

Zintegrowany system predykcji i detekcji usterek urządzeń chłodniczych z wykorzystaniem bezprzewodowych sensorów IoT i algorytmów sztucznej inteligencji

Piotr Szydłowski, Karol Zaręba, Bartosz Kozłowski

Efento Sp. z o.o., ul. Przemysłowa 12, 30-701 Kraków

Piotr A. Kowalski

Akademia Górniczo-Hutnicza, Wydział Fizyki i Informatyki Stosowanej, al. Mickiewicza 30, 30-059 Kraków

Streszczenie: W artykule zaprezentowano kompleksowe podejście do projektowania i wdrażania systemu wykrywania oraz predykcji usterek urządzeń chłodniczych, opartego na bezprzewodowych sensorach Internetu Rzeczy i algorytmach sztucznej inteligencji. Zaproponowany system umożliwia wczesne wykrywanie awarii sprzętu chłodniczego, takich jak usterki wentylatorów, sprężarki czy sterownika, co w praktyce pozwala ograniczyć przestoje oraz zminimalizować straty wynikające z uszkodzeń urządzeń i przechowywanych w nich produktów. Rozwiązanie zrealizowano w architekturze rozproszonej, z przesyłem danych pomiarowych do chmury obliczeniowej, gdzie odbywa się ich analiza. Do opracowania modeli diagnostycznych użyto różnych sieci neuronowych, a najlepsze wyłoniono na podstawie analizy skuteczności klasyfikacyjnej i wydajności obliczeniowej. System składa się z klasyfikatora ogólnego wykrywającego odstępstwa od normalnej pracy oraz zestawu detektorów przypisanych konkretnym typom usterek. Przeprowadzone testy na danych rzeczywistych oraz symulowanych potwierdziły wysoką skuteczność detekcji – dokładność klasyfikatora ogólnego i detektorów dedykowanych przekroczyła 98 % w większości scenariuszy. Artykuł kończy się wskazaniem możliwych kierunków dalszego rozwoju, w tym adaptacji systemu do innych klas urządzeń oraz optymalizacji liczby sensorów w celu redukcji kosztów wdrożenia.

Słowa kluczowe: sztuczna inteligencja, Internet Rzeczy, predykcyjne utrzymanie ruchu, urządzenia chłodnicze, sensory bezprzewodowe

1. Wprowadzenie

Internet Rzeczy (IoT) zyskał w ostatnich latach popularność. Stosowany w wielu sektorach przemysłu, umożliwia zdalne monitorowanie urządzeń i procesów w czasie rzeczywistym. Zwiększająca się ilość danych generowanych przez urządzenia IoT stawia przed naukowcami i inżynierami wyzwania związane z ich efektywnym przetwarzaniem, analizą i wykorzystaniem do podejmowania decyzji w oparciu o konkretne wnioski. W odpowiedzi na te potrzeby rozwijane są zaawanso-

wane systemy analizy danych oparte na sztucznej inteligencji, które coraz częściej pozwalają nie tylko na detekcję anomalii ale również na predykcyjne utrzymanie ruchu (ang. *predictive maintenance*). Takie podejście przynosi duże oszczędności wynikające przede wszystkim z braku przestojów spowodowanych awariami oraz ograniczeniem strat materialnych będących następstwem awarii. Systemy wykrywania oraz prognozowania awarii oparte o urządzenia Internetu Rzeczy są z powodzeniem wdrażane do w wielu zastosowań. Jako przykłady przywołać można monitoring floty autobusów miejskich [1], monitoring sprzętu medycznego [2], monitoring maszyn przemysłowych [3], a nawet monitoring elektrowni [4].

W artykule przedstawiono zaprojektowany oraz zaimplementowany autorski system wykrywania zarówno usterek jak i zbliżających się usterek sprzętu chłodniczego oparty o bezprzewodowe sensory IoT oraz algorytmy sztucznych sieci neuronowych. Autorzy zaprezentowali zbiór poszczególnych, uniwersalnych kroków umożliwiających zaprojektowanie takiego systemu do praktycznie dowolnych zastosowań.

Struktura artykułu złożona jest z kilku rozdziałów. W Rozdziale 2 omówiono główne założenia systemu, w tym wyzwania

Autor korespondujący:

Piotr Szydłowski, piotr.szydowski@efento.pl

Artykuł recenzowany

nadesłany 12.05.2025 r., przyjęty do druku 16.01.2026 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 4.0 Int.

związane z detekcją usterek w systemach chłodniczych. Przegląd najczęstszych awarii sprzętu chłodniczego oraz metod ich wykrywania został opisany w Rozdziale 3. Kolejny rozdział opisuje system pomiarowy użyty do gromadzenia danych, z uwzględnieniem charakterystyki rejestratorów i sposobu integracji z modulem analitycznym pracującym w chmurze. W Rozdziale 5 przedstawiono opis badań nad optymalizacją modeli sztucznych sieci neuronowych do wykrywania usterek na podstawie danych historycznych i w czasie rzeczywistym. Przedostatni rozdział zawiera analizę uzyskanych wyników, w tym skuteczność i dokładność systemu w różnych scenariuszach testowych. Artykuł kończy się podsumowaniem, gdzie zidentyfikowano kluczowe wnioski oraz wskazano kierunki dalszych prac nad rozwojem systemu.

2. Główne założenia systemu i wyzwania związane z detekcją usterek w systemach chłodniczych

Głównym celem opracowanej procedury było zwiększenie niezawodności sprzętu chłodniczego przez implementację systemów predykcyjnej konserwacji, które umożliwiają identyfikację potencjalnych problemów przed ich eskalacją do poważnych awarii. Takie podejście pozwala na redukcję kosztów eksploatacyjnych, minimalizację przestojów oraz ograniczenie strat wynikających z niewłaściwego działania systemów chłodniczych, szczególnie w krytycznych zastosowaniach, takich jak przechowywanie żywności i leków [5]. W efekcie uzyskano rozwiązanie, którego cena i złożoność instalacji są na tyle niskie, że mogą być stosowane w jak największej liczbie lodówek czy lad chłodniczych.

2.1. Wyzwania w detekcji usterek systemów chłodniczych

Punktem wyjścia przeprowadzonych prac są nie tylko liczne rozmowy z praktykami utrzymania ruchu i serwisu chłodniczego, ale także krytyczna analiza wniosków z trzech uzupełniających się nurtów literatury: przekrojowych wyzwań predykcyjnej konserwacji [6], ramy decyzji w utrzymaniu opartym na kondycji (CBM) [7] oraz lekkiej detekcji anomalii w strumieniach danych czujnikowych przetwarzanych w trybie on-line [8]. Prowadzą one do wniosku, że skuteczność rozwiązań dla instalacji chłodniczych zależy w równym stopniu od inżynierii danych i operacjonalizacji decyzji, a także od samego wyboru algorytmu: należy pogodzić heterogeniczne, sezonowe strumienie pomiarów z wymaganiami przetwarzania na brzegu sieci i zrozumiałą, kosztowo ugruntowaną logiką alarmowania.

Z perspektywy przeglądu wyzwań predykcyjnej konserwacji [6] kluczowe jest opanowanie heterogeniczności i zmienności danych: temperatury (medium i otoczenia), prądu/energii, opcjonalnie ciśnień oraz sygnałów stanów (np. cykli odszraniania), mierzonych z różnymi częstotliwościami i obciążonych szumem. W chłodnictwie wyzwanie to potęgują reżimy pracy – chłodzenie, odszranianie, rozruch – które generują sygnatury, które mogą być mylone z anomaliami, choć mieszczą się w normie eksploatacyjnej. Zgodnie z [6] przyjęto warstwę wstępnego przetwarzania obejmującą harmonizację częstotliwości, filtrację artefaktów, normalizację per reżim oraz monitoring dryfu danych w statystykach cech.

