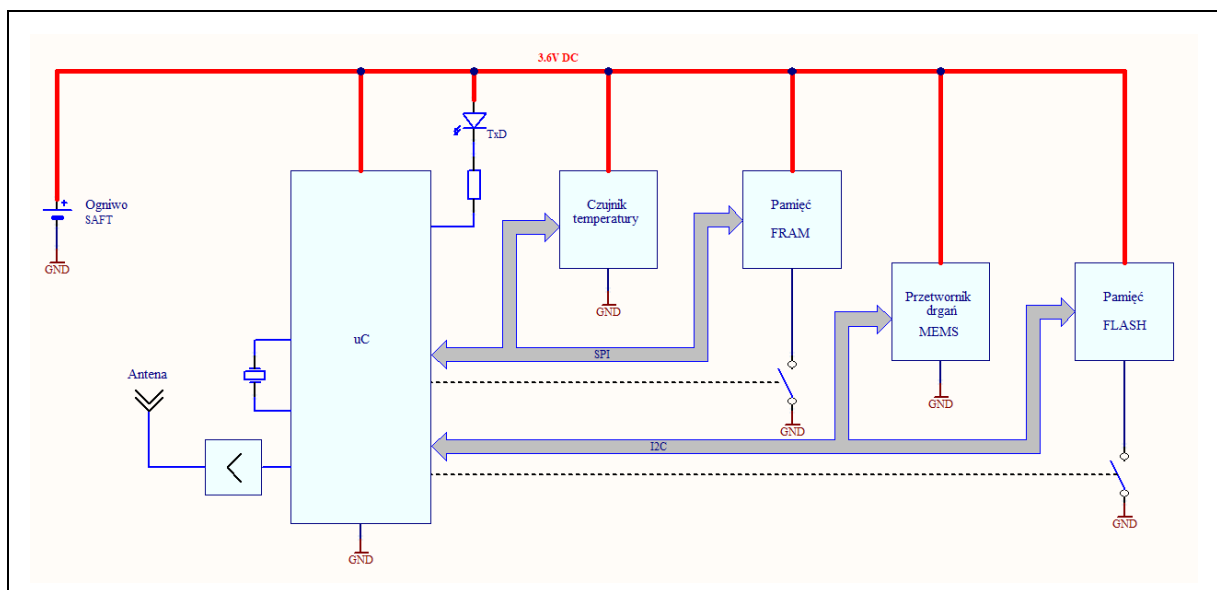


Rys. 13 Pojemność ogniwa LS 14250 w funkcji prądu obciążenia [115].

Na Rys. 12 pokazano charakterystyki rozładowania baterii. Można tu zauważyć, że przez większość czasu pracy, niezależnie od poboru prądu napięcie wyjściowe baterii jest stałe co do wartości. Jest to zaleta z punktu widzenia stabilności układu zasilania, ale rodzi pewne problemy z diagnostyką stanu zużycia baterii. Jeśli taka funkcjonalność opiera się na pomiarze napięcia zasilania, procedura pomiaru musi być przeprowadzana przy powtarzalnych warunkach poboru prądu, a informacja o konieczności wymiany baterii pojawia się stosunkowo późno.

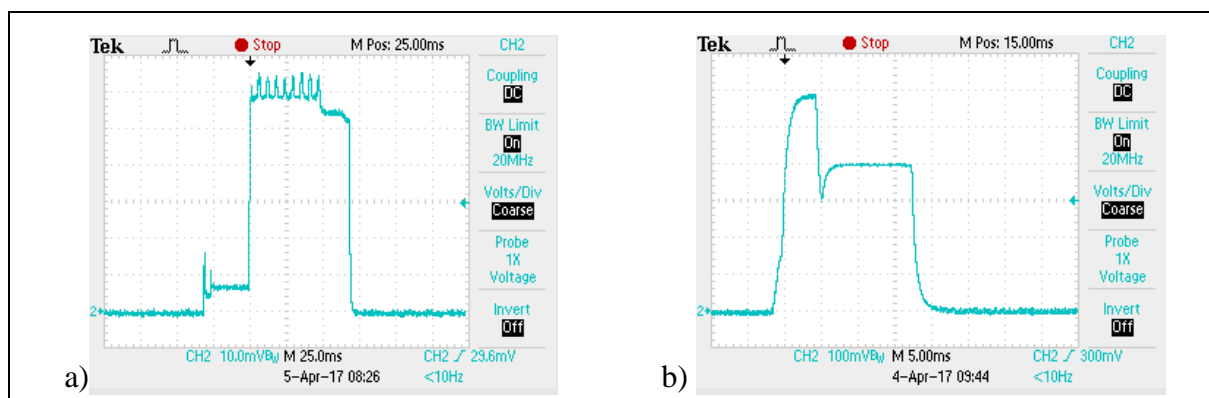
3.1.5. Strategia poboru mocy zasilania w systemie bazowym

Przy projektowaniu czujników dla pierwszej wersji systemu podjęto decyzję, by wszystkie elementy układu czujnika były zasilane wprost napięciem baterii. Założono wtedy, że system będzie bardziej wydajny energetycznie ze względu na fakt uniknięcia strat mocy wynikających z ograniczonej sprawności potencjalnych przetwornic DC/DC. Uproszczony schemat blokowy układu przedstawiono na Rys. 14. Elementy czujnika dobrano pod kątem jak najniższego poboru mocy zarówno w stanie aktywnym jak i w stanie uśpienia. Układy, których pobór prądu w stanie uśpienia przekracza pojedyncze μA – układy pamięci FRAM oraz FLASH, doposażono w klucze tranzystorowe wykonane w technologii MOSFET przeznaczone do odłączania zasilania.



Rys. 14 Schemat blokowy czujnika bezprzewodowego w wersji bazowej.

Zabiegi te pozwoliły ograniczyć prąd pobierany przez cały układ w trybie uśpienia do wartości $20 \mu\text{A}$. Pobór prądu w trybie aktywnym zależy od czynności wykonywanej przez układ. W algorytmie pracy czujnika można wyodrębnić naprzemienne cykle: pomiarowe i transmisyjne.



Rys. 15 Pobór prądu przez czujnik WS-VT1 w cyklach: a) pomiarowym, b) transmisyjnym.

Na Rys. 15 przedstawiono oscylogramy reprezentujące pobór prądu przez czujnik dla obu tych cykli. Na oscylogramach wyświetlono napięcie zmierzone na rezystorze $22\ \Omega$ włączonym szeregowo z baterią zasilającą układ czujnika. Oznacza to, że w przypadku oscylogramu reprezentującego cykl pomiarowy, przy ustawionym wzmacnieniu $10\ \text{mV}$ na działkę każda działka na osi Y reprezentuje około $450\ \mu\text{A}$ poboru prądu, przy podstawie czasu $25\ \text{ms}$ na działkę. Wykres przedstawiający pobór prądu w cyklu transmisyjnym wyskalowany jest w osi Y na $4,5\ \text{mA}$ /działkę przy podstawie czasu $5\ \text{ms}$ /działkę.

Tabela 1 przedstawia pobór prądu w poszczególnych fazach cyklu pomiarowego. Początkowy pobór mocy związany jest z rozruchem poszczególnych elementów układu po ich wybudzeniu ze stanu uśpienia. W kolejnej fazie następuje wzrost poboru mocy związany z powtarzanymi cyklami próbkowania i buforowania danych w pamięci podręcznej. Ostatnia faza odpowiada za obliczenia związane głównie z wyznaczeniem estymaty RMS spróbkowanego sygnału.

Tabela 1

Pobór prądu przez czujnik WS-VT1 w poszczególnych fazach cyklu pomiarowego

Faza cyklu	Prąd	Czas	Ładunek
Start akcelerometru	0,36 mA	30 ms	10,8 μAs
Pomiar + odczyt danych	3 mA	50 ms	150 μAs
Obliczenia	2,3 mA	18 ms	41,4 μAs
Suma dla cyklu pomiarowego			202,2 μAs

W Tabeli 2 zestawiono pobór prądu dla poszczególnych faz typowego cyklu transmisyjnego. Można tu zaobserwować o rząd większy pobór prądu ze źródła zasilania. Związane jest to głównie z poborem mocy generatora obwodów wysokiej częstotliwości układu radiowego i wzmacniacza mocy. W każdym z cykli transmisyjnych wyróżniamy fazę transmisji danych, trwającą około $5\ \text{ms}$ oraz następującą po niej fazę gotowości na odbiór

ewentualnych danych z sytemu nadrzędneho. Faza faktycznego odbioru danych następuje bardzo rzadko – wyłącznie w chwilach parametryzacji czujnika, dlatego nie została uwzględniona w obliczeniach poboru mocy.

Tabela 2

Pobór prądu przez czujnik WS-VT1 w poszczególnych fazach cyklu transmisyjnego

Faza cyklu	Prąd	Czas	Ładunek
Nadawanie danych	27 mA	5 ms	135 μ As
Gotowość na odbiór danych	18 mA	12,5 ms	225 μ As
<i>Suma dla cyklu transmisyjnego</i>			360 μAs

Dysponując tymi danymi można wyznaczyć czas pracy czujnika na pojedynczym ogniwie w funkcji odstępu pomiędzy cyklami transmisyjno-pomiarowymi:

$$t_b = \frac{Q_b}{\frac{T_{\text{dobowy}}}{T_c}(Q_p + Q_t) + Q_s} \quad (7)$$

Gdzie:

t_b – czas pracy czujnika na pojedynczym ogniwie w dniach,

Q_b – pojemność baterii w μ As,

T_{dobowy} – okres doby w sekundach,

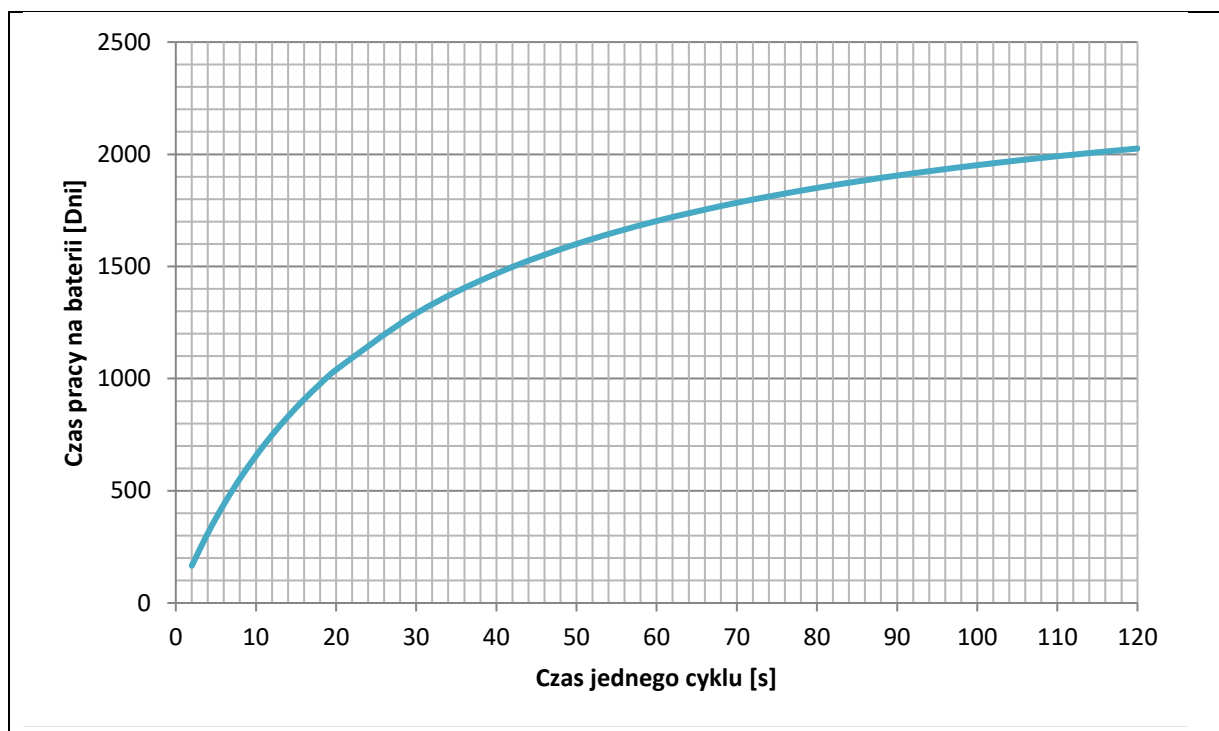
T_c – okres pomiędzy kolejnymi cyklami transmisyjnymi w sekundach,

Q_p – ładunek pobrany ze źródła zasilania w pojedynczym cyklu pomiarowym w μ As,

Q_t – ładunek pobrany ze źródła zasilania w pojedynczym cyklu transmisyjnym w μ As,

Q_s – ładunek pobrany dobowo ze źródła zasilania w trybie uśpienia w μ As.

Na Rys. 16 przedstawiono obliczoną ilość dni pracy czujnika na pojedynczym ogniwie w funkcji odstępu pomiędzy cyklami pomiarowo – transmisyjnymi. Z wykresu wynika, że przy pomiarach realizowanych co 8 sekund uzyskujemy ponad roczny czas pracy na pojedynczej baterii, a dla pomiarów realizowanych co 20 sekund czas pracy na pojedynczej baterii powinien przekraczać trzy lata.



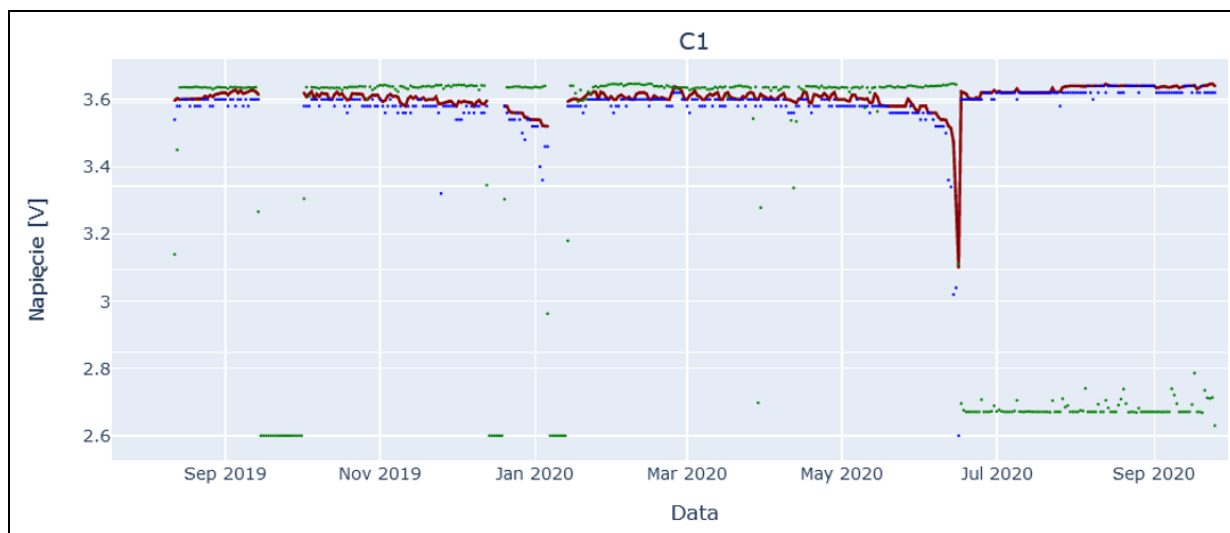
Rys. 16 Prognoza zużycia baterii dla czujnika WS-VT1 w zależności od częstotliwości cykli pomiarowych.

W ramach prac nad pierwszą wersją systemu monitorowania wdrożono jeszcze dodatkowy mechanizm oszczędzania energii polegający na redukcji poboru mocy ze źródła zasilania w chwilach beczynności monitorowanego obiektu. Tryb beczynności identyfikowany był na podstawie zmierzonej amplitudy drgań, tzn., gdy amplituda nie przekraczała założonej wartości progowej próbkowanie danych z akcelerometru w ramach cykli pomiarowych były realizowane na zredukowanej długości bufora i jednocześnie wydłużany był okres pomiędzy cyklami transmisyjnymi. Przekroczenie wartości progowej w dowolnym cyklu pomiarowym skutkowało powrotem do trybu aktywnego. Strategia ta miała uzasadnienie w przypadku monitorowania obiektów pracujących cyklicznie bądź obiektów odstawianych z ruchu na długie okresy czasu.

3.1.5.1. Weryfikacja obliczeń poboru energii rozwiązania bazowego

Duża liczba wdrożeń realizowanych z użyciem czujników w wersji bazowej pozwoliła na weryfikację obliczeń teoretycznych. Na Rys. 17 przedstawiono wykresy wartości średniej (kolor czerwony) i wartości minimalnej zagregowanych dobowo zmierzonych wartości napięcia baterii jednego z czujników wdrożonych w ramach systemu monitorowania pomp zespołu agregatów hydraulicznych jednego z zakładów produkcyjnych. Dodatkowo na wykresie przedstawiono dobową ilość odebranych ramek z wynikami pomiarów. W przedstawionym okresie czujniki pracowały w cyklach pomiarowych realizowanych co dwie sekundy. Wykresy potwierdzają fakt, że pomiar napięcia baterii nie jest optymalny przy

jego zastosowaniu do prognozowania zużycia baterii: czujniki przez większość czasu utrzymują stałe na pięcie na poziomie 3.6 V, a spadek napięcia następuje na kilka dni przed całkowitym rozładowaniem baterii czujnika.



Rys. 17 Napięcie baterii czujnika WS-VT1 zastosowanego w systemie monitorowania pomp agregatu hydraulicznego (wykres przedstawia dobowe agregaty napięcia maksymalnego – kolor niebieski, średniego – kolor brązowy, minimalnego – kolor zielony).

Tabela 3 zestawia dane na temat cykli rozładowania baterii czujników zebranych w ramach jednego z realizowanych wdrożeń systemu.

Tabela 3

Cykle rozładowania baterii czujników WS-VT1

Wdrożenie	Czujnik [-]	Data montażu baterii [dd-mm- rrrr]	Data Demontażu baterii [dd-mm-rrrr]	Interwał Transmisji [s]	Czas Pracy [dni]	Ilość nadanych ramek [-]
Agregaty pompowe	1	12-08-2019	06-01-2020	2	147	6350400
Agregaty pompowe	2	12-08-2019	13-01-2020	2	154	6652800
Agregaty pompowe	3	12-08-2019	10-01-2020	2	151	6523200
Agregaty pompowe	4	12-08-2019	13-01-2020	2	154	6652800
Agregaty pompowe	5	12-08-2019	13-01-2020	2	154	6652800
Agregaty pompowe	6	14-01-2020	07-01-2020	2	148	6393600
Agregaty pompowe	1	14-01-2020	14-06-2020	2	152	6566400
Agregaty pompowe	2	14-01-2020	16-06-2020	2	154	6652800
Agregaty pompowe	3	14-01-2020	16-06-2020	2	154	6652800
Agregaty pompowe	4	14-01-2020	16-06-2020	2	154	6652800
Agregaty pompowe	5	14-01-2020	16-06-2020	2	154	6652800
Agregaty pompowe	6	14-01-2020	16-06-2020	2	154	6652800

Przy założeniu dwusekundowego interwału transmisji danych, czujnik powinien pracować 166 dni do momentu wyczerpania baterii. W eksperymencie otrzymano wartość średnio o 10 dni mniejszą, co i tak daje dobre przybliżenie modelu, przy innych czynnikach

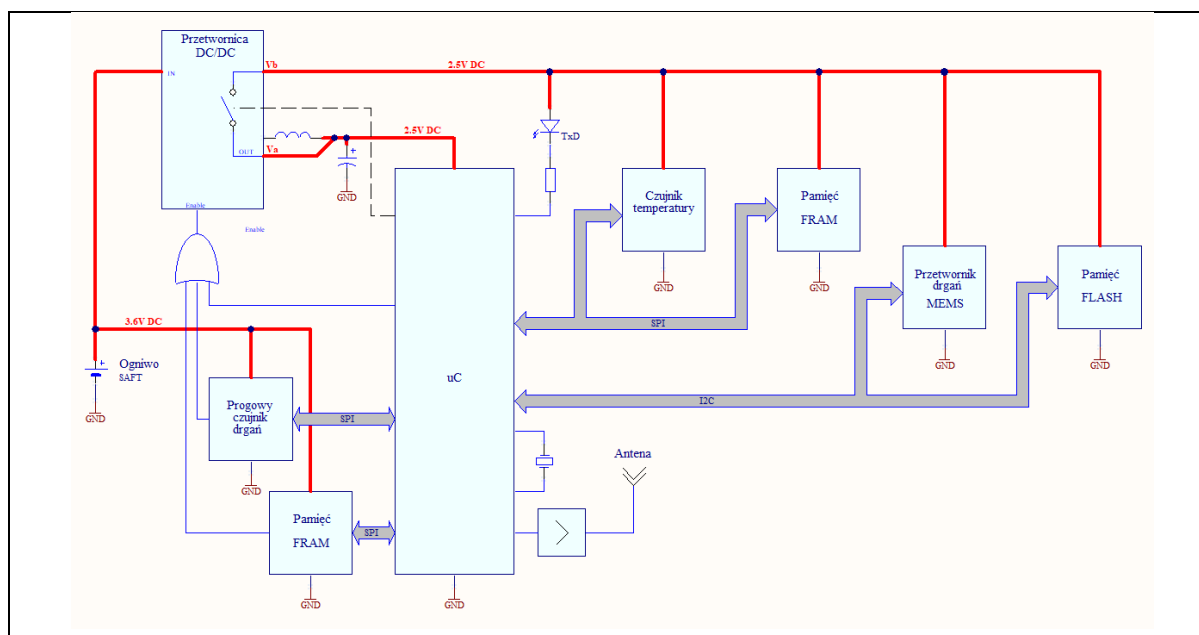
wpływających na nominalną pojemność baterii (np. temperaturę pracy, znamionowy pobór prądu, czas i warunki magazynowania przed użyciem).

3.1.6. Strategia redukcji poboru mocy

W ramach prac nad drugą generacją systemu zweryfikowano budowę i algorytm działania czujnika pod kątem poprawy bilansu energetycznego. Pierwszym z zabiegów była modyfikacja układu zasilania czujnika. W tym celu w obwód zasilania wprowadzono dodatkową przetwornicę opartą o układ TPS62740 umożliwiającą obniżenie napięcia zasilania podzespołów czujnika (mikrokontrolera wraz z układem transceivera radiowego, przetwornika MEMS, przetwornika temperatury, pamięci podręcznych) do wartości 2,5 V ze sprawnością 90%. Pozwoliło to na redukcję mocy pobieranej przez poszczególne elementy w trybie aktywnym. Dodatkową zaletą stosowania przetwornicy była możliwość selektywnego odłączania napięcia zasilania wybranych bloków czujnika, dzięki czemu zredukowano poziom poboru mocy w trybie uśpienia.

Kolejnym zabiegiem była modyfikacja strategii oszczędzania energii w chwilach bezczynności monitorowanego obiektu. W tym celu zastosowano dodatkowy przetwornik drgań typu ADXL362 działający w trybie detekcji ruchu. Układ przetwornika zasilany jest bezpośrednio napięciem baterii, a jego prąd zasilania zredukowany jest do wartości 270 nA. Przetwornik wybudza się po przekroczeniu ustalonej wartości progowej amplitudy mierzonego przyspieszenia. Po przekroczeniu tego progu następuje aktywacja przetwornicy DC/DC odpowiedzialnej za zasilanie pozostałych bloków czujnika. Uzupełnieniem mechanizmu jest układ wyzwiania czasowego przetwornicy, pozwalający na jej uruchomienie w regularnych, ustalanych programowo jednostkach czasu celem wysłania tzw. „ramki życia” przez układ transmisyjny czujnika w trybie bezczynnościowym.

Schemat blokowy zmodyfikowanej konstrukcji czujnika przedstawiono na Rys. 18.



Rys. 18 Schemat blokowy czujnika bezprzewodowego z wdrożoną strategią redukcji poboru mocy.

Modyfikacji podlegał także algorytm pracy czujnika. Najbardziej istotną z punktu widzenia poprawy bilansu energetycznego czujnika była modyfikacja cyklu transmisyjnego. W czujnikach pierwszej generacji każdy cykl transmisyjny składał się z dwóch faz: nadawania i gotowości na odbiór danych. W zmodernizowanych pod kątem redukcji zużycia energii czujnikach zdecydowano, że faza gotowości na odbiór danych będzie obsługiwana nie częściej niż raz na 60 sekund. Uciążliwość z tym związana jest akceptowalna z punktu widzenia obsługi - odbiór danych przez czujnik jest wykorzystywany wyłącznie w celu parametryzacji czujnika, a ta operacja wykonywana jest sporadycznie.

Tabela 4

Pobór prądu przez zmodyfikowany czujnik WS-VT1 w poszczególnych fazach cyklu pomiarowego


Faza cyklu	Prąd	Czas	Ładunek
Start akcelerometru	0,26 mA	30 ms	7,8 μ As
Pomiar + odczyt danych	2,19 mA	50 ms	109,5 μ As
Obliczenia	1,68 mA	18 ms	30,24 μ As
Suma dla cyklu pomiarowego			147,54 μAs

Tabela 5

Pobór prądu przez zmodyfikowany czujnik WS-VT1 w poszczególnych fazach cyklu transmisyjnego

Faza cyklu	Prąd	Czas	Ładunek
Nadawanie danych	19,7 mA	5 ms	98,5 μ As
Gotowość na odbiór danych	13,2 mA	12,5 ms	165 μ As

Tabela 4 oraz Tabela 5 zestawia parametry poboru prądu przez czujnik z oprogramowaniem wdrażającym opracowaną strategię redukcji poboru mocy odpowiednio w cyklu pomiarowym i transmisyjnym.



Rys. 19 Porównanie czasu pracy czujników WS-VT1 przed i po wdrożeniu strategii redukcji poboru mocy.

Uzyskany zysk energetyczny jest szczególnie widoczny dla okresów krótkich okresów transmisyjnych. W tym przypadku szczególnego znaczenia nabierają pobory mocy związane z pracą poszczególnych bloków czujnika w trybie aktywnym. Wraz ze wzrostem przerw pomiędzy cyklami transmisyjnymi czas rozładowania baterii bardziej zależy od poborów mocy w trybie uśpienia.

Przedstawione wykresy nie uwzględniają dodatkowych oszczędności energii uzyskiwanych w okresach beczynności monitorowanego obiektu. Oczywistym powodem tego jest uzależnienie wyniku od lokalnych warunków eksploatacji monitorowanych obiektów.

3.1.6.1. Algorytm sygnalizacji poziomu rozładowania źródła zasilania

Istotnym z punktu widzenia operatora systemu jest bieżąca znajomość poziomu rozładowania baterii poszczególnych czujników. W systemie bazowym sygnalizację stanu rozładowania oparto na pomiarze napięcia baterii realizowanym w każdym z cykli pomiarowych. Ze względu na płaską charakterystykę rozładowania zastosowanych baterii (patrz Rys. 12) informacja o rozładowaniu źródła zasilania pojawiała się w momencie, gdy

bateria gromadziła poniżej 1% energii. W aktualnej wersji opracowanej w ramach pracy zastosowano algorytm bieżącego zliczania wydatku energetycznego uwzględniający wydatek energii związany z każdą cząstkową fazą pracy czujnika: cyklem akwizycji danych, obliczeń, transmisji i nasłuchu danych (Rys. 20). Algorytm uwzględnia również różnice zapotrzebowania energetycznego zależne od ustawionych w czujniku parametrów pomiarowych, jak np. liczba osi, częstotliwość próbkowania, liczba transmitowanych parametrów, moc nadajnika, itp. Zliczanie energii następuje bezpośrednio w czujniku, a wartość tego licznika jest cyklicznie transmitowana wraz z danymi telemetrycznymi.

```
Dla każdego z czujników zdefiniowano licznik wydatkowanej energii  $L$  [Ah]
```

```
Po wybudzeniu czujnika z trybu uśpienia:
```

```
Uwzględnij wydatek energii w trybie uśpienia:
```

```
 $L += \text{długość cyklu uśpienia} * \text{prąd w trybie uśpienia}$ 
```

```
Uwzględnij wydatek energii na próbkowanie danych przez akcelerometr
```

```
 $L += (1/\text{częstotliwość próbkowania}) * \text{dł. bufora} * \text{prąd próbkowania}$ 
```

```
W zależności od zdefiniowanego trybu przetwarzania oszacuj czas na przetwarzanie danych.
```

```
 $L += \text{czas przetwarzania danych} * \text{prąd w trybie przetwarzania danych}$ 
```

```
Przygotuj ramkę do transmisji radiowej
```

```
 $L += (1/\text{prędkość transmisji danych}) * \text{długość ramki} * \text{prąd w trybie nadawania}$ 
```

```
 $L += \text{czas nasłuchu danych} * \text{prąd w trybie nasłuchu}$ 
```

```
Jeśli przyszła ramka z żądaniem zmiany parametrów
```

```
 $L += (1/\text{prędkość transmisji danych}) * \text{długość ramki} * \text{prąd w trybie odbioru}$ 
```

```
 $L += (1/\text{prędkość transmisji danych}) * \text{długość ramki potwierdzenia} * \text{prąd w trybie nadawania}$ 
```

```
Przejdź w tryb uśpienia
```

Rys. 20 Algorytm zliczania wydatku energii czujnika.

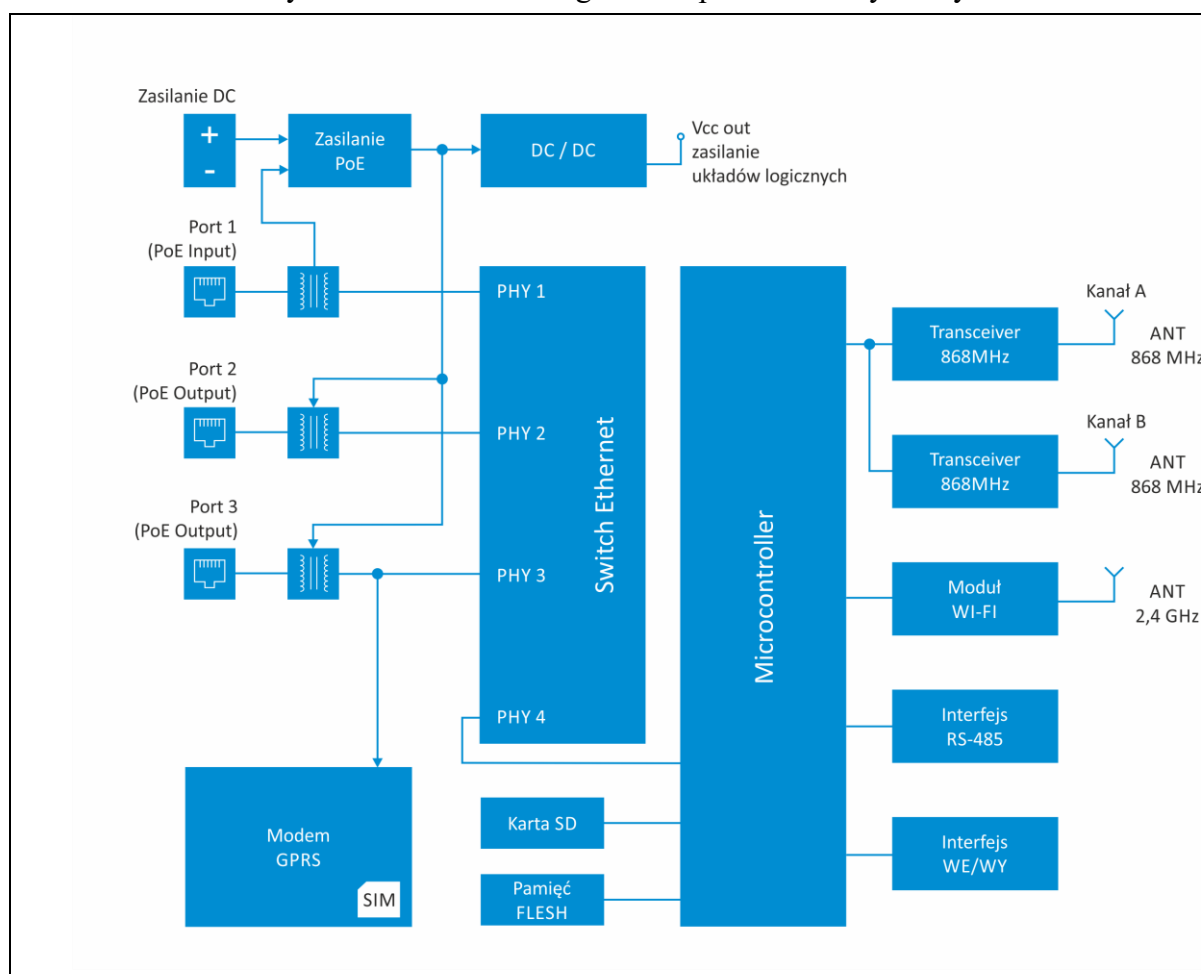
Użytkownik uzyskuje więc bieżącą informację na temat procentowego stanu rozładowania baterii oraz prognozę tego stanu aktualizowaną po każdej zmianie parametrów pracy czujnika. Pozwala to na wypracowanie rekomendowanej daty wymiany baterii.

3.2. Infrastruktura odbiorcza

Infrastruktura odbiorcza odpowiada za komunikację radiową z czujnikami. Głównym zadaniem tej warstwy jest odbiór danych telemetrycznych, wysyłanych przez czujniki. Ponad to urządzenia infrastruktury odbiorczej zarządzają funkcjami konfiguracji i diagnostyki czujników. W ramach tej warstwy opracowano dwie klasy urządzeń tzw. Transceivery radiowe oraz lokalne stacje diagnostyczne. Funkcje pierwszych z nich ograniczają się do wymiany danych pomiędzy siecią czujników bezprzewodowych i serwerem obliczeniowym. Lokalne stacje diagnostyczne rozszerzają tę funkcjonalność o możliwość archiwizacji i przetwarzania danych telemetrycznych. Ze względu na ograniczone zasoby sprzętowe funkcje te realizowane są w ograniczonym zakresie co do rozmiaru przetwarzanych danych jak i stopnia skomplikowania modeli diagnostycznych.

3.2.1. Transceivery radiowe

Schemat blokowy transceivera radiowego został przedstawiony na Rys. 21.



Rys. 21 Schemat blokowy transceivera radiowego typu ITR-2.

Transciever radiowy bazuje na mikrokontrolerze typu SMT32 z systemem operacyjnym czasu rzeczywistego typu RTOS. Z czujnikami komunikuje się za pośrednictwem dwóch niezależnych modułów radiowych opartych o układ CC1120 podłączonych poprzez interfejs SPI. Pozwala to na jednoczesną komunikację na dwóch kanałach radiowych, z których jeden jest przeznaczony do bieżącej wymiany danych telemetrycznych i konfiguracyjnych, a drugi do funkcji specjalnych, takich jak transmisja aktualizacji oprogramowania firmware czy odbiór ramek specjalnych, np. zawierających pełne widmo sygnału zmierzonego przez wybrany czujnik. Za komunikację z serwerem obliczeniowym odpowiada układ WIZNET (W3150A) będący sprzętowym kontrolerem Ethernet z zaimplementowanym stosem TCP/IP. Układ WIZNET podłączony jest do jednego z portów switcha Ethernet zbudowanego na układzie KSZ 8795. Pozostałe trzy porty udostępniają trzy zewnętrzne interfejsy Ethernet. Całość może być zasilana na dwa sposoby: napięciem pochodzącym z zewnętrznego zasilania lub poprzez interfejs wejściowy Ethernet w standardzie PoE. Układ transceivera

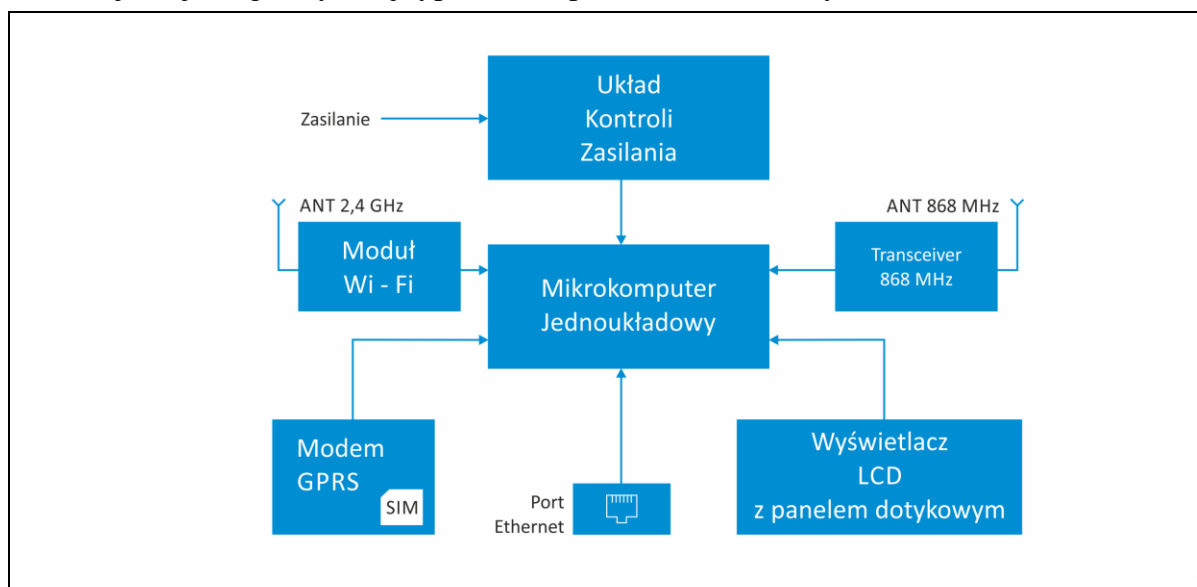
wyposażony jest w regenerator zasilania PoE, pozwalając na zasilanie kolejnych transceiverów infrastruktury sieciowej.