Ramy CBM [7] przypominają, że detektor to tylko połowa układu: decyzja serwisowa musi uwzględniać koszty fałszywych alarmów i opóźnień, okna serwisowe oraz różnorodność scenariuszy awarii. Dla chłodnictwa oznacza to progi i eskalacje zależne od kontekstu (od ostrzeżeń po alarmy krytyczne), walidowane osobno dla reżimów pracy i pór roku. Wprowadzono zatem funkcję kosztu wiążącą sygnał modelu z decyzją operacyjną oraz mechanizm szybkiej kalibracji lokalnej, który pozwala przenosić

modele między placówkami o odmiennych charakterystykach cieplnych. Tam, gdzie to potrzebne, odniesiono progi do uzgodnionych umów o poziomie usług.

Wreszcie, paradygmat detekcji anomalii online [8] wskazuje, że w rozproszonych instalacjach o zmiennej łączności przewagę daje lekkość obliczeniowa i przetwarzanie brzegowe: aktualizacja parametrów „w locie”, niskie zużycie zasobów oraz minimalizacja ruchu sieciowego przez raportowanie zdarzeń zamiast pełnych strumieni surowych danych. Został zastosowany dwuetapowy tor: (i) reguły maskujące znane stany operacyjne (np. odszranianie, przełączenia trybów), (ii) strumieniową detekcję odchyśleń z krótkimi oknami aktualizacji, co skraca czas do alarmu i redukuje liczbę fałszywych wzbudzeń podczas typowych zjawisk przejściowych.

Na tej podstawie zostają uporządkowane najważniejsze wyzwania specyficzne dla systemów chłodniczych – od złożoności układów, przez jakość i różnorodność danych, po konieczność dostosowania modeli sztucznej inteligencji do realnych warunków operacyjnych. Najważniejszym z nich jest złożoność systemów chłodniczych. Wydajność i poprawność pracy urządzenia zależy od wielu współzależnych komponentów. Awarie mogą wynikać zarówno z problemów mechanicznych, jak i elektrycznych, co utrudnia jednoznaczną diagnozę. Drugim wyzwaniem jest poprawność i jakość danych pomiarowych. Dane gromadzone przez sensory Internetu Rzeczy (IoT) mogą być obciążone szumem, co wymaga wstępnego przetwarzania w celu zapewnienia ich jakości [9]. Następnym wyzwaniem jest różnorodność danych i scenariuszy awarii, w szczególności w systemach chłodniczych różne typy awarii (np. wyciek czynnika chłodniczego, problemy z kompresorem czy błędy w sterowaniu) generują odmienne wzorce danych. Stworzenie uniwersalnego modelu detekcji wymaga uwzględnienia tej różnorodności. Ostatnim ze zidentyfikowanych wyzwań jest dostosowanie modelu AI do środowiska operacyjnego – modele uczenia maszynowego muszą być odpowiednio skalibrowane do specyficznych warunków pracy danego urządzenia, takich jak zmienne obciążenia czy różne konfiguracje systemów.

2.2. Główne założenia system detekcji

Biorąc pod uwagę omówione cele i wyzwania zdecydowano się na następujące założenia:

- Nie jest możliwe wykrycie/predykcja każdego rodzaju usterek, dlatego skupiono się na najważniejszych usterekach, biorąc pod uwagę częstość ich występowania i skutki.
- Przetwarzanie danych i ich analiza musi odbywać się po stronie serwera. Umożliwia to zastosowanie maksymalnie uproszczonych urządzeń IoT, których zadanie polega jedynie na wykonywaniu pomiarów i transmisji danych.
- Liczba punktów pomiarowych niezbędnych do wykrywania/przewidywania awarii powinna być jak najmniejsza, natomiast instalacja urządzeń jak najprostsza. Ograniczenie liczby punktów pomiarowych nie powinno mieć wpływu na rozpoznawanie wzorców awarii.
- Wzorec usterek powinien być wykrywany i rozpoznawany jak najwcześniej, aby dać użytkownikom odpowiednio długi czas na reakcję. Ze względu na charakter procesu, czas od momentu pojawienia się pierwszych symptomów awarii do momentu jej wystąpienia jest na ogół dość długi, co umożliwia przesyłanie danych w większych interwałach czasowych.

3. Przegląd najczęstszych awarii sprzętu chłodniczego oraz metod ich wykrywania

W celu zdefiniowania najczęstszych przyczyn awarii poddano analizie protokoły serwisowe jednego z krajowych producen-

Tabela 1. Analiza częstości występowania poszczególnych rodzajów usterek sprzętu chłodniczego na podstawie protokołów serwisowych zgromadzonych w latach 2011–2019 przez jednego z krajowych producentów sprzętu chłodniczego
Table 1. Analysis of the frequency of different types of refrigeration equipment failures based on service reports collected between 2011 and 2019 by one of the domestic refrigeration equipment manufacturers

Usterka	Czy usterka jest związana z układem chłodzenia?	Częstość występowania w zbiorze wszystkich usterek (%)	Częstość występowania w zbiorze usterek układu chłodzenia (%)
Awaria wentylatora/wentylatorów	Tak	29,1	35,2
Awaria sprężarki	Tak	22,1	26,7
Awaria oświetlenia	Nie	13,3	–
Awaria sterownika	Tak	12,0	14,5
Awaria czujnika temperatury	Tak	10,4	12,5
Awaria grzałki odparowywania skroplin	Tak	8,1	9,7
Awaria elektrozaworu	Nie	2,6	–
Awaria ogrzewania szyb	Nie	1,4	–
Nieszczelność	Tak	1,1	1,3

tów sprzętu chłodniczego zgromadzone w latach 2011–2019. Awarie podzielono na awarie układu chłodzenia i pozostałe, które nie mają wpływu na funkcje chłodnicze urządzenia (np. awaria oświetlenia, uszkodzenia mechaniczne wynikające ze złego użytkowania). Wyniki analizy usterek zaprezentowano w Tabeli 1.

Dla każdej z usterek określono potencjalne skutki jej wystąpienia: niskie – brak wpływu na produkty i urządzenie; średnie

– brak wpływu na produkty, niewielki wpływ na urządzenie; wysokie – wpływ na produkty i urządzenie. Następnie utworzono macierz ryzyka.

Na podstawie przeprowadzonych analiz zdecydowano, że system wyposażony w algorytmy sztucznej inteligencji powinien przewidywać lub wykrywać następujące awarie: awaria wentylatora/wentylatorów, awaria sprężarki, awaria sterownika, awaria czujnika temperatury, awaria grzałki odparowywania skroplin. Wybrane awarie stanowią 98,7 % wszystkich awarii chłodzenia oraz 81,6 % wszystkich awarii.

Dla każdej z wybranych awarii na podstawie rozmów z ekspertami z branży oraz testów określono przyczyny usterek, następstwa, wpływ na zmiany parametrów pracy oraz sposób prognozowania/wykrycia w oparciu o zmiany parametrów pracy.