Dodatkowo transceiver wyposażony jest w cyfrowe interfejsy wyjściowe przeznaczone dla sygnalizacji bądź sterowania oraz szeregowy interfejs komunikacyjny RS-485.

W ramach systemu opracowano również uproszczoną (pod względem konstrukcji) wersję transceivera: ITR-1. Urządzenie to wyposażone jest w pojedynczy interfejs radiowy do komunikacji z czujnikami oraz interfejs szeregowy RS-485 lub CAN do komunikacji z warstwą nadrzędną. Uproszczenie konstrukcji pozwoliło na jego dostosowanie do wymagań urządzeń pracujących w strefach zagrożonych wybuchem gazów i/lub pyłów. Pozwala to na jego stosowanie między innymi w wyrobiskach podziemnych zakładów górniczych.

3.2.2. Lokalne stacje diagnostyczne

Lokalne stacje diagnostyczne zostały oparte o mikrokomputer kompatybilny z RaspberryPi pracujący pod kontrolą systemu operacyjnego Linux. Schemat blokowy lokalnej stacji diagnostycznej typu LDS-1 przedstawiono na Rys. 22.




Rys. 22 Schemat blokowy lokalnej stacji diagnostycznej typu LDS.

Wykorzystanie systemu operacyjnego Linux wymagało rozbudowy układu zasilania urządzenia. Urządzenie musi być odporne na utratę napięcia zasilającego w dowolnej chwili. Wadą układów pracujących pod kontrolą systemu operacyjnego Linux jest konieczność poprawnego zamknięcia systemu plików. W skrajnym przypadku może to doprowadzić do braku możliwości ponownego uruchomienia systemu. Zastosowany układ kontroli zasilania wyposażony jest w akumulator buforowy, podtrzymujący napięcie układów do czasu poprawnego zamknięcia systemu.

Zaletą zastosowania systemu operacyjnego jest możliwość implementacji standardowych bibliotek uczenia maszynowego, co pozwoliło na implementację (w ograniczonym zakresie)

modeli diagnostycznych. W praktyce zastosowano tutaj modele oparte o prostą analizę trendów. Możliwa była także instalacja opisanej w kolejnych rozdziałach platformy wizualizacji.

Urządzenie zostało wyposażone w kolorowy, graficzny wyświetlacz LCD z panelem dotykowym stanowiący interfejs użytkownika. Głównym jego przeznaczeniem jest prezentacja danych pochodzących z bieżących i archiwalnych pomiarów oraz wyników analiz. Przykład takiej planszy prezentuje Rys. 23



Rys. 23 Lokalna Stacja Diagnostyczna z przykładową planszą platformy wizualizacji.

Z oczywistych względów lokalna stacja diagnostyczna została wyposażona w moduł transceivera radiowego umożliwiającego komunikację z czujnikami bezprzewodowymi w paśmie 868MHz. Dodatkowo została ona wyposażona w interfejsy komunikacji z warstwą przetwarzania danych. Podobnie jak w przypadku transceiverów ITR, odbywa się ona bądź z wykorzystaniem lokalnej sieci Ethernet bądź z wykorzystaniem sieci GSM.

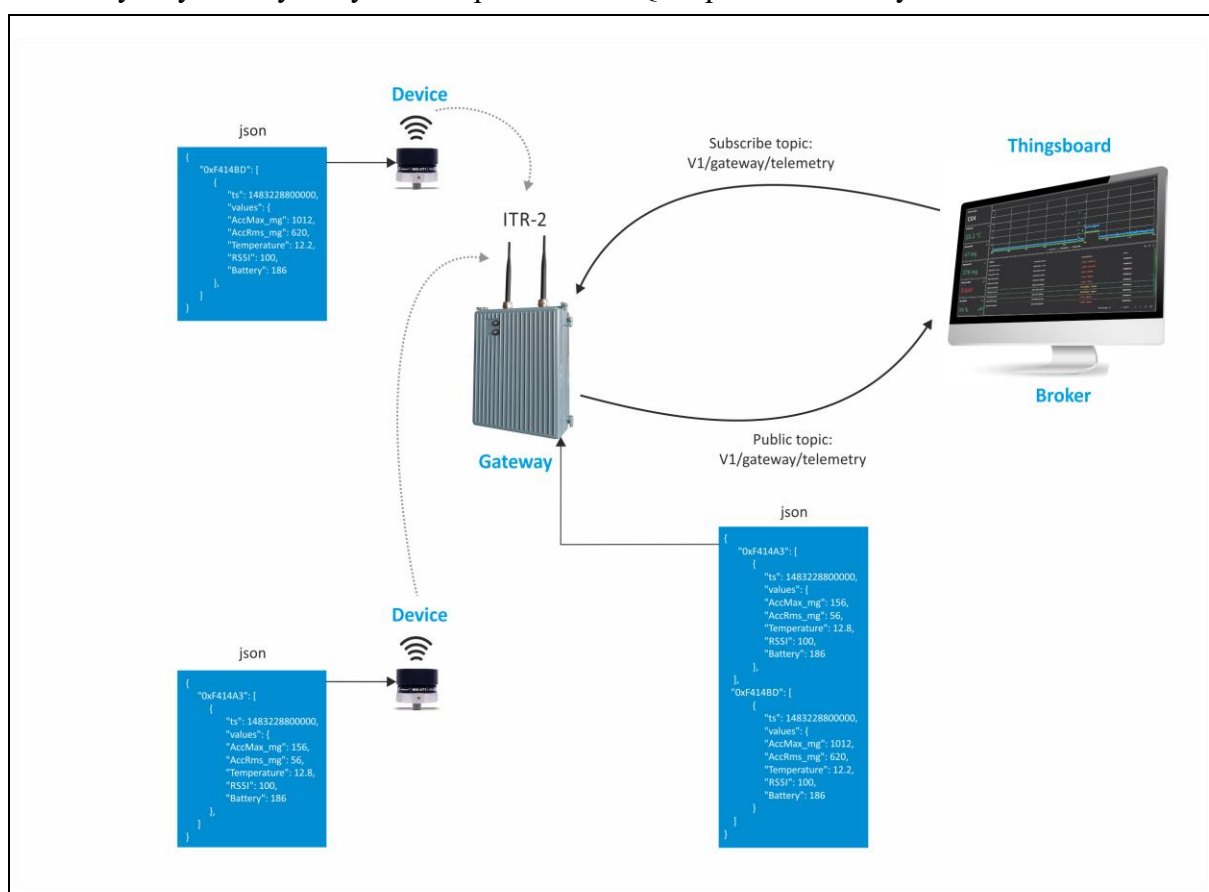
W szczególnych przypadkach lokalna stacja diagnostyczna może pełnić rolę terminala serwera obliczeniowego. W tym przypadku użytkownik systemu otrzymuje możliwość dostępu do wizualizacji danych w lokalizacjach montażu monitorowanych maszyn.

3.2.3. Komunikacja z warstwą przetwarzania danych

Na potrzeby komunikacji z warstwą przetwarzania danych zastosowano protokół MQTT [30]. Jest to protokół stworzony na potrzeby komunikacji w ramach systemu M2M (ang. Machine to Machine) już w roku 1999. Opiera się na modelu publikacja/subskrypcja [116]. Funkcję serwera komunikacyjnego odpowiedzialnego za zarządzanie komunikacją w ramach protokołu pełni tzw. Broker MQTT. W przyjętym modelu poszczególni klienci, na równorzędnych zasadach łączą się z brokerem w celu subskrypcji lub publikacji danych (tzw. wiadomości w ramach dowolnego tematu (ang. topic). Broker MQTT odpowiada za autoryzację poszczególnych klientów oraz za transmisję wiadomości do subskrybentów którzy zarejestrowali chęć odbioru wiadomości w danym temacie. Każdy z klientów może

pełnić rolę subskrybenta (ang. subscriber) i/lub nadawcy (ang. publisher) danych. Każdy z nadawców może publikować dane o dowolnym temacie. Odbiorca danych może w dowolnej chwili zrezygnować z subskrypcji danego tematu.

W przedmiotowym systemie broker MQTT jest elementem bramy transportowej serwera obliczeniowego. Dane pomiarowe są publikowane przez koncentratory danych (transceivery radiowe oraz lokalne stacje diagnostyczne) pod tematem „*/**devices/me/telemetry**”, dane organizacyjne pod tematem „*/**devices/me/atributes**”. Tematy te subskrybowane są przez warstwę akwizycji danych serwera obliczeniowego systemu. Organizacja danych w ramach poszczególnych tematów opiera się na hierarchicznych strukturach **klucz:wartość** zdefiniowanych w plikach konfiguracyjnych w formacie json. Za dekodowanie danych odpowiada warstwa akwizycji danych serwera obliczeniowego. Przykład wymiany danych telemetrycznych z wykorzystaniem protokołu MQTT pokazano na Rys. 24.



Rys. 24 Sekwencja wymiany danych z wykorzystaniem protokołu MQTT.

4. Warstwa programowa

Platforma ThingsBoard (ThB) zapewnia funkcjonalności związane z przechowywaniem danych i wizualizacją procesów, natomiast silnik analityczny odpowiada za realizację zadań z obszaru tzw. data science.

O wyborze rozwiązania ThB zdecydowały jej cechy odpowiadające wymaganiom przedstawionym w Rozdziale 2. Były to między innymi:

- Skalowalność – platforma ma być dostosowana zarówno dla małych aplikacji monitorujących kilka (maksymalnie kilkanaście) zmiennych jak i duże systemy złożone z kilkuset czujników.
- Możliwość wdrażania w wariantach chmurowych obsługujących akwizycję danych z rozproszonych graficznie punktów pomiarowych i pozwalający na zdalny dostęp do platformy.
- Możliwość instalacji w ramach lokalnych sieci zakładowych, izolowanych od sieci WAN.
- Jednoczesny dostęp do interfejsu użytkownika dla wielu klientów z wykorzystaniem urządzeń stacjonarnych i przenośnych zarządzanych przez różne systemy operacyjne.
- System autoryzacji, pozwalający na gradację uprawnień dostępu do poszczególnych danych.
- Szyfrowanie komunikacji.
- Skalowalność ceny systemu stosownie do rozmiaru aplikacji.

Wymóg skalowalności platformy został spełniony dzięki temu, że platforma ThB może być instalowana w wersji monolitycznej (ang. monolithic mode) na komputerach z pojedynczą jednostką centralną oraz rozproszonej – w postaci zestawu mikro-usług (ang. microservices mode) uruchamianych na klastrach obliczeniowych. Archiwizacja danych bazuje na dwóch technologiach bazodanowych, PostgreSQL i jego rozszerzeniu dedykowanym do przetwarzania danych o charakterze szeregów czasowych TimescaleDB [117] oraz Cassandra [118].

Mimo z definicji chmurowego, opartego na technologiach sieciowych charakteru platformy istnieje możliwość jej instalacji na maszynach izolowanych od sieci Internet. Dotyczy to zarówno wersji otwartej (open source) jak i wariantów płatnych.

Powłoka interfejsu użytkownika działa w oparciu o przeglądarkę internetową. Umożliwia to dostęp do plansz wizualizacyjnych, paneli administracyjnych, raportów analitycznych ograniczony wyłącznie polityką bezpieczeństwa informatycznego zakładu w wykorzystaniem dowolnego typu terminala – w tym urządzeń przenośnych. Plansze budowane za pomocą specjalnego edytora. Możliwe jest również tworzenie zaawansowanych pulpitów

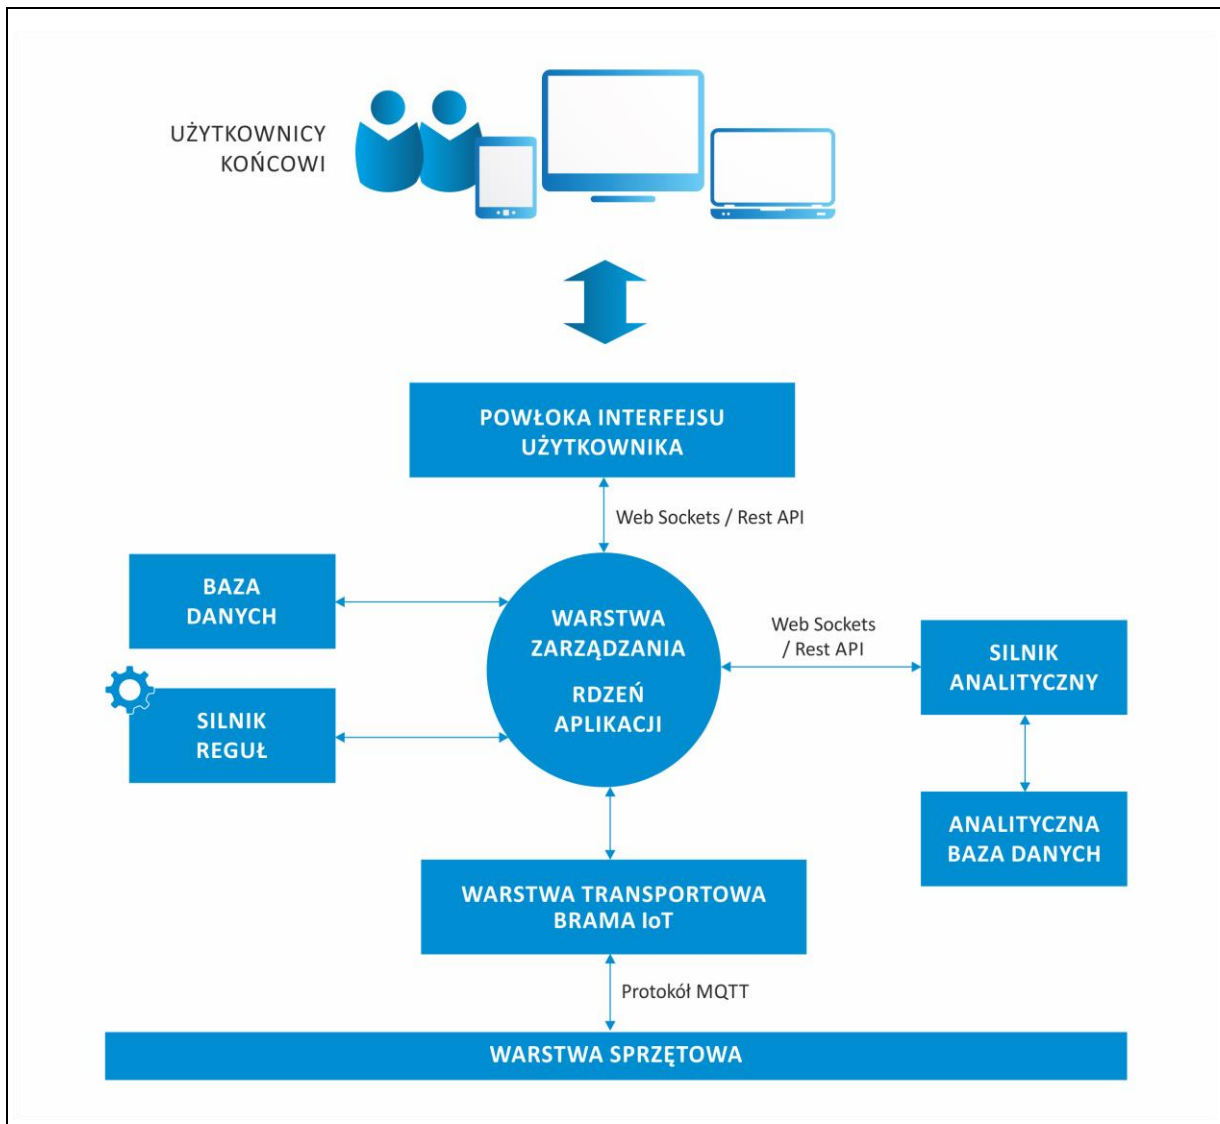
wizualizacyjnych poprzez osadzanie na planszach komponentów (tzw. widgetów) zaprojektowanych i zaimplementowanych we własnym zakresie.

Platforma oferuje rozbudowany system kontroli uprawnień umożliwiający wdrożenie praktycznie dowolnej kombinacji praw dostępu do poszczególnych jej elementów. Każdy dostęp jest autoryzowany i rejestrowany. Tak więc administrator systemu ma możliwość weryfikacji operacji dokonywanych przez poszczególnych użytkowników systemu.

Skalowalność ceny systemu może być realizowana w dwojaki sposób. Po pierwsze platforma może być wdrażana w różnych wariantach płatności, od darmowych, opartych o wersję open source, poprzez warianty abonamentowe z ceną zależną od liczby obsługiwanych sygnałów pomiarowych po wersje pełne z licencją bezterminową. Druga możliwość opiera się na wykorzystaniu możliwości różnicowania praw dostępu. W tym wariantcie pojedyncza instancja platformy w wersji pełnej, rejestruje dane wielu klientów udostępniając każdemu z nich dostęp do danych generowanych na podstawie sygnałów pochodzących wyłącznie z ich obiektów. Oczywiście, wariant ten możliwy jest wyłącznie dla klientów dopuszczających w swej polityce bezpieczeństwa informatycznego rozwiązania chmurowe.

Ostatnie z wymagań – możliwość integracji z systemami trzecimi – zostało spełnione przez wykorzystanie rozbudowanego interfejsu REST API platformy. Dzięki temu możliwe było osadzenie w platformie niezależnego bloku silnika analitycznego. Silnika analityczny na podstawie zapytań REST API ma możliwość pobierania danych z repozytorium platformy. Ten sam interfejs pozwala na prezentację wyników analiz oraz na dostęp do kokpitów menadżerskich silnika poprzez plansze wizualizacyjne platformy. Tak więc użytkownik ma pełen dostęp do wszystkich usług systemu łącząc się – z jego punktu widzenia – wyłącznie z interfejsem platformy ThB.

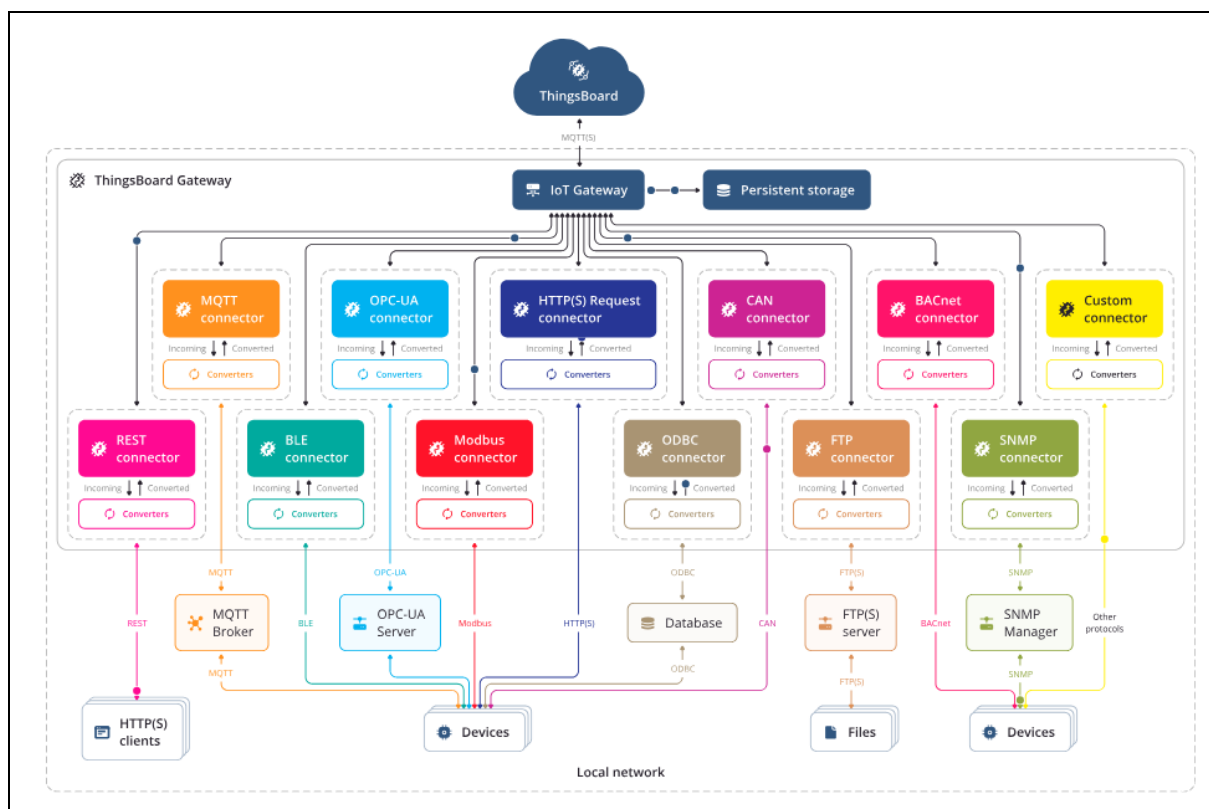
Na Rysunku 25 zaprezentowano schemat architektury warstwy programowej systemu, składowe Silnik Analityczny i Baza Analityczna są rozwiązaniami wytworzonymi od podstaw, natomiast pozostałe składniki zrealizowano w oparciu o ThB.



Rys. 26 Schemat blokowy warstwy programowej.

4.1. Warstwa transportowa platformy ThingsBoard

Pozyskiwanie surowych danych do platformy realizowane jest za pośrednictwem warstwy transportowej. Schemat architektury warstwy transportowej przedstawia na Rys. 27.



Rys. 28 Schemat blokowy warstwy transportowej platformy ThingsBoard [119].

Warstwa transportowa ThB udostępnia trzy główne interfejsy API oparte na protokołach MQTT [30], HTTP oraz CoAP [120]. Każdym z tych trzech interfejsów zarządza oddzielny komponent serwera platformy. Dodatkowo platforma udostępnia komponent bramy IoT (ang. IoT gateway) umożliwiający integrację platformy z protokołami komunikacyjnymi stosowanymi w klasycznych, przemysłowych układach sterowania oraz innymi źródłami danych. Przykładami takich protokołów są OPC-UA, Modbus, BLE (Bluetooth Low Energy), CAN i inne. Pozwala to na integrację platformy z instalacjami kontrolno-pomiarowymi zastanymi na obiektach klienta lub na uzupełnienie nowo budowanych systemów o sygnały pomiarowe systemów już istniejących. Usługa bramy IoT pośredniczy w komunikacji między komponentem MQTT warstwy transportowej i łącznikami danych (ang. Connectors). Brama IoT jest widziana przez komponent brokera MQTT jako kolejny klient. Brama dysponuje podręcznym magazynem zdarzeń (ang. Event Storage) przeznaczonym do buforowania danych telemetrycznych i konfiguracyjnych pochodzących z łączników, zanim zostaną przekazane do warstwy przetwarzania platformy. Głównym zadaniem bufora jest zapewnienie integralności danych na wypadek awarii sieci oraz minimalizacja ilości operacji wejścia/wyjścia. Łącznik danych natomiast, odpowiada za połączenie z urządzeniami końcowymi lub serwerami pośredniczącymi, w tym za konfigurację komunikacji stosownie do wymagań odpowiedniego protokołu (cykle wysyłania zapytań o dane, subskrybowanie tematów z danymi itp.). W komunikacji z urządzeniami końcowymi

pośredniczą konwertery odpowiedzialne za przetworzenie danych zablokowanych w sposób specyficzny dla każdego z obsługiwanych protokołów do formatu specyficznego dla komunikacji w ramach platformy.

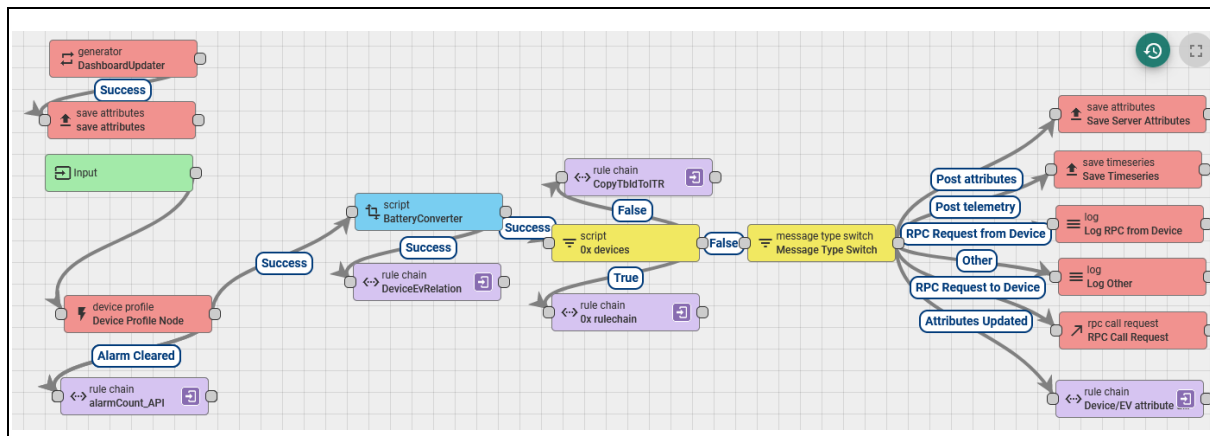
W przedmiotowym przypadku, tj. w ramach implementacji platformy Thinksboard w systemie diagnostyki maszyn jako podstawowy protokół komunikacyjny warstwy transportowej wybrano protokół MQTT. Nie oznacza to, że nie dopuszcza się fragmentarycznego dopuszczenia innych protokołów dla wybranych aplikacji. Jest to konieczne w przypadkach, gdzie implementowane protokoły diagnostyczne wymagają danych procesowych z zastanych na obiekcie źródeł, nieobsługujących protokołu MQTT.

4.2. Warstwa zarządzania

Warstwa zarządzania platformy oparta jest na dwóch głównych komponentach: rdzeniu aplikacji (ang. ThinksBoard core) oraz silniku reguł (ang. rule engine). Rdzeń platformy przetwarza wywołania REST API i subskrypcje WebSocket. Odpowiada za aktywne sesje urządzeń i monitoruje jakość stanu ich połączeń. Silnik reguł natomiast, odpowiada za przetwarzanie przychodzących wiadomości. W ramach tego przetwarzania mogą być realizowane operacje filtrowania, uzupełniania czy przekształcania danych. Reguły silnika pozwalają także na inicjację zdarzeń zależnych od kontekstu danych i zdefiniowanych operacji logicznych, w tym alarmowanie, powiadomienia czy komunikację z systemami zewnętrznymi. Reguły silnika mogą być łączone w złożone łańcuchy reguł (tzw. rule chains). Niezależnie od wbudowanych w ramach silnika reguł systemowych, możliwe jest elastyczne definiowanie reguł użytkownika. Funkcjonalność ta została wykorzystana w systemie monitorowania maszyn, między innymi do sygnalizacji przekroczeń stanów ostrzegawczych i alarmowych monitorowanych parametrów oraz uruchamiania procedur diagnostycznych przez warstwę analityczną.

Silnik reguł przetwarza informacje w diagramach przepływów opartych na zdarzeniach. Wejściem każdej reguły jest tzw. wiadomość (ang. message) w formie danych telemetrycznych przychodzących z urządzeń, danych z cyklu życia poszczególnych urządzeń, wywołań REST API, itp. Przetwarzanie wiadomości odbywa się w funkcjach zwanych węzłami (ang. Rule Nodes). Węzły przetwarzają pojedynczą wiadomość na raz, generując na wyjściu jedną lub wiele wiadomości wychodzących. W edytorze silnika reguł węzły odwzorowywane są w postaci graficznych bloków. Środowisko udostępnia bibliotekę węzłów różnego typu (w tym logiczne, matematyczne, komunikacyjne, bazodanowe, itd.). Możliwe jest też definiowanie niestandardowych węzłów w postaci skryptów napisanych w języku java script. Węzły mają charakter hierarchiczny, tzn. poszczególne bloki mogą reprezentować zagnieżdżone podrzędne łańcuchy reguł. Węzły są łączone w łańcuchy reguł za pośrednictwem tzw. relacji używanych do kierowania wiadomości wychodzących.

Zależnie od reguł zdefiniowanych w węzłach mogą to być relacje różnego typu, np. „Sukces” lub „Niepowodzenie”, „Prawda” lub „Fałsz”, relacje oparte na wartości zmiennej, itd.



Rys. 29 Przykładowa definicja łańcucha reguł.

Przykład łańcucha reguł przedstawiono na Rys. 29. Jest to główny łańcuch reguł aplikacji (tzw. root rulechain) jednego z przykładowych wdrożeń. Głównym jego zadaniem jest rozdzielanie wiadomości do wyspecjalizowanych łańcuchów podrzędnych. Wiadomości pozyskane przez warstwę transporotową systemu trafiają do bloku Input, w którym zaczyna się ich procedowanie. Blok „Device Profile Node” odpowiada między innymi za odrzucanie duplikatów, oddzielenie różnych typów wiadomości (w tym telemetry od atrybutów), autoryzację wiadomości pod względem listy obsługiwanych czujników, itp. Blok „alarmCount_API” obsługuje reguły zdefiniowane dla obsługi alarmów w tym ich filtrację, sygnalizację, zatwierdzanie, anulowanie oraz selekcję użytkowników powiadamianych poprzez wiadomości email i/lub SMS. Blok „Battery Counter” obsługuje funkcje kontroli i sygnalizacji stopnia rozładowania baterii poszczególnych czujników. Za identyfikację wiadomości pochodzące od czujników drgań odpowiada blok „0x devices”. Z kolei blok „Message Type Switch” rozdziela komunikaty między reguły podrzędne, odpowiedzialne za obsługę wiadomości różnych typów.

4.3. Repozytorium danych telemetrycznych

Platforma ThB wykorzystuje technologie bazodanowe celem przechowywania informacji organizacyjnych (o urządzeniach końcowych, strukturach obiektów, użytkownikach, organizacji planów wizualizacyjnych) oraz procesowych (dane telemetryczne, atrybuty, statystyki, zdarzenia, wyniki analiz).

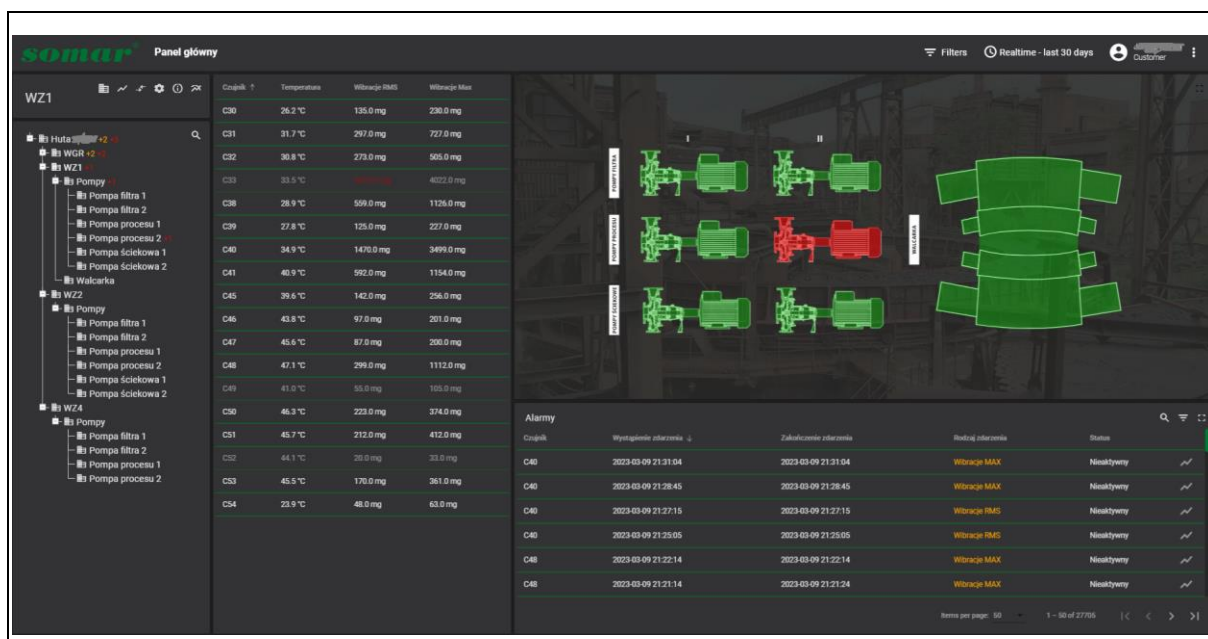
Jak już wspomniano do przechowywania i archiwizacji danych ThB oferuje alternatywnie dwa dojrzałe technologicznie i wydajne rozwiązania - PostgreSQL rozszerzony o modyfikację TimeScaleDB dedykowaną do przechowywania zbiorów danych o charakterze szeregowych oraz tzw. NoSQL-ową bazę danych Cassandra. Cassandra jest

rozwiązaniem skalowalnym, gdyż wraz ze wzrostem dostępnej infrastruktury informatycznej (liczby serwerów) można za jej pośrednictwem operować na zbiorach danych spełniających paradygmat dużych danych (Big Data) [121]. W większości rozwiązań wdrażanych do chwili obecnej, w opracowanym i prezentowanym w niniejszej rozprawie systemie PdM, to właśnie Cassandra pełniła rolę repozytorium danych.

4.4. Wizualizacja danych

Powłoka użytkownika udostępniana jest przez przeglądarkę internetową. Użytkownik po autoryzacji uzyskuje możliwość dostępu do danych systemu poprzez elementy wizualizacyjne - widżety zgrupowane w panelach/kokpitach operatorskich.


Realizując system wypracowano spójne zasady prezentacji danych celem ustandaryzowania procesu wdrażania platformy wizualizacji w ramach różnych instalacji technicznych. Postanowiono, że podstawowym elementem wizualizacyjnym będą plansze typu SCADA gromadzące ogólne informacje o monitorowanym systemie. Plansze te są zorganizowane na zasadzie hierarchicznej prezentacji danych od ogółu do szczegółu. W centralnej części zamieszczona jest graficzna reprezentacja obiektu z uszczegółowieniem zależnym od poziomu. Dla bardzo rozległych systemów mogą to być wskazane na mapie lokalizacje poszczególnych fabryk, oddziałów monitorowanej organizacji, następnie plan zakładu z zaznaczonymi wydziałami, instalacje pogrupowane w ramach oddziału, poszczególne zespoły maszyn w ramach instalacji po oddzielne punkty pomiarowe zaznaczone w ramach podzespołów maszyn. Ponadto w ramach planszy prezentowana jest ta sama hierarchia obiektów w formie drzewa, lista punktów pomiarowych wchodzących w skład danego poziomu prezentacji oraz lista alarmów i ostrzeżeń wygenerowana dla tych punktów.



Rys. 30 Przykład zbiorczej planszy wizualizacyjnej.

Przykład takiej planszy pochodzącej z rzeczywistego wdrożenia zaprezentowano na Rys. 30. W lewej części planszy odwzorowano drzewo hierarchii obiektów, w środkowej części listę podzbioru czujników na wybranym poziomie wraz z przedstawionymi tabelarycznie wartościami podstawowych danych telemetrycznych. W prawym górnym rogu graficzną reprezentację obiektu, a w dolnym lewym rogu listę ostatnio zgłoszonych alarmów i ostrzeżeń wraz z ich aktualnym statusem. Nawigacja pomiędzy elementami może się odbywać poprzez wybieranie poszczególnych obiektów w drzewie bądź poprzez wybieranie symboli graficznych. Dla wszystkich elementów użytkownik otrzymuje informację o jego statusie w formie sygnalizacji odpowiednim kolorem: zielonym dla stanu normalnego, pomarańczowym dla stanu ostrzegawczego, czerwonym dla alarmowego i szarym w przypadku braku aktualnych danych.