3.1. Awaria wentylatorów


Awaria polega na zmniejszeniu wydajności lub całkowitym zatrzymaniu pracy wentylatorów. Najczęściej wynika to ze zużycia łożysk wentylatorów. Czasami dochodzi również do ich zalania z winy użytkownika. Awarie wentylatorów można podzielić na:

- awarie wentylatora zamontowanego w komorze agregatu, który pracuje jako wentylator skraplacza,
- awarie wentylatora parownika generującego ruch powietrza w części przechowalniczej urządzenia.

Objawami awarii wentylatora parownika jest wzrost temperatury wewnątrz części przechowalniczej, spadek temperatury parownika oraz zmiana parametrów drgań wraz ze zużyciem łożysk. W następstwie awarii wentylatora komory agregatu ciepło nie jest odprowadzane z komory agregatu/skraplacza, co powoduje również wzrost temperatury wewnątrz komory agregatu. Długoterminowo prowadzi do uszkodzeń pozostałych elementów urządzenia znajdujących się w komorze agregatu.

3.2. Awaria sprężarki

Awaria polega na całkowitej lub częściowej utracie wydajności chłodniczej sprężarki. Ponieważ sprężarka jest zamknięta w hermetycznej obudowie nie da się określić, który z jej elementów uległ awarii. W następstwie usterek sprężarki następuje wzrost temperatury w części przechowalniczej oraz wzrost temperatury parownika.



Rys. 1. Macierz ryzyka prezentująca prawdopodobieństwo wystąpienia usterek i jej potencjalne skutki. Kolorem żółtym zaznaczono awarie układu chłodzenia, kolorem białym pozostałe awarie. 1 – Awaria wentylatora/wentylatorów, 2 – Awaria sprężarki, 3 – Awaria oświetlenia, 4 – Awaria sterownika, 5 – Awaria czujnika temperatury, 6 – Awaria grzałki odparowywania skroplin, 7 – Awaria elektrozaworu, 8 – Awaria ogrzewania szyb, 9 – Nieszczelność
Fig. 1. Risk matrix showing the probability of failure occurrence and its potential consequences. Cooling system failures are marked in yellow, while other failures are marked in white. 1 – Fan failure, 2 – Compressor failure, 3 – Lighting failure, 4 – Controller failure, 5 – Temperature sensor failure, 6 – Condensate evaporation heater failure, 7 – Solenoid valve failure, 8 – Glass heating failure, 9 – Leakage

3.3. Awaria sterownika

Sterownik zarządza pracą sprężarki oraz wentylatorów. Awaria sterownika sprowadza się do awarii któregoś z przełączników i skutkuje brakiem włączenia wentylatora/wentylatorów lub sprężarki. Awarii przełącznika nie da się przewidzieć – działanie przełączników jest zero-jedynkowe. Jeżeli awarii uległ przełącznik sterujący pracą wentylatora parownika to następuje wzrost temperatury w części przechowalniczej i spadek temperatury parownika. W przypadku awarii przełącznika kontrolującego wentylator komory agregatu następuje wzrost temperatury wewnątrz komory agregatu. Z kolei awaria przełącznika sterującego sprężarką objawia się przez wzrost temperatury w części przechowalniczej oraz wzrost temperatury parownika. Ze względu na specyfikę tych usterek nie jest możliwe ich przewidywanie, a jedynie wykrywanie.

3.4. Awaria czujnika temperatury

Czujnik temperatury zamontowany jest w części przechowalniczej i wykorzystywany jest do pomiaru temperatury tamże. Odczyty wykonane przez czujnik temperatury wykorzystywane są do sterowania pracą urządzenia. Najczęstszą awarią czujników temperatury jest mechaniczne uszkodzenie przez użytkownika. Objawami usterki są całkowity brak odczytu temperatury albo pomiary, których wartości są nierealne. Uniemożliwia to poprawną pracę sterownika – regulację pracy wentylatorów i sprężarki, a w konsekwencji zmianę temperatury w części przechowalniczej. Ze względu na specyfikę tej usterki nie jest możliwe jej przewidywanie, a jedynie wykrycie.

3.5. Awaria grzałki odparowywania skroplin

Grzałka odparowywania skroplin jest niezbędnym elementem urządzenia chłodniczego. Jest ona umieszczona jest w pojemniku na skropliny i umożliwia zbieranie się w nim kondensatu z procesu odszraniania, a następnie jego odparowanie. Awaria grzałki odparowywania skroplin skutkuje wyciekami kondensatu z urządzenia. W efekcie awarii spada efektywność chłodzenia, co powoduje wzrost temperatury w części przechowalniczej i widoczną zmianę w zużyciu energii elektrycznej przez urządzenie. Ze względu na specyfikę tej usterki nie jest możliwe jej przewidywanie, a jedynie wykrycie.

Na podstawie znanych objawów potencjalnych usterek określone zostały punkty w urządzeniu chłodniczym, które należy monitorować: temperatura i wilgotność w komorze agregatu, temperatura i wilgotność w części przechowalniczej, temperatura i wilgotność otoczenia, temperatura skraplacza, wibracje wentylatora skraplacza, wibracje wentylatora parownika oraz zużycie energii elektrycznej przez urządzenie chłodnicze.


4. System pomiarowy

4.1. Charakterystyka wykorzystanych rejestratorów

Do realizacji pomiarów wykorzystano system pomiarowy złożony z rejestratorów bezprzewodowych. Głównym kryterium doboru rejestratorów była ich niezawodność, dokładność pomiarów oraz możliwość długiej pracy przy zasilaniu bateryjnym. Pierwotnie system składał się z rejestratorów temperatury, wilgotności oraz zużycia energii elektrycznej.

Mimo że część usterek objawia się zmianą charakterystyki drgań wentylatorów wraz ze zużyciem łożysk, zdecydowaliśmy się nie używać rejestratorów wibracji do diagnostyki stanu pracy urządzenia. Wynika to z faktu, że rejestratory te generują bardzo duże ilości danych, co utrudnia ich wysyłkę do serwera. Z kolei analiza danych w pamięci rejestratorów wymagałaby zastosowania znacznie mocniejszych platform sprzętowych, co prowadziłoby do wzrostu kosztów wdrożenia systemu.

Aby zebrać dane pomiarowe i przeprowadzić eksperymenty, zbudowano układ pomiarowy dla urządzenia chłodniczego Juka Vienna [20] (rys. 2). Urządzenie składa się z części przechowalniczej, w której utrzymywana jest zadana temperatura do przechowywania produktów, oraz z komory agregatu (sprężarki, sterownik, wentylatory, moduł zasilania). Podczas eksperymentów w urządzeniu umieszczono sondy pomiarowe zgodnie z wymaganiami, tak aby rejestrowane były zarówno temperatury w części przechowalniczej, jak i w kluczowych punktach elementów komory agregatu (rys. 3).



Rys. 2. Urządzenie chłodnicze wraz z oznaczeniem monitorowanych parametrów. Komora agregatu oznaczona na czerwono, część przechowalnicza na niebiesko

Fig. 2. Refrigeration device with indication of the monitored parameters. Unit chamber marked with red, storage compartment marked with blue



Rys. 3. Wnętrze komory agregatu z zaznaczonym umiejscowieniem sond temperatury (1, 2, 3)

Fig. 3. Inside the compressor chamber with marked locations of temperature probes (1, 2, 3)

Pomiary temperatury wykonywane były przez rejestratory oparte na czujnikach cyfrowych charakteryzują się wysoką dokładnością w zakresie od $-40\text{ }^{\circ}\text{C}$ do $+85\text{ }^{\circ}\text{C}$, z błędem pomiaru nieprzekraczającym $0,5\text{ }^{\circ}\text{C}$. Do monitorowania wilgotności zastosowano rejestrator wyposażony w czujnik mierzący wilgotność względną w zakresie $0-95\%$, z błędem pomiaru nieprzekraczającym 4% . Dokładność pomiarów rejestratorów temperatury i wilgotności została potwierdzona przez akredytowane laboratorium wzorcowujące. Zużycie energii elektrycznej monitorowane było przez licznik wykonujący pomiar z rozdzielczością 1 Wh . Wszystkie rejestratory wykonywały pomiar co minutę.