Dla każdego z wdrożeń przygotowywane są również plansze prezentujące komplet danych telemetrycznych dla pojedynczego punktu pomiarowego w postaci listy aktualnych wartości, wykresów czasowych i histogramów (Rys. 31).



Rys. 31 Prezentacja danych telemetrycznych przykładowego punktu pomiarowego.

Możliwe jest też prezentowanie wykresów czasowych dla grupy punktów. Jest to szczególnie przydatne przy porównywaniu danych z podobnych obiektów.

W ramach platformy przygotowywane są również plansze odpowiedzialne za konfigurację samej platformy oraz sieci fizycznej. W ramach tych plansz autoryzowany użytkownik uzyskuje możliwość edycji wartości progów ostrzegawczych i alarmowych, częstości dokonywania pomiarów, zakresów pomiarowych czujników itd.

Obiekty wizualizacji odpowiadają również za prezentację wyników działania modeli uruchamianych w ramach silnika analitycznego – tematyka ta zostanie szerzej omówiona w rozdziałach opisujących metody analityczne.

4.5. Silnik analityczny

Silnik - moduł - analitycznego jest realizacją wszystkich zadań związanych z tworzeniem, wdrażaniem i utrzymaniem modeli diagnostycznych. Część tych zadań realizowana jest automatycznie, a część wymaga działania analityka danych (w żargonie nazywanego również data scientist`ą). Ogólny schemat architektury modułu przedstawia Rys. 32.

bazę danych odczytuje konfigurację jak należy przekształcić dane surowe dla konkretnego modelu diagnostycznego.

Dwa kolejne elementy schematu związane są z wizualizacją efektów pracy Modułu ML - Wizualizacja oraz Raporty analityczne. Pierwszy z nich służy prezentacji bieżących danych na planszach diagnostycznych (stąd połączenie z kolejnym modułem – SCADA), drugi zajmuje się prezentacją wyników modeli analitycznych w formie dedykowanej dla końcowego użytkownika. Wyniki działania modeli analitycznych obejmują m.in. porównanie wartości rzeczywistych z prognozami, prezentowanie informacji o trafności prognoz, liczbę fałszywych alarmów, objaśnieniu przyczyn podjęcia konkretnej decyzji, etc.

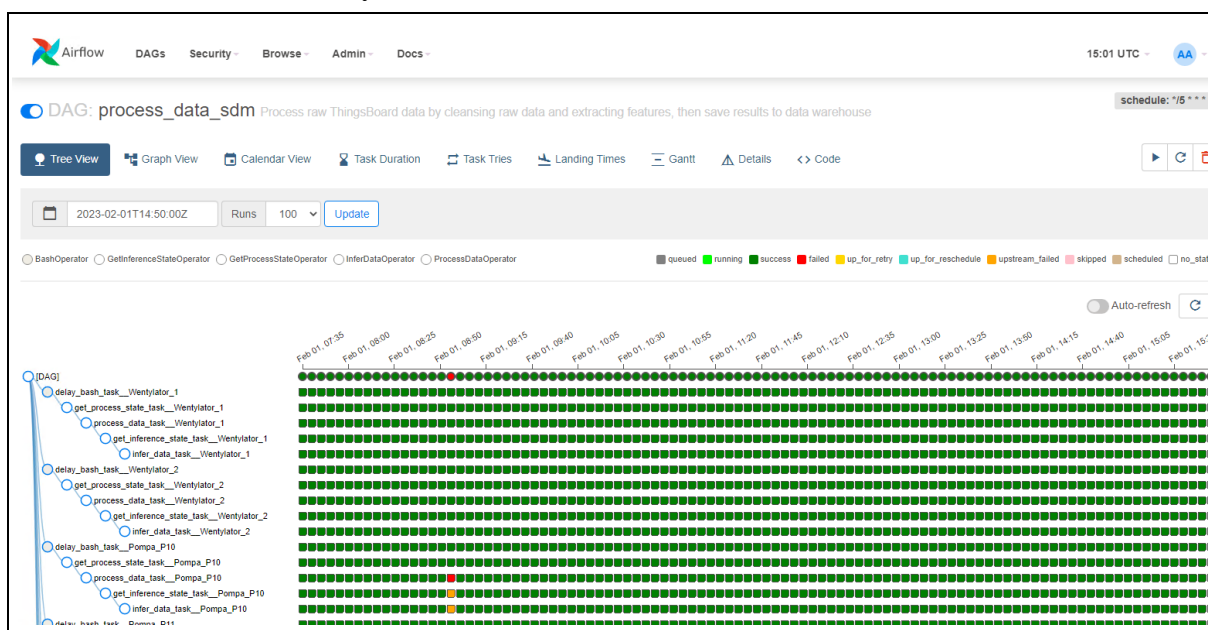
Wizualizacja danych bezpośrednich została oparta o dwie technologie: Grafana [122] i ThB [29]. Powodem zastosowania dodatkowego narzędzia był fakt, że komponenty platformy ThB są przygotowane do prezentacji danych bezpośrednio zbieranych przez platformę, osadzonych w repozytoriach danych platformy. Wizualizacja modeli diagnostycznych możliwa jest również w rozwiązaniu ThB oraz dodatkowo poprzez platformę ShinyProxy [123], dzięki czemu możliwe jest przygotowywanie bardziej zaawansowanych raportów analitycznych. Mogą one zawierać różnego rodzaju wykresy i zestawienia ilustrujące działanie modeli diagnostycznych oraz oferują bardziej zaawansowane i wygodne niż w ThB możliwości interaktywnej parametryzacji. W tym przypadku wynikowe plansze przygotowuje się bezpośrednio w językach analizy (Python, R) co pozwala na skrócenie czasu ich przygotowywania dla użytkownika końcowego. Narzędzie to może też stanowić pole współpracy analityka z użytkownikiem końcowym, pełniącym rolę eksperta dziedzinowego aplikacji, skracając czas opracowywania formy i treści poszczególnych raportów. Tak jak wspomniano, docelowo powstałe raporty mogą być również udostępniane użytkownikowi końcowemu w ramach plansz generowanych w oparciu o ThB.

Moduł Data Science służy możliwości tworzenia modeli diagnostycznych bezpośrednio na podstawie danych telemetrycznych. Moduł ten jest w zasadzie środowiskiem pracy analityka danych. Moduł Data Science realizowany jest w oparciu o platformę Jupyter Hub. Powodem osadzenia Jupyter Hub w ramach silnika analitycznego był fakt, że zazwyczaj klient końcowy nie chce lub nie może udostępniać danych z procesu na zewnątrz organizacji. W klasycznym podejściu, opracowywanie modeli diagnostycznych dla nowych obiektów odbywa się poza środowiskiem wdrożeniowym: analityk projektuje i dostraja modele diagnostyczne na podstawie próbek danych rzeczywistych pochodzących z obiektu z użyciem swoich, zewnętrznych narzędzi, by następnie wdrożyć je w środowisku wdrożeniowym. Osadzenie tych narzędzi w środowisku wdrożeniowym, pozwala na przygotowywanie analiz bezpośrednio w systemie klienta ułatwia również pobieranie danych do analizy.

Zestawienie wielu niezależnych platform w ramach jednego systemu może powodować pewne niedogodności spowodowanych koniecznością indywidualnych autoryzacji w ramach każdego z narzędzi, często z użyciem różnych nazw kont i haseł dostępu. By temu zapobiec, w opracowanym rozwiązaniu wdrożono system uwierzytelniania KeyCloak [124]. Dzięki czemu użytkownik uwierzytelnia się wyłącznie w ramach platformy ThB, zaś za logowanie do systemów podrzędnych odbywa się w sposób automatyczny, niewidoczny dla użytkownika.

Moduł Logi systemowe stanowi dodatkowe uzupełnienie dla administratora systemu. Zapisywanie logów realizowane jest przez narzędzie ELK [125]. Oprócz samego gromadzenia danych ELK udostępnia narzędzia do analizy i wizualizacji logów. Docelowym użytkownikiem narzędzia jest administrator systemu. Wykorzystuje on narzędzie do identyfikacji źródeł ewentualnych problemów wynikających z błędnego działania poszczególnych elementów systemu, zarządzania bezpieczeństwem danych, monitorowania wydajności systemu.

Moduł ML jest jednym z najważniejszych modułów systemu, został zrealizowany w oparciu o rozwiązanie MLFlow [31], które pozwala na budowanie, przechowywanie i zarządzanie różnego rodzaju modelami analitycznymi. Głównym zadaniem modułu jest uruchamianie procedur diagnostycznych dla poszczególnych maszyn i urządzeń do tego celu stosowane są skrypty stworzone w językach Python i R. Rozwiązanie jest niezależne od architektury systemu: może być wdrażane w oparciu o pojedynczą jednostkę serwerową lub w wariantach chmurowych.



Rys. 33 Wizualizacja przykładowych procesów realizowanych przez moduł MLFlow.

Wizualizację stanu poszczególnych procesów realizowanych w module AirFlow zaprezentowano na Rys. 33. W lewej części planszy zdefiniowano nazwy poszczególnych

procesów wraz z graficzną reprezentacją kolejności ich uruchamiania, zaś w prawej części planszy przedstawiono symbolicznie aktualny lub końcowy status operacji (np. szary kwadrat – kolejgowany, jasno zielony kwadrat – uruchomiony, ciemno zielony kwadrat – zakończony sukcesem, czerwony kwadrat – zakończony błędem itd.).

Proces diagnostyki konkretnego obiektu za pomocą konkretnego modelu analitycznego przebiega według następującego scenariusza. Surowe dane pobierane są z głównego repozytorium danych platformy ThB i poddawane standardowym procesom ETL. W ich ramach przeprowadzana jest procedura podnoszenia jakości tych danych obejmująca fazy czyszczenia, agregacji i ekstrakcji cech. To w jaki sposób mają zostać przetworzone i oczyszczone dane determinuje konfiguracja w bazie analitycznej, która w sposób jednoznaczny definiuje dany obiekt oraz model analityczny.

Faza czyszczenia danych obejmuje procesy:

- eliminacji pomiarów nieprawidłowych (w przypadku np. błędów w transmisji czy też na samym początku – błędów pomiaru czujnika),
- eliminacji pomiarów zduplikowanych (powtarzające się pomiary z tego samego czujnika, zarejestrowane w tym samym momencie),
- zmiany częstotliwości rejestrowania danych (np. agregacja danych sekundowych do minutowych),
- eliminacji wartości odstających/skrajnych (niekoniecznie muszą to być dane błędne, jednakże mogą zbyt mocno wpływać na jakość modeli predykcyjnych czy diagnostycznych),
- eliminacji wartości wskazujących na przerwę w pracy urządzenia.

Niektóre modele diagnostyczne mogą wymagać fazy agregacji danych i generowanie zmiennych wywiedzionych. To jak należy agregować dane (szerokość okna funkcje agregujące) oraz jakie zmienne wywiedzione mają zostać wygenerowane również definiowane jest w konfiguracji modelu diagnostycznego.

Jak już wspomiano, każdy model prognostyczny jest skojarzony z konkretnym obiektem, który podlega diagnostyce predykcyjnej. Pierwsze wersje modeli tworzone są przez analityków danych, zapisywane są w analitycznej bazie danych i uruchamiane pod nadzorem MLFlow. MLFlow zapisuje również do bazy analitycznej prognoz modeli, tak aby możliwe było śledzenie jakości prognoz.

Na działanie modeli nałożone są pewne ograniczenia: m.in. w zadanym czasie (przesuwne okno czasowe lub przyrostowe okno czasowe) sprawdzane jest czy w świetle danych historycznych (np. w poprzedniej godzinie) model spełniał minimalne wymagania jakości. Minimalne kryteria jakości mogą być definiowane jako wartości standardowych miar jakości lub błędów - co zazwyczaj jest niezrozumiałe dla użytkownika końcowego lub jako liczba pomyłek, jakie popełnił model w określonym przedziale czasu (przedmiot

konfiguracji) lub liczba pomyłek o określonej wartości (rozdzielamy przeszacowanie i niedoszacowanie w przypadku prognozowania wartości lub liczbę fałszywych alarmów (false positives) i nie wykrycia sytuacji niepożądanych (false negatives) jakie popełnił model.

Jeśli takie minimalne wymagania jakości przestają być spełnione, model jest trenowany ponownie na najnowszym zestawie danych. W przypadku dalszej niemożności uzyskania zadowalających – spełniających minimalne kryteria jakości – wyników modelowania, generowany jest komunikat o konieczności opracowania przez analityka danych nowego modelu diagnostycznego. Ponadto, diagnostyka zgodnie z dotychczasowym modelem przestaje być realizowana, czujnik/urządzenie nie podlega diagnostyce a system SCADA generuje odpowiedni komunikat.

Do jednego czujnika/urządzenia może być przyporządkowanych wiele modeli prognozowania.

Ważnym elementem całego rozwiązania jest analityczna baza danych, którą zaprojektowano i zrealizowano w systemie PostgreSQL. Analityczna baza danych przechowuje referencje do danych, na podstawie których trenowano i testowano modele analityczne/diagnostyczne oraz informacje o działaniu i konfiguracji modeli. W szczególności są to informacje:

- o modelu – gdzie działał, w jakim czasie, jaka była jego konfiguracja (parametry nie tylko modelu, ale też horyzont prognozy, minimalne kryteria jakości);
- o obiekcie/czujniku – jakie modele “prognozowały ten obiekt”, przez jaki czas, jaka była jakość tych prognoz, jakie były parametry minimalnej jakości dla tego obiektu, jaki był horyzont prognozy.

W szczególności przechowywane są informacje dotyczące:

1. Prognoz generowanych przez modele prognostyczne m.in.

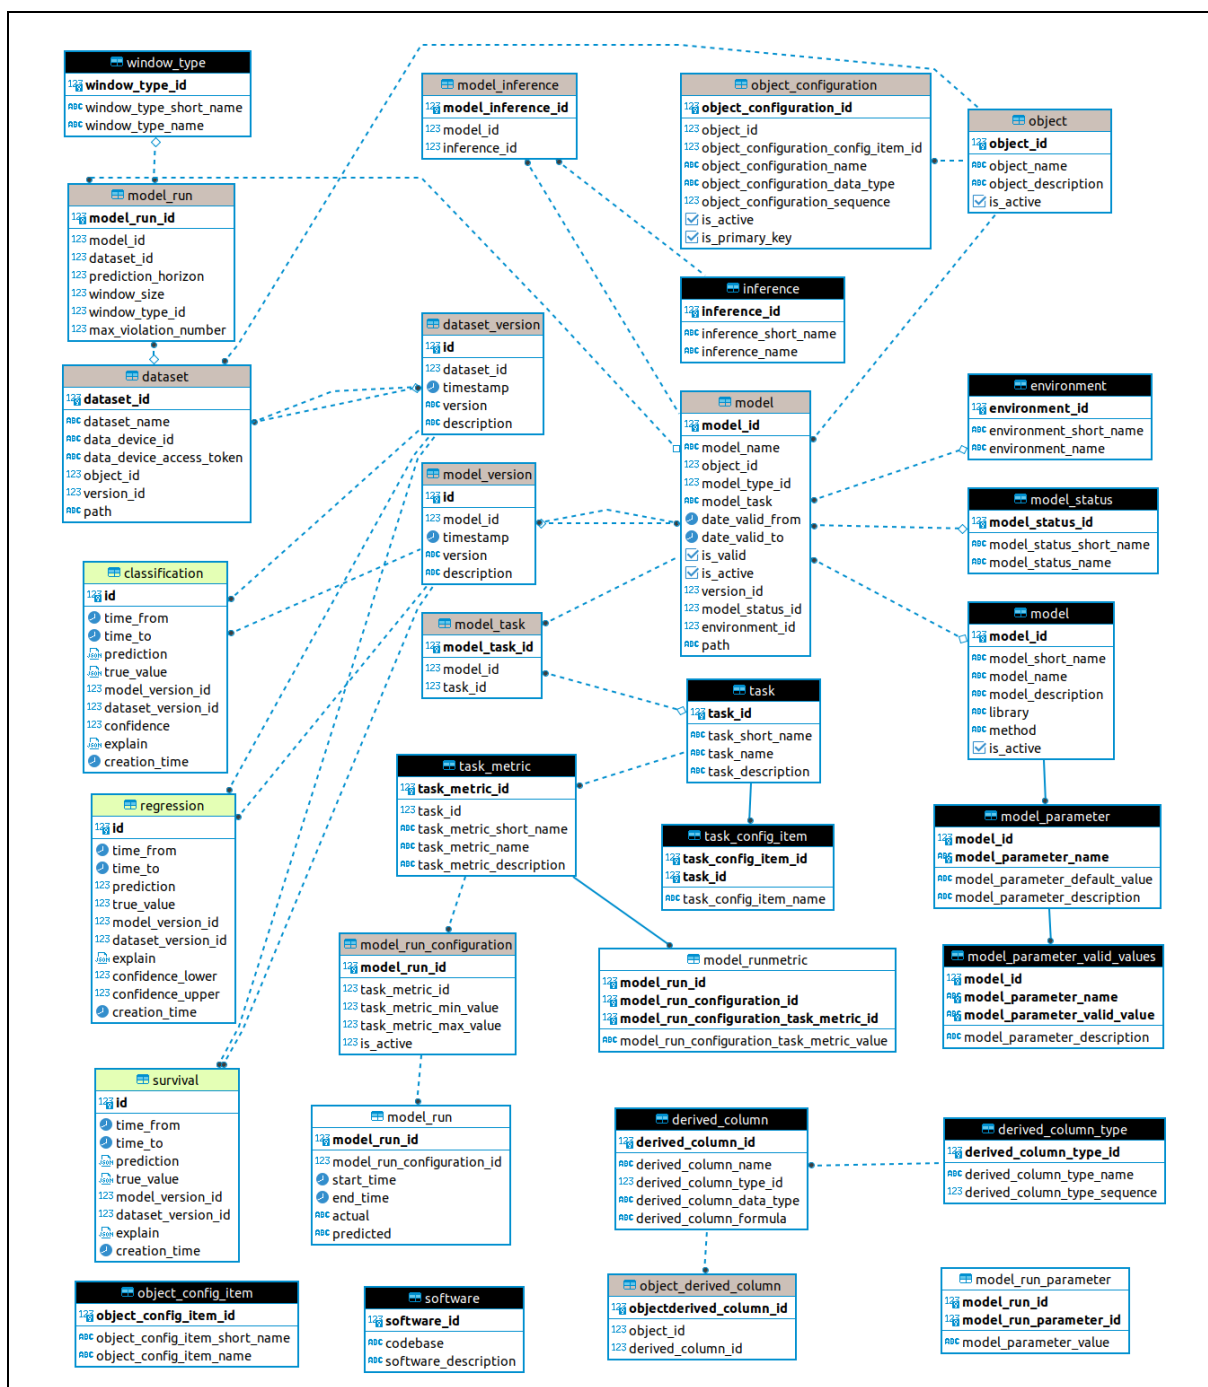
- identyfikator modelu,
- wartość prognozy,
- obiektu/czujnika, którego dotyczy prognoza,
- parametry modelu i obiektu w trakcie podejmowania prognozy (horyzont, parametry modelu; dane wejściowe do modelu i sposób ich wyliczania – odpowiedni skrypt lub program).

2. Danych konfiguracyjnych dotyczących modeli

- metoda (nazwa metody analitycznej np.XGB),
- nazwa pakietu implementującego metodę,
- w jakich przedziałach czasu model był wykorzystywany, jakie obiekty monitorował i z jakimi wartościami parametrów (tzw. hiperparametrów),
- na jakich danych wejściowych model był trenowany i testowany,
- jakie wykorzystano procedury agregacji i przekształcania danych surowych w dane wejściowe dla modelu (skrypt, program),

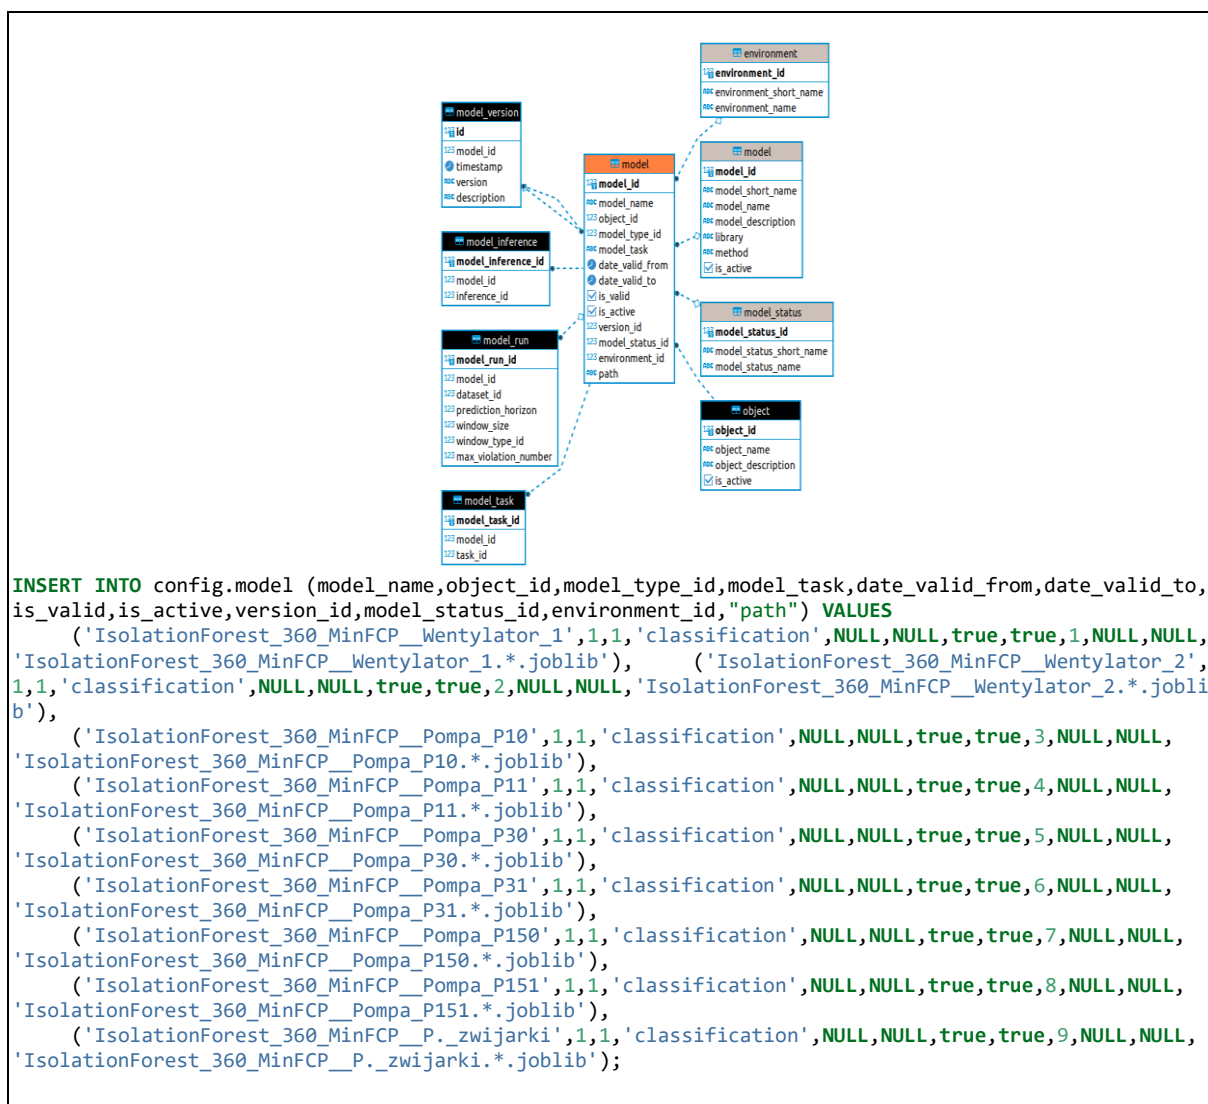
- tryb działania.
3. Danych konfiguracyjnych o obiektach podlegających prognozowaniu
 - co jest przedmiotem prognozowania,
 - horyzont prognozy,
 - skąd pochodzą dane źródłowe.
 4. Danych konfiguracyjnych o akceptowalnych progach prognozy
 - metoda nadzorowania (przesuwne okno, rozszerzające się okno),
 - szerokość okna, częstotliwość sprawdzania jakości modelu,
 - wartości progowe parametru minimalnej jakości w oknie czasowym (może być kilka takich parametrów, a ich spełnienie lub nie opisywane jest formułą logiczną np. koniunkcją spełnienia wszystkich z nich),
 - okres obowiązywania danych parametrów – użytkownik może zmienić te wartości, więc zmiany te są archiwizowane, aby można było odtworzyć efektywności modelu dla danych kryteriów minimalnej jakości.
 5. Danych treningowych i walidacyjnych, na jakich były trenowane i optymalizowane modele.

Od strony technicznej baza danych składa się z 31 tabel w czterech przestrzeniach nazw: codes , config, prediction i run. Uproszczony schemat bazy został przedstawiony na Rys. 34.



Rys. 34 Schemat bazy danych.

Główną tabelą bazy reprezentującą instancję modelu analitycznego/diagnostycznego jest tabela model schematu config (Rys. 35). Pole *path* jest ścieżką do konkretnego pliku zawierającą zserializowany model. Tabela model_task definiuje konkretne zadanie, które ten model realizuje, np. klasyfikacja (tabela classification) czy regresja (tabela regression). Z kolei tabela task_metric zawiera definicje metryk, które mogą zostać wykorzystane podczas ewaluacji modeli.



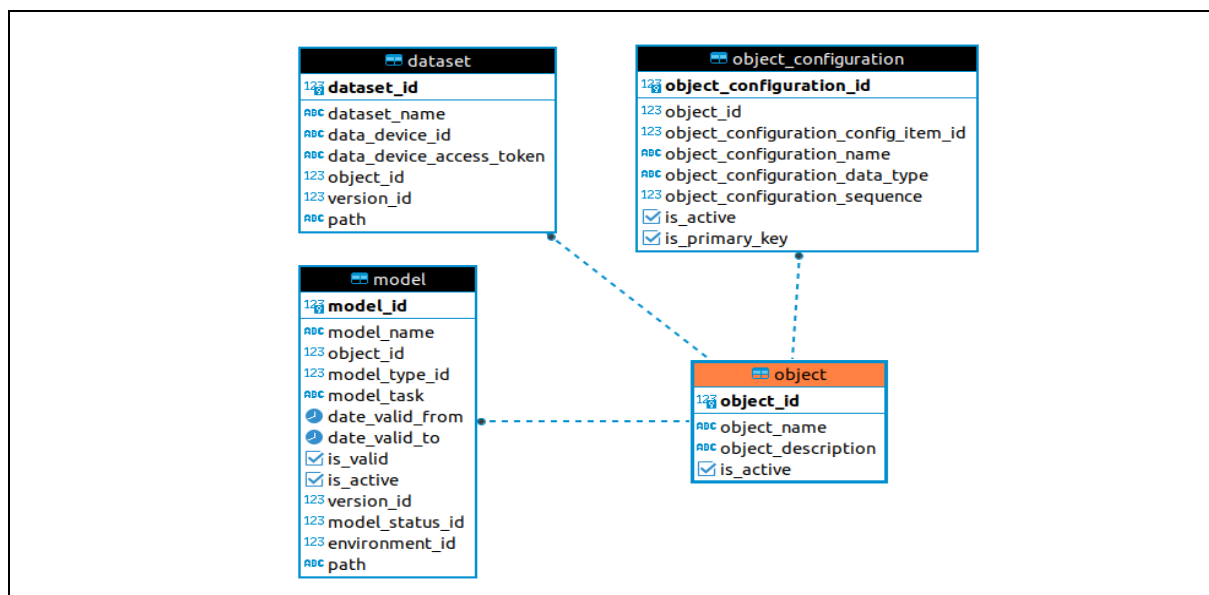
Rys. 35 Tabela model z przykładową zawartością.

Pierwszy wiersz (nazwany jako 'IsolationForest_360_MinFCP__Wentylator_1' w przykładowej zawartości na Rys. 35) wskazuje na model typu IsolationForest (model_type_id = 1, lista dostępnych typów modeli zawarta jest w tabeli codes.model) zbudowanym na danych pochodzących z obiektu (maszyny lub urządzenia) o object_id=1 (szczegółowe informacje o obiektach są podane w tabeli config.object). Pole model_task (jest to typ wyliczeniowy (enum) o wartościach classification, regression lub survival) w tym przypadku wskazuje na model wykorzystywany do klasyfikacji (classification), co w przypadku tego modelu (IsolationForest to algorytm do detekcji anomalii w danych) jest interpretowane jako pojawienie się stanu odstającego od normy danego obiektu. Pola date_valid_from, date_valid_to, is_valid służą do określenia, czy model jest aplikowalny do obecnej konfiguracji obiektu - w wyniku zmian konfiguracyjnych obiektu (np.. dodania nowych czujników) wcześniej zbudowane modele mogą nie być już poprawne ze względu na zmiany w danych. W takim przypadku pole is_valid jest ustawiane na false, a pola

date_valid_from, date_valid_to są uzupełniane okresem, w których model był stosowany. Flaga is_active pozwala na wyłączenie modelu - przykładowo, dla danego obiektu może istnieć kilka równoległe działających modeli, a flaga ta umożliwia wyłączenie wybranych z nich. Pole version_id zawiera nr porządkowy wersji modelu. W założeniu kolejne wersje modelu powstają kiedy zostanie one przebudowany na nowszych danych treningowych (parametry i typ modelu pozostają bez zmian, jak również zestaw cech zbioru). Pola model_status_id oraz environment_id służą do określenia statusu modelu (możliwe wartości to In preparation, In training, Trained, Deployed) oraz w jakim środowisku programistycznym model ten jest obecnie dostępny (możliwe środowiska to deweloperskie, testowe, produkcyjne).

Każdorazowo przy uruchamianiu modeli tworzona jest instancja tabeli model_run. Modele są uruchamiane w parze z wybranym zbiorem danych z tabeli dataset. Samo działanie (tzn. prognozy) modelu jest reprezentowane w tabeli model_inference.

Zbiór danych tabeli dataset definiowany jest przez listę atrybutów (czyli kolumn w tym zbiorze) zdefiniowanych w tabeli object_configuration (Rys. 36). Przykładowe atrybuty zdefiniowane są w kolumnach object_configuration_name (nazwa atrybutu), object_configuration_data_type (typ atrybutu), itd.



Rys. 36 Definicja atrybutów tabeli dataset.

Platforma jest zintegrowana z Apache Spark [126] oraz Kubernetes [127], dzięki czemu spełnia warunek skalowalności.

5. Model diagnostyczny suwnicy bramowej

5.1. Opis przedmiotu monitorowania

Przedmiotem monitorowania były suwnice bramowe o nośności 500 T eksploatowane w jednej z hut stali zlokalizowanych na terenie Polski. Huta wykorzystuje dwie takie suwnice, obie umiejscowione są na wydziale stalowni i przeznaczone są do transportu kadzi z surówką. Obie suwnice mogą operować zamiennie wzdłuż hali wydziału stalowni o długości 300m i obsługują dwa piece konwertorowe. Pełny cykl pracy obejmuje podniesienie kadzi z surówką z wózka transportowego, następnie jej przemieszczenie w kierunku pieca konwertorowego, podniesienie na wysokość gardzieli pieca, obsługa operacji wlewania surówki do gardzieli pieca wymagająca pochylenia kadzi i odstawienie pustej kadzi na wózek transportowy.



Rys. 37 Suwnica bramowa 500T.

Suwnica jest istotnym elementem zapewnienia ciągłości procesu produkcji stali. Awaria jednej z suwnic prowadzi do spadku wydajności procesu, zaś awaria obu do jego zatrzymania. Obie sytuacje wpływają negatywnie na wynik finansowy przedsiębiorstwa, dlatego istotna z punktu widzenia służb utrzymania ruchu jest bieżąca znajomość stanu technicznego maszyny oraz wyprzedzając informacja o postępującym uszkodzeniu, pozwalająca na zaplanowanie remontu w dogodnym dla podtrzymania procesu produkcyjnego momencie.

Z praktyki służb utrzymania ruchu wynika, że newralgicznym elementem maszyny jest przekładnia mechanizmu windy odpowiedzialnej za podnoszenie i opuszczanie kadzi (Rys. 38). Koła zębate oraz łożyska przekładni narażone są na wnikanie pyłów, w skład których wchodzi głównie tlenki metali. Dodatkowo mechanizm pracujący przy dużych

obciążeniach narażony jest na udary temperaturowe. Wszystko to powoduje, że każda z przekładni wymaga generalnego remontu nie rzadziej, niż raz do roku.




Rys. 38 Widok przekładni mechanizmu widny suwnicy.

Postępujące uszkodzenie mechanizmu objawia się przez wzrost drgań mechanizmu. W zaawansowanej fazie uszkodzenia drgania te są przenoszone kolejno przez obudowę przekładni, ramę i wózki jezdne suwnicy na elementy konstrukcyjne hali zakładu. Wibracje są wówczas wyraźnie odczuwalne przez operatora suwnicy.

5.1.1. Układ pomiarowy

Jako że głównym symptomem diagnostycznym monitorowanego mechanizmu są drgania, jako element pomiarowy zostały wybrane bezprzewodowe czujniki drgań typu WS-VT1. Sposób ich rozmieszczenia na mechanizmie suwnicy zaprezentowano na Rys. 39.

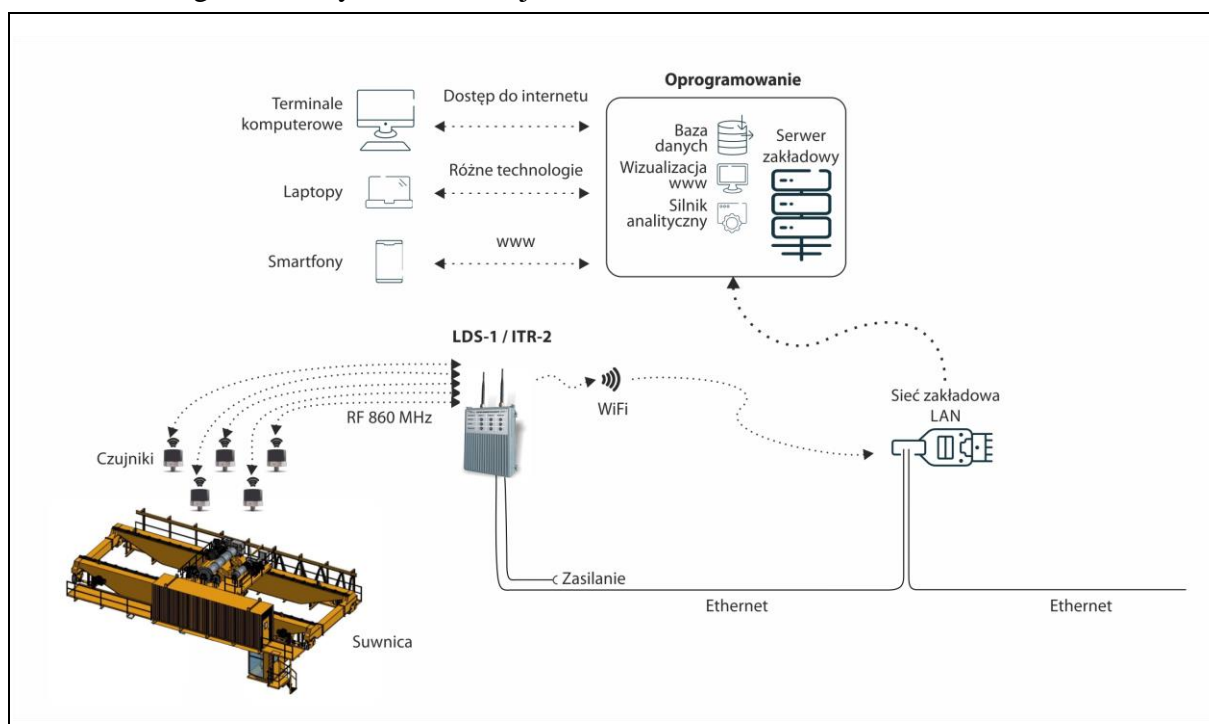


Rys. 39 Lokalizacja punktów pomiarowych na mechanizmie suwnicy.

Mechanizm windy suwnicy S-201 wyposażony jest w dwa symetryczne (lewy i prawy) układy napędowe z przekładniami zębatymi. Czujniki zamontowano na wałkach napędowych obu przekładni (1, 6), łożyskach zębniaka (2, 5) oraz belce nośnej (3, 4). Czujniki 3 i 4 pełnią funkcje pomocnicze, w szczególności pozwalają na monitorowanie poziomu drgań tła. Monitorowaniu podlegały obie suwnice zakładu. Czujniki suwnicy S-202 rozmieszczono analogicznie i nadano numery w zakresie 7 - 12.

Architekturę systemu pomiarowego zaprezentowano na Rys. 40. Sygnały z czujników typu WS-VT1 przekazywane są drogą radiową do transceivera radiowego typu ITR-2. Transceiver podłączony jest do sieci lokalnej Ethernet zakładu i za jej pośrednictwem

przekazuje odebrane dane telemetryczne do bazy danych serwera analitycznego zainstalowanego na maszynie wirtualnej zakładu.

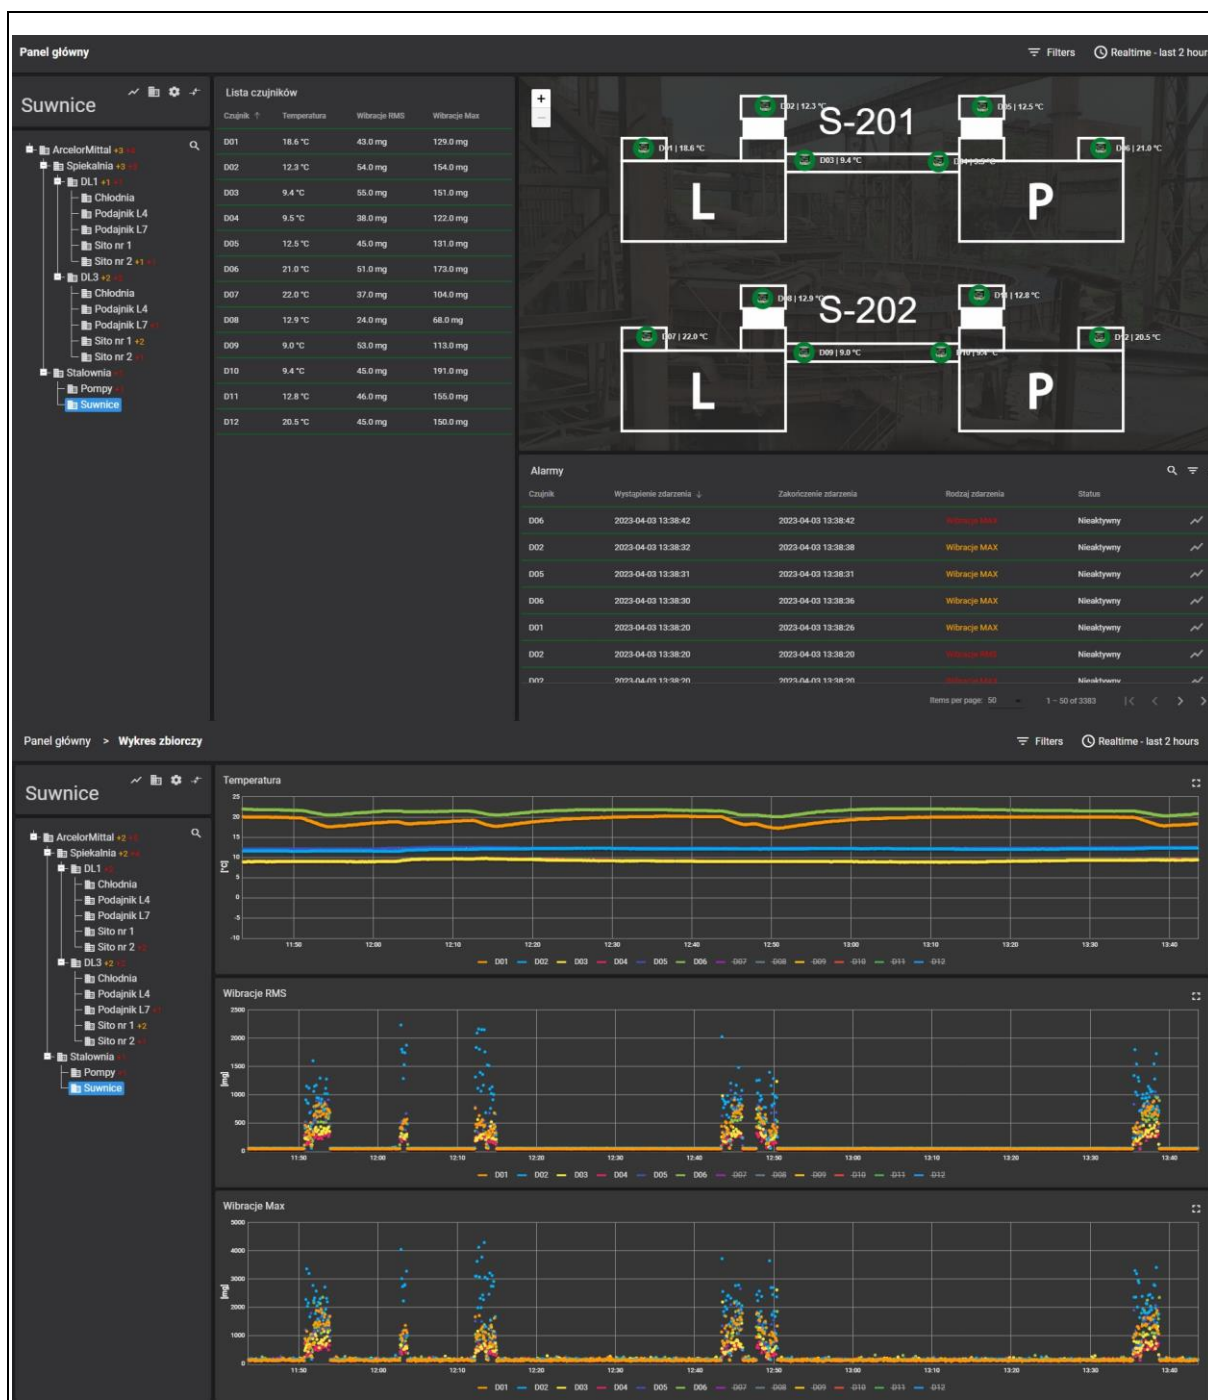


Rys. 40 Architektura systemu pomiarowego suwnicy bramowej.

Dla służb utrzymania ruchu skonfigurowano plansze wizualizacji platformy ThB pozwalające m.in. na:

- prezentację bieżących wartości drgań, temperatury i poziomu naładowania baterii,
- konfigurację i ustawianie prawidłowych, ostrzegawczych i alarmowych poziomów drgań (generalnie parametrów procedury diagnostycznej) oraz poziomów temperatury i naładowania baterii,
- prezentację danych bieżących i historycznych na wykresach (Rys. 41),
- prezentację wybranych wyników analizy danych, wykonywanych przez analityczną część systemu,
- generowanie raportów okresowych (zmianowych, dobowych, długoterminowych).

Aplikacja umożliwia również prowadzenie dziennika awarii i prac remontowo-konserwatorskich. Jak już wspomniano, jest to bardzo ważna cecha systemu pozwalająca na wykorzystanie informacji zawartych w dzienniku podczas analizy danych. W szczególności, informacja o wymianie dowolnego z monitorowanych elementów suwnicy powoduje zresetowanie informacji o bezawaryjnym czasie pracy tego elementu.



Rys. 41 Okno wizualizacji pomiarów dla grupy czujników – widoczne są bieżące pomiary (tablica wartości), alarmy oraz pomiary historyczne (na rysunku pomiary z ostatnich dwóch godzin).

Kluczowym zadaniem diagnostycznym jest analiza poziomu drgań i określenie na tej podstawie czy w horyzoncie kilku lub kilkunastu dni możliwe będzie dalsze normalne użytkowanie suwnicy. Procedura diagnostyczna powinna ułatwiać służbom utrzymania ruchu, podejmowanie decyzji dotyczących wykonania remontu czy też doraźnych – poza

zaplanowanym harmonogramem – prac utrzymaniowych (np. wymianę oleju/smaru przekładniowego, kontrolę uzębienia wałów).

Z praktycznego punktu widzenia pożądanym jest, aby procedura diagnostyczna była parametryzowalna, gdyż np. niemożność rozmieszczenia czujników drgań za każdym razem w tym samym miejscu powoduje, że poziomy drgań nieakceptowalne w jednym warunkach eksploatacyjnych mogą okazać się akceptowalne w innych warunkach. W przedstawionej w rozdziale 5.2 analizie danych dużą rolę odegrał fakt posiadania informacji pochodzących z tzw. dziennika zdarzeń, w którym zapisywane były wszystkie prace konserwatorskie i remontowe wykonywane na monitorowanym obiekcie. Informacje te wykorzystano do opracowania i oceny efektywności przedstawionej metody. Pozwoliło to m.in. odnieść poziom drgań do wykonanych prac remontowych i, w szczególności, nie traktować nagłych spadków poziomu drgań jako błędów danych.

Proponowana procedura diagnostyczna musiała nawiązywać do zastanych w zakładzie praktyk w zakresie monitorowania stanu diagnostycznego suwnicy. Bazowały one na analizie historycznych poziomów drgań poszczególnych węzłów zidentyfikowanych na podstawie cyklicznych pomiarów dokonywanych przez służby utrzymania ruchu. Stanowiły one podstawę do oceny trendów wynikających z tych obserwacji. Stąd zdecydowano o zaproponowaniu metod bazujących właśnie na analizach trendu.

5.2. Procedura diagnostyczna

5.2.1. Wstępne przetwarzanie danych

Dwie suwnice były monitorowane za pomocą zestawu sześciu czujników każda. Do analizy wykorzystano informację o zarejestrowanych wartościach drgań – maksymalnej (VibrMAX) oraz skutecznej (VibrRMS).

Pierwszy etap przetwarzania danych polegał na przygotowaniu dwóch zbiorów danych (po jednym dla każdej suwnicy), w których każdy kolejny wiersz zawiera informacje o maksymalnym i skutecznym poziomie drgań rejestrowanych przez każdy z 6 czujników w kolejnych sekundach (Tabela 6).

Tabela 6

Zbiór danych podstawowych opisujących pracę każdej z suwnic.


Data/czas	VibrRMS1	...	VibrRMS12	VibrMAX1	...	VibrMAX12
2017-05-05 15:12:00	28	...	29	71	...	74
2017-05-05 15:12:01	28	...	30	70	...	72

W sytuacji, w której z danego czujnika w danej sekundzie nie odnotowano pomiarów, a przerwa w danych wynosiła mniej niż 30 sekund, brakujące dane uzupełniano ostatnią z zarejestrowanych wartości. Okres 30 sekund wynikał z konfiguracji transmisji, w której

wymuszano przesyłanie danych z czujników nie rzadziej niż 30 sekund. Przerwy dłuższe niż 120 sekund traktowano jako braki w danych.

Procedura diagnostyczna bazuje na analizie wektora zmiennych, który opisuje pojedynczy cykl pracy suwnicy. Cykl pracy powinien odzwierciedlać działanie suwnicy polegające na podniesieniu przenoszonego elementu przemieszczeniu go w inne miejsce i jego opuszczeniu. Ponieważ nie dysponowano informacjami o pracy tych elementów, które odpowiadają za podnoszenie i przemieszczanie się suwnicy, cykl zdefiniowano jako okres czasu, w którym czujniki rejestrowały podwyższone poziomy drgań. Ponadto, w celu identyfikacji cykli pracy przyjęto następujące dodatkowe założenia:

- podstawą identyfikacji cykli były pomiary, dla których zarejestrowana wartość skuteczna drgań przekraczała 150 mg; wartości niższe traktowane były jako przerwa w pracy suwnicy,
- zidentyfikowane cykle o długości krótszej niż 70 sekund nie były brane pod uwagę,
- jeśli przerwa pracy trwała mniej 60 sekund, dwa kolejne cykle były łączone.



Rys. 42 Przykład identyfikacji cykli pracy suwnicy – szare obszary oznaczają zidentyfikowane cykle pracy.

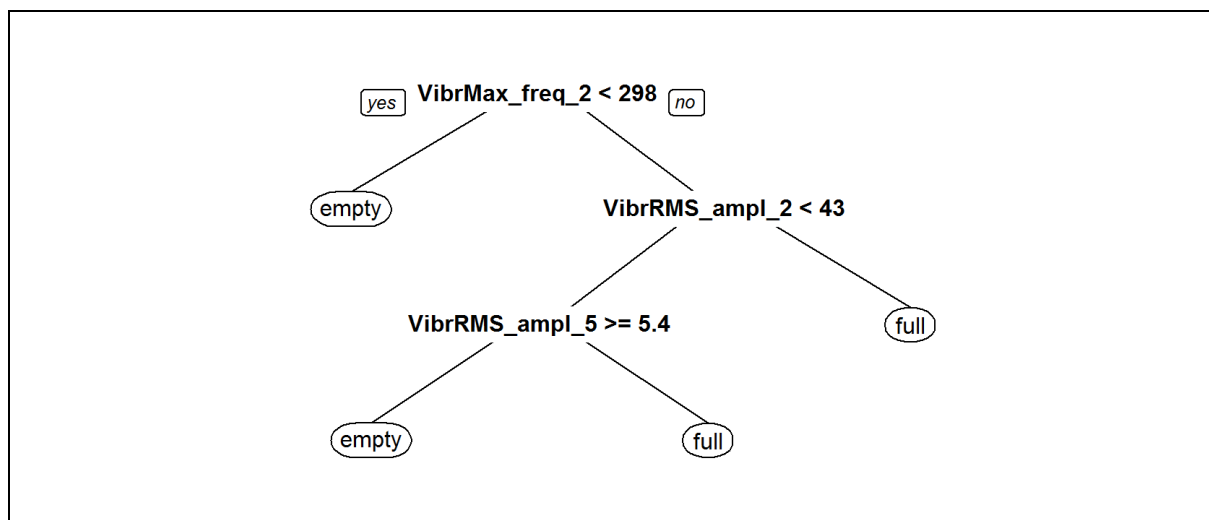
Dla każdego ze zidentyfikowanych cykli pracy obliczano szereg parametrów opisujących charakterystyki przebiegów zmiennych VibrMAX oraz VibrRMS. Obliczeń dokonano w całym zakresie rejestrowanych wartości oraz dla odfiltrowanych wartości tych cech w przedziałach 2000-2500 mg, 2500-3000 mg, 3000-3500 mg. Dla VibrMAX i VibrRMS wyznaczano m.in.:

- wartość minimalną,
- wartość średnią i jej piąty (ozn. P5) oraz dziewięćdziesiąty piąty (ozn. P95) percentyl,
- liczbę pomiarów powyżej 3500 mg,
- wyniki analizy harmonicznej sygnału wartości skutecznej drgań: częstotliwość 10-ciu pierwszych składowych harmonicznym (łącznie ze składową stałą) oraz ich amplitudę,

- wyniki analizy harmonicznej sygnału wartości maksymalnej drgań: częstotliwość 10-ciu pierwszych składowych harmoniczných (łącznie ze składową stałą) oraz ich amplitudę,
- pierwszy kwartył (ozn. Q1),
- medianę (ozn. Q2),
- trzeci kwartył (ozn. Q3),
- wartość maksymalną,
- rozstęp międzykwartyłowy (Q3-Q1),
- rozstęp percentylowy (P95-P5),
- modę zarejestrowanych wartości.

Efektom końcowym przeprowadzonej analizy był, dla każdego czujnika, wektor 115 cech charakteryzujących każdy cykl pracy suwnicy.

Pierwsza z wykonanych analiz polegała na sprawdzeniu czy na podstawie powyższych parametrów da się jednoznacznie rozpoznawać cykle pracy, w których suwnica obciążona jest ciężarem pełnej kadzi. Do badań dysponowano bardzo ograniczonym zbiorem treningowym składającym się z 48 przejazdów suwnicy, które zostały przez obsługę kwalifikowane jako „przejazd pełny” (24 przykłady), „przejazd pusty” (24 przykłady). Na podstawie dostępnych przykładów wygenerowano – stosując algorytm RPART [128] – drzewo decyzyjne załączone na Rys. 43.



Rys. 43 Drzewo decyzyjne do identyfikacji pustych i pełnych przejazdów suwnicy.

Cechy bazujące na analizie Fouriera pozwoliły na uzyskanie drzewa o zdolności klasyfikacji wynoszącej odpowiednio: dokładność klasy empty 0.792 oraz dokładność klasy full 0.958. Niestety, po uruchomieniu klasyfikatora na danych gromadzonych przez dłuższy okres czasu zaobserwowano, że większość przykładów (5467 z 6439) została zaklasyfikowana jako empty). Pomimo tego, że przykłady nie posiadały etykiet klas, taki wynik klasyfikacji uznano za zły, gdyż ze specyfiki pracy suwnicy rozkład przykładów

powinien być zbliżonych do równomiernego. Ostatecznie, dalszej analizie podawano cykle pracy suwnicy bez rozgraniczania czy oznaczają one przejazd pusty czy pełny.

W dalszej części badań do określenia procedury diagnostycznej użyto danych z jednej suwnicy, dane z drugiej suwnicy wykorzystano do weryfikacji przeprowadzonych badań.

W celu identyfikacji cech mających największe znaczenie diagnostyczne, zastosowano metodę selekcji cech bazującą na rankingu cech klasyfikatora utworzonego za pomocą metody lasów losowych [129]. Wektor kolejnych cykli z okresu 4 miesięcy pracy suwnicy (w sumie 11 818 cykli) etykietowano w ten sposób, że cykлом jakie zarejestrowano w okresie do dwóch tygodni bezpośrednio przed awarią i po jej usunięciu nadano etykietę 0 (suwnica sprawna), a cykлом jakie zarejestrowano w okresie dwóch tygodni przed awarią aż do wystąpienia awarii nadano etykietę 1 (suwnica w stanie przed-awaryjnym). Uzyskano w ten sposób zbiór, w którym 9275 przykładów wskazywało na klasę 0 i 2543 przykłady wskazywały na klasę 1. Na przygotowanym – dla każdego czujnika drgań oddzielnie – zbiorze danych trenowano klasyfikator złożony z 1000 drzew decyzyjnych. Głównym kryterium podziału i oceny węzła było kryterium Gini [129]. Uzyskano następującą jakość klasyfikacji:

- czujnik 1 – specyficzność 0,984, czułość 0,898,
- czujnik 2 – specyficzność 0,991, czułość 0,722,
- czujnik 3 – specyficzność 0,986, czułość 0,828.

Na podstawie analizy drzew tworzących las losowy oceniano istotność każdej z rozważanych cech z punktu widzenia jej ważności w utworzonym klasyfikatorze. Ważność cechy X na podstawie utworzonego lasu losowego została wyznaczona według wzoru:

$$Imp(X) = \frac{1}{M} \sum_T \sum_{t \in T: v(t)=X} \frac{N_t}{N} \cdot \left\{ G(t) - \left[\frac{N_{tL}}{N_t} G(t_L) + \frac{N_{tR}}{N_t} G(t_R) \right] \right\} \quad (8)$$

gdzie:

- M – liczba wszystkich drzew T w lesie losowym (w tym przypadku 1000),
- t – węzeł drzewa T ,
- t_L, t_R – lewy i prawy potomek węzła t ,
- $v(t)$ – cecha pojawiająca się w warunku węzła t ,
- N – liczba wszystkich obserwacji w zbiorze treningowym (w tym przypadku 11818),
- N_t – liczba obserwacji w węźle t ,
- $G(t)$ – indeks Giniego dla węzła t ; $G(t) = 1 - \frac{N_t^+}{N_t} - \frac{N_t^-}{N_t}$, gdzie N_t^+ i N_t^- to odpowiednio liczba przykładów pozytywnych (klasa 1) i negatywnych (klasa 0) w węźle t .

Im wyższa wartość miary $Imp(x)$, tym cecha opisująca cykl pracy suwnicy lepiej rozróżnia stany diagnostyczne, a tym samym jest bardziej pożądana jako cecha diagnostyczna. Jeżeli cecha nie występowała w żadnym z drzew tworzących las losowy, jej ważność wynosiła 0.

Rankingi cech według miary (8) zostały utworzone dla każdego z czujników z osobna. Uzyskano w ten sposób 3 rankingi cech. Ostateczna ranga danej cechy była średnią arytmetyczną pozycji, jaką cecha zajmowała w każdym z tych rankingów.

Pierwsze pięć cech w rankingu wykorzystano do dalszych prac nad opracowaniem procedury diagnostycznej. Cechami tymi były:

- VibrMax2000_Q3 – wartość 3 kwartyła cechy VibrMAX; w obliczeniach uwzględniono jedynie wartości $\text{VibrMAX} > 2000$,
- VibrMax3000_Q3 – analogicznie jak wyżej,
- VibrMax2500_Q3 – analogicznie jak wyżej
- VibrMax_P95 – wartość 95 centyla cechy VibrMAX;
- VibrMax2000_P95 – wartość 95 centyla cechy VibrMAX; w obliczeniach uwzględniono jedynie wartości $\text{VibrMAX} > 2000$.

5.2.2. Analiza trendu

Analiza trendu wykorzystywana jest do prognozowania kierunku zmian monitorowanej wielkości. W pracy [130] przedstawiono przegląd informacji na temat stosowania trendów liniowych i nieliniowych w zakresie metod regresji nieparametrycznej, wygładzania i modelowania statystycznego.

Stylizowaną analizę trendu przestawiono w [131]. Celem badania była identyfikacja standardowych procedur operacyjnych związanych z konserwacją i wymianą sprzętu na podstawie danych historii procesów w zakładzie prowadzących do usterek i zdarzeń potencjalnie wypadkowych spowodowanych błędami operatora lub awariami sprzętu.

W pracy [132] przedstawiono zautomatyzowany system zbierania danych w transporcie kolejowym, który pomaga w analizie ewolucji trendów uszkodzeń i przewidywaniu awarii. Z kolei w pracy [133] opisano zastosowanie zintegrowanego modelu autoregresyjnego ze średnią ruchomą ARIMA do prognozowania żądań zmiany modelu w procesie tworzenia dużego oprogramowania w ramach projektu open source.

Metody analizy trendu stosowano w zadaniach PdM, między innymi do estymacji stanu generatora turbiny wiatrowej [134], analizy prędkości drgań układu wentylatorów młynowych stosowanych w elektrowni [135], diagnostyki układów prasowania maszyn papierniczych [136, 137] oraz predykcji zmian ciśnienia oleju, ciśnienia paliwa, niewyważenia sprężania, prądu rozruchowego i rezystancji wewnętrznej akumulatora pojazdów [138].

W [139] przestawiono przegląd niektórych istniejących metod ekstrakcji trendów i szacowania podobieństwa, natomiast w [140] przedstawiono przegląd metod estymacji trendów statystycznych, w tym krzywe liniowe, punkty zmiany, przyspieszone wzrosty, inne

zachowania nieliniowe oraz opisy nieparametryczne na przykładzie szeregów czasowych zmiennych klimatycznych.

W pracy [141] zaproponowano podejście do oceny zależności i różnic wielowymiarowych trendów oparte na konstrukcji wielowymiarowych tablic z szeregów czasowych danych rejestracyjnych parametrów technicznych złożonych obiektów technicznych, natomiast w pracy [142] skupiono się na oszacowaniu modelu analizy trendów niezawodności typu power law przy niepełnych danych o awariach z wielu jednorodnych maszyn.

Podstawą procedury diagnostycznej jest analiza trendu zmian wartości cech (nazwijmy je zmiennymi diagnostycznymi) zidentyfikowanych w poprzednim podrozdziale jako kluczowe. Analiza trendu wykonywana jest jednocześnie na podstawie danych historycznych dla $h1$, $h2$, $h3$ cykli pracy suwnicy. Przy czym $h1$ opisuje krótki okres czasu, a $h2=2h1$, $h3=3h1$. Pozwala to na wychwycenie dynamicznych (ale być może krótkotrwałych), jak również stałych tendencji zmian w analizowanym szeregu czasowym.

W procedurze uwzględniane są również następujące parametry:

- stopień wygładzania (ozn. sm) – ze względu na bardzo dużą wariancję wartości zmiennych diagnostycznych, przed wykonaniem analizy trendu wartości są wygładzane średnią ruchomą uwzględniającą 100 wcześniejszych wartości (100 cykli pracy suwnicy),
- graniczny poziom wartości zmiennej diagnostycznej (ozn. cvl) – poziom ten jest poziomem odniesienia pozwalającym na estymację liczby cykli pracy suwnicy pozostałych do przekroczenia tego poziomu; poziom ten nie musi być utożsamiany z awarią suwnicy ale jest związany co najmniej z sytuacją która stanowiącą zagrożenie dla ciągłości działania suwnicy.

Ekstrapolacja trendu pozwala na oszacowanie liczby cykli pozostałych do przekroczenia poziomu cvl . Zamiast liczbą cykli, można posługiwać się liczbą dni za jaką zostanie przekroczony poziom cvl , w tym celu przyjmuje się, że ustalana jest (arbitralnie) lub obliczana (na podstawie danych historycznych) średnia dzienna liczba cykli pracy (ozn. awc), która jest ekwiwalentem jednego dnia pracy suwnicy. Wartość ta może być modyfikowana w miarę gromadzenia informacji o pracy konkretnej suwnicy.

Niech S oznacza szereg czasowy kolejnych wartości zmiennej diagnostycznej w dziedzinie cykli pracy. Niech S_{sm} oznacza szereg czasowy wartości S wygładzony za pomocą średniej ruchomej z ostatnich sm wartości S . Analiza trendu liniowego w szeregu S_{sm} , którym do estymacji parametrów regresji wykorzystano h ostatnich wartości szeregu S_{sm} prowadzi do uzyskania modelu postaci:

$$\hat{S}_{sm,h}(i) = Ai + B \tag{9}$$

gdzie: i to numer cyklu pracy suwnicy, A i B to parametry modelu estymowane na podstawie h ostatnich wartości szeregu S_{sm} .

Oznaczając przez $\hat{S}_{sm,h}(i)$ aktualną wartość modelu (9), liczbę cykli pracy pozostałych do przekroczenia wartości progowej cvl obliczamy według wzoru:

$$\Delta i = \begin{cases} \frac{cvl - \hat{S}_{sm,h}(i) - B}{A} & A \neq 0 \\ \infty & A = 0 \end{cases} \quad (10)$$

Przyjmując, że średnia dzienna liczba cykli pracy suwnicy wynosi awc , możliwe jest określenie liczby dni pracy suwnicy, po której wartość rozważanej zmiennej diagnostycznej przekroczy poziom cvl . Chcielibyśmy w sposób bardziej zrozumiały dla użytkownika móc interpretować wartości wskaźnika (10). Zdefiniujemy w tym celu dwa dodatkowe wskaźniki Δi_+ oraz Δi_- . Analiza wartości tych wskaźników będzie dodatkową informacją diagnostyczną dla użytkownika. Wartości Δi_+ interpretowane są w sposób następujący:

- $\Delta i_+ = 0$ wtedy i tylko wtedy, gdy $\Delta i < 0$ lub $\Delta i = \infty$ – odpowiada to sytuacji, gdy mamy do czynienia z trendem malejącym lub bocznym,
- $\Delta i_+ = 1$ wtedy i tylko wtedy, gdy $\Delta i \in [0,1]$ – odpowiada to sytuacji, w której poziom cvl został przekroczony lub zostanie przekroczony za mniej niż awc cykli pracy suwnicy,
- $\Delta i_+ = (\frac{1}{awc})\Delta i$ w pozostałych przypadkach.

Wskaźnik Δi_+ nie odzwierciedla spadku wartości zmiennej diagnostycznej. Dokładniej, w przypadku trendu bocznego lub malejącego wartość $\Delta i_+ = 0$, w szczególności będzie tak w sytuacji, gdy wartości badanej zmiennej ustabilizują się na jakimś poziomie (również na poziomie $>cvl$).

Wskaźnik Δi_- pozwala wskazać przedziały czasu, w których mamy do czynienia z malejącym trendem monitorowanej wartości. Wartość progową minimalną dla tego wskaźnika ustalono w niniejszym badaniu na 0. Inne rozwiązanie to ustalenie tej wartości jako średniego poziomu drgań w okresie, w którym mamy pewność, że suwnica była sprawna (ozn. nvl) Interpretacja Δi_- jest następująca:

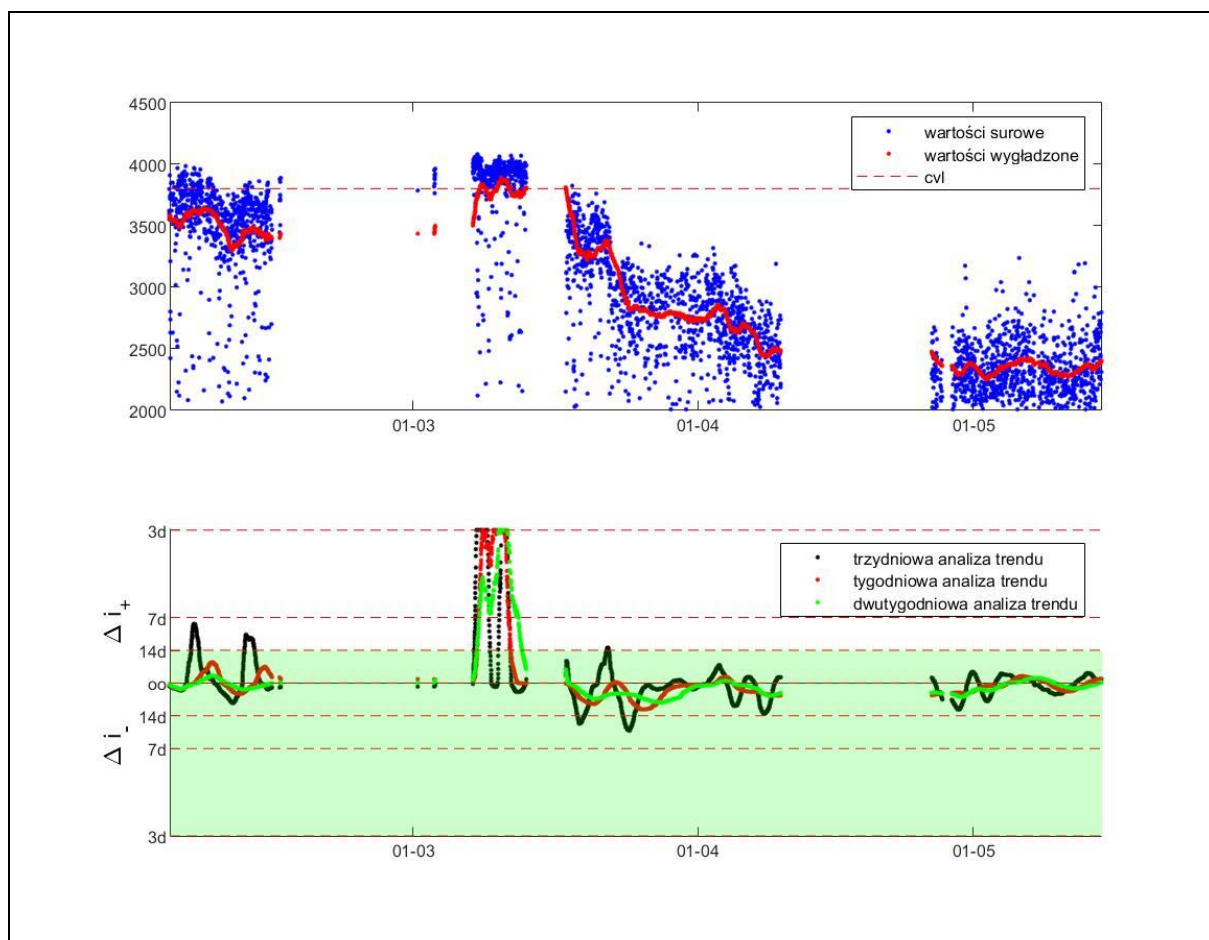
- $\Delta i_- = 0$ wtedy i tylko wtedy, gdy $\Delta i < 0$ lub $\Delta i = \infty$ – odpowiada to sytuacji, gdy mamy do czynienia z trendem rosnącym lub bocznym,
- $\Delta i_- = 1$ wtedy i tylko wtedy, gdy $\Delta i \in [0,1]$ – odpowiada to sytuacji, w której poziom 0 został osiągnięty lub zostanie osiągnięty za mniej niż awc cykli pracy suwnicy,
- $\Delta i_- = (\frac{1}{awc})\Delta i$ w pozostałych przypadkach.

Wartości Δi można wizualizować na wykresie, na którym oś X odzwierciedla kolejne cykle pracy suwnicy, a oś Y pokazuje umowną liczbę „dni” do przekroczenia poziomu cvl (górną część wykresu – powyżej umownego znacznika ∞) lub do osiągnięcia poziomu nvl

(np. $nvl=0$; dolna część wykresu). Przez ∞ rozumie się etykietę oznaczającą że suwnica jest sprawna i nie występują żadne symptomy świadczące o tym, aby w długim (nieskończonym) okresie miał zostać przekroczony poziom cvl . Na Rys. 44 na osi Y zaznaczono umowną liczbę dni do przekroczenia poziomu cvl (część wykresu powyżej ∞). Wartości znajdujące się poniżej ∞ wskazują na liczbę dni jaka przy obecnym trendzie jest wymagana aby osiągnąć poziom nvl (tutaj $nvl=0$). W niniejszym badaniu przyjęto, że prognoza iż poziom drgań przekroczy limit cvl za więcej niż 14 dni jest informacją diagnostyczną nie wymagającą od dyspozytora podejmowania działań zaradczych, odpowiednią część wykresu oznaczono kolorem zielonym.

Wartości na wykresie powyżej etykiety ∞ oznaczają, że mamy do czynienia z trendem rosnącym, jeśli wartości te rosną oznacza to, że występuje silna dynamika wzrostu trendu drgań, jeśli wartości maleją oznacza to, że trend rosnący się wygasza (dynamika wzrostów jest coraz mniejsza; w szczególności przechodzimy do trendu bocznego). Wartości na wykresie poniżej etykiety ∞ oznaczają że mamy do czynienia z trendem malejącym. Spadki wartości w tym obszarze oznaczają, że zwiększa się dynamika trendu malejącego, wzrosty oznaczają, że dynamika spadku trendu jest coraz mniejsza (w szczególności przechodzimy do trendu bocznego). Zatem, wartości Δi powyżej etykiety ∞ mają związek z wartościami Δi_+ , a poniżej z Δi_- .

Analizując wykres widoczny na Rys. 44, w pierwszej połowie lutego obserwujemy dwa momenty znaczącego pogarszania się stanu diagnostycznego urządzenia (analizę przeprowadzono dla $hl=7$ dni, $awc=40$, $cvl=4000$). Analizując wykres, pierwszy z nich osiąga maksimum lokalne wskazujące na niecałe 7 dni pozostałych do przekroczenia dopuszczalnego poziomu wartości zmiennej diagnostycznej, a w przypadku drugim jest to około 10 dni. Widać to szczególnie na wykresach trendów budowanych na podstawie analizy ostatnich 3 (kolor czarny) i 7 (kolor czerwony) dni pracy suwnicy. Z kolei wykres pomiędzy tymi sytuacjami nie pokazuje znaczącej poprawy stanu diagnostycznego pomiędzy tymi okresami, chociaż analiza wygładzonego przebiegu zmiennej diagnostycznej (Rys. 44, wykres górny) uwidacznia drobny chwilowy spadek wartości zmiennej diagnostycznej.



Rys. 44 Wykres monitorowania wartości VibrMax2000_Q3 – suwnica 1. Wykres górny: wartości oryginalne (niebieski), wartości wygładzone (czerwony) oraz poziom *cvl*. Wykres dolny: wartości wskaźnika Δi generowane na podstawie analizy trendu wykonanej w oparciu o 3, 7 i 14 poprzednich dni pracy suwnicy.

Na wykresie dolnym Rys. 44 – ze względu na jego przejrzystości – oś Y ograniczono do wartości odpowiadającej umownym trzem dniom do przekroczenia *cvl*. Ponadto, jako wartość *nvl* przyjęto 0 (suwnica nie drga w ogóle).