4.2. Architektura systemu pomiarowego

System pomiarowy został zaprojektowany w architekturze rozproszonej, gdzie poszczególne moduły pomiarowe komunikują się z bramką (ang. *gateway*) za pomocą protokołu Bluetooth Low Energy (BLE). Wybór tej technologii podyktowany był jej niskim zapotrzebowaniem na energię oraz wystarczającym zasięgiem do opomiarowania pojedynczych instalacjach chłodniczych. Protokół BLE zapewnia również stabilną komunikację w środowisku przemysłowym, gdzie mogą występować zakłócenia radiowe [10].

Bramka systemu została wyposażona w moduł komunikacyjny NB-IoT (ang. *Narrowband Internet of Things*), umożliwiający przesyłanie zgromadzonych danych do chmury obliczeniowej. Ta technika komunikacji została wybrana ze względu na jej energooszczędność, szeroki zasięg oraz zdolność do działania w trudnych warunkach, gdzie tradycyjne sieci komórkowe mogą mieć ograniczony zasięg [11]. Bramka wyposażona jest w lokalną pamięć buforową, zabezpieczającą dane w przypadku czasowej utraty łączności z serwerem. Każdy moduł pomiarowy posiada unikalny numer seryjny, co pozwala na jednoznaczną identyfikację źródła danych oraz ułatwia konfigurację systemu.

Ponieważ urządzenia pomiarowe zasilane są bateryjnie szczególną uwagę poświęcono optymalizacji zużycia energii przez moduły pomiarowe. Zastosowano adaptacyjny algorytm doboru częstotliwości transmisji danych, który dostosowuje ich intensywność do dynamiki mierzonych parametrów. W okresach stabilnej pracy układu chłodniczego częstotliwość transmisji jest zmniejszana, co znacząco wydłuża czas pracy urządzeń bez konieczności wymiany baterii.

4.3. Walidacja i przetwarzanie danych pomiarowych

W celu maksymalnego uproszczenia konstrukcji rejestratorów, a przez to minimalizację kosztów wdrożenia systemu zdecydowano nie przetwarzać danych pomiarowych po stronie rejestratorów/bramki. Dane przesyłane są do platformy chmurowej, gdzie następuje ich przetwarzanie.

Rejestratory wykonują jedynie walidację wartości pomiarów – zastosowano algorytm weryfikacji poprawności pomiaru oraz detekcji wartości odstających, co pozwala na eliminację błęd-

nych odczytów już na poziomie akwizycji danych. Każdy pomiar opatrzony jest znacznikiem czasowym oraz informacją o statusie sensora, co umożliwia weryfikację wiarygodności danych. Dodatkowo system pomiarowy wyposażono w mechanizmy auto-diagnostyki, które monitorują stan baterii, jakość połączenia bezprzewodowego oraz poprawność działania rejestratorów.

4.4. Integracja z systemem analitycznym

Dane pomiarowe przesyłane są do chmury obliczeniowej, gdzie podlegają dalszemu przetwarzaniu przez algorytmy sztucznej inteligencji. Opracowano dedykowane API, które zapewnia dwukierunkową komunikację między systemem pomiarowym a modulem analitycznym i oprócz przyjmowania danych pomiarowych umożliwia zdalną zmianę ustawień rejestratorów. System umożliwia również konfigurację progów alarmowych oraz definiowanie reguł powiadamiania użytkowników, które mogą być modyfikowane zdalnie w zależności od specyfiki zastosowania.


Opracowana architektura systemu pomiarowego (rys. 4) stanowi podstawę do implementacji algorytmów detekcji anomalii i predykcji awarii, które zostaną omówione w kolejnym rozdziale.

5. Sposób przygotowania modeli sztucznych sieci neuronowych do predykcji i detekcji awarii w systemach chłodniczych

W tym rozdziale zaprezentowano etapy, których realizacja pozwoliła opracować model systemu umożliwiającego wczesne wykrywanie potencjalnych usterek urządzenia chłodniczego.

5.1. Dobór wektora cech (symptomów) dla systemu analitycznego

Dane zbierane przez system pomiarowy zapisywane są w bazie danych w postaci szeregu czasowego składającego się z wartości zmierzonych przez poszczególne sensory. Przykładowy wektor wejściowy prezentuje Tabela 2.




Rys. 4. Schemat architektury rozwiązania systemu pomiarowego zintegrowanego z systemem analitycznym
Fig. 4. Diagram of the architecture of the measurement system integrated with the analytical system

Tabela 2. Przykładowe dane wejściowe do systemu analitycznego zebrane przez system pomiarowy. Oznaczenia kolumn: A – temperatura w komorze agregatu, B – wilgotność w komorze agregatu, C – temperatura otoczenia, D – wilgotność otoczenia, E – zużycie energii elektrycznej, F – temperatura w chłodziarce, G – temperatura - sonda nr 1, H – temperatura - sonda nr 2, I – temperatura - sonda nr 3
Table 2. Sample input data for the analytical system collected by the measurement system. Column labels: A – Temperature in the compressor chamber, B – Humidity in the compressor chamber, C – Ambient temperature, D – Ambient humidity, E – Electrical energy consumption, F – Temperature in the cooler, G – Temperature - probe no. 1, H – Temperature - probe no. 2, I – Temperature - probe no. 3

A	B	C	D	E	F	G	H	I
34,4	29	24,7	51	540	7,3	72,8	42	18,3
34,5	29	24,7	51	660	7	75,6	42,3	17,8
34,8	29	24,7	51	660	6,8	76,1	42,1	17,5
35,1	29	24,8	51	600	6,4	76,4	42,1	17,2
35,4	29	24,8	51	540	6,5	72	40,1	16,8
35,4	28	24,8	51	120	6,8	60,7	39,4	16,9
35,1	28	24,8	51	60	7,1	52,4	39	17,7
34,8	28	24,7	51	120	7,3	46,9	38,6	18,6
34,4	29	24,8	51	300	7,4	68,7	41,2	18,6
34,4	29	24,8	51	600	7,1	74,9	42,3	17,9