W rozważanym okresie, w dzienniku napraw nie odnotowano żadnych informacji na temat podjętych działań naprawczych – zapisano jednak, że operator odnotowuje podwyższony poziom drgań. Przerwa w danych pomiarowych wynika z przerwy pracy suwnicy, następnie około 10 marca suwnica ponownie pracowała, ale jak widać w zasadzie do początku jej użytkowania wskaźnik Δi osiągnął bardzo szybko wartość graniczną (3 dni), co potwierdza podążający za zwiększającymi się wartościami wskaźnika, zwiększający się poziom drgań. Następnie suwnica przeszła kilkudniowy remont i ponownie została oddana do użytkowania. Fakt wykonania remontu znajduje odzwierciedlenia w spadku wartości Δi . Przejścia z obszaru wykresu związanego z Δi_+ do obszaru związanego z Δi_- , a następnie stabilizacji trendów 7 i 14-dniowych wartości wskaźnika.

Interpretację zmian wartości wskaźników Δi_+ oraz Δi_- oraz wartości zmiennej diagnostycznej na podstawie, której wskaźniki te są obliczane można umieścić w raporcie, którego przykład prezentuje Tabela 7.

Wartości umieszczane w raporcie wyznaczane są według następującej zasady:

- OK! - jeśli wskaźnik Δi_+ jest równy 0 oraz wartości zmiennej diagnostycznej są poniżej poziomu cvl 0,7; dodatkowo jeśli trend jest rosnący, to podawana jest liczba „dni” za jakie zostanie przekroczony poziom cvl o ile liczba ta jest mniejsza od 35;
- W - jeśli Δi_+ jest równy 0 oraz wartości zmiennej diagnostycznej są w przedziale (cvl 0,7, cvl 0,8]; dodatkowo jeśli trend jest rosnący, to podawana jest liczba „dni” za jakie zostanie przekroczony poziom cvl o ile liczba ta jest mniejsza od 28; jeśli liczba ta jest większa od 28, podawana jest jedynie informacja o kierunku trendu,
- A - jeśli wartości zmiennej diagnostycznej są powyżej poziomu cvl 0,8; dodatkowo jeśli trend jest rosnący, to podawana jest liczba „dni” za jakie zostanie przekroczony poziom cvl o ile liczba ta jest mniejsza od 21; jeśli liczba ta jest większa od 21, podawana jest jedynie informacja o kierunku trendu.

Zakresy wartości definiujące wpisy „OK!”, „W” oraz „A” pojawiające się na raporcie dobrano do specyfiki rozważanego obiektu technologicznego i jego utrzymania przez odpowiednie służby. W szczególności, ustalenie tych wartości jest przedmiotem konfiguracji systemu.

Tabela 7

Raport diagnostyczny trendów wartości zmiennej diagnostycznej opisującej poziom drgań w poszczególnych cyklach pracy suwnicy (suwnica 1).

Suwnica SW1 trendy zmian wartości Di_+				
Zmienna diagnostyczna Vibr_Max2000_Q3	Analiza trendu na podstawie ostatnich:			
Data	3 dni	7 dni	14 dni	Zgodnych
2017-02-04	A (8)	A(↑)	A (↑)	3
2017-02-05	A (10)	A(↑)	A(↑)	3
...	
2017-02-08	A(↓)	A(↑)	A(↑)	2
...
2017-03-24	W(↓)	W(↓)	W(↓)	3
...	
2017-05-09	OK!	OK!	OK!	3

Ostania kolumna raportu zawiera liczbę jednakowych decyzji dla analiz trendu przeprowadzonych na podstawie ostatnich 3, 7 i 14 „dni”. Kolumna ta pozwala na śledzenie stabilności zmian wartości zmiennej diagnostycznej.

W miarę potrzeb użytkownika raport może dotyczyć jednego lub większej liczby czujników, a także większej liczby zmiennych diagnostycznych.

Raport nie podaje w sposób jednoznaczny sugestii dotyczących czasu, w jakim wystąpi awaria lub konieczność remontu suwnicy. Pozwala natomiast w uporządkowany sposób obserwować trendy zmian cechy (lub cech) zidentyfikowanych jako zmienne diagnostyczne.

5.2.3. Faza wdrożeniowa

Praktyczne wykorzystanie przedstawionej powyżej metody wymaga:

- rozmieszczenia czujników na monitorowanej suwnicy,
- identyfikacji cykli pracy suwnicy zgodnie z metodą przedstawioną na początku sekcji 5.2.2,
- obliczenia dla każdego z czujników wartości cechy $VibrMax2000_Q3$ i ew. kolejnych cech z rankingu zamieszczonego w sekcji,
- ustaleniu wartości cvl (ewentualnie nwl) oraz awc ,
- cyklicznym – np. raz na dobę – obliczaniu wartości wskaźników Δi_+ , Δi_- ; podczas obliczania wartości tych wskaźników wartości parametrów sm i hl ustawione są odpowiednio na domyślne wartości 100 i $7awc$
- generowaniu wykresów wartości Δi_+ , Δi_- oraz raportu przedstawionego w Tabeli 7.

Z praktycznego punktu widzenia należy również doprecyzować warunki postępowania w przypadku: wykonania prac remontowych (czy historia wartości zmiennej diagnostycznej ma zostać wyzerowana?).


Przedstawiona wyżej procedura może być wprost stosowana do diagnostyki suwnic zbliżonych budową do obiektów wzorcowych, na których były prowadzone badania. W przypadku konieczności jej stosowania na obiektach, których konstrukcja odbiega istotnie od budowy obiektu wzorcowego może być konieczne powtórzenie opisanej w sekcji 5.2.2 fazy strojenia parametrów modelu włącznie z etapem selekcji cech.

5.2.4. Badania weryfikacyjne

Badania weryfikacyjne przeprowadzono na drugiej identycznej suwnicy, pracującej w tym samym zakładzie hutniczym. Z dziennika remontów wynikało, że suwnica ta przechodziła remont w okresie 16-18.08.2017. Przy czym remont ten został wykonany nieprawidłowo i suwnica w krótkim czasie musiała przejść kolejny remont polegający na wymianie układu zębniaka (remont ten wykonano w październiku). W okresie od początku września do terminu drugiego remontu suwnica pracowała zdecydowanie rzadziej niż w sytuacji jej pełnej sprawności.

Na Rys. 45 przedstawiono oryginalne i wygładzone wartości zmiennej diagnostycznej $VibrMax2000_Q3$ oraz wartości wskaźników Δi_+ i Δi_- . W Tabeli 8 przedstawiono raport dla kilku początkowych dni sierpnia. Warto dodać, że dwa tygodnie przed remontem suwnicy

pracowała ona jedynie na biegu rozruchowym – co osłabiło nieco dynamikę wzrostu poziomu drgań. Jest to widoczne na wykresie wartości zmiennej diagnostycznej VibrMax2000_Q3.



Rys. 45 Wykres monitorowania wartości VibrMax2000_Q3 – suwnica 2. Wykres górny: wartości oryginalne (niebieski), wartości wygładzone (czerwony) oraz poziom cvl . Wykres dolny: wartości wskaźnika Δi generowane na podstawie analizy trendu wykonanej w oparciu o 3, 7 i 14 poprzednich dni pracy suwnicy.

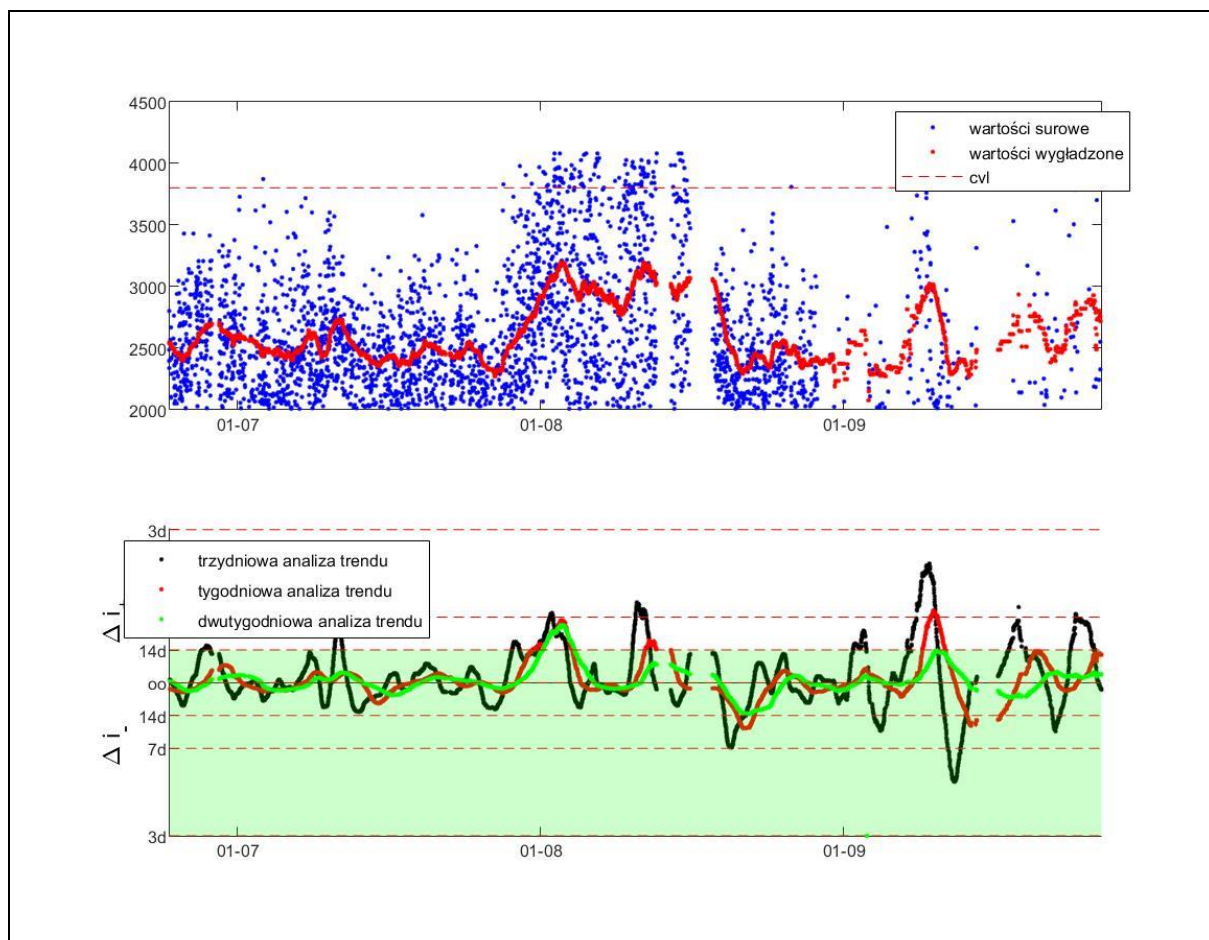
Tabela 8

Raport diagnostyczny trendów wartości zmiennej diagnostycznej opisującej poziom drgań w poszczególnych cyklach pracy suwnicy (suwnica 2).

Suwnica SW2 trendy zmian wartości Di_+

Zmienna diagnostyczna Vibr_Max2000_Q3	Analiza trendu na podstawie ostatnich:			
	3 dni	7 dni	14 dni	Zgodnych
Data				
2017-07-25	OK!	OK!	OK!	3
...
2017-08-07	W(↓)	W(↑)	W(↑)	2
...	
2017-08-11	A(5)	A(20)	A(↑)	3

Na Rys. 46 przedstawiono również wykres zmiennej diagnostycznej VibrMax2000_P95, jest to ostatnia ze zmiennych istotnych zidentyfikowanych w podrozdziale 5.2.2.



Rys. 46 Wykres monitorowania wartości VibrMax2000_P95 – suwnica 2. Wykres górny: wartości oryginalne (niebieski), wartości wygładzone (czerwony) oraz poziom *cvl*. Wykres dolny: wartości wskaźnika Δi generowane na podstawie analizy trendów wykonanej w oparciu o 3, 7, 14 poprzednich dni pracy suwnicy.

Zmienna ta bardzo dobrze obrazuje proces pogarszania się stanu suwnicy, gdyż wyraźne trendy wzrostowe obserwowane są w początkowym okresie sierpnia – wtedy, gdy suwnica pracowała jeszcze w normalnych warunkach (na biegu roboczym zamiast rozruchowego). Następnie – pomimo obniżenia biegu pracy – prawidłowo prognozowany jest moment, w którym konieczne było wykonanie remontu. Po nieprawidłowo wykonanym remoncie również sygnalizowane są nieprawidłowości w pracy urządzenia.

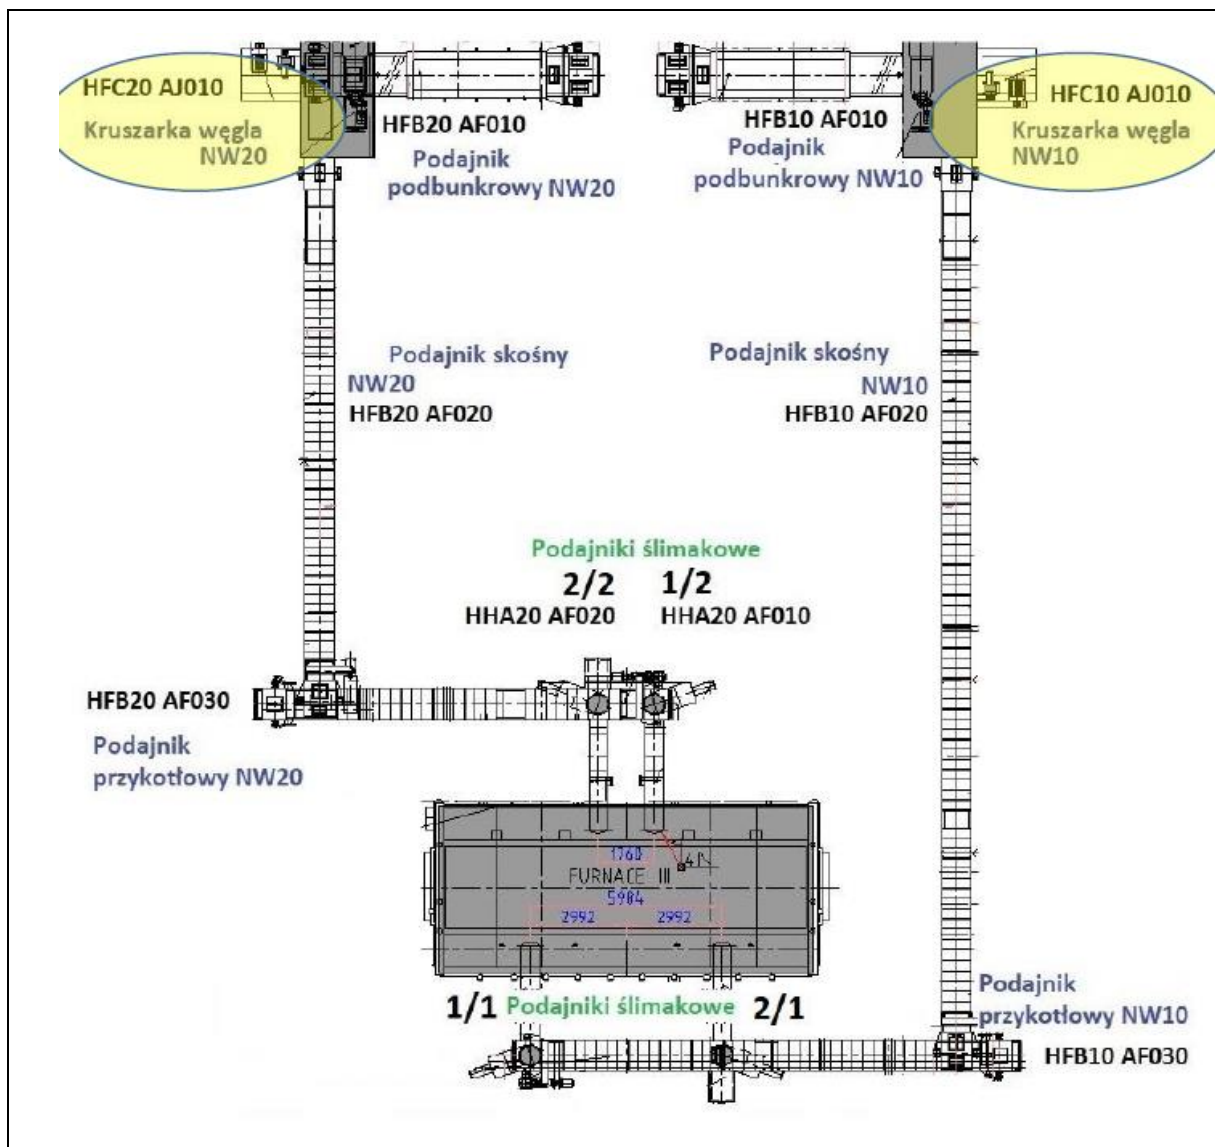
Przykład ten obrazuje jak istotne jest generowanie wykresów i raportów diagnostycznych dla zmiennych diagnostycznych zidentyfikowanych jako istotne (rozdział 5.2.2), dla wszystkich monitorowanych czujników. Z praktycznego punktu widzenia analiza i interpretacja tak dużej liczby wykresów i raportów jest – w wykonaniu dyspozytora – niemożliwa, dlatego rekomendacje dotyczące tego, którą zmienną diagnostyczną i jakie poziomy drgań *cvl* i *nvl* mają być podstawą do generowania raportu powinny być

wpracowywane przez służby utrzymania wspólnie z analitykiem danych. Praca taka jest coraz częściej realizowana jako usługa utrzymania systemu wspomaganie decyzji przez działy tzw. *data science* firm dostarczających tego typu systemy.

6. Model diagnostyczny kruszarki węgla


6.1. Opis przedmiotu monitorowania

Przedmiotem monitorowania były kruszarki węgla stanowiące element instalacji podawania paliwa do kotła fluidalnego elektrowni węglowej zlokalizowanej na południu Polski. Schemat fragmentu instalacji przedstawiono na Rys. 47. Paliwo trafia do kruszarek z zamontowanych bezpośrednio nad nimi zbiorników z wykorzystaniem podajników podbunkrowych. Rolą kruszarek jest rozdrobnienie paliwa celem dostosowania jego granulacji do odpowiedniej dla kotła fluidalnego. Rozdrobnione paliwo odbierane jest poprzez zestaw podajników taśmowych i wprowadzane do paleniska kotła z wykorzystaniem podajników ślimakowych.



Rys. 47 Fragment schematu instalacji nawęglania kotła fluidalnego.

Do kruszenia węgla zastosowano kruszarki bębnowo młotkowe (ang. Mud Hog Crushers) produkcji BJD Crushers Ltd. Fotografie kruszarki wraz z rysunkiem objaśniającym zasadę działania przedstawiono na Rys. 48.




Rys. 48 Kruszarka typu Mud Hog produkcji BJD Crushers Ltd.

Rozdrabniany materiał trafia do kruszarki przez jej górny otwór i jest przenoszony na ścieżkę młotów z wykorzystaniem tzw. płyty łamacza (ang. Breaker plate) – napędzanej, zbudowanej ze stalowych płytek taśmy. Młoty zamontowane są na obracającym się bębnie. Rozdrobniony materiał opuszcza kruszarkę przez otwór dolny trafiając na jeden z podajników.

Służby utrzymania ruchu elektrowni wskazują kruszarki jako jeden z istotnych elementów zapewniających ciągłość wytwarzania energii. Uszkodzenie jednej kruszarki powoduje spadek wydajności procesu, uszkodzenie obu – jego zatrzymanie. Obie sytuacje wiążą się ze stratami ekonomicznymi przedsiębiorstwa. Jako element ulegający najczęstszym uszkodzeniom wskazywane są łożyska bębna obrotowego. Do uszkodzeń tych łożysk dochodzi średnio dwa razy do roku. Pierwszym symptomem uszkodzenia jest wzrost amplitudy drgań, w następnej kolejności następuje wzrost temperatury. W końcowej fazie eksploatacji łożysko jest dodatkowo chłodzone strumieniem sprężonego powietrza.

W tym konkretnym typie kruszarki zastosowano łożyska typu SNH 520-617 produkcji SKF. Rys. 49 prezentuje przekrój łożyska wraz ze wskazaniem zalecanych punktów montażu czujników diagnostycznych.



Rys. 49 Łożysko typu SNH 520-617 produkcji SKF (źródło - karta katalogowa producenta).

6.1.1. Układ pomiarowy

Zgodnie z sugestią pracowników linii utrzymania ruchu monitorowaniem objęto łożyska bębnowe obu kruszarek identyfikowanych oznaczeniami NW10 oraz NW20. Każda z kruszarek ma dwa takie łożyska: lewe, montowane po stronie pasa napędowego oraz prawe, montowane po stronie koła zamachowego. Tabela 9 prezentuje lokalizację czujników w trakcie eksperymentu.

Tabela 9

Model diagnostyczny kruszarki węgla – rozmieszczenie czujników

Czujnik	Kruszarka	Łożysko
C122	NW10	Strona napędu
C123		Strona koła zamachowego
C124	NW20	Strona napędu
C125		Strona koła zamachowego

W układzie pomiarowym zastosowano bezprzewodowe czujniki drgań i temperatury typu WS-VT1. Wyniki pomiarów wykonywanych przez poszczególne czujniki były transmitowane do transceiverów radiowych typu ITR-2. Transceivery komunikowały się

z serwerem systemu poprzez sieć Ethernet. Dane telemetryczne były rejestrowane w telemetrycznej bazie danych serwera analitycznego. Układ pomiarowy był zbliżony do prezentowanego na Rys. 40 – różnił się od niego wyłącznie obiektem, na którym montowane były czujniki.

6.1.2. Cele badań

Celem badań było opracowanie procedury diagnostycznej wspierającej działania służb utrzymania ruchu w zakresie wspierania działań zapobiegającym nieplanowanym przestojom tych urządzeń. System ten musi bazować na wielkościach pomiarowych rejestrowanych w układzie tj. drganiach i temperaturze. Podczas monitorowania obiektu, a także w danych historycznych jakie udało się zdobyć zarejestrowano małą liczbę rzeczywistych uszkodzeń (potwierdzonych w książce serwisowej). Z tego względu założono, że procedura diagnostyczna nie powinna bazować na algorytmach nadzorowanych wymagających odpowiedniej liczby przykładów pozytywnych (awarii). W ramach prowadzonych prac badawczych zaproponowano procedurę bazującą na analizie wartości odstających. W badaniach duży nacisk położono również na ograniczaniu liczby fałszywych alarmów generowanych przez procedurę diagnostyczną. Zbyt częste generowanie niepotwierdzonych przez operatora alarmów prowadzi do utraty zaufania operatorów, wynikiem czego rekomendacje systemu są przez nich ignorowane. Podobny efekt wywołują rekomendacje niepoparte jasnymi dla operatora przesłankami, dlatego procedura diagnostyczna wyposażona została w funkcje objaśniania decyzji przez nią podejmowanych.

6.2. Metoda

6.2.1. Wartości odstające

Metody identyfikacji wartości odstających zwanych anomaliami stosowane są w wielu zadaniach związanych z analizą danych. Zwykle celem identyfikacji wartości odstających jest eliminacja ze zbioru danych, wartości nietypowych, uznawanych za wynik błędnego działania procesu pozyskiwania danych. W innych przypadkach analiza anomalii może być stosowana do identyfikacji niepożądanych stanów analizowanego procesu. W literaturze przedmiotu wartość odstająca / anomalia definiowana jest w różny sposób. Definicja zawarta w [143] stwierdza, że obserwacja odstająca to ta, która wydaje się znacząco różnić od pozostałych obserwacji w danej próbie. Zgodnie z definicją zaproponowaną w [144] wartość odstająca charakteryzuje się tym, że mechanizm wygenerowania tej wartości różni się od mechanizmu generowania pozostałych wartości rozważanej zmiennej. Z kolei w [145] jako obserwację odstającą uznaje się wartość niespójną z pozostałymi wartościami.

W pracy [146] zaproponowano podział anomalii na różne typy:

- ze względu na zasięg, zależnie od tego czy pojedyncza, czy też grupa obserwacji uznawane są za odstającą,
- ze względu na zakres, który może obejmować lokalną różnicę względem sąsiadów, bądź globalną różnicę względem całości danych,
- ze względu na rodzaj wprowadzanych danych, gdzie dla wektorów różnice są określane na bazie podobieństwa ich położenia w przestrzeni, a dla grafów różnicuje się położenie obiektów na wykresie.

W szczególności w analizie szeregów czasowych należy również wskazać na znaczenie wpływu momentu rejestracji obserwacji na fakt uznania jej za anomalię. Do tego celu można przywołać intuicyjny przykład średniej dobowej temperatury w ciągu dnia – wartość 20 stopni Celsjusza nie powinna zostać uznana za anomalię w czerwcu, jednak z pewnością powinna zostać uznana jako taką w styczniu bądź w lutym (zakładając, że odnosimy się do warunków meteorologicznych panujących w Polsce). Warto w tym momencie również podkreślić, że określenie „wartość (obserwacja) odstająca” nie wskazuje w żaden sposób wymiarowości danych, które podlegają analizie.

Opracowano wiele metod wykrywania wartości odstających. Niektóre z nich reprezentują podejście statystyczne wychodzące od znanego kryterium trójek, testu Grubba [147], czy też GESD (ang. Generalized Extreme Studentized Deviate Test) [148]. Inne uwzględniają lokalne rozproszenie danych, takie jak LOF (Local Outlier Factor) [149] oraz RKOF (Robust Kernel-Based Local Outlier Factor) [150]. Ponadto do takiego zagadnienia stosuje się techniki grupowania, takie jak DBSCAN (Density-Based Spatial Clustering of Applications with Noise) [151] – główną ideą jest interpretacja szumu (próbek nie przypisanych do żadnego klastra) jako wartości odstających. Inną techniką wykrywania anomalii wykorzystującą partycjonowanie danych (choć zbudowaną przy zupełnie innych założeniach niż w przypadku DBSCAN) jest las izolacyjny [152]. Ta metoda przedstawia zidentyfikowane partycjonowanie jako drzewo binarne, gdzie im dłuższa ścieżka do obiektu, tym bardziej typowy jest obiekt. Obserwacje leżące blisko korzenia drzewa są uważane za anomalie. Algorytmy klasyfikacji to kolejna grupa metod wykorzystywanych do wykrywania anomalii. Maszyna wektorów nośnych (SVM) [153] została pomyślnie zmodyfikowana pod kątem wykrywania anomalii — jednoklasowy algorytm SVM [154] identyfikuje optymalny margines między typowymi danymi a „szumem”. Poza tym metody regresji (CART w [155]) mogą stać się przydatne do wykrywania kontekstowych wartości odstających. W ostatnich latach do identyfikacji wartości odstających zastosowano głębokie sieci neuronowe [35, 156] m.in. o architekturze autoenkodera, takie jak sieci LSTM [157, 158]; metody wykorzystują fakt, że przykłady odstające charakteryzują się dużym błędem rekonstrukcji w wyniku zastosowania autoenkodera.

Podejście oparte na wykrywaniu anomalii znalazło również zastosowanie w zadaniach PdM. W pracy [159] do analizy danych procesu spawania wykorzystano kilka metod wykrywania anomalii [160–162]. Z kolei w pracy [163] przedstawiono zastosowanie sieci neuronowych do wykrywania anomalii w systemach fotowoltaicznych. Sieci neuronowe wykorzystano również do wykrywania anomalii w zużyciu energii przez układy wytwarzania sprężonego powietrza [164]. Ponadto w pracy [165] można znaleźć wspólne zastosowanie modeli XAI (ang. eXplainable Artificial Intelligence) i LSTM do wykrywania anomalii w danych opisujących proces walcowania na gorąco.

6.2.2. Wykorzystanie algorytmu identyfikacji wartości odstających do wykrywania zdarzeń niepożądanych z punktu widzenia diagnostyki maszyn i urządzeń

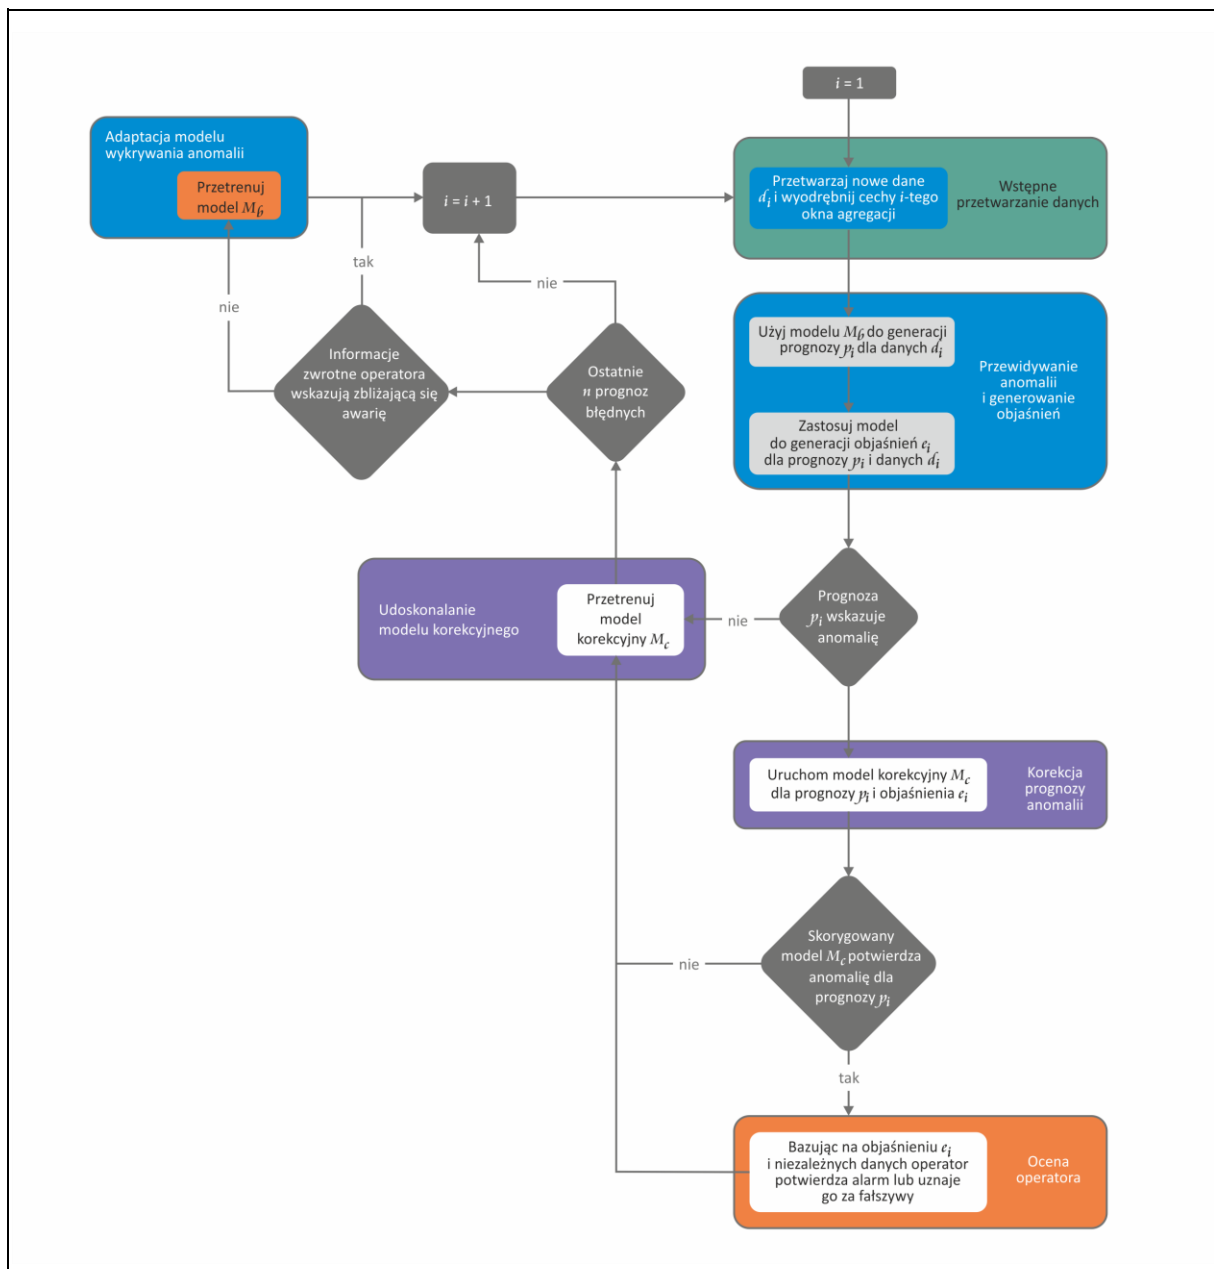
Metoda ma na celu identyfikację stanów maszyny, które mogą być uznawane są przez służby utrzymania ruchu za alarmujące lub wskazujące na zbliżającą się awarię.

Metoda składa się z dwóch faz. Pierwsza faza to inicjalizacja, podczas tej fazy zbierane są dane na podstawie, których utworzony zostanie pierwszy model identyfikujący wartości odstające. Gromadzone przykłady są przetwarzane tak, aby mogły być procesowane w fazie drugiej – w szczególności następuje ich agregacja i ekstrakcja cech charakteryzujących monitorowany(e) szereg(gi) czasowe.

Druga główna faza wykonywana jest cyklicznie w pętli. Wartości napływające z systemu pomiarowego są gromadzone w równych odstępach czasu, definiując ramkę do przetwarzania, agregacji danych i ekstrakcji cech – operacje te są identyczne jak w pierwszej fazie. Tak przygotowane dane trafiają do modelu identyfikacji wartości odstających utworzonego w fazie inicjalizacji, model ten generuje prognozę o tym czy dany kolejny pomiar jest czy nie jest wartością odstającą. Po prognozie następuje wyjaśnienie decyzji modelu. Do objaśnień stosuje się metody XAI [166–168].

Nierozzerwalnym elementem działania metody jest interakcja z użytkownikiem (operatorem). Interakcja ta odbywa się cyklicznie. Częstość interakcji jest parametrem metody np. 1h lub 1 zmiana. Jeśli w tym przedziale czasu model zidentyfikuje wartości odstające, które przez operatora uznawane są (przykłady takie są oznaczane przez operatora i trafiają do systemu) za fałszywe alarmy, to uruchamiany jest tzw. model korygujący. Celem modelu korekcyjnego jest ograniczenie liczby fałszywych alarmów zgłaszanych do operatora. Model korekcyjny jest systemem klasyfikującym bazującym na metodzie gradient boosting (wykorzystano algorytm Random Forest [129]), którego zadaniem jest nauczenie się sytuacji, w których wartość odstająca zgłaszana przez model identyfikujący te wartości jest fałszywym alarmem. Jeśli nowy przykład uznawany jest przez model identyfikacji wartości odstających za wartość odstającą, a model korekcyjny zaklasyfikuje go jako fałszywy alarm to komunikat o wykryciu anomalii nie jest unieważniany, w przeciwnym przypadku zgłaszana jest anomalia. Model korekcyjny jest trenowany cyklicznie po każdej interakcji z operatorem.

Pozwala to na zgromadzenie coraz większej liczby fałszywych alarmów (przykładów pozytywnych dla algorytmu Random Forest). W konsekwencji, metoda zwraca mniej alarmów które prezentowane są operatorowi. Jeśli - pomimo działania modelu korekcyjnego - określona liczba (kolejny parametr metody) ostatnich obserwacji zostanie nieprawidłowo oznaczona jako fałszywie dodatnie, aktualizowany jest także model identyfikacji wartości odstających. Opisane etapy przedstawiono na Rys. 50. Dla uproszczenia na diagramie pominięto inicjalizację modelu korekcyjnego, która jest realizowana tylko wtedy, gdy zgromadzona zostanie wystarczająca liczba fałszywych alarmów, mogących stanowić zbiór uczący.



Rys. 50 Schemat blokowy przebiegu właściwego etapu metody diagnostycznej.

Proponowana metoda opiera się na następujących założeniach:

- Uruchomienie metody poprzedza okres zbierania danych, które mogą posłużyć do zainicjowania metody, czyli stworzenia pierwszego modelu identyfikacji wartości odstających. Okres ten nie musi zawierać pozytywnych przykładów, czyli rzeczywistych awarii lub naprawy wynikających ze złej kondycji urządzenia. Zakłada się, że w analizowanym zbiorze danych określony odsetek - w eksperymentach jest to maksymalnie 1% - wartości może być uznanych za odstające. W ten sposób możliwe jest ustalenie parametrów algorytmu identyfikującego wartości odstające np. wartości progową jaką zwraca algorytm dla każdego przykładu powyżej której przykład uznawany jest za anomalię.
- Przyjmuje się, że okres poprzedzający awarię charakteryzuje się znacznymi zmianami w pracy urządzenia w szczególności zwiększonym poziomem drgań. Celem metody jest identyfikacja takich zmian. Oznacza to, że w okresie przed awarią nasycenie liczby identyfikowanych wartości odstających powinno być duże i zwiększać się wraz ze zbliżaniem się do momentu awarii.
- Oczekuje się zatem, że w sytuacji idealnej w czasie poprzedzającym awarię model oznaczy wszystkie obserwacje jako wartości odstające. Poza tym okresem zakłada się, że udział wartości odstających jest bardzo mały (np. wynosi maksymalnie 1%).
- Za okres następujący bezpośrednio po renowacji urządzenia przyjęto czas potrzebny na dotarcie się elementów urządzenia. W tym czasie żaden model nie jest uruchamiany ani ponownie aktualizowany. Długość tego okresu jest kolejnym parametrem metody.
- Zakłada się, że operator jest w stanie określić przybliżony stan urządzenia na podstawie swojego doświadczenia, innych często niemierzalnych sygnałów lub analizy na miejscu. Dzięki temu operatorzy mogą w czasie interakcji z metodą diagnostyczną odrzucić alarmy część lub wszystkie zgłoszone przez nią alarmy.

Dane surowe - podlegające analizie wymagają ich wstępnego przetworzenia. Mają one postać wielowymiarowego szeregu czasowego i zawierają informacje na temat zmierzonego poziomu drgań (wartość maksymalna i średniokwadratowa RMS przyspieszeń drgań w oknie pomiarowym) oraz temperatury.

Proces przygotowania danych odbywa się w następujących krokach:

- 1) Określenie zakresu agregacji – dane są agregowane na podstawie przesuwnej okna czasowego. Parametrem metody jest rozmiar okna. Początek i koniec zakresu agregacji muszą być ustalone w stosunku do cyklu zmianowego, tak by agregować dane z tych samych okresów w ciągu dnia. Dlatego rozmiar okna jest definiowany w godzinach.
- 2) Usunięcie duplikatów – istnienie duplikatów wynika z zastosowania bezprzewodowych czujników, które mogą się znajdować w zasięgu odbioru więcej niż jednego transceivera

odbiorczego. Każdy z nich działa niezależnie od siebie i w takim przypadku duplikują w bazie danych systemu rekordy odzwierciedlające ten sam pomiar.

- 3) Normalizacja częstotliwości próbkowania – czujniki są wybudzane ze stanu oszczędzania energii w losowych momentach czasu. Stąd, mimo że rejestrują dane zwykle w tych samych odstępach czasu, to nie w tym samym momencie. Dlatego istnieje potrzeba ujednoczenia znaczników czasu dla wszystkich czujników celem zebrania wektora cech. Niezależnie od tego odstępy między pomiarami w czujnikach mogą się różnić ze względu na brak danych lub specyfikę działania czujnika.
- 4) Brakujące dane – metoda musi uwzględniać fakt braku wybranych pomiarów w zbiorze danych. Brak danych może wynikać z czasowego lub trwałego pogorszenia warunków propagacji radiowej, problemów z baterią zasilającą, itp. Założono, że jeśli przerwa w transmisji powodująca braki danych jest krótsza od pewnej (parametr metody) wartości progowej to braki danych uzupełniane są wartościami uzyskanymi podczas ostatniej zakończonej sukcesem transmisji. W innym przypadku do bazy zapisywane są przykłady zawierające brakujące dane.
- 5) Usunięcie ze zbioru danych okresów nieaktywności urządzenia – przykłady zawierające pomiary z okresu przestojów mogą wpłynąć na wyniki działania modelu diagnostycznego, stąd wymagają usunięcia ze zbioru. Przestoje identyfikuje się na podstawie przekroczenia wartości progowej poziomu drgań dla danego punktu pomiarowego. Wartość tego progu jest dobierana empirycznie dla każdego z analizowanych przypadków.
- 6) Ekstrakcja cech – dla każdego z wyodrębnionych okien agregacji wyznaczany jest wektor cech wywiedzionych, których zadaniem jest opisanie charakterystyki / dynamiki szeregu czasowego zarejestrowanego w oknie agregacji. Do ekstrakcji cech wykorzystano bibliotekę tsfresh [169] i standardowo generowany przez nią zestaw cech wywiedzionych.

Jak już wspomniano, proponowane rozwiązanie przewiduje działanie dwóch modeli. Na podstawie zebranych danych pomiarowych tworzony jest model bazowy M_b . Celem tego modelu jest identyfikacja wartości odstających w danych, aby ostrzec operatora o nienormalnym stanie urządzenia. Jeśli model bazowy wymaga korekty to nowe wartości wymaganych przez niego parametrów ustalane są na nowo na podstawie ostatnio zebranych przykładów, liczba tych przykładów, a więc zakres danych historycznych jakie należy wziąć pod uwagę jest parametrem metody. W szczególności do aktualizacji parametrów modelu można również wykorzystać wszystkie dostępne dane historyczne.

Drugim modelem stosowanym przez metodę model korekcyjny M_c . Model ten jest modelem klasyfikacyjnym i jego zadaniem jest weryfikacja, czy dany alert identyfikacji wartości odstających powinien zostać przedstawiony użytkownikowi. Dane uczące dla tego

modelu zawierają te same atrybuty, co dane uczące dla M_b . Model korekcyjny trenowany jest ponownie po każdym cyklu interakcji z operatorem. Model korekcyjny uruchamiany jest pod warunkiem zebrania wystarczającej liczby obserwacji, które zostały błędnie oznaczone jako odstające przez model bazowy.

Oceny efektywności działania algorytmów realizujących zadanie identyfikacji wartości odstających można dokonać w szczególności za pomocą takich miar, jak: precision, recall, krzywej ROC, lub innych wskaźników dedykowanych dla dwuklasowych problemów klasyfikacji np. f-score, g-mean [170, 171]. Zadanie metody bazującej na identyfikacji wartości odstających jest podobne do problemu klasyfikacji dwuklasowej, ale w naszym przypadku zbiór przykładów się zmienia (powiększa). Dla oceny efektywności działania przedstawionej powyżej metody zdecydowano się bazować na wskaźnikach zbliżonych do czułości, specyficzności i miary g-mean. Zdefiniujmy trzy wartości: P, N oraz Score. Biorąc pod uwagę, że dysponujemy zbiorem danych D, założmy, że algorytm wykrywania wartości odstających identyfikuje $m > 0$ potencjalnych anomalii, z których m_t są prawdziwymi wartościami odstającymi. Jeśli w zbiorze D znajduje się d_t rzeczywistych wartości odstających, P jest zdefiniowane jako:

$$P = \frac{m_t}{d_t} \quad (11)$$

Wartość P jest równa 1, jeśli algorytm znajdzie wszystkie prawdziwe wartości odstające. W przypadku braku rzeczywistych wartości odstających w zbiorze D ($d_t = 0$) uznaje się, że miara P ma wartość 1. N jest zdefiniowane jako:

$$N = \frac{m - m_t}{D - d_t} = \frac{m_f}{d_f} \quad (12)$$

gdzie: m_f to liczba normalnych wartości oznaczonych błędnie jako odstające, a d_f to liczba wszystkich (nie odstających) zgromadzonych i zagregowanych pomiarów. N jest równe 0, jeśli algorytm nie oznaczy żadnej wartości nie będącej wartością odstającą jako wartości odstającej. Wskaźnik Score łączy d i N w jedną wartość i definiowany jest jako:

$$Score = \sqrt{(1 - N) \cdot P} \quad (13)$$

Wskaźnik ten jest on równy 1, gdy wszystkie wartości odstające zostały zidentyfikowane jako wartości odstające, a wszystkie wartości normalne zostały określone jako normalne.


6.3. Eksperymenty

Ocenę zaproponowanej metody przeprowadzono na zbiorze danych pomiarowych opisujących pracę kruszarek. Dodatkowo efektywność metody badano również na danych syntetycznych – symulowanych. Celem tych działań było m.in. sprawdzenie, który z algorytmów identyfikacji wartości odstających nadaje się jako algorytm podstawowy – stosowany rutynowo - dla metody bazowej.

Przeprowadzone badania przeprowadzono w środowisku języka Python [172] (wersja 3.7). Główne biblioteki, które zostały użyte to: Pandas [173], która zapewnia struktury do przedstawiania zbiorów danych, scikit-learn [174], która zapewnia implementacje większości używanych algorytmów, tsfresh [169], która implementuje metody ekstrakcji i selekcji cech z danych mających charakter szeregów czasowych. Stosowano również bibliotekę shap [175], który udostępnia metody XAI.

6.3.1. Zbiory danych

Zbiór danych syntetycznych został wygenerowany jako dwa szeregi czasowe zawierające po 30 000 obserwacji. W pierwszym szeregu czasowym (oznaczonym jako x1) charakterystyka pracy hipotetycznego urzędnika była okresowo zmieniana, aby symulować zbliżającą się awarię. Wygenerowano dwa okresy, w których wartości symulowanych pomiarów stopniowo wzrastają, a następnie szybko wracają do normalnej wartości. W ten sposób zasymulowano pogarszający się stan urządzenia, który powraca do normy po pracach konserwacyjnych. Charakterystyka drugiego szeregu czasowego (oznaczona jako x2) jest stabilna. Oba szeregi czasowe zilustrowano na Rys. 51, a ich charakterystykę przedstawia Tabela 10.



Rys. 51 Wykres czasowy danych syntetycznych eksperymentu.

Tabela 10


Podstawowe parametry statystyczne zbioru danych syntetycznych.

zbiór	mean	std	min	25%	50%	75%	max
x1	520.78	47.14	450.00	484.42	515.82	544.11	698.48
x2	499.93	28.88	450.00	475.06	499.73	524.82	550.00

Zestaw danych rzeczywistych powstał z wartości pomiarowych zarejestrowanych dla dwóch kruszarek (NW10 oraz NW20) zebranych w okresie od połowy lipca 2019 r do końca marca 2021 r. Dla każdej z kruszarek zarejestrowano około 4 mln obserwacji. Zebrane dane obejmują trzy wartości mierzone przez czujnik WS-VT1:

- maksymalną wartość przyspieszeń drgań zarejestrowaną w oknie pomiarowym,
- średniokwadratową wartość (RMS) przyspieszeń z okna pomiarowego,
- temperaturę.

Odstęp między obserwacjami wynosił 10 sekund. Szeregi czasowe zarejestrowane dla jednej z kruszarek (NW-10) zaprezentowano na Rys. 52, a podstawowe dane statystyczne zbioru prezentuje Tabela 11.



Rys. 52 Wykres czasowy danych surowych dla kruszarki NW-10.

Tabela 11

Statystyki opisowe zbioru danych dla kruszarek NW10 oraz NW20.

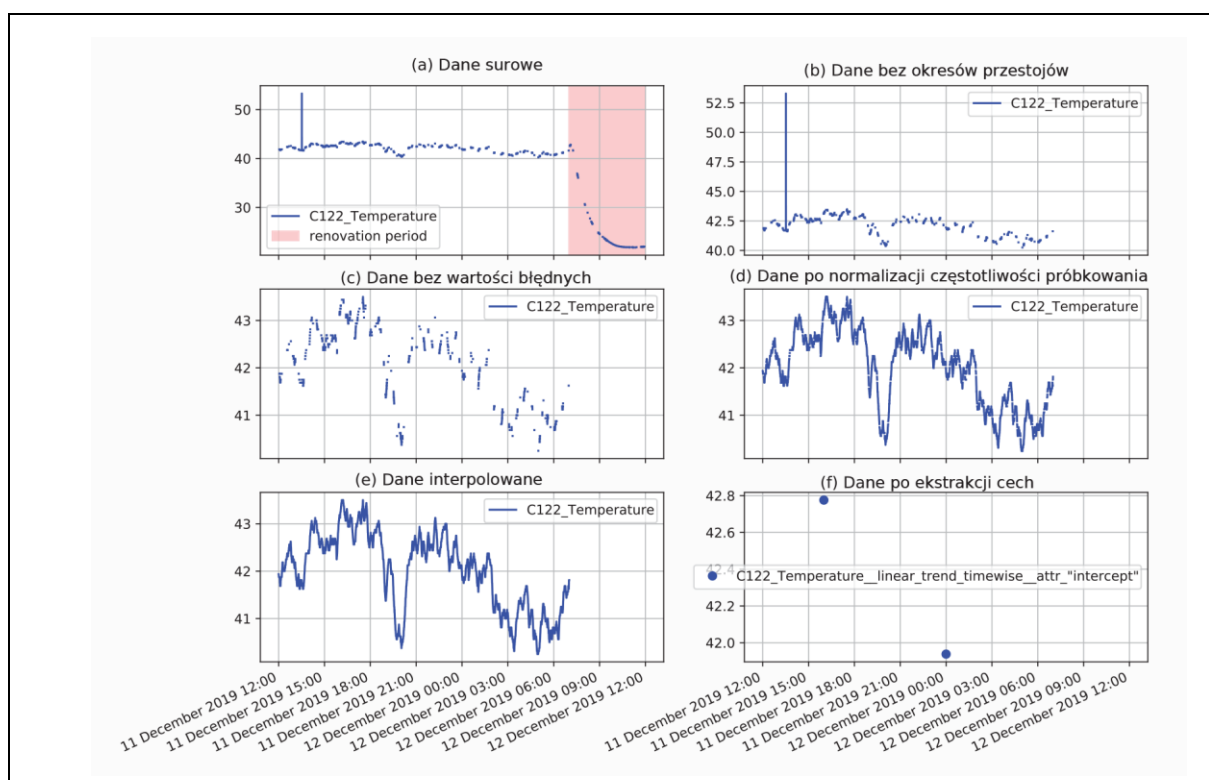
zbiór	czujnik	atrybut	mean	std	min	25%	50%	75%	max
NW10	C122	VibrRMS	638.85	322.14	100.0	386.00	535.0	803.0	5500.0
		VibrMax	1697.42	857.0	200.0	1018.00	1473.0	2183.0	7803.0
		Temp	34.49	4.91	3.75	31.13	34.25	37.31	56.13
	C123	VibrRMS	784.98	357.10	103.0	320.00	622.0	1034.0	4786.0
		VibrMax	2085.28	1410.79	143.0	845.00	1715.0	2916.0	7841.0
		Temp	33.84	5.69	15.38	29.75	33.25	37.69	67.75
NW20	C124	VibrRMS	1118.55	541.05	100.0	742.00	1019.0	1362.0	6152.0
		VibrMax	3017.39	1278.28	200.0	2011.00	2995.0	3781.0	7926.0
		Temp	35.34	6.49	10.25	30.31	35.50	39.63	70.38
	C125	VibrRMS	880.50	284.61	100.0	650.00	826.0	1102.0	5280.0
		VibrMax	2349.91	761.61	181.0	1747.00	2283.0	2877.0	7855.0
		Temp	35.33	7.20	8.88	29.13	35.56	41.19	72.38

Od służb utrzymania ruchu otrzymano informacje na temat remontów i regulacji dokonywanych w okresie objętym eksperymentem. Na podstawie dziennika remontowego zidentyfikowano 6 zdarzeń związanych z kruszarką NW10 oraz jedno zdarzenie powiązane z kruszarką NW20.

6.3.2. Parametry eksperymentu

Zgodnie z założeniami metody przedstawionymi w rozdziale 6.2.2 dane telemetryczne uzyskane z systemu monitorowania poddano procesowi wstępnego przetwarzania.

Przykładową ilustrację wyników obróbki wstępnej przedstawiono na Rys. 53. Przedstawione na tym rysunku wykresy odpowiadają kolejnym operacjom przetwarzania zastosowanym do wybranego fragmentu szeregu czasowego pomiaru temperatury zebranego na kruszarce węgla NW-10. Zastosowane operacje obejmują usuwanie okresów renowacji, gdy pomiary nie reprezentują codziennej pracy, usuwanie jawnie nieważnych wartości, normalizację częstotliwości próbkowania, interpolację i wreszcie ekstrakcję cech pochodnych.



Rys. 53 Ilustracja procesu wstępnego przetwarzania danych z kruszarki NW-10.

Do badania wpływu wielkości okna przesunowego agregacji wykorzystano zbiór wartości $\{4, 6, 8\}$ godzin.

W eksperymentach zdefiniowano dwa zbiory zmiennych wywiedzionych, aby zweryfikować, który zestaw cech pozwala uzyskać najlepszą jakość systemu, tzn. sprawdzono jaka minimalna konfiguracja zbioru cech pozwala uzyskać zadowalającą wartość wskaźnika Score.

Zdefiniowane zbiory cech obejmują:

- minimalny zestaw cech obejmujący podstawowe statystyki opisowe: mediana, średnia, odchylenie standardowe, maksimum i minimum,
- zbiór cech opartych na czasie obejmujących takie cechy jak: współczynnik korelacji, punkt przecięcia linii regresji, nachylenie linii regresji, błąd standardowy oszacowanego nachylenia (gradient), przy założeniu normalności residuum, dwustronna wartość p dla testu, którego hipotezą zerową jest to, że nachylenie wynosi zero, przy użyciu testu Walda z rozkładem t statystyki testowej [176].

Analizę wykonano dla każdego zbioru oddzielnie oraz dla sumy cech z obu zbiorów.

Ze względu na fakt, że czujniki obu kruszarek były obsługiwane przez jedną stację odbiorczą, a same kruszarki były zainstalowane w pomieszczeniu izolowanym elektromagnetycznie od innych części systemu monitorowania, liczba duplikatów w zebranych zbiorze była znikoma i nie wymagała specjalnego traktowania. Brakujące dane

w zbiorze zastępowano daną poprzednią, jeśli przerwa w transmisji danych była krótsza niż 50s, w przeciwnym przypadku luki były traktowane jako brakujące dane.

W ramach prac dobrano wartość progową drgań RMS, poniżej której identyfikowano okresy przestojów maszyny. Został on określony na poziomie 100 mg.

W związku z założeniami przyjętymi dla proponowanej metody, do wykonania modelu bazowego przyjęto następujące parametry. Inicjalizacja modelu bazowego następuje po zebraniu danych reprezentujących 30 dni pracy urządzenia. Założono, że długość okresu poprzedzającego wydarzenie powinna wynosić 2 tygodnie. Czas ten powinien wystarczyć na podjęcie działań prewencyjnych. Założono, że udział wartości odstających w monitorowanych danych wyniósł 1% i może on wynikać z różnych zakłóceń pomiarów. Model bazowy jest dostosowywany do nowych danych (generowany jest nowy model) po przekroczeniu tego progu. Okres bezpośrednio po remoncie urządzenia, podczas którego docierają się nowe podzespoły i dane nie są analizowane, ustalono na 1 tydzień. Model korekcyjny jest przestrajany po trzech prognozach oznaczonych przez M_c jako wartości odstające, które nie zostały potwierdzone przez użytkownika.

W przeprowadzonych eksperymentach zbadano kilka metod identyfikacji wartości odstających. Były to algorytmy:

- Algorytm HDBSCAN [177] rozszerzający oryginalną metodę DBSCAN,
- LOF [149],
- isolation forest [152],
- jednoklasową SVM [154].

Wartości parametrów algorytmów dostrajane były za każdym razem, gdy został przekroczony jednoprocetowy próg dopuszczalnej liczby zidentyfikowanych wartości odstających.

Do strojenia modelu bazowego zastosowano metodę przeszukiwania siatki (metodę gridową), a parametry zmodyfikowane dla każdej z metod przedstawia Tabela 12.

Tabela 12

Parametry bazowych metod identyfikacji wartości odstających

Metoda	Parametr	Opis
HDBSCAN	min_samples	Minimalna liczba punktów, które muszą znajdować się w klastrze, aby został on uznany za poprawny i uwzględniony w wynikach grupowania [177].
LOF	n_neighbors	Domyślna liczba sąsiadów branych pod uwagę przy obliczaniu lokalnego wskaźnika odstępstwa (ang. local outlier factor) dla każdego punktu danych [149]
	algorithm	Algorytm zastosowany do wyznaczania k najbliższych sąsiadów dla każdego punktu danych.
	leaf_size	Rozmiar liścia drzewa k-d (ang. dimensional tree) używanego do znajdowania k najbliższych sąsiadów w przypadku zastosowania algorytmu „kd_tree” [149].
Isolation Forest	contamination	Procentowy udział punktów odstających w zbiorze danych które mają zostać wykryte [152].
One-Class SVM	nu	Poziom akceptacji punktów odstających przez model rozumiany jako maksymalna wartość proporcji punktów odstających w stosunku do rozmiaru zbioru danych [154].
	kernel	Typ jądra używanego w algorytmie do transformacji danych wejściowych w przestrzeń wielowymiarową [154].

Przeprowadzone eksperymenty obejmowały weryfikację podejścia z wykorzystaniem modelu korekcyjnego i bez niego. W przedstawionych eksperymentach, biorąc pod uwagę działanie modelu korekcyjnego, założono, że wszystkie zdarzenia zachodzące poza dwutygodniowymi okresami przed-awaryjnymi zostały oznaczone jako fałszywe. Klasyfikator realizujący zadanie modelu korekcyjnego został wygenerowany metodą Random Forest [129]. Liczbę drzew w zespole ustalono na 40, a maksymalną głębokość drzew na 8.

6.4. Wyniki

W eksperymentach weryfikowano jakość metody dla każdego układu wartości rozważanych parametrów. Każdy model podstawowy był zatem uruchamiany 9 razy (cztero-, sześć- oraz ośmiogodzinne okno agregacji dla zbiorów cech minimalnego i bazującego na czasie oraz dla sumy tych zbiorów) dla każdego zestawu danych (kruszarki NW-10 oraz NW-20, zbiór syntetyczny).

Przyjęte powyżej założenia eksperymentu oznaczają, że każdy model został uruchomiony na 27 zestawach danych w celu weryfikacji jakości metody.

Do oznaczenia zbiorów wykorzystano informacje o rzeczywistych awariach zidentyfikowanych i odnotowanych w dziennikach remontowych przez służby utrzymania ruchu (kruszarka NW-10 – 2 awarie, NW-20 – 1 awaria). Wszystkie anomalie zgłoszone

w tych momentach oraz w okresie dwóch tygodni poprzedzających awarie uznawano za prawdziwe. Wszelkie anomalnie zgłaszane poza tymi okresami uznawano za fałszywe. W analogiczny sposób oznaczono zbiór syntetyczny.

Z oczywistych powodów, taka metodyka nie może być stosowana w przypadku praktycznego wdrożenia, ale do oceny eksperymentalnej nadaje się dobrze.

Zestawienie uzyskanych wyników w postaci średnich wartości przyjętych miar jakości (N, P i Score) dla każdego rozważanego modelu bazowego przedstawia Tabela 13.

Przedstawione w tabeli wyniki uzyskano bez zastosowania modelu korekcyjnego. W ten sposób faktyczną jakość modelu bazowego można zweryfikować bez wpływu modelu korygującego, którego celem jest poprawa jakości “prognoz” procedury diagnostycznej.

Tabela 13

Średnie wartości miar P, N, Score dla różnych metod identyfikacji wartości odstających – wyniki bez stosowania modelu korygującego.

	Miara	HDBSCAN	LOF	Isolation Forest	One-Class SVM
NW-10	N	0.189 (± 0.022)	0.077 (± 0.031)	0.098 (± 0.048)	0.243 (± 0.088)
	P	0.651 (± 0.051)	0.115 (± 0.049)	0.366 (± 0.174)	0.163 (± 0.039)
	Score	0.726 (± 0.026)	0.318 (± 0.072)	0.550 (± 0.155)	0.349 (± 0.044)
NW-20	N	0.317 (± 0.061)	0.102 (± 0.019)	0.225 (± 0.096)	0.402 (± 0.012)
	P	0.172 (± 0.189)	0.015 (± 0.013)	0.049 (± 0.040)	0.042 (± 0.018)
	Score	0.281 (± 0.213)	0.093 (± 0.072)	0.185 (± 0.074)	0.156 (± 0.034)
Syntetyczny	N	0.087 (± 0.026)	0.018 (± 0.017)	0.020 (± 0.036)	0.106 (± 0.098)
	P	0.934 (± 0.024)	0.978 (± 0.012)	0.102 (± 0.104)	0.573 (± 0.466)
	Score	0.923 (± 0.011)	0.980 (± 0.011)	0.256 (± 0.195)	0.605 (± 0.410)

Wyniki przedstawione w Tabeli 13 pozwalają określić ranking modeli bazowych. Ranking opiera się na średnich wartościach miary Score, uzyskanej dla każdej z metod. Tabela 14 prezentuje średnią pozycję w rankingu danego modelu bazowego dla każdego z badanych zestawów danych.

Tabela 14

Pozycja metody identyfikacji wartości odstających w rankingu – wyniki bez stosowania modelu korygującego.

	HDBSCAN	LOF	Isolation Forest	One-Class SVM
NW-10	1.00 (± 0.00)	3.56 (± 0.53)	2.22 (± 0.44)	3.22 (± 0.83)
NW-20	1.72 (± 1.20)	3.28 (± 1.09)	2.44 (± 1.01)	2.56 (± 0.73)
syntetyczny	2.44 (± 0.53)	1.00 (± 0.00)	3.67 (± 0.50)	2.89 (± 0.93)

Wyniki podsumowane w formie rankingu w Tabeli 14 pokazują, że metoda HDBSCAN jako model bazowy sprawdza się dobrze w przypadku większości problemów. Wyniki tej metody są średnio najlepsze na zbiorach danych kruszarki NW-10 i NW-20 oraz dla zbioru danych syntetycznych model ten zajął drugie miejsce. Poniżej przedstawiono bardziej szczegółową analizę dla tego modelu bazowego.

Tabela 15 przedstawia ocenę metody stosującej jako model bazowy HDBSCAN.

Tabela 15

Średnie wartości P, N, Score w sytuacji zastosowania do analizy wartości odstających algorytmu HDBSCAN.

Obiekt	Miara	Metoda HDBSCAN (z adaptacją i korekcją)	Samodzielna HDBSCAN (bez adaptacji i korekcji)
NW-10	N	0.095 (± 0.089)	0.654 (± 0.082)
	P	0.602 (± 0.160)	0.707 (± 0.081)
	Score	0.737 (± 0.379)	0.487 (± 0.052)
NW-20	N	0.104 (± 0.096)	0.939 (± 0.077)
	P	0.161 (± 0.042)	1.000 (± 0.000)
	Score	0.311 (± 0.191)	0.208 (± 0.142)
syntetyczny	N	0.036 (± 0.059)	0.457 (± 0.147)
	P	0.917 (± 0.567)	0.992 (± 0.004)
	Score	0.940 (± 0.586)	0.727 (± 0.102)

Porównując wyniki zaproponowanej metody przedstawione w Tabela 13 i Tabela 15 (odpowiednio bez i z modelem korekcyjnym) można zauważyć, że model korekcyjny zwiększa wartości miary Score, zmniejszając wartość N i znacznie mniej znacząco zmniejszając wartość P. Pokazuje to, że model korekcyjny działa zgodnie z przeznaczeniem i zmniejsza liczbę fałszywych alarmów, gdy maszyna pracuje prawidłowo. Analizując wyniki samodzielnej metody HDBSCAN można zauważyć, że brak adaptacji modelu bazowego daje bardzo wysokie wartości N, szczególnie w przypadku danych rzeczywistych, co skutkuje niskimi wartościami wskaźnika Score.

Kwantyfikując opisane różnice porównywanych metod, zastosowanie adaptacji modelu bazowego zredukowało fałszywe alarmy średnio o 77,41% w stosunku do wydajności samodzielnej metody HDBSCAN. Zastosowanie zarówno adaptacji modelu bazowego, jak i modelu korekcyjnego zmniejszyło liczbę fałszywych alarmów średnio o 90,14% w stosunku do wydajności metody HDBSCAN stosowanej samodzielnie. Wzrost wartości mediany Score w tych przypadkach wyniósł odpowiednio 35,72% i 39,80%.

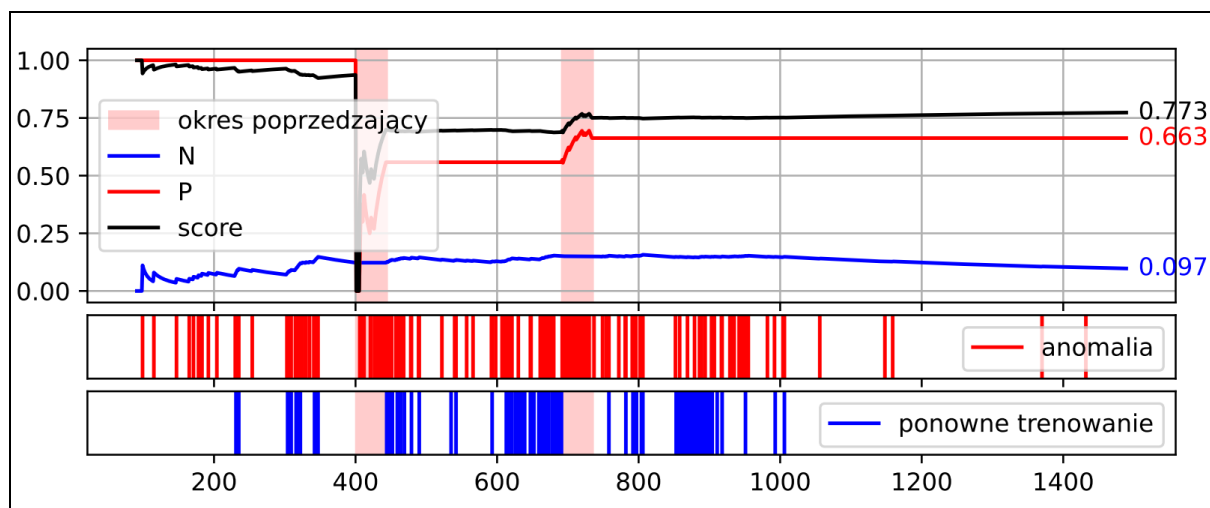
Aby w pełni zilustrować wydajność i jakość proponowanej metody, wykresy wartości każdej miary w kolejnych oknach agregacji przedstawiono na Rys. 54 - Rys. 56. Jasnoczerwone obszary wykresów oznaczają okresy dwóch tygodni przed awarią. Pod każdym wykresem zaznaczone są wystąpienia identyfikowania anomalii zgłaszane operatorowi jako alarm oraz przypadki ponownego uczenia modelu podstawowego w celu utrzymania założonej niskiej liczby zidentyfikowanych anomalii.

Przedstawione wykresy zostały stworzone dla metody HDBSCAN na każdym ze zbiorów danych. Wartości parametrów, które przyjęto do uzyskania wybranych wyników oraz uzyskaną wartość Score przedstawia Tabela 16.


Tabela 16

Wartości parametrów metody dla rozważanych zbiorów danych.


Obiekt	Długość okna agregacji	Rodzaj zbioru cech	Score
NW-10	8	minimalny, bazujący na czasie	0.773
NW-20	4	bazujący na czasie	0.648
syntetyczny	6	bazujący na czasie	0.959



Rys. 54 Wykres wartości wszytkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych NW-10).



Rys. 55 Wykres wartości wszytkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych NW-20).



Rys. 56 Wykres wartości wszystkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych syntetycznych).

Rys. 56 ilustruje wyniki działania metody na syntetycznym zbiorze danych. Zbiór ten powstał w celu wykazania poprawności działania proponowanej metody i dobrze identyfikuje okresy poprzedzające awarię. W tym okresie zidentyfikowano dużą liczbę wartości odstających odzwierciedlających zmiany w danych. Poza tym okresem liczba zidentyfikowanych anomalii jest niska, a model bazowy był przetrenowany jednokrotnie.

Na Rys. 54 oraz Rys. 55 zilustrowano działanie metody kolejno na kruszarkach NW-10 i NW-20. W początkowym okresie pracy kruszarki NW-10 sygnalizowane anomalie są poprawnie korygowane działaniem modelu korekcyjnego i przez przetrenowania modelu bazowego. Poprawnie zidentyfikowany jest okres przed pierwszą awarią – sygnalizowane są wówczas liczne anomalie. Nieco bardziej skomplikowaną sytuację obserwujemy przed drugą awarią. Wykres uwidacznia wzrastające nasycenia zgłaszanych anomalii, którego kulminację można zaobserwować w momencie rzeczywistej awarii. Oznacza to, że model poprawnie przewidywał symptomy zbliżającej się awarii. Próby przetrenowania modelu przed tym okresem wynikają z faktu, że symptomy awarii były sygnalizowane jeszcze przed przyjętym na potrzeby eksperymentu dwutygodniowym okresem. Natomiast po usunięciu drugiej awarii, wszystkie zgłaszane anomalie są poprawnie korygowane przez procedurę i liczba ich zgłoszeń maleje w czasie. Obserwację tą potwierdza stabilna, utrzymywana na wysokim poziomie o wartości 0,773 wartość wskaźnika Score.

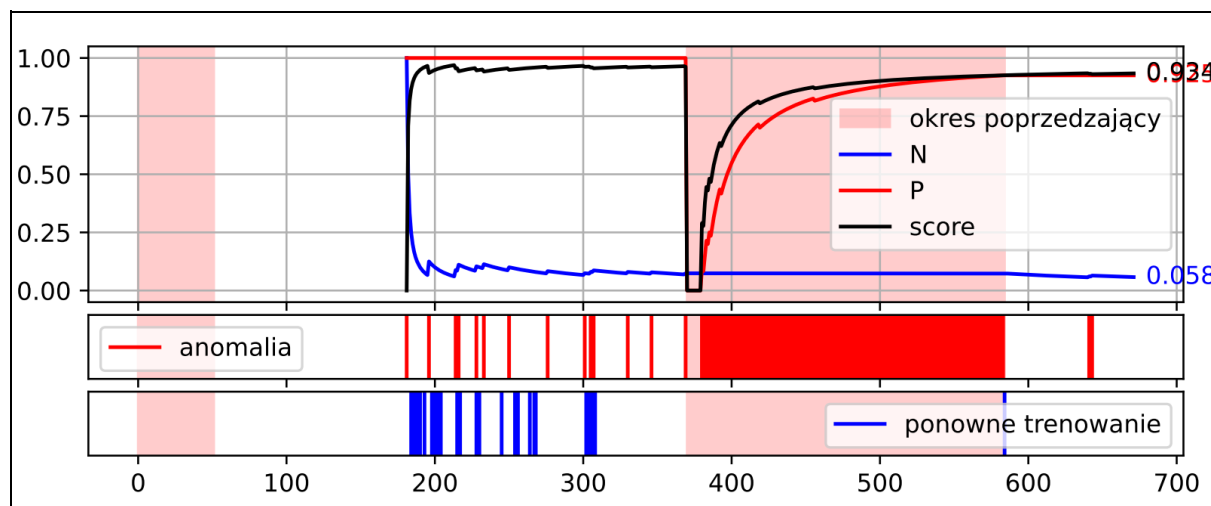
Podobną sytuację obserwujemy w przypadku analizy drugiej z kruszarek – NW-20 (Rys. 55). Anomalie zgłaszane w okresie poprawnej pracy maszyny, na długo przed pierwszą awarią są poprawnie korygowane przez model. Poprawnie jest też zidentyfikowany moment awarii – widoczne jest wyraźne zagęszczenie zgłaszanych przez procedurę anomalii. W okresie poawaryjnym, zgłaszane anomalie są korygowane, a wartość wskaźnika Score jest utrzymywana na stabilnym poziomie o wartości zbliżonej do 0,648.

Przedstawioną metodę dodatkowo zweryfikowano na zbiorach danych pochodzących z systemu monitorowania suwnic bramowych, opisanych w rozdziale 5.1. Dane pochodziły z dwóch bliźniaczych obiektów: suwnicy S201 oraz S020. Na każdej z maszyn zamontowano po 12 czujników rejestrujących poziom drgań i temperatury. W tym przypadku odstęp między obserwacjami wynosił 30 sekund. Także w tym przypadku, jako model bazowy najlepiej się sprawdził HDBSCAN. Średnie miary jakości dla tej metody, oraz wpływ adaptacji i korekcji na wyniki dla zbioru z suwnic prezentuje Tabela 17. Natomiast wykresy wartości miar jakości metody dla jednej z suwnic (S-202) w kolejnych oknach agregacji przedstawiono na Rys. 57.

Tabela 17

Średnie wartości P, N, Score w sytuacji zastosowania do analizy wartości odstających algorytmu HDBSCAN dla zbiorów z suwnic.