Wstępna analiza wektorów składających się z wartości zmierzonych w dziewięciu kluczowych punktach systemu chłodniczego ujawniła, że nie wszystkie parametry wejściowe charakteryzują się jednakowo istotną wartością prognostyczną.
Zauważono, że niektóre parametry, takie jak temperatura otoczenia (C) i wilgotność otoczenia (D), mają znikomy wpływ na wzorce awarii. Ta obserwacja stanowiła podstawę do przeprowadzenia analizy statystycznej mającej na celu optymalizację wektora wejściowego. Szczególny nacisk położono na identyfikację zmiennych wykazujących statystycznie istotne różnice między stanem normalnej (poprawnej) pracy, a stanami świadczącymi o zbliżającej się awarii i stanami awaryjnymi.
Analiza miała na celu redukcję liczby wymiarów przy jednoczesnym zachowaniu maksymalnej informatywności zbioru danych. W przypadku systemów pomiarowych składających się

z sensorów bezprzewodowych umożliwia to ograniczenie liczby urządzeń pomiarowych i ilości transmitowanych danych, co bezpośrednio przekłada się na koszty wdrożenia. Ograniczenie parametrów wejściowych powinno też skutkować ograniczeniem szumu pomiarowego i zwiększeniem efektywności obliczeniowej modelu, a w efekcie poprawą zdolności generalizujących systemu wykrywania potencjalnych awarii.
W trakcie analizy danych brano pod uwagę zgromadzone dane historyczne, uwzględniające zarówno okresy normalnej pracy urządzeń chłodniczych, jak i zarejestrowane stany świadczące o potencjalnych awariach.
Pierwszym krokiem było opracowanie macierzy korelacji poszczególnych pomiarów. Na ich podstawie stwierdzono, które parametry wejściowe są skorelowane ze sobą, przez co użycie obu takich parametrów do detekcji potencjalnych awarii nie wnosi



Rys. 5. Macierze korelacji dla pomiarów zgromadzonych w trakcie poprawnej pracy urządzenia chłodniczego (strona lewa) i we wzorcu poprzedzającym awarię wentylatora komory agregatu (strona prawa)
Fig. 5. Correlation matrices for measurements collected during the normal operation of the refrigeration unit (left side) and in the pattern preceding the fan failure in the compressor chamber (right side)

dużej wartości prognostycznej. Macierze korelacji zostały opracowane zarówno dla pracy normalnej jak i w momencie wystąpienia wzorców poprzedzających awarię. Przykładowe macierze korelacji dla pomiarów zgromadzonych w trakcie pracy normalnej i dla wzorca poprzedzającego awarię wentylatora komory agregatu zaprezentowano na rys. 5.

Dodatkowo opracowano histogramy zawierające wartości pomiarów poszczególnych kanałów w trakcie pracy normalnej i w momentach poprzedzających awarię.

Przeprowadzona analiza wykazała, że pięć spośród dziewięciu pierwotnie rozważanych parametrów zawiera większość niezbędnych informacji diagnostycznych umożliwiających wykrycie nieprawidłowej pracy urządzenia chłodniczego. Zidentyfikowane parametry o najwyższej wartości prognostycznej obejmują: temperaturę w komorze agregatu (A), wilgotność w komorze agregatu (B) oraz wskazania trzech sond pomiarowych (G, H, I).

Wybrane parametry charakteryzują się reprezentatywną kombinacją czułości na zmiany stanu systemu chłodniczego i szybkiej reakcji na pojawiające się anomalie, a dodatkowo cechują się wyraźnym zróżnicowaniem wartości między stanem normalnym, a stanami awaryjnymi.

W wyniku przeprowadzonej analizy możliwe było zredukowanie pierwotnego wektora cech danych wejściowych przedstawionego w Tabeli 2. do postaci przedstawionej w Tabeli 3., co wiązało się ze znaczącą redukcją złożoności obliczeniowej modelu

Tabela 3. Wektor wejściowy systemu analitycznego po ograniczeniu wymiarowości
Table 3. Input vector for the analytical system after dimensionality reduction

A	B	G	H	I
34,4	29	72,8	42	18,3
34,5	29	75,6	42,3	17,8
34,8	29	76,1	42,1	17,5
...	...	...	...	...


przy jednoczesnym zachowaniu jego wysokiej skuteczności diagnostycznej.

5.2. Architektura systemu detekcji anomalii i predykcji awarii


W trakcie prac badawczych rozważano trzy modele detekcji usterek:

- 1. model z jednym detektorem wykrywającym i klasyfikującym wszystkie wzorce usterek,
- 2. model zawierający zbiór detektorów, z których każdy wykrywa jeden wzorec usterek,
- 3. model zbudowany na bazie ogólnego klasyfikatora stanu pracy urządzenia („praca poprawna” lub „praca niepoprawna”), a w przypadku wykrycia nieprawidłowości dalszą analizę wzorca za pomocą detektorów dedykowanych do wykrywania wzorca konkretnej usterek.

Po przeprowadzeniu testów skuteczności detekcji oraz wydajności opisanych wyżej modeli wybrano architekturę opartą na modelu trzecim. Do jego największych zalet należą szybkość reakcji i wysoka wydajność. Dane otrzymane z systemu pomiarowego przetwarzane są przez jedną sieć neuronową klasyfikującą wzorce „praca poprawna”/„praca niepoprawna”, a detektory wzorców poszczególnych potencjalnych usterek uruchamiane są dopiero w wyniku wykrycia odstępstw od poprawnej pracy. Dodatkowo zastosowanie takiego modelu umożliwia wykrywanie praktycznie wszystkich nieprawidłowości w pracy urządzenia, nie tylko zdefiniowane wcześniej wzorce zbliżających się usterek. W przypadku wystąpienia jakiegokolwiek odstępstwa od poprawnej pracy (opisane wyżej rodzaje usterek, których nie da się prognozować, a jedynie wykryć - awaria sterownika, awaria czujnika temperatury, awaria grzałki odparowywania skroplin) klasyfikator stanu pracy urządzenia wykrywa, że praca urządzenia jest niepoprawna mimo że system analityczny nie jest w stanie jednoznacznie przypisać wzorca do konkretnej usterek. Takie podejście minimalizuje ryzyko uszkodzenia produktów przechowywanych w urządzeniu chłodniczym i zwiększa korzyści z wdrożenia rozwiązania. Schemat blokowy przyjętej architektury systemu detekcji anomalii i predykcji awarii zaprezentowano na rys. 7.



Rys. 6. Histogramy zawierające dane pomiarowe ze wszystkich kanałów w trakcie pracy normalnej (strona lewa) i w momentach poprzedzających awarię wentylatora komory agregatu (strona prawa)
Fig. 6. Histograms containing measurement data from all channels during normal operation (left side) and moments preceding the fan failure in the compressor chamber (right side)



Rys. 7. Schemat blokowy algorytmu wykrywania usterek urządzenia w oparciu o ogólny klasyfikator stanu pracy urządzenia i detektory dedykowane

Fig. 7. Block diagram of the device fault detection algorithm based on a general device operating state classifier and dedicated detectors

5.3. Wybór architektury i trening sztucznych sieci neuronowych

W celu wyboru modelu do detekcji anomalii w pracy urządzeń chłodniczych przetestowano modele oparte na czterech przykładach architektury sieci neuronowych, które charakteryzują się odmiennymi właściwościami w zakresie rozpoznawania wzorców diagnostycznych:

1. Sieci konwolucyjne (CNN) – wybrane ze względu na ich zdolność ekstrakcji lokalnych wzorców co jest kluczowe w detekcji charakterystycznych sygnatur anomalii w wielowymiarowych danych pomiarowych [12];
2. Sieci rekurencyjne (RNN) – implementowane w celu modelowania dynamicznych zależności w sekwencjach czasowych parametrów diagnostycznych, co umożliwia uwzględnienie ewolucji stanu systemu chłodniczego w czasie [13];
3. Sieci LSTM (ang. *Long Short-Term Memory*) – zastosowane z uwagi na ich zdolność do modelowania długoterminowych zależności temporalnych przy jednoczesnym eliminowaniu problemu zanikającego gradientu, typowego dla klasycznych RNN [14];
4. Sieci GRU (ang. *Gated Recurrent Unit*) – wybrane jako potencjalnie efektywniejsza obliczeniowo alternatywa dla LSTM, zachowująca podobne właściwości w zakresie modelowania zależności temporalnych [15].