Obiekt	Miara	Metoda HDBSCAN (z adaptacją i korekcją)	Samodzielna HDBSCAN (bez adaptacji i korekcji)
S201	N	0.026 (± 0.109)	0.903 (± 0.140)
	P	0.078 (± 0.459)	0.972 (± 0.053)
	Score	0.237 (± 0.638)	0.207 (± 0.226)
S202	N	0.115 (± 0.105)	0.925 (± 0.039)
	P	0.737 (± 0.558)	0.994 (± 0.011)
	Score	0.804 (± 0.677)	0.263 (± 0.078)



Rys. 57 Wykres wartości wszystkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych S-202).

Także dla tego zbioru danych metoda działa poprawnie. W początkowym okresie zbierania danych nieliczne zgłoszenia fałszywych alarmów są korygowane. Liczne anomalie są sygnalizowane w momencie rzeczywistego uszkodzenia suwnicy. Po usunięciu awarii model praktycznie nie sygnalizuje wartości odstających, a wartość wskaźnika Score utrzymywana jest na wysokim poziomie o wartości 0,934.


Z przedstawionych wyżej analiz, można wyciągnąć ogólny wniosek, że do interpretacji wyników działania metody najbardziej pomocna jest obserwacja zagęszczenia zgłaszanych anomalii. Pierwsze symptomy rzeczywistej awarii są sygnalizowane w postaci pojedynczych alarmów, których intensywność wzrasta wraz rozwijającą się awarią. Mniejsze znaczenie mają bezwzględne wartości wskaźników jakości – w szczególności miara P narasta stopniowo i nie osiąga skokowej wartości 1 nawet dla syntetycznych zbiorów danych.

6.5. Objaśnialność decyzji


Do wygenerowania wyjaśnień przyczyn identyfikacji danej wartości jako anomalie wykorzystano implementację metody SHAP [175]. Operator może uruchomić metodę objaśniania przyczyn dla każdej zidentyfikowanej wartości odstającej (zarówno tej zidentyfikowanej poprawnie jak i niepoprawnie).

Metoda SHAP określa wpływ cech w stosunku do wartości bazowej (średni wynik modelu na treningowy zestaw danych). Decyzją modelu może być wartość anomalii lub normalna, które są reprezentowane przez SHAP odpowiednio jako -1 i 1. Dlatego wpływ cech ilustrują wartości zmierzające do decyzji -1 (lub 1).

Poniżej przedstawiono dwa przykłady wygenerowanych wyjaśnień dla kruszarki węgla NW-10. Wyjaśnienia te uzupełniają wykresy wartości cech z okresu obejmującego analizowany przypadek (okno agregacji). Rys. 58 przedstawia wyjaśnienie przypadku prawdziwej pozytywnej identyfikacji anomalii. Wyjaśnienie to uzupełnia Rys. 59 przedstawiający wykresy czterech najważniejszych cech wskazanych przez SHAP. Wyjaśnienie dotyczy miejsca oznaczonego czerwoną pionową linią.



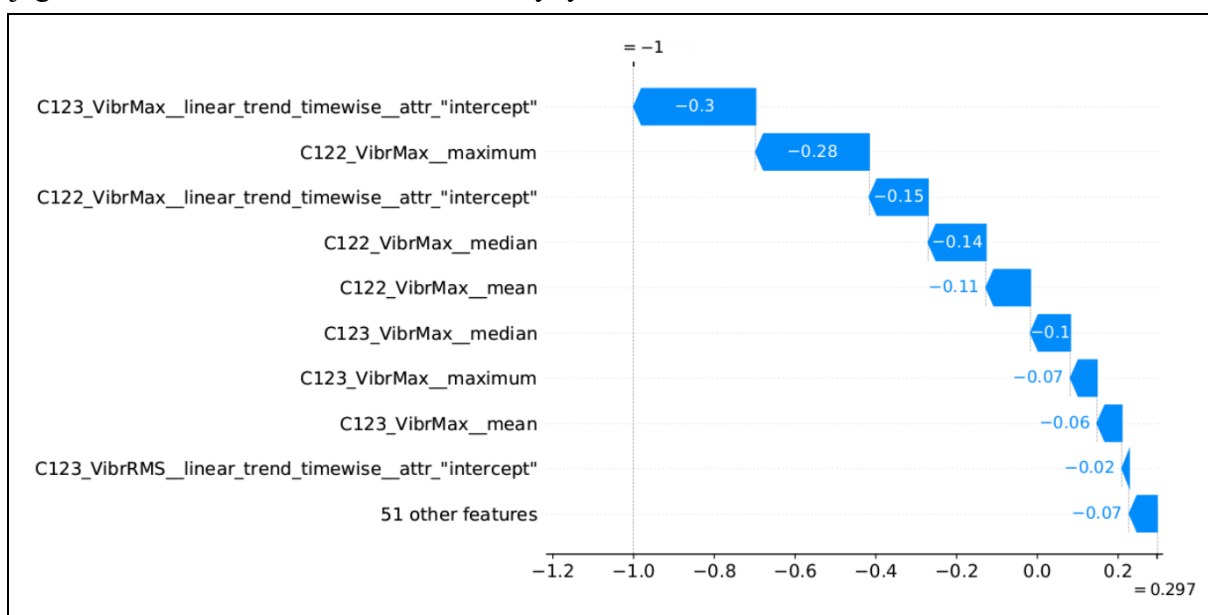
Rys. 58 Wykres kaskadowy wyjaśnień SHAP dla indywidualnej predykcji anomalii (przypadek prawdziwie pozytywny) — wyjaśnienie dotyczy miejsca zaznaczonego czerwoną linią prostą na Rys. 59.




Rys. 59 Wybrany fragment wykresu najważniejszych cech wskazanych przez metodę objaśniającą na Rys. 58. (zbiór danych kruszarki NW 10)

Przykładowo, analizując cechy modelu możemy w momencie uszkodzenia zaobserwować, wzrost trendu liniowego utworzonego na bazie drgań maksymalnych mierzonych czujnikiem C123 oraz wzrost maksymalnych wartości drgań RMS rejestrowanych na tym czujniku. Także liniowy trend drgań maksymalnych rejestrowanych czujnikiem C122 może potwierdzać pozytywną identyfikację anomalii.

Rys. 60 przedstawia wyjaśnienie przypadku identyfikacji fałszywie dodatniej anomalii. Ponownie wyjaśnienie to uzupełnia Rys. 61, przedstawiający wykresy czterech najważniejszych cech wskazanych przez SHAP. Wyjaśnienie dotyczy przykładu oznaczonego czerwoną pionową linią. Wygenerowane w ten sposób wyjaśnienia zwracają uwagę operatora na wybrane aspekty pomiarów i mogą być pomocnym uzupełnieniem jego doświadczenia w ocenie stanu maszyny.



Rys. 60 Wykres kaskadowy wyjaśnień SHAP dla indywidualnej identyfikacji anomalii (przypadek fałszywie dodatni) — wyjaśnienie dotyczy przykładu zaznaczonego czerwoną linią prostą na Rys. 61 (zbiór danych kruszarki NW-10).



Rys. 61 Wybrany fragment wykresu najważniejszych cech wskazanych przez metodę objaśniającą na Rys. 60.

6.6. Praktyczna procedura diagnostyczna

Model wykrywania wartości odstających jest próbą odpowiedzi na podstawowy problem związany z zastosowaniem algorytmów uczenia maszynowego w zadaniach PdM związany z ograniczonym dostępem do danych zarejestrowanych w momentach rzeczywistych awarii. Z oczywistych względów służby utrzymania ruchu starają się nie dopuścić do takich sytuacji, a jeśli nawet takie się zdarzają, to ich liczba jest niewystarczająca do implementacji większości metod opartych o uczenie nadzorowane. Model wykrywania wartości odstających może być uruchamiany dla danych reprezentujących stan maszyny o której stanie jeszcze niewiele wiadomo. W tym przypadku użytkownik ma być informowany o wszelkich sygnałach odbiegających od stanu określanego mianem normalnego. Dlatego kluczową jest rola eksperta, który każdorazowo musi ocenić, czy sygnalizowana anomalia wynika z przesłanek związanych ze zbliżającą się awarią, czy z innych, niezależnych od stanu technicznego przyczyn. Często okazuje się, że użytkownik dysponuje taką wiedzą dopiero po pewnym czasie – narzędzia diagnostyczne, którymi dysponuje użytkownik mogą nie pozwalać na identyfikację początkowych symptomów awarii.

Praktyczna realizacja niniejszej procedury diagnostycznej musi uwzględniać udział eksperta (w osobie operatora maszyny lub pracownika utrzymania ruchu). Jego rolą jest potwierdzanie lub odrzucanie zgłaszanych przez procedurę anomalii. Z oczywistych względów, nie jest możliwe, by użytkownik był w stanie dokonać takiej oceny po każdym

uruchomieniu procedury diagnostycznej. Zakłada się, że taka ocena będzie dokonywana okresowo (np. co zmianę roboczą) dla grupy prognoz.

W typowy scenariuszu realizacji procedury diagnostycznej można założyć, że:

- Prognoza jest uruchamiana w regularnych chwilach czasu (np. co godzinę).
- Użytkownik otrzymuje graficzną informację o stwierdzonej anomalii w postaci pionowego słupka, naniesionego na osi czasu, o wysokości proporcjonalnej do prawdopodobieństwa wystąpienia anomalii.
- W regularnych, zależnych od zasad organizacyjnych przedsiębiorstwa chwilach czasu, użytkownik dokonuje grupowej oceny prognoz zgłoszonych za poprzedni okres, przy czym każda zgłoszona anomalia domyślnie jest traktowana jako prawdziwa. Użytkownik ma wyłącznie możliwość odrzucania błędnych - jego zdaniem - alarmów.
- Informacje zwrotne użytkownika są wykorzystywane przez ścieżkę korekcyjną procedury diagnostycznej. W pierwszym etapie wpływają na przetrenowanie modelu korekcyjnego, a jeśli to nie przynosi skutków – prowadzą do ponownego trenowania modelu bazowego. Zgodnie z założeniami metody fałszywe alarmy będą eliminowane w kolejnych prognozach.

Warstwa SCADA systemu udostępnia użytkownikowi szereg narzędzi wspierających jego ocenę. Dla każdej z prognoz użytkownik może uruchomić metodę objaśniania przyczyn w postaci kaskadowego wykresu wyjaśnień, wskazujących cechy najbardziej istotne z punktu widzenia podjętej decyzji. Dodatkowo, dla każdej z tych cech użytkownik może uruchomić wykres jej zmienności w czasie.

W przypadku rozwijającej się awarii, użytkownik powinien obserwować wzrastające zagęszczenie zgłaszanych anomalii. W ostatnim okresie przed awarią, większość prognoz powinna być oznaczona przez metodę jako wartość odstająca. Istotnym z punktu widzenia praktycznej implementacji metody jest to, by użytkownik sygnalizował w systemie fakt przeprowadzenia akcji remontowych, w szczególności związanych z wymianą podzespołów maszyny.

W skrajnych przypadkach, może się okazać, że metoda w sposób ciągły zgłasza fałszywe alarmy, a ścieżka korekcyjna metody nie jest w stanie poprawić jakości prognoz mimo wielokrotnego trenowania modeli. W takim przypadku użytkownik może podjąć decyzję o wyłączeniu modelu z diagnostyki i zgłoszeniu tego faktu do działu Data Science organizacji. W tym momencie konieczna jest interwencja zespołu analityków. Mogą oni przykładowo zdecydować o zmianie parametrów lub typu modelu bazowego (fakt, że z badań przedstawionych w rozdziale 6.3 wynika, że algorytm HDBSCAN był średnio najlepszy dla badanych zbiorów, nie oznacza, że tak będzie dla każdego zbioru danych). Mogą też dokonać głębokiej modyfikacji parametrów modelu korekcyjnego. W skład architektury modułu

analitycznego systemu wchodzi moduł Jupyter Hub udostępniający narzędzia do tworzenia modeli diagnostycznych bezpośrednio w środowisku wdrożeniowym (patrz Rys. 32).

7. Podsumowanie

W niniejszej rozprawie przedstawiono kompletny system diagnostyki maszyn obejmujący warstwę sprzętową i programową. W ramach pracy doktorskiej przeprowadzono pełny proces projektowania systemu:

- zebrano wymagania wynikające z doświadczeń i potrzeb potencjalnych użytkowników,
- przeanalizowano je pod kątem potencjalnych rozwiązań sprzętowych i programowych,
- zaproponowano architekturę systemu uwzględniającą te wymagania,
- zaprojektowano, zbudowano i przebadano poszczególne elementy składające się na architektury systemu,
- Zaproponowano dwie metody diagnostyczne, pierwsza bazuje na analizach trendu zmian monitorowanych wielkości, a druga na metodach identyfikacji wartości odstających.

W szczególności zostały zaprojektowane bezprzewodowe czujniki drgań i temperatury pełniące w systemie funkcję podstawowego źródła danych telemetrycznych oraz bezprzewodowe czujniki innych wielkości fizycznych, pełniące rolę uzupełniającą. Opracowano między innymi czujniki ciśnienia, wilgotności, natężenia prądu i prędkości obrotowej.

W ramach prac związanych z optymalizacją poboru mocy z bateryjnych źródeł zasilania czujników zaproponowano następujące rozwiązania układowe i programowe wspierające funkcję oszczędności poboru energii:

- zmodyfikowano układ zasilania czujników – poszczególne elementy czujnika nie są zasilane bezpośrednio z napięcia baterii, ale są zasilane z wykorzystaniem dodatkowej przetwornicy DC/DC o wysokiej sprawności pozwalającej na redukcję napięcia zasilania oraz selektywną dystrybucję zasilania pozwalającą na redukcję poboru mocy w trybie uśpienia,
- zastosowano dodatkowy, progowy czujnik drgań pozwalający na dodatkową oszczędność energii w momentach, gdy monitorowana maszyna nie pracuje,
- zweryfikowano poszczególne elementy układu pod kątem poboru mocy,
- zmodyfikowano algorytm pracy czujnika, optymalizując czas pracy w poszczególnych fazach przetwarzania (w szczególności fazy nasłuchu danych).

Wszystkie te zabiegi pozwoliły na istotne wydłużenie czasu pracy czujnika po wymianie baterii (dla typowych częstości pomiaru nawet dwukrotnie). Dodatkowo ulepszono sposób sygnalizacji stanu naładowania baterii, poprzez wprowadzenie algorytmu sukcesywnego zliczania wydatku energii w miejsce pomiaru napięcia baterii zasilającej.

W ramach prac wybrano i wdrożono protokoły transmisji danych odpowiednie dla komunikacji w ramach poszczególnych warstw systemu. Zorganizowano transmisję danych w kanale radiowym pomiędzy czujnikami i warstwą akwizycji danych uwzględniając konieczność oszczędności pasma transmisyjnego, oszczędności energii urządzeń radiowych, unikania kolizji w trakcie komunikacji, konieczność zapewnienia dwustronnej wymiany danych w warunkach braku synchronizacji momentów inicjacji pomiarów. Dla komunikacji pomiędzy warstwą akwizycji danych i warstwą programową wytypowano i wdrożono protokół MQTT pozwalający na wydajną i bezpieczną wymianę danych dla urządzeń IoT. Zastosowane rozwiązania pozwalają na spełnienie wszystkich wymagań funkcjonalnych związanych z działaniem systemu (akwizycja wyników pomiarów), obsługą funkcji konfiguracyjnych dla czujników (parametryzacja w zakresie ustalenia zakresów pomiarowych, częstotliwości próbkowania, trybów przetwarzania pomiarów, odstępów czasu pomiędzy pomiarami, czułości, itp.) i transceiverów radiowych (ustalenie parametrów sieciowych, puli obsługiwanych urządzeń, synchronizacji czasu, itp.), wdrażaniem funkcji autodiagnostycznych (kontrola stanu rozładowania baterii, jakość komunikacji radiowej i sieciowej, aktualizacja oprogramowania wbudowanego firmware wszystkich elementów warstwy sprzętowej).

W drugiej części prac opracowano i wdrożono rozwiązania dla poszczególnych elementów warstwy programowej systemu. Wybrano i dostosowano środowisko odpowiedzialne za funkcje SCADA systemu. Środowiskiem tym jest platforma ThingsBoard. Środowisko to uwzględnia wymogi skalowalności, otwartości na warianty zamknięte i chmurowe, a także pozwala na integrację z narzędziami analityki danych. W całym systemie zapewniono narzędzia do autoryzacji dostępu. Bazując na ThB:

- Skonfigurowano warstwę transportową platformy do dwukierunkowej wymiany danych ze sprzętową warstwą akwizycji danych.
- Przygotowano komponenty wizualizacyjne (widżety) dostosowane do specyfiki systemu.
- Opracowano struktury danych telemetrycznych i konfiguracyjnych.
- Wdrożono rozwiązania bazodanowe w zakresie przechowywania danych telemetrycznych w oparciu bazę danych PostgreSQL lub Casandra.
- Przygotowano interfejs wymiany danych z silnikiem analitycznym systemu.
- W ramach silnika reguł biznesowych dostępnego w rozwiązaniu ThB, zaimplementowano procedury konfiguracji warstwy sprzętowej, ustawiania progów ostrzegawczych i alarmowych dla danych telemetrycznych, filtracji i czyszczenia danych, powiadamiania użytkowników o zdarzeniach itd.

Całość platformy podzielono na bloki funkcjonalne i przygotowano do wdrażania z wykorzystaniem konteneryzacji w technologii Docker. Pozwala to na dostosowywanie

architektury fizycznej serwera do aktualnych wymagań obliczeniowych (skalowanie względem rozmiaru wdrażanej aplikacji) oraz dostosowywanie do polityki bezpieczeństwa informatycznego klienta (wybór pomiędzy wariantem stacjonarnym i chmurowym).

Platformę ThB wpleciono architekturę całego systemu w szczególności połączono z silnikiem analitycznym. Silnik analityczny rozumiany jest jako środowisko do monitorowania i uruchamiania modeli diagnostycznych. Silnik jest w całości oparty na rozwiązaniach open source. Głównym modułem silnika analitycznego oparto o moduł MLFlow pozwalający na budowanie, przechowywanie i zarządzanie różnego rodzaju modelami analitycznymi/diagnostycznymi. Silnik analityczny realizuje pełny cykl przetwarzania danych zgodny z metodyką CRISP (CRoss Industry Standard Process for Data Mining) Data Mining. Surowe dane pobierane są ze telemetrycznej bazy danych z wykorzystaniem zapytań REST API i trafiają do modułu ETL odpowiedzialnego za procesy czyszczenia danych i przygotowania danych. Tak przygotowane dane trafiają do analitycznej bazy danych. Moduł ML pobiera z analitycznej bazy danych pliki modeli wraz z ich parametrami i uruchamia modele na wcześniej przygotowanych danych. Wyniki działania modeli diagnostycznych trafiają ponownie do analitycznej bazy danych. Wyniki analiz pokazywane są w ramach pulpitów menadżerskich w postaci interaktywnych, opracowanych na potrzeby wizualizacji wyników analiz kontrolek typu Widget. Do tworzenia kontrolki wykorzystano między innymi rozwiązania ShinyProxy oraz Grafana.

Poszczególne procedury diagnostyczne danego wdrożenia są uruchamiane z godnie z harmonogramem narzucanym i kontrolowanym przez moduł AirFlow. Wyniki działania modeli są analizowane przez silnik reguł platformy ThB i w szczególnych przypadkach, zdefiniowanych regułami biznesowymi silnika reguł ThB są raportowane użytkownikowi w postaci komunikatów email lub sms.

W ramach silnika analitycznego wdrożono również platformę JupyterHub pozwalającą na tworzenie i testowanie nowych modeli w środowisku produkcyjnym klienta (eksperymentowanie). Jest to szczególnie przydatne w przypadku współpracy z organizacjami nie pozwalającymi na udostępnianie danych poza sieć organizacji. Dodatkowym zadaniem wykonanym w ramach prac nad silnikiem analitycznym było wdrożenie modułu ELK do raportowania pracy silnika w postaci logów oraz KeyCloak odpowiedzialny za spójną autoryzację użytkownika w poszczególnych narzędziach składowych platformy.

Duży wkład pracy włożono w zaprojektowanie analitycznej bazy danych. Opracowana struktura bazy danych oprócz tego, że pozwala na przechowywanie odpowiednio przetworzonych i zagregowanych zbiorów cech gromadzi informacje o modelu w zakresie parametrów prognoz wygenerowanych przez modele, rzeczywistych wartości przedmiotu prognozowania, danych konfiguracyjnych o modelach, danych konfiguracyjnych o obiektach

podlegających prognozowaniu, danych konfiguracyjnych o akceptowalnych progach prognozy, danych treningowych i walidacyjnych na jakich były trenowane i optymalizowane modele.

Bardzo ważnym zadaniem realizowanym w ramach doktoratu było opracowanie metod diagnostycznych dla wybranych problemów wdrożeniowych. W ramach tych prac Przedstawiono dwie metody służące do realizacji zadań PdM bazujące na analizie trendu i analizie wartości odstających. W obu wymienionych przypadkach wytypowano zmienne diagnostyczne, opracowano odpowiednie procedury analityczne oraz opracowano sposób prezentacji wyników działania modeli. Oba modele przetestowano na danych pochodzący z rzeczywistych obiektów, na których został zainstalowany system: model analizy trendów na wybranych węzłach łożyskowych suwnicy bramowej służącej do transportu kadzi z surówką w ramach wydziału stalowni huty stali, a model wykrywający wartości odstające w ramach systemu monitorowania kruszarek węgla pracujących w instalacji podawania paliwa do kotła fluidalnego elektrowni węglowej.

Istotnym elementem opracowanej metodyki diagnozowania jest dodanie elementów objaśnilności wyników działania modeli diagnostycznych. Systemy diagnostyki bazujące na algorytmach maszynowego uczenia są nowością w środowisku służb utrzymania ruchu. Trzeba także zauważyć, że aktualny etap rozwoju tych narzędzi nie pozwala jeszcze na bezkrytyczne przyjmowanie wyników ich działania. Pełnią one dzisiaj rolę systemów wspomagania decyzji. Dlatego użytkownik musi mieć możliwość oceny ryzyka prezentowanej prognozy zanim podejmie działania mające na przykład na celu zatrzymanie procesu produkcyjnego.

Dla obu opracowanych metod zaproponowano praktyczne procedury diagnostyczne, pozwalające na ich wdrażanie w środowisku produkcyjnym. Dla modelu diagnostycznego suwnicy bramowej wynikiem działania tej procedury jest raport prezentujący zestawienie informacji o trendach poszczególnych zmiennych diagnostycznych dla trzech różnych horyzontów prognozy wraz z podsumowaniem liczby trendów zgodnych. Pozwala to użytkownikowi na śledzenie stabilności zmian wartości zmiennej diagnostycznej. Przygotowano również propozycję praktycznej procedury diagnostycznej wspomagającej decyzje pracowników służb utrzymania ruchu nadzorujących prace kruszarek. W tym przypadku użytkownik posiłkuje się graficznymi informacjami przedstawionymi na planszy prezentującej wyniki działania procedury diagnostycznej opartej o analizę anomalii. Fakt rozwijającej się awarii może zinterpretować na podstawie stopniowego wzrostu zagęszczenia ilości alarmów. Proponowana procedura uwzględnia praktyczną obsługę ścieżki korekcyjnej modelu – użytkownik ma możliwość grupowej oceny jakości prognoz i zgłaszania fałszywych alarmów. Dysponuje również narzędziami wspomagania tej oceny w postaci

graficznej prezentacji wyników działania metod objaśnialności przyczyn zgłaszanych anomalii.

Opracowany system był już przedmiotem licznych wdrożeń w zakładach przemysłowych o różnych profilach produkcyjnych. Dotychczasowe wdrożenia to m.in.:

- Elektrownia Jaworzno II - monitorowaniem objęto instalację podawania paliwa do kotła biomasowego (120 punktów pomiarowych) oraz kruszarki węgla w instalacji nawęglania kotła fluidalnego (4 punkty pomiarowe).
- Huta stali w Dąbrowie Górniczej w zakresie suwnic o nośności 500 ton transportujących kadzie z surówką (12 punktów pomiarowych), pompy wody (16 punktów pomiarowych), przenośniki wibracyjne przeznaczone do transportu spieku (20 punktów pomiarowych) oraz wentylatory chłodzące spiek (10 punktów pomiarowych).
- Huta Aluminium w Koninie w zakresie monitorowania wentylatorów, pomp hydraulicznych, przekładni walcarek i samych walcarek w procesie walcowania zimnego i gorącego (w sumie 55 punktów pomiarowych).
- Kopalnia Piast, w której monitorowaniu objęto wentylatory głównego przewietrzania wyrobisk (12 punktów pomiarowych).
- Wytwórnia lin stalowo-gumowych SAG Katowice, gdzie monitorowane są pompy emulsji zakładu (6 punktów pomiarowych).
- Huta Zawiercie, gdzie monitorowaniu podlegają klatki walcownicze pracujące w ramach trzech linii walcowniczych (32 punkty pomiarowe),
- Elektrownia Połaniec, monitorowaniu podlega zestaw wentylatorów młynowych (12 punktów pomiarowych).

Kilka z tych wdrożeń obejmuje nie tylko monitorowanie, ale również diagnostykę urządzeń, dwa z nich opisano w rozdziałach piątym i szóstym.

W związku z tematyką doktoratu przygotowano kilka artykułów naukowych. Pierwszy artykuł dotyczy badań nad procedurą diagnostyczną łożysk rolek przenośnika taśmowego [178]. Pracę opublikowano w czasopiśmie *Studia Informatica* (9 pkt. MNiSW). W czasopiśmie *Maintenance and Reliability* (IF 1.383; 25 pkt. MNiSW – stara lista) podsumowano badania nad modelem diagnostycznym suwnicy bramowej [179]. Prace nad modelem diagnostycznym kruszarek, bazującym na analizie wartości odstających podsumowano w publikacji [180] jaka ukazała się w czasopiśmie *Sensors* (IF 3.847; 100 pkt. MNiSW).

Planowane są dalsze prace nad rozwijaniem systemu monitorowania maszyn. W zakresie sprzętowym planowane jest dalsze rozszerzanie rodziny czujników bezprzewodowych kompatybilnych z systemem. W szczególności planuje się opracowanie bezprzewodowych czujników odległości niezbędnych przy analizie uszkodzeń wałów wolnobrotowych.

Ponadto planuje się rozpoczęcie prac nad czujnikami badającymi skład atmosfery oraz czujnikami przeznaczonymi do bezpośredniego pomiaru poboru mocy przez poszczególne napędy. W zakresie warstwy akwizycji danych planowana jest implementacja standardowych protokołów komunikacji ze sterownikami PLC celem umożliwienia integracji systemu monitorowania z rozwiązaniami PLC wiodących producentów.

W związku z licznymi zapytaniem o analizę widma drgań węzłów łożyskowych, trwają prace nad dodaniem funkcjonalności transmisji surowego przebiegu spróbkowanych danych, zakłada się, że taka transmisja będzie wykonywana nie częściej niż raz dziennie, bądź na żądanie w przypadku konieczności dokonania dogłębnej analizy widma. W związku z tą funkcjonalnością konieczne będzie również rozszerzenie warstwy programowej o narzędzia udostępniające i wspomagające analizę widmową pomiarów. Pozwoli to także na przygotowanie dedykowanych modeli diagnostycznych bazujących na analizie częstotliwościowej przebiegów. W zakresie warstwy analitycznej planuje się wzbogacenie systemu o kolejne – w miarę pojawiania się kolejnych wdrożeń - procedury diagnostyczne oraz rozbudowę narzędzi odpowiedzialnych objaśnianie wyników działania diagnostyki. W szczególności dalszego rozwoju wymaga warstwa systemu odpowiedzialna za uzyskiwanie informacji zwrotnej od użytkownika systemu. Musi ona wpierać adaptację modeli diagnostycznych (potwierdzanie lub korektę prognoz, identyfikację zdarzeń serwisowych, itp.) bez obciążania użytkownika nadmierną liczbą zadań zwiększających uciążliwość obsługi systemu. Istotnym elementem prac będzie walidacja tych metod w środowisku produkcyjnym.

Przedmiotowy system jest rozwiązaniem kompleksowym i złożonym, oczywiste jest, że autor nie byłby w stanie samodzielnie zrealizować całego rozwiązania. Wsparcie w realizacji prac wdrożeniowych i programistycznych stanowił zespół pracowników Somar S.A. oraz współpracujący zespół Politechniki Śląskiej pod kierunkiem promotora. Jednakże zasadnicze prace - główne efekty doktoratu wymienione na początku podsumowania - były realizowane przez autora lub przy jego znaczącym udziale.

BIBLIOGRAFIA

1. EBSCOhost | 121771778 | INDUSTRY 4.0 CONCEPTION. [Online]. Dostępne: <https://web.p.ebscohost.com/abstract?direct=true&profile=ehost&scope=site&authtype=crawler&jrnl=20673809&AN=121771778&h=iVOg7KPGLbbXGRTOM6HYmuqJCoe pZMUI6FVsV4dZeI3Br6dfDJP9bfvSbWWdeqoYRV6KUfAEFJV9h%2bQCBPL2g%3d%3d&crl=c&resultNs=AdminWebAuth&resultLocal=ErrCrlNotAuth&crlhashurl=logi n.aspx%3fdirect%3dtrue%26profile%3dehost%26scope%3dsite%26authtype%3dcrawle r%26jrnl%3d20673809%26AN%3d121771778>. [Dostęp: 05-luty-2023].
2. Zhou, K., Liu, T., Zhou, L.: Industry 4.0: Towards future industrial opportunities and challenges. [w:] 2015 12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD), 2015, p. 2147÷2152.
3. Group, S.M.A., Engineering (NITIE), N.I. of I., Lake, V., i in.: Internet of Things (IoT): A Literature Review. *J. Comput. Commun.*, t. 03, nr 05, 2015, p. 164.
4. Compare, M., Baraldi, P., Zio, E.: Challenges to IoT-Enabled Predictive Maintenance for Industry 4.0. *IEEE Internet Things J.*, t. 7, nr 5, maj 2020, p. 4585÷4597.
5. van Kranenburg, R., Bassi, A.: IoT Challenges. *Commun. Mob. Comput.*, t. 1, nr 1, lis. 2012, p. 9.
6. Peres, R.S., Jia, X., Lee, J., i in.: Industrial Artificial Intelligence in Industry 4.0 - Systematic Review, Challenges and Outlook. *IEEE Access*, t. 8, 2020, p. 220121÷220139.
7. Lee, J., Singh, J., Azamfar, M.: Industrial Artificial Intelligence. arXiv, 21-paź-2019.
8. Géron, A.: Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, Inc.2022.
9. Ahuja, I.P.S., Khamba, J.S.: Total productive maintenance: literature review and directions. *Int. J. Qual. Reliab. Manag.*, sie. 2008.
10. Walczak, M.: System utrzymania ruchu czynnikiem przewagi konkurencyjnej przedsiębiorstwa,[w:] Mikoła B.(red.): Historia i perspektywy nauk o zarządzaniu. *Fund. Uniw. Ekon. W Krakowie Kraków*, 2012, p. 415.
11. Legutko, S.: Trendy rozwoju utrzymania ruchu urządzeń i maszyn. *Eksploat. Niezawodn.*, t. nr 2, 2009, p. 8÷16.
12. Ran, Y., Zhou, X., Lin, P., i in.: A Survey of Predictive Maintenance: Systems, Purposes and Approaches. *ArXiv191207383 Cs Eess*, grudz. 2019.
13. Mobley, R.K.: *An Introduction to Predictive Maintenance*. Elsevier2002.
14. Florian, E., Sgarbossa, F., Zennaro, I.: Machine learning-based predictive maintenance: A cost-oriented model for implementation. *Int. J. Prod. Econ.*, t. 236, cze. 2021, p. 108114.
15. Carvalho, T.P., Soares, F.A.A.M.N., Vita, R., i in.: A systematic literature review of machine learning methods applied to predictive maintenance. *Comput. Ind. Eng.*, t. 137, lis. 2019, p. 106024.
16. Campbell, J.D., Jardine, A.K., McGlynn, J.: *Asset management excellence: optimizing equipment life-cycle decisions*. CRC Press2016.
17. Koops, L.: *ROC-based Business Case Analysis for Predictive Maintenance – Applications in Aircraft Engine Monitoring*. 2018, p. 14.
18. He, Y., Gu, C., Chen, Z., Han, X.: Integrated predictive maintenance strategy for manufacturing systems by combining quality control and mission reliability analysis. *Int. J. Prod. Res.*, t. 55, nr 19, paź. 2017, p. 5841÷5862.

19. Koochaki, J., Bokhorst, J.A.C., Wortmann, H., Klingenberg, W.: The influence of condition-based maintenance on workforce planning and maintenance scheduling. *Int. J. Prod. Res.*, t. 51, nr 8, kwi. 2013, p. 2339÷2351.
20. Fridholm, V.: IMPROVE MAINTENANCE EFFECTIVENESS AND EFFICIENCY BY USING HISTORICAL BREAKDOWN DATA FROM A CMMS : Exploring the possibilities for CBM in the Manufacturing Industry. 2018.
21. Rausand, M.: Reliability centered maintenance. *Reliab. Eng. Syst. Saf.*, t. 60, nr 2, maj 1998, p. 121÷132.
22. Bengtsson, M., Lundström, G.: On the importance of combining “the new” with “the old” – One important prerequisite for maintenance in Industry 4.0. *Procedia Manuf.*, t. 25, sty. 2018, p. 118÷125.
23. Moubray, J.: Reliability-centered Maintenance. Industrial Press Inc.2001.
24. Klimowski, M.: Diagnostyka łożysk tocznych silników elektrycznych przy wykorzystaniu metody analizy częstotliwościowej oraz metody detekcji obwiedni. *Zesz. Probl. Elektr.*, nr 2, 2014, p. 102.
25. Cempel, C.: Diagnostyka wibroakustyczna maszyn. Wydawnictwo Politechniki Poznańskiej1985.
26. Dwojak, J., Rzepiela, M.: Diagnostyka i obsługa techniczna łożysk tocznych: poradnik. Biuro Gamma2003.
27. Żółtowski, B., Cempel, C.: Inżynieria diagnostyki maszyn. Polskie Tow. Diagnostyki Technicznej2004.
28. Szymaniec, S.: MONITORING STANU TECHNICZNEGO NAPĘDÓW ELEKTRYCZNYCH W PRZEMYŚLE – DOŚWIADCZENIA WŁASNE. .
29. thingsboard/thingsboard. ThingsBoard - Open-source IoT Platform, 03-mar-2021.
30. MQTT - The Standard for IoT Messaging. [Online]. Dostępne: <https://mqtt.org/>. [Dostęp: 05-mar-2021].
31. MLflow - A platform for the machine learning lifecycle, *MLflow*. [Online]. Dostępne: <https://mlflow.org/>. [Dostęp: 12-mar-2021].
32. Borgi, T., Hidri, A., Neef, B., Naceur, M.S.: Data analytics for predictive maintenance of industrial robots. [w:] 2017 International Conference on Advanced Systems and Electric Technologies (IC_ASET), 2017, p. 412÷417.
33. Çınar, Z.M., Abdussalam Nuhu, A., Zeeshan, Q., i in.: Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0. *Sustainability*, t. 12, nr 19, sty. 2020, p. 8211.
34. Serradilla, O., Zugasti, E., Rodriguez, J., Zurutuza, U.: Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. *Appl. Intell.*, t. 52, nr 10, sie. 2022, p. 10934÷10964.
35. Pang, G., Shen, C., Cao, L., Hengel, A.V.D.: Deep Learning for Anomaly Detection: A Review. *ACM Comput. Surv.*, t. 54, nr 2, mar. 2021, p. 38:1-38:38.
36. Venkateswarlu, Y., Baskar, K., Wongchai, A., i in.: An Efficient Outlier Detection with Deep Learning-Based Financial Crisis Prediction Model in Big Data Environment. *Comput. Intell. Neurosci.*, t. 2022, sie. 2022, p. e4948947.
37. Chalapathy, R., Chawla, S.: Deep Learning for Anomaly Detection: A Survey. *arXiv*, 23-sty-2019.
38. Hesser, D.F., Markert, B.: Tool wear monitoring of a retrofitted CNC milling machine using artificial neural networks. *Manuf. Lett.*, t. 19, sty. 2019, p. 1÷4.

39. Luo, B., Wang, H., Liu, H., i in.: Early Fault Detection of Machine Tools Based on Deep Learning and Dynamic Identification. *IEEE Trans. Ind. Electron.*, t. 66, nr 1, sty. 2019, p. 509÷518.
40. Jimenez-Cortadi, A., Irigoien, I., Boto, F., i in.: Predictive Maintenance on the Machining Process and Machine Tool. *Appl. Sci.*, t. 10, nr 1, grudz. 2019, p. 224.
41. Luo, W., Hu, T., Ye, Y., i in.: A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. *Robot. Comput.-Integr. Manuf.*, t. 65, paź. 2020, p. 101974.
42. Biswal, S., Sabareesh, G.R.: Design and development of a wind turbine test rig for condition monitoring studies. [w:] 2015 International Conference on Industrial Instrumentation and Control (ICIC), Pune, India, 2015, p. 891÷896.
43. Canizo, M., Onieva, E., Conde, A., i in.: Real-time predictive maintenance for wind turbines using Big Data frameworks. [w:] 2017 IEEE International Conference on Prognostics and Health Management (ICPHM), Dallas, TX, USA, 2017, p. 70÷77.
44. Durbhaka, G.K., Selvaraj, B.: Predictive maintenance for wind turbine diagnostics using vibration signal analysis based on collaborative recommendation approach. [w:] 2016 International Conference on Advances in Computing, Communications and Informatics (ICACCI), Jaipur, India, 2016, p. 1839÷1842.
45. Eriksson, J.: Machine Learning for Predictive Maintenance on Wind Turbines : Using SCADA Data and the Apache Hadoop Ecosystem. 2020.
46. Zhang, Y., Liu, J., Hanachi, H., i in.: Physics-based Model and Neural Network Model for Monitoring Starter Degradation of APU. [w:] 2018 IEEE International Conference on Prognostics and Health Management (ICPHM), 2018, p. 1÷7.
47. Coraddu, A., Oneto, L., Ghio, A., i in.: Machine learning approaches for improving condition-based maintenance of naval propulsion plants. *Proc. Inst. Mech. Eng. Part M J. Eng. Marit. Environ.*, t. 230, nr 1, luty 2016, p. 136÷153.
48. Lacaille, J., Rabenoro, T.: A Trend Monitoring Diagnostic Algorithm for Automatic Pre-identification of Turbofan Engines Anomaly. [w:] 2018 Prognostics and System Health Management Conference (PHM-Chongqing), 2018, p. 819÷823.
49. Nguyen, K.T.P., Medjaher, K.: A new dynamic predictive maintenance framework using deep learning for failure prognostics. *Reliab. Eng. Syst. Saf.*, t. 188, sie. 2019, p. 251÷262.
50. Scalabrini Sampaio, G., Vallim Filho, A.R. de A., Santos da Silva, L., Augusto da Silva, L.: Prediction of Motor Failure Time Using An Artificial Neural Network. *Sensors*, t. 19, nr 19, sty. 2019, p. 4342.
51. Amruthnath, N., Gupta, T.: A research study on unsupervised machine learning algorithms for early fault detection in predictive maintenance. [w:] 2018 5th International Conference on Industrial Engineering and Applications (ICIEA), 2018, p. 355÷361.
52. Amihai, I., Gitzel, R., Kotriwala, A.M., i in.: An Industrial Case Study Using Vibration Data and Machine Learning to Predict Asset Health. [w:] 2018 IEEE 20th Conference on Business Informatics (CBI), 2018, t. 01, p. 178÷185.
53. Fernandes, S., Antunes, M., Santiago, A.R., i in.: Forecasting Appliances Failures: A Machine-Learning Approach to Predictive Maintenance. *Information*, t. 11, nr 4, kwi. 2020, p. 208.
54. Janssens, O., Loccupier, M., Van Hoecke, S.: Thermal Imaging and Vibration-Based Multisensor Fault Detection for Rotating Machinery. *IEEE Trans. Ind. Inform.*, t. 15, nr 1, sty. 2019, p. 434÷444.

55. Quiroz, J.C., Mariun, N., Mehrjou, M.R., i in.: Fault detection of broken rotor bar in LS-PMSM using random forests. *Measurement*, t. 116, luty 2018, p. 273÷280.
56. dos Santos, T., Ferreira, F.J.T.E., Pires, J.M., Damásio, C.: Stator winding short-circuit fault diagnosis in induction motors using random forest. [w:] *2017 IEEE International Electric Machines and Drives Conference (IEMDC)*, 2017, p. 1÷8.
57. Du, Y., Chen, Y., Meng, G., i in.: Fault Severity Monitoring of Rolling Bearings Based on Texture Feature Extraction of Sparse Time–Frequency Images. *Appl. Sci.*, t. 8, nr 9, wrz. 2018, p. 1538.
58. Ahmad, W., Khan, S.A., Islam, M.M.M., Kim, J.-M.: A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliab. Eng. Syst. Saf.*, t. 184, kwi. 2019, p. 67÷76.
59. Gebraeel, N., Lawley, M., Liu, R., Parmeshwaran, V.: Residual life predictions from vibration-based degradation signals: a neural network approach. *IEEE Trans. Ind. Electron.*, t. 51, nr 3, cze. 2004, p. 694÷700.
60. Korbicz, J., Kościelny, J.M., (Red.): *Modeling, Diagnostics and Process Control: Implementation in the DiaSter System*. Springer-Verlag, Berlin Heidelberg 2011.
61. Mazurkiewicz, D.: Computer-aided maintenance and reliability management systems for conveyor belts. *Ekspluat. Niezawodn.*, t. 16, sty. 2014, p. 377÷382.
62. Zio, E.: Some challenges and opportunities in reliability engineering. *IEEE Trans. Reliab.*, t. 65, nr 4, 2016, p. 1769÷1782.
63. Korbicz, J., Koscielny, J.M., Kowalczyk, Z., Cholewa, W.: *Fault diagnosis: models, artificial intelligence, applications*. Springer Science & Business Media 2012.
64. Wu, S., Zuo, M.J.: Linear and nonlinear preventive maintenance models. *IEEE Trans. Reliab.*, t. 59, nr 1, 2010, p. 242÷249.
65. Przystałka, P., Moczulski, W.: Methodology of neural modelling in fault detection with the use of chaos engineering. *Eng. Appl. Artif. Intell.*, t. 41, 2015, p. 25÷40.
66. Wachla, D., Moczulski, W.A.: Identification of dynamic diagnostic models with the use of methodology of knowledge discovery in databases. *Eng. Appl. Artif. Intell.*, t. 20, nr 5, 2007, p. 699÷707.
67. Heno, H., Capolino, G.-A., Fernandez-Cabanas, M., i in.: Trends in Fault Diagnosis for Electrical Machines: A Review of Diagnostic Techniques. *IEEE Ind. Electron. Mag.*, t. 8, nr 2, cze. 2014, p. 31÷42.
68. Zhang, K., Alqahtani, S., Demirbas, M.: A Comparison of Distributed Machine Learning Platforms. [w:] *2017 26th International Conference on Computer Communication and Networks (ICCCN)*, Vancouver, BC, Canada, 2017, p. 1÷9.
69. Roy, A., Qureshi, S., Pande, K., i in.: Performance Comparison of Machine Learning Platforms. *Inf. J. Comput.*, t. 31, nr 2, kwi. 2019, p. 207÷225.
70. Idoine, A.C., Krensky, P., Brethenoux, E., i in.: Magic Quadrant for Data Science and Machine-Learning Platforms. p. 40.
71. Baruti, R.: *Learning Alteryx: A beginner's guide to using Alteryx for self-service analytics and business intelligence*. Packt Publishing Ltd 2017.
72. *Self-Service Analytics, Data Science & Process Automation | Alteryx*. [Online]. Dostępne: <https://www.alteryx.com/>. [Dostęp: 12-luty-2022].
73. Bakos, G.: *KNIME Essentials*. Packt Publishing Ltd 2013.
74. *KNIME | Open for Innovation*. [Online]. Dostępne: <https://www.knime.com/>. [Dostęp: 12-luty-2022].
75. *Databricks - The Data and AI Company*. [Online]. Dostępne: <https://databricks.com/>. [Dostęp: 12-luty-2022].

76. Etaati, L.: Azure Databricks, [w:] Etaati, L. (Red.): Machine Learning with Microsoft Technologies: Selecting the Right Architecture and Tools for Your Project, Apress, Berkeley, CA , 2019, p. 159÷171.
77. Predictive Maintenance Software, *RapidMiner*. [Online]. Dostępne: <https://rapidminer.com/solutions/predictive-maintenance/>. [Dostęp: 28-luty-2023].
78. IoT Analytics for Manufacturing. [Online]. Dostępne: https://www.sas.com/pl_pl/industry/manufacturing/technology/iot.html. [Dostęp: 28-luty-2023].
79. martinekuan: Predictive maintenance - Azure Solution Ideas. [Online]. Dostępne: <https://learn.microsoft.com/en-us/azure/architecture/solution-ideas/articles/predictive-maintenance>. [Dostęp: 28-luty-2023].
80. martinekuan: Condition monitoring for industrial IoT - Azure Architecture Center. [Online]. Dostępne: <https://learn.microsoft.com/en-us/azure/architecture/solution-ideas/articles/condition-monitoring>. [Dostęp: 28-luty-2023].
81. khilscher: Azure industrial IoT guidance - Azure Architecture Center. [Online]. Dostępne: <https://learn.microsoft.com/en-us/azure/architecture/guide/iiot-guidance/iiot-architecture>. [Dostęp: 28-luty-2023].
82. BeanAir: Wireless Industrial IOT Sensors, *BeanAir*. [Online]. Dostępne: <https://www.beanair.com/index.html>. [Dostęp: 28-luty-2023].
83. WiMon Condition Monitoring System, *Oil & Gas*. [Online]. Dostępne: <https://new.abb.com/oil-and-gas/products/rotating-machines/wimon>. [Dostęp: 28-luty-2023].
84. Analyst - Condition monitoring (Instrumentation) | ABB. [Online]. Dostępne: <https://new.abb.com/power-generation/instrumentation/condition-monitoring/analyst>. [Dostęp: 28-luty-2023].
85. Machine Health Optimization. [Online]. Dostępne: <https://kcftech.com/>. [Dostęp: 28-luty-2023].
86. Wibro, *AMC VIBRO*. [Online]. Dostępne: <https://amcvibro.pl/products/wibro/>. [Dostęp: 28-luty-2023].
87. Baza wiedzy, *Queris - producent i dostawca systemów IT dla przemysłu*. .
88. RSIMS. Platforma analityki predykcyjnej i preskrypcyjnej | ReliaSol - Modele Predykcyjne i Platforma do Analityki Preskrypcyjnej, *ReliaSol*. .
89. Du, W., Li, A., Ye, P., Liu, C.: Fault diagnosis of plunger pump in truck crane based on relevance vector machine with particle swarm optimization algorithm. *Shock Vib.*, t. 20, nr 4, 2013, p. 781÷792.
90. Zuber, N., Bajrić, R., Šostakov, R.: Gearbox faults identification using vibration signal analysis and artificial intelligence methods. *Ekspluat. Niezawodn.*, t. 16, nr 1, 2014, p. 61÷65.
91. Peng, Z.K., Chu, F.L.: Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mech. Syst. Signal Process.*, t. 18, nr 2, 2004, p. 199÷221.
92. Yan, R., Gao, R.X., Chen, X.: Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal Process.*, t. 96, 2014, p. 1÷15.
93. Ye, Z., Wu, B., Zargari, N.: Online mechanical fault diagnosis of induction motor by wavelet artificial neural network using stator current. [w:] *Industrial Electronics Society, 2000. IECON 2000. 26th Annual Conference of the IEEE, 2000*, t. 2, p. 1183÷1188.

94. Hu, X., Ji, Y., Yu, W.: The application of wavelet singularity detection in fault diagnosis of high voltage breakers. [w:] Industrial Electronics Society, 2001. IECON'01. The 27th Annual Conference of the IEEE, 2001, t. 1, p. 490÷494.
95. Głowacz, A.: Diagnostics of direct current machine based on analysis of acoustic signals with the use of symlet wavelet transform and modified classifier based on words. *Eksploat. Niezawodn.*, t. 16, nr 4, 2014, p. 554÷558.
96. Antoni, J.: The spectral kurtosis: a useful tool for characterising non-stationary signals. *Mech. Syst. Signal Process.*, t. 20, nr 2, 2006, p. 282÷307.
97. Barszcz, T., Randall, R.B.: Application of spectral kurtosis for detection of a tooth crack in the planetary gear of a wind turbine. *Mech. Syst. Signal Process.*, t. 23, nr 4, 2009, p. 1352÷1365.
98. Wang, Y., Liang, M.: An adaptive SK technique and its application for fault detection of rolling element bearings. *Mech. Syst. Signal Process.*, t. 25, nr 5, 2011, p. 1750÷1764.
99. Samuel, P.D., Pines, D.J.: A review of vibration-based techniques for helicopter transmission diagnostics. *J. Sound Vib.*, t. 282, nr 1÷2, 2005, p. 475÷508.
100. Bartelmus, W., Zimroz, R.: Vibration condition monitoring of planetary gearbox under varying external load. *Mech. Syst. Signal Process.*, t. 23, nr 1, sty. 2009, p. 246÷257.
101. Bartelmus, W., Zimroz, R.: A new feature for monitoring the condition of gearboxes in non-stationary operating conditions. *Mech. Syst. Signal Process.*, t. 23, nr 5, 2009, p. 1528÷1534.
102. Osiński, Z.: *Teoria drgań*. Państw. Wydaw. Naukowe 1980.
103. Kucharski, T.: *System pomiaru drgań mechanicznych*. 2002, p. 1÷142.
104. Acar, C., Shkel, A.M.: Experimental evaluation and comparative analysis of commercial variable-capacitance MEMS accelerometers. *J. Micromechanics Microengineering*, t. 13, nr 5, maj 2003, p. 634÷645.
105. Varanis, M., Silva, A., Mereles, A., Pederiva, R.: MEMS accelerometers for mechanical vibrations analysis: a comprehensive review with applications. *J. Braz. Soc. Mech. Sci. Eng.*, t. 40, nr 11, paź. 2018, p. 527.
106. Gao, R., Li Zhang: Micromachined microsensors for manufacturing. *IEEE Instrum. Meas. Mag.*, t. 7, nr 2, cze. 2004, p. 20÷26.
107. Chu, A.: Accelerometer selection based on applications. *Endevco Tech. Pap.* TP291, 2012.
108. Cao, Y., Rong, X.L., Shao, S.J., He, K.P.: Present Situation and Prospects of Vibration Sensors. [w:] 2012 International Conference on Computer Distributed Control and Intelligent Environmental Monitoring, 2012, p. 515÷518.
109. Tomasini, E.P., Revel, G.M., Castellini, P.: Laser based measurement, *Encyclopaedia of Vibration*. London: Academic 2001.
110. Castellini, P., Martarelli, M., Tomasini, E.P.: Laser Doppler Vibrometry: Development of advanced solutions answering to technology's needs. *Mech. Syst. Signal Process.*, t. 20, nr 6, sie. 2006, p. 1265÷1285.
111. Feng, D., Feng, M.Q.: Experimental validation of cost-effective vision-based structural health monitoring. *Mech. Syst. Signal Process.*, t. 88, maj 2017, p. 199÷211.
112. Baqersad, J., Poozesh, P., Niezrecki, C., Avitabile, P.: Photogrammetry and optical methods in structural dynamics – A review. *Mech. Syst. Signal Process.*, t. 86, mar. 2017, p. 17÷34.
113. Yang, Y., Dorn, C., Mancini, T., i in.: Blind identification of full-field vibration modes from video measurements with phase-based video motion magnification. *Mech. Syst. Signal Process.*, t. 85, luty 2017, p. 567÷590.

114. ADXL355 Datasheet and Product Info | Analog Devices. [Online]. Dostępne: <https://www.analog.com/en/products/adx1355.html#>. [Dostęp: 09-paź-2020].
115. LS, LSH, LSP, *Saft Batteries | We energize the world.*, 19-maj-2017. [Online]. Dostępne: <https://www.saftbatteries.com/products-solutions/products/ls-lsh-lsp>. [Dostęp: 15-kwi-2021].
116. Naik, N.: Choice of effective messaging protocols for IoT systems: MQTT, CoAP, AMQP and HTTP. [w:] 2017 IEEE International Systems Engineering Symposium (ISSE), 2017, p. 1÷7.
117. Timescale Docs. [Online]. Dostępne: <https://docs.timescale.com/>. [Dostęp: 02-mar-2023].
118. Apache Cassandra | Apache Cassandra Documentation. [Online]. Dostępne: https://cassandra.apache.org/_/index.html. [Dostęp: 02-mar-2023].
119. thingsboard: What is ThingsBoard IoT Gateway?, *ThingsBoard*. [Online]. Dostępne: <https://thingsboard.io/docs/iot-gateway/what-is-iot-gateway/>. [Dostęp: 08-mar-2023].
120. Shelby, Z., Hartke, K., Bormann, C.: The Constrained Application Protocol (CoAP). [Online]. Dostępne: <https://tools.ietf.org/html/rfc7252>. [Dostęp: 05-mar-2021].
121. Mana, S.C.: BIG DATA PARADIGM AND A SURVEY OF BIG DATA SCHEDULERS. *Int. J. Comput. Eng. Technol.*, t. 8, nr 5, 2017, p. 11÷14.
122. Grafana: The open observability platform, *Grafana Labs*. [Online]. Dostępne: <https://grafana.com/>. [Dostęp: 12-mar-2021].
123. ShinyProxy. [Online]. Dostępne: /. [Dostęp: 12-mar-2021].
124. Keycloak. [Online]. Dostępne: <https://www.keycloak.org/>. [Dostęp: 12-mar-2021].
125. ELK Stack: Elasticsearch, Logstash, Kibana. [Online]. Dostępne: <https://www.elastic.co/what-is/elk-stack>. [Dostęp: 12-mar-2021].
126. Apache Spark™ - Unified Engine for large-scale data analytics. [Online]. Dostępne: <https://spark.apache.org/>. [Dostęp: 18-sie-2022].
127. Production-Grade Container Orchestration, *Kubernetes*. [Online]. Dostępne: <https://kubernetes.io/>. [Dostęp: 18-sie-2022].
128. Therneau, T., Atkinson, B., port, B.R. (producer of the initial R., maintainer 1999-2017): rpart: Recursive Partitioning and Regression Trees. 21-paź-2022.
129. Breiman, L.: Random Forests. *Mach. Learn.*, t. 45, nr 1, paź. 2001, p. 5÷32.
130. Schimek, M.G.: Smoothing and Regression: Approaches, Computation, and Application. John Wiley & Sons 2013.
131. Fang, Y., Rasel, M. a. k., Richmond, P.C.: A stylized trend analysis approach for process monitoring and fault diagnosis. *Process Saf. Prog.*, t. 37, nr 3, 2018, p. 411÷418.
132. Francis, F., Mohan, M.: ARIMA Model based Real Time Trend Analysis for Predictive Maintenance. [w:] 2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA), 2019, p. 735÷739.
133. Kenmei, B., Antoniol, G., di Penta, M.: Trend Analysis and Issue Prediction in Large-Scale Open Source Systems. [w:] 2008 12th European Conference on Software Maintenance and Reengineering, 2008, p. 73÷82.
134. Guo, P., Infield, D., Yang, X.: Wind Turbine Generator Condition-Monitoring Using Temperature Trend Analysis. *IEEE Trans. Sustain. Energy*, t. 3, nr 1, sty. 2012, p. 124÷133.
135. Hadjiski, M.B., Doukowska, L.A., Kojnov, S.L.: Nonlinear Trend Analysis of Mill Fan System Vibrations for Predictive Maintenance and Diagnostics. *Int. J. Electron. Telecommun.*, t. 58, nr 4, grudz. 2012, p. 351÷356.

136. Lahdelma, S., Juuso, E.: Trend analysis in condition monitoring of process equipments. [w:] 8th International Conference on Condition Monitoring and Machinery Failure Prevention Technologies, CM, 2011.
137. Juuso, E., Box, P.O.: Intelligent Trend Indices and Recursive Modelling in Prognostics.
138. Miller, J.R.: Results using trend analysis for predicting automotive maintenance needs. [w:] Proceedings, IEEE AUTOTESTCON, 2002, p. 809÷817.
139. Maurya, M.R., Rengaswamy, R., Venkatasubramanian, V.: Fault diagnosis using dynamic trend analysis: A review and recent developments. Eng. Appl. Artif. Intell., t. 20, nr 2, mar. 2007, p. 133÷146.
140. Mudelsee, M.: Trend analysis of climate time series: A review of methods. Earth-Sci. Rev., t. 190, mar. 2019, p. 310÷322.
141. Myrhorod, V., Hvozdeva, I., Derenh, Y.: Two-dimensional trend analysis of time series of complex technical objects diagnostic parameters. AIP Conf. Proc., t. 2164, nr 1, paź. 2019, p. 060013.
142. Na, I.Y., Chang, W.: Multi-system reliability trend analysis model using incomplete data with application to tank maintenance. Qual. Reliab. Eng. Int., t. 33, nr 8, 2017, p. 2385÷2395.
143. Grubbs, F.E.: Procedures for Detecting Outlying Observations in Samples. Technometrics, t. 11, nr 1, luty 1969, p. 1÷21.
144. Hawkins, D.M.: Identification of Outliers. Springer Netherlands, Dordrecht 1980.
145. Sinha, S.K.: Outliers in Statistical Data (Vic Barnett and Toby Lewis). SIAM Rev., t. 21, nr 4, paź. 1979, p. 2.
146. Boukerche, A., Zheng, L., Alfandi, O.: Outlier Detection: Methods, Models, and Classification. ACM Comput. Surv., t. 53, nr 3, cze. 2020, p. 55:1-55:37.
147. Barnett, V., Lewis, T.: Outliers in statistical data. t. 3, Wiley New York 1994.
148. Rosner, B.: Percentage Points for a Generalized ESD Many-Outlier Procedure. Technometrics, t. 25, nr 2, maj 1983, p. 165÷172.
149. Breunig, M.M., Kriegel, H.-P., Ng, R.T., Sander, J.: LOF: identifying density-based local outliers. [w:] Proceedings of the 2000 ACM SIGMOD international conference on Management of data, New York, NY, USA, 2000, p. 93÷104.
150. RKOF: Robust Kernel-Based Local Outlier Detection | SpringerLink. [Online]. Dostępne: https://link.springer.com/chapter/10.1007/978-3-642-20847-8_23. [Dostęp: 03-kwi-2023].
151. Ester, M., Kriegel, H.-P., Sander, J., Xu, X.: A density-based algorithm for discovering clusters in large spatial databases with noise. [w:] kdd, 1996, t. 96, nr 34, p. 226÷231.
152. Liu, F.T., Ting, K.M., Zhou, Z.-H.: Isolation Forest. [w:] 2008 Eighth IEEE International Conference on Data Mining, 2008, p. 413÷422.
153. Boser, B.E., Guyon, I.M., Vapnik, V.N.: A training algorithm for optimal margin classifiers. [w:] Proceedings of the fifth annual workshop on Computational learning theory, 1992, p. 144÷152.
154. Schölkopf, B., Williamson, R.C., Smola, A., i in.: Support Vector Method for Novelty Detection. [w:] Advances in Neural Information Processing Systems, 1999, t. 12.
155. Portela, E., Ribeiro, R.P., Gama, J.: The search of conditional outliers. Intell. Data Anal., t. 23, nr 1, sty. 2019, p. 23÷39.
156. He, Y., Zhao, J.: Temporal Convolutional Networks for Anomaly Detection in Time Series. J. Phys. Conf. Ser., t. 1213, nr 4, cze. 2019, p. 042050.

157. Hochreiter, S., Schmidhuber, J.: Long Short-Term Memory. *Neural Comput.*, t. 9, nr 8, lis. 1997, p. 1735÷1780.
158. Lindemann, B., Maschler, B., Sahlab, N., Weyrich, M.: A survey on anomaly detection for technical systems using LSTM networks. *Comput. Ind.*, t. 131, paź. 2021, p. 103498.
159. Carrasco, J., López, D., Aguilera-Martos, I., i in.: Anomaly detection in predictive maintenance: A new evaluation framework for temporal unsupervised anomaly detection algorithms. *Neurocomputing*, t. 462, paź. 2021, p. 440÷452.
160. Histogram-based outlier score (HBOS) - Google Scholar. [Online]. Dostępne: https://scholar.google.com/scholar?hl=pl&as_sdt=0%2C5&q=Histogram-based+outlier+score+%28HBOS%29&btnG=. [Dostęp: 04-kwi-2023].
161. Pevný, T.: Loda: Lightweight on-line detector of anomalies. *Mach. Learn.*, t. 102, nr 2, luty 2016, p. 275÷304.
162. Zhao, Y., Hryniewicki, M.K.: XGBOD: Improving Supervised Outlier Detection with Unsupervised Representation Learning. [w:] 2018 International Joint Conference on Neural Networks (IJCNN), 2018, p. 1÷8.
163. De Benedetti, M., Leonardi, F., Messina, F., i in.: Anomaly detection and predictive maintenance for photovoltaic systems. *Neurocomputing*, t. 310, paź. 2018, p. 59÷68.
164. Santolamazza, A., Cesarotti, V., Introna, V.: Anomaly detection in energy consumption for Condition-Based maintenance of Compressed Air Generation systems: an approach based on artificial neural networks. *IFAC-Pap.*, t. 51, nr 11, sty. 2018, p. 1131÷1136.
165. Jakubowski, J., Stanisław, P., Bobek, S., Nalepa, G.J.: Explainable anomaly detection for Hot-rolling industrial process. [w:] 2021 IEEE 8th International Conference on Data Science and Advanced Analytics (DSAA), 2021, p. 1÷10.
166. Holzinger, A., Saranti, A., Molnar, C., i in.: Explainable AI Methods - A Brief Overview, [w:] Holzinger, A., Goebel, R., Fong, R., i in. (Red.): *xxAI - Beyond Explainable AI: International Workshop, Held in Conjunction with ICML 2020, July 18, 2020, Vienna, Austria, Revised and Extended Papers, Lecture Notes in Computer Science*, Springer International Publishing, Cham, 2022, p. 13÷38.
167. Gunning, D., Stefik, M., Choi, J., i in.: XAI—Explainable artificial intelligence. *Sci. Robot.*, t. 4, nr 37, grudz. 2019, p. eaay7120.
168. Gunning, D., Aha, D.: DARPA's Explainable Artificial Intelligence (XAI) Program. *AI Mag.*, t. 40, nr 2, cze. 2019, p. 44÷58.
169. Christ, M., Braun, N., Neuffer, J., Kempa-Liehr, A.W.: Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package). *Neurocomputing*, t. 307, wrz. 2018, p. 72÷77.
170. Cao, H., Si, G., Zhang, Y., Jia, L.: Enhancing effectiveness of density-based outlier mining scheme with density-similarity-neighbor-based outlier factor. *Expert Syst. Appl.*, t. 37, nr 12, grudz. 2010, p. 8090÷8101.
171. Powers, D.M.W.: Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation. *arXiv*, 10-paź-2020.
172. Van Rossum, G., Drake, F.L.: Python reference manual. Centrum voor Wiskunde en Informatica Amsterdam 1995.
173. McKinney, W.: Data Structures for Statistical Computing in Python. zaprezentowano na Python in Science Conference, Austin, Texas, 2010, p. 56÷61.
174. Pedregosa, F., Varoquaux, G., Gramfort, A., i in.: Scikit-learn: Machine Learning in Python. *Mach. Learn. PYTHON*.
175. Lundberg, S.M., Lee, S.-I.: A Unified Approach to Interpreting Model Predictions. [w:] *Advances in Neural Information Processing Systems*, 2017, t. 30.

176. Klopp, E.: A tutorial on testing the equality of standardized regression coefficients in structural equation models using Wald tests with lavaan. *PsyArXiv*, t. 10, 2019.
177. Campello, R.J.G.B., Moulavi, D., Sander, J.: Density-Based Clustering Based on Hierarchical Density Estimates. [w:] *Advances in Knowledge Discovery and Data Mining*, Berlin, Heidelberg, 2013, p. 160÷172.
178. Szczyrba, K., Sikora, M., Wróbel, \Lukasz: Monitoring and diagnostics of a belt conveyor based on a wireless system for measurement and analysis of the vibrations level. *Stud. Inform.*, t. 39, 2018.
179. Sikora, M., Szczyrba, K., Wróbel, \Lukasz, Michalak, M.: Monitoring and maintenance of a gantry based on a wireless system for measurement and analysis of the vibration level. *Eksploat. Niezawodn.*, t. 21, nr 2, 2019, p. 341÷350.
180. Hermansa, M., Kozielski, M., Michalak, M., i in.: Sensor-based predictive maintenance with reduction of false alarms—A case study in heavy industry. *Sensors*, t. 22, nr 1, 2021, p. 226.

SPIS ILUSTRACJI

Rys. 1 Krzywa PF (ang. Potential to Functional Failure) [23].	13
Rys. 2 Schemat blokowy architektury systemu.	17
Rys. 3 Architektura systemu.	18
Rys. 4 Fazy komunikacji radiowej czujników z Transceiverami: 1 – wybudzenie czujnika, 2 – cykl pomiarowy, 3 – transmisja wyników pomiarów, 4 – tryb nasłuchu radiowego, 5 – wejście w tryb uśpienia, 6 – żądanie zmiany parametrów konfiguracyjnych czujnika, 7 – potwierdzenie zmiany parametrów, 8 – tryb nasłuchu radiowego, 9 – wejście w tryb uśpienia.	21
Rys. 5 Schemat ogólny architektury systemu.	23
Rys. 6 Uproszczona budowa akcelerometru MEMS.	32
Rys. 7 Schemat blokowy przetwornika ADXL 355 [114].	34
Rys. 8 Bezprzewodowy prędkości obrotowej.	36
Rys. 9 Sonda pomiarowa bezprzewodowego czujnika natężenia prądu.	37
Rys. 10 Bezprzewodowy czujnik ciśnienia i temperatury.	37
Rys. 11 Bezprzewodowy czujnik wilgotności i temperatury.	38
Rys. 12 Charakterystyka rozładowania ogniwa LS 14250 w temperaturze pokojowej [115].	40
Rys. 13 Pojemność ogniwa LS 14250 w funkcji prądu obciążenia [115].	40
Rys. 14 Schemat blokowy czujnika bezprzewodowego w wersji bazowej.	41
Rys. 15 Pobór prądu przez czujnik WS-VT1 w cyklach: a) pomiarowym, b) transmisyjnym.	42
Rys. 16 Prognoza zużycia baterii dla czujnika WS-VT1 w zależności od częstości cykli pomiarowych.	44
Rys. 17 Napięcie baterii czujnika WS-VT1 zastosowanego w systemie monitorowania pomp agregatu hydraulicznego (wykres przedstawia dobowe agregaty napięcia maksymalnego – kolor niebieski, średniego – kolor brązowy, minimalnego – kolor zielony).	45
Rys. 18 Schemat blokowy czujnika bezprzewodowego z wdrożoną strategią redukcji poboru mocy.	47
Rys. 19 Porównanie czasu pracy czujników WS-VT1 przed i po wdrożeniu strategii redukcji poboru mocy.	48
Rys. 20 Algorytm zliczania wydatku energii czujnika.	49
Rys. 21 Schemat blokowy transceivera radiowego typu ITR-2.	50
Rys. 22 Schemat blokowy lokalnej stacji diagnostycznej typu LDS.	51
Rys. 23 Lokalna Stacja Diagnostyczna z przykładową planszą platformy wizualizacji.	52
Rys. 24 Sekwencja wymiany danych z wykorzystaniem protokołu MQTT.	53
Na Rysunku 25 zaprezentowano schemat architektury warstwy programowej systemu, składowe Silnik Analityczny i Baza Analityczna są rozwiązaniami wytworzonymi od podstaw, natomiast pozostałe składniki zrealizowano w oparciu o ThB.	55
Rys. 26 Schemat blokowy warstwy programowej.	56
Pozyskiwanie surowych danych do platformy realizowane jest za pośrednictwem warstwy transportowej. Schemat architektury warstwy transportowej przedstawia na Rys. 27.	56
Rys. 28 Schemat blokowy warstwy transportowej platformy ThigsBoard [119].	57
Rys. 29 Przykładowa definicja łańcucha reguł.	59
Rys. 30 Przykład zbiorczej planszy wizualizacyjnej.	61
Rys. 31 Prezentacja danych telemetrycznych przykładowego punktu pomiarowego.	62
Rys. 32 Ogólny schemat modułu analitycznego.	63

Rys. 33 Wizualizacja przykładowych procesów realizowanych przez moduł MLFlow.	65
Rys. 34 Schemat bazy danych.	69
Rys. 35 Tabela model z przykładową zawartością.	70
Rys. 36 Definicja atrybutów tabeli dataset.	71
Rys. 37 Suwnica bramowa 500T.	72
Rys. 38 Widok przekładni mechanizmu widny suwnicy.	73
Rys. 39 Lokalizacja punktów pomiarowych na mechanizmie suwnicy.	73
Rys. 40 Architektura systemu pomiarowego suwnicy bramowej.	74
Rys. 41 Okno wizualizacji pomiarów dla grupy czujników – widoczne są bieżące pomiary (tablica wartości), alarmy oraz pomiary historyczne (na rysunku pomiary z ostatnich dwóch godzin).	75
Rys. 42 Przykład identyfikacji cykli pracy suwnicy – szare obszary oznaczają zidentyfikowane cykle pracy.	77
Rys. 43 Drzewo decyzyjne do identyfikacji pustych i pełnych przejazdów suwnicy.	78
Rys. 44 Wykres monitorowania wartości VibrMax2000_Q3 – suwnica 1. Wykres górny: wartości oryginalne (niebieski), wartości wygładzone (czerwony) oraz poziom <i>cvl</i> . Wykres dolny: wartości wskaźnika Δi generowane na podstawie analizy trendu wykonanej w oparciu o 3, 7 i 14 poprzednich dni pracy suwnicy.	84
Rys. 45 Wykres monitorowania wartości VibrMax2000_Q3 – suwnica 2. Wykres górny: wartości oryginalne (niebieski), wartości wygładzone (czerwony) oraz poziom <i>cvl</i> . Wykres dolny: wartości wskaźnika Δi generowane na podstawie analizy trendu wykonanej w oparciu o 3, 7 i 14 poprzednich dni pracy suwnicy.	87
Rys. 46 Wykres monitorowania wartości VibrMax2000_P95 – suwnica 2. Wykres górny: wartości oryginalne (niebieski), wartości wygładzone (czerwony) oraz poziom <i>cvl</i> . Wykres dolny: wartości wskaźnika Δi generowane na podstawie analizy trendów wykonanej w oparciu o 3, 7, 14 poprzednich dni pracy suwnicy.	88
Rys. 47 Fragment schematu instalacji nawęglania kotła fluidalnego.	90
Rys. 48 Kruszarka typu Mud Hog produkcji BJD Crushers Ltd.	91
Rys. 49 Łożysko typu SNH 520-617 produkcji SKF (źródło - karta katalogowa producenta).	92
Rys. 50 Schemat blokowy przebiegu właściwego etapu metody diagnostycznej.	96
Rys. 51 Wykres czasowy danych syntetycznych eksperymentu.	100
Rys. 52 Wykres czasowy danych surowych dla kruszarki NW-10.	101
Rys. 53 Ilustracja procesu wstępnego przetwarzania danych z kruszarki NW-10.	103
Rys. 54 Wykres wartości wszystkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych NW-10).	108
Rys. 55 Wykres wartości wszystkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych NW-20).	108
Rys. 56 Wykres wartości wszystkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych syntetycznych).	109
Rys. 57 Wykres wartości wszystkich miar (P, N i Score) w kolejnych oknach agregacji – metoda stosująca jako bazowy algorytm HDBSCAN (zbiór danych S-202).	110
Rys. 58 Wykres kaskadowy wyjaśnień SHAP dla indywidualnej predykcji anomalii (przypadek prawdziwie pozytywny) — wyjaśnienie dotyczy miejsca zaznaczonego czerwoną linią prostą na Rys. 59.	112
Rys. 59 Wybrany fragment wykresu najważniejszych cech wskazanych przez metodę objaśniającą na Rys. 58. (zbiór danych kruszarki NW 10).	112

Rys. 60 Wykres kaskadowy wyjaśnień SHAP dla indywidualnej identyfikacji anomalii (przypadek fałszywie dodatni) — wyjaśnienie dotyczy przykładu zaznaczonego czerwoną linią prostą na Rys. 61 (zbiór danych kruszarki NW-10).	113
Rys. 61 Wybrany fragment wykresu najważniejszych cech wskazanych przez metodę objaśniającą na Rys. 60.....	114