Eksperymenty przeprowadzono w środowisku Python 3.10.11, natomiast do przetwarzania i wizualizacji danych zastosowano biblioteki *pandas 1.3.5*, *matplotlib 3.5.2* oraz *seaborn 0.11.2*, natomiast do klasycznych procedur uczenia maszynowego — *scikit-learn 1.0.2*. Modele oparte na sieciach neuronowych trenowano w TensorFlow 2.9.1 (API *tf.keras*). Strumienie pomiarowe były wstępnie oczyszczane (usuwanie braków i artefaktów), synchronizowane czasowo i normalizowane; stany eksploatacyjne typowe dla chłodnictwa (np. odszranianie) były maskowane na etapie przygotowania cech, aby ograniczyć wpływ zjawisk przejściowych na proces uczenia. Uczenie prowadzono z użyciem optymalizatora Adam; w zadaniach klasyfikacyjnych wykorzystywano funkcję straty *binary cross-entropy* oraz metryki AUC, Precision i Recall, a w zadaniach regresyjnych — odpowiednio MSE/MAE. Stabilność estymacji zapewniono za pomocą walidacji krzyżowej z utrzymaniem proporcji klas (stratyfikacja); monitorowano stratę walidacyjną i stosowano wczesne zatrzymanie (ang. *early stopping*) wraz z zapisem najlepszego wariantu modelu (ang. *model checkpoint*). Parametry treningowe (m.in. szybkość uczenia, liczba epok, rozmiar partii) były dobierane empirycznie w oparciu o wyniki walidacyjne.

Po przeprowadzeniu wstępnych testów ustalono, że najbardziej obiecującymi strukturami neuronowymi są sieci ze sprzężeniem zwrotnym – LSTM oraz GRU i to właśnie na nich skupiono się w dalszej części badań. Dokładnej analizie poddano jednowarstwową sieć LSTM, wielowarstwową sieć LSTM, jednowarstwową sieć GRU i wielowarstwową sieć GRU.


Architektura modelu jednowarstwowej sieci LSTM składała się łącznie z pięciu warstw: warstwa normalizacyjna dopasowana do wielkości wektora wejściowego, warstwa LSTM o rozmiarze 100, dropout 50 % mający za zadanie przeciwdziałać zbyt niemu dopasowaniu się sieci do zbioru uczącego (ang. *overfitting*) [16], gęsta warstwa klasyfikacyjna o rozmiarze 100 oraz warstwa wyjściowa. Wielowarstwową sieć LSTM składała się z warstwy normalizacyjnej, a następnie czterech warstw LSTM o rozmiarze 50 przeplatanych warstwami dropout 40 %. Ostatnią warstwą modelu była warstwa gęsta o rozmiarze 1. Sieci jednowarstwowe i wielowarstwowe GRU miały dokładnie tę samą strukturę, z tą różnicą, że warstwy LSTM zastąpione warstwami GRU.

Zbiór danych uczących składał się ze wzorców pracy poprawnej oraz wzorców poprzedzających usterkę/świadczących o usterce. Wzorce awarii przyporządkowane były do poszczególnego rodzaju usterki i w odpowiedni sposób oznaczone. Przykładowy przebieg pomiarów świadczących o potencjalnej awarii wentylatora parownika przedstawia rys. 8.


Zbiory uczące zostały przygotowane osobno dla każdej z trenowanych sieci neuronowych. Do zbiorów uczących wykorzystanych do szkolenia detektorów dedykowanych poszczególnym rodzajom usterek włączono wzorce innych usterek jako wzorce

reprezentujące poprawną pracę urządzenia chłodniczego. Na przykład, model dedykowany do wykrywania awarii wentylatora komory agregatu był trenowany na zbiorze zawierającym jako przykłady negatywne: wzorce poprawnej pracy urządzenia, wzorce świadczące o usterce wentylatora parownika, wzorce świadczące o usterce sprężarki. Celem takiego podejścia było nauczenie detektorów lepszego różnicowania poszczególnych typów usterek i zmniejszenie liczby fałszywych alarmów. Zbiór uczący zastosowany do treningu klasyfikatora ogólnego zawierał wzorce poprawnej pracy urządzenia – przykłady negatywne oraz wzorce wszystkich rodzajów awarii – przykłady pozytywne. Łącznie w zbiorze uczącym znajdowało się ponad 500 wektorów prezentujących zarówno poprawną pracę urządzenia, jak i każdą z analizowanych awarii.


Do oceny modeli zastosowano metodę walidacji krzyżowej (ang. *cross-validation*) [17] z parametrem $fold = 5$, co oznacza, że dane były dzielone na pięć równych części, gdzie w każdej iteracji 80 % danych używano do treningu, a 20 % do walidacji. Dodatkowo dla każdego rodzaju sieci i dla każdego rodzaju usterek przeprowadzono testy długości wektora wejściowego (2, 5, 10 i 31 minut). Najlepsze rezultaty uzyskano dla wektora wejściowego zawierającego pomiary z 10 minut. Najgorsze rezultaty z kolei osiągały modele trenowane z użyciem wektorów wejściowych zawierających pomiary z 2 i 5 minut. Wynika to prawdopodobnie z tego, że takie serie są za krótkie, żeby uchwycić trend awarii. Modele wytrenowane na wektorach wejściowych zawierające pomiary z 31 minut również dawały gorsze wyniki od tych wytrenowanych na wektorach zawierających pomiary



Rys. 8. Przykładowy wzorzec pomiarów świadczących o potencjalnej awarii wentylatora parownika
Fig. 8. Exemplary measurement pattern indicating a potential evaporator fan failure



Rys. 9. Wartość funkcji straty w zależności od epoki dla jednowarstwowej sieci LSTM i wektora uczącego zawierającego pomiary z 10 minut
Fig. 9. Loss function value depending on the epoch for a single-layer LSTM network and a training vector containing 10-minute measurements



Rys. 10. Wartość funkcji straty w zależności od epoki dla jednowarstwowej sieci LSTM i wektora uczącego zawierającego pomiary z 31 minut
Fig. 10. Loss function value depending on the epoch for a single-layer LSTM network and a training vector containing 31-minute measurements

z 10 minut. Przedstawiają to rys. 9 i 10, które prezentują wartość funkcji straty w zależności od epoki dla wielowarstwowej sieci LSTM wytrenowanej do wykrywania awarii wentylatora komory agregatu.

Opisane etapy przeprowadzono dla detektorów każdej z usterek. Po zakończeniu procesu nauki dla każdej z usterek i każdego z czterech modeli sieci neuronowych (LSTM jednowarstwowa, LSTM wielowarstwowa, GRU jednowarstwowa, GRU wielowarstwowa) opracowano macierze pomyłek. Następnie korzystając z analizy Precision-Recall [18] na podstawie macierzy pomyłek wybrano najlepsze modele do detekcji poszczególnych usterek:

- Awaria wentylatora komory agregatu – wielowarstwowa sieć LSTM – skuteczność rozpoznawania usterek: 0,99, precyzja i czułość powyżej 0,99 na zbiorze testowym

- Awaria wentylatora parownika – wielowarstwowa sieci GRU – skuteczność rozpoznawania usterek: 0,97, precyzja 0,99, czułość 0,975 na zbiorze testowym
- Awaria sprężarki – jednowarstwowa sieć GRU – skuteczność rozpoznawania usterek: 0,99, precyzja i czułość powyżej 0,99 na zbiorze testowym

Po dobraniu modeli sieci neuronowych pracujących jako detektory dedykowane każdej z usterek i zakończeniu procesu trenowania opracowano finalny model systemu analitycznego poprzez połączenie ich z ogólnym klasyfikatorem stanu pracy urządzenia (zgodnie ze schematem z rys. 7). Następnie system analityczny został połączony przez API z systemem pomiarowym, co umożliwiło zasilanie go danymi pomiarowymi. Uzyskane rezultaty zostały zaprezentowane w Rozdziale 6.

Tabela 4. Wyniki klasyfikacji wzorców poszczególnych awarii jako poprawnej lub niepoprawnej pracy przez system analityczny
Table 4. Classification results of fault patterns as correct or incorrect operation by the analytical system

Rodzaj usterek	TP	FP	FN	TN	Dokładność	Precyzja	Czułość	F1	Swoistość
Wentylator komory agregatu	1386	0	0	567	1,0000	1,0000	1,0000	1,0000	1,0000
Wentylator komory parownika	3129	0	1	1011	0,9998	1,0000	0,9997	0,9998	1,0000
Sprężarka	1540	0	10	500	0,9951	1,0000	0,9935	0,9968	1,0000
Praca normalna	0	0	0	1643	1,0000	–	–	–	1,0000

Tabela 5. Wyniki klasyfikacji wzorców przez detektor dedykowany wykrywaniu usterek wentylatora komory agregatu
Table 5. Classification results of patterns by the dedicated detector for detecting the fan failure in the compressor unit chamber

Usterka	TP	FP	FN	TN	Dokładność	Precyzja	Czułość	F1	Swoistość
Wentylator komory parownika	0	1	0	3128	0,9997	0	–	0	0,9997
Sprężarka	0	0	0	1540	1,0000	–	–	–	1,0000
Wentylator komory agregatu	1386	0	0	0	1,0000	1,0000	1,0000	1,0000	–
Praca normalna	0	0	0	0	–	–	–	–	–

6. Wyniki testów systemu analitycznego

Testy systemu detekcji usterek oraz potencjalnych usterek przeprowadzone były na danych historycznych nie wykorzystanych w procesie trenowania detektorów oraz na danych otrzymywanych przez system na bieżąco z opomiarowanego urządzenia chłodniczego, na którym symulowano różnego rodzaju usterek m.in. przez wymianę poszczególnych części na zużyte czy przez ograniczanie przepływu powietrza przez wentylatory.

Detekcja pracy poprawnej i niepoprawnej

Jak wspomniano, przed próbą rozpoznania wzorca potencjalnej usterki system analityczny klasyfikuje otrzymany wzorec jako pracę poprawną lub niepoprawną. Dopiero w przypadku wykrycia pracy niepoprawnej uruchamiane są pozostałe detektory w celu identyfikacji usterki. Wyniki działania detektora ogólnego zaprezentowano w Tabeli 4. Dla każdej z trzech usterek oraz pracy normalnej podane zostały liczby poprawnych klasyfikacji (TP – prawdziwie pozytywne, TN – prawdziwie negatywne) oraz liczby błędnych klasyfikacji (FP – fałszywie pozytywne, FN – fałszywie negatywne).

W przypadku wykrycia nieprawidłowej pracy urządzenia chłodniczego aktywowano detektory poszczególnych rodzajów usterek w celu identyfikacji wzorca i określenia rodzaju usterki. Wyniki pracy poszczególnych detektorów prezentują Tabele 5–7.

Analizując wyniki należy zwrócić uwagę, że detektory usterki wentylatora parownika i usterki sprężarki błędnie klasyfikowały niektóre wzorce. Detektor dedykowany wykrywaniu usterki wentylatora parownika błędnie klasyfikował usterkę sprężarki jako usterkę wentylatora parownika (FP) oraz nie klasyfikował usterki wentylatora parownika (FN). Natomiast detektor usterki sprężarki nie klasyfikował części usterek sprężarki (FN). Wynika to najprawdopodobniej z cyklicznego mechanizmu odszraniania urządzenia chłodniczego, które nakłada się i zmienia standardowe wzorce awarii. Jeśli po wykryciu nieprawidłowej pracy przez klasyfikator ogólny dwa lub więcej detektory dedykowane zgłosiły usterkę lub żaden detektor nie zgłosił usterki, system informował użytkownika o usterce określając ją jako „nieznana”.

7. Wnioski i kierunki dalszych prac nad rozwojem systemu

W ramach przeprowadzonych prac opracowano system umożliwiający poprawną predykcję i detekcję najczęstszych usterek sprzętu chłodniczego. Należy podkreślić, że monitoring i predykcja odbywają się na podstawie danych pomiarowych pochodzących z niedrogich sensorów Internetu Rzeczy. Umożliwia to wdrożenie tego rozwiązania w dużej liczbie urządzeń chłodniczych. Ze względu na wysokie koszty następstw awarii, system prawdopodobnie powinien być wdrażany w urządzeniach chłodniczych stosowanych do przechowywania leków i szczepionek.

Zaprezentowana w artykule metodyka opracowania systemu analitycznego wykrywającego usterki oraz potencjalne usterki w oparciu o dane pomiarowe pochodzące z sensorów Internetu Rzeczy może być użyta do budowy podobnych systemów w innych zastosowaniach. Na podstawie wiedzy branżowej i specyfiki pracy monitorowanych urządzeń należy dobrać odpowiedni rodzaj sensorów i monitorowanych punktów.

Dalsze prace nad systemem detekcji usterek/potencjalnych usterek urządzeń chłodniczych będą obejmować następujące aspekty:

- dalsze testy opracowanego rozwiązania na dużej grupie urządzeń chłodniczych pracujących w warunkach rzeczywistych z uwzględnieniem różnorodności warunków pracy, w szczególności warunków środowiskowych w pomieszczeniach, w których pracują urządzenia chłodnicze, ustawienia temperatury w komorze przechowywania i różne objętości zawartości komory przechowywania,
- eliminację wpływu odszraniania na klasyfikację wzorca usterki,
- próbę uogólnienia rozwiązania na inne klasy oraz modele urządzeń chłodniczych,
- formalną optymalizację oraz analiza istotności wielkości wektora wejściowego, a co za tym idzie ograniczenie liczby sensorów niezbędnych do wykrywania nieprawidłowości pracy urządzeń chłodniczych. Umożliwiłoby to dalsze ograniczenie kosztów wdrożenia i utrzymania samego systemu.

Tabela 6. Wyniki klasyfikacji wzorców przez detektor dedykowany wykrywaniu usterki wentylatora parownika

Table 6. Classification results of patterns by the dedicated detector for detecting the evaporator fan failure

Usterka	TP	FP	FN	TN	Dokładność	Precyzja	Czułość	F1	Swoistość
Wentylator komory parownika	3077	0	52	0	0,9834	1,0000	0,9834	0,9916	–
Sprężarka	0	110	0	1430	0,9286	0	–	0	0,9286
Wentylator komory agregatu	0	0	0	1386	1,0000	–	–	–	1,0000
Praca normalna	0	0	0	0	–	–	–	–	–

Tabela 7. Wyniki klasyfikacji wzorców przez detektor dedykowany wykrywaniu usterki sprężarki

Table 7. Classification results of patterns by the dedicated detector for detecting compressor failure

Usterka	TP	FP	FN	TN	Dokładność	Precyzja	Czułość	F1	Swoistość
Wentylator komory parownika	0	2	0	3127	0,9994	0	–	0	0,9994
Sprężarka	1364	0	176	0	0,8857	1,0000	0,8857	0,9394	–
Wentylator komory agregatu	0	0	0	1386	1,0000	–	–	–	1,0000
Praca normalna	0	0	0	0	–	–	–	–	–

Podziękowania

Artykuł zawiera wyniki prac badawczo-rozwojowych przeprowadzonych w ramach projektu „Opracowanie systemu zdalnej identyfikacji i wczesnego przewidywania usterek (ang. *Predictive maintenance*) sprzętu chłodniczego w oparciu o zasilane bateryjnie urządzenia Internetu Rzeczy i algorytmy sztucznej inteligencji”, współfinansowany przez Unię Europejską ze środków Regionalnego Programu Operacyjnego Województwa Małopolskiego na lata 2014–2020 w ramach programu Gospodarka Wiedzy.

Bibliografia

1. Killeen P., Ding B., Kiringa I., Yeap T., *IoT-based predictive maintenance for fleet management*, “Procedia Computer Science”, Vol. 151, 2019, 607–613, DOI: 10.1016/j.procs.2019.04.184.
2. Shamayleh A., Awad M., Farhat J., *IoT Based Predictive Maintenance Management of Medical Equipment*, “Journal of Medical Systems”, Vol. 44, 2020, DOI: 10.1007/s10916-020-1534-8.
3. Mourtzis D., Angelopoulos J., Panopoulos N., *Design and development of an IoT enabled platform for remote monitoring and predictive maintenance of industrial equipment*, “Procedia Manufacturing”, Vol. 54, 2021, 166–171, DOI: 10.1016/j.promfg.2021.07.025.
4. Civerchia F., Bocchino S., Salvadori C., Rossi E., Maggiani L., Petracca M., *Industrial Internet of Things monitoring solution for advanced predictive maintenance applications*, “Journal of Industrial Information Integration”, Vol. 7, 2017, 4–12, DOI: 10.1016/j.jii.2017.02.003.
5. Bousdekis A., Apostolou D., Mentzas G., *Predictive Maintenance in the 4th Industrial Revolution: Benefits, Business Opportunities, and Managerial Implications*, “IEEE Engineering Management Review”, Vol. 48, No. 1, 2020, 57–62, DOI: 10.1109/EMR.2019.2958037.
6. Nunes P., Santos J., Rocha E., *Challenges in predictive maintenance – A review*, “CIRP Journal of Manufacturing Science and Technology”, Vol. 40, 2023, 53–67, DOI: 10.1016/j.cirpj.2022.11.004.
7. Sakib N., Wuest T., *Challenges and Opportunities of Condition-based Predictive Maintenance: A Review*, “Procedia CIRP”, Vol. 78, 2018, 267–272, DOI: 10.1016/j.procir.2018.08.318.
8. Yao Y., Sharma A., Golubchik L., Govindan R., *Online anomaly detection for sensor systems: A simple and efficient approach*, “Performance Evaluation”, Vol. 67, No. 11, 2010, 1059–1075, DOI: 10.1016/j.peva.2010.08.018.
9. Ge M., Bangui H., Buhnova B., *Big Data for Internet of Things: A Survey*, “Future Generation Computer Systems”, Vol. 87, 2018, 601–614, DOI: 10.1016/j.future.2018.04.053.
10. Rondón R., Gidlund M., Landernäs K., *Evaluating Bluetooth Low Energy Suitability for Time-Critical Industrial IoT Applications*, “International Journal of Wireless Information Networks”, Vol. 24, 2017, 278–290, DOI: 10.1007/s10776-017-0357-0.
11. Singh Bali M., Gupta K., Kour Bali K., Singh P., *Towards energy efficient NB-IoT: A survey on evaluating its suitability for smart applications*, “Materials Today: Proceedings”, Vol. 49, Part 8, 2022, 3227–3234, DOI: 10.1016/j.matpr.2020.11.1027.
12. Kattenborn T., Leitloff J., Schiefer F., Hinz S., *Review on Convolutional Neural Networks (CNN) in vegetation remote sensing*, “ISPRS Journal of Photogrammetry and Remote Sensing”, Vol. 173, 2021, 24–49, DOI: 10.1016/j.isprsjprs.2020.12.010.
13. Medsker L.R., Jain L.C., *Recurrent neural networks Design and Applications*, CRC Press, 2001, DOI: 10.5555/553011.
14. Sherstinsky A., *Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network*, “Physica D: Nonlinear Phenomena”, Vol. 404, 2020, DOI: 10.1016/j.physd.2019.132306.
15. Nosouhian S., Nosouhian F., Kazemi Khoshouei A., *A Review of Recurrent Neural Network Architecture for Sequence Learning: Comparison between LSTM and GRU*, “Preprints”, 2021, DOI: 10.20944/preprints202107.0252.v1.
16. Bejani M.M., Ghatte M., *A systematic review on overfitting control in shallow and deep neural networks*, “Artificial Intelligence Review”, Vol. 54, No. 8, 2021, 6391–6438, DOI: 10.1007/s10462-021-09975-1.
17. Schaffer C., *Selecting a classification method by cross-validation*, “Machine Learning”, Vol. 13, 1993, 135–143, DOI: 10.1007/BF00993106.
18. Maxwell A.E., Warner T.A., Guillén L.A., *Accuracy Assessment in Convolutional Neural Network-Based Deep Learning Remote Sensing Studies—Part 1: Literature Review*, “Remote Sensing”, Vol. 13, No. 13, 2021, DOI: 10.3390/rs13132450.
19. Kokosiński Z., Szydłowski P., Kozłowski B., *Data-Driven Detection and Prediction of Refrigeration Equipment Failures Using Rough Sets Theory and the Internet of Things*, “Processes”, Vol. 13, 2025, 3618, DOI: 10.3390/pr13113618

Inne źródła

20. Chłodziarka Juka Vienna — prezentacja produktu, parametry techniczne i karta katalogowa: <https://juka.com.pl/en/products/refrigerated-cabinets/229-vienna-o>.

Integrated System for Fault Prediction and Detection in Refrigeration Equipment Based on Wireless IoT Sensors and Artificial Intelligence Algorithms

Abstract: This paper presents a comprehensive approach to the design and implementation of a system for fault detection and prediction in refrigeration equipment, based on wireless Internet of Things sensors and artificial intelligence algorithms. The proposed system enables early identification of the most common refrigeration equipment failures, such as fan, compressor, or controller malfunctions, which in practice helps to reduce downtime and minimize losses resulting from equipment damage and spoiled products. The solution is implemented in a distributed architecture, with measurement data transmitted to a cloud platform for analysis. Various types of neural networks were employed to develop diagnostic models, and the most effective ones were selected based on classification accuracy and computational efficiency. The system consists of a general classifier for detecting deviations from normal operation and a set of dedicated detectors assigned to specific types of faults. Tests conducted on both real and simulated datasets confirmed high detection effectiveness – the accuracy of the general classifier and dedicated detectors exceeded 98 % in most scenarios. The paper concludes by outlining potential directions for further development, including system adaptation to other classes of devices and optimization of the number of sensors to reduce implementation costs.

Keywords: artificial intelligence, Internet of Things, predictive maintenance, refrigeration equipment, wireless sensors

mgr inż. Piotr Szydłowski

piotr.szydowski@efento.pl
ORCID: 0009-0007-1384-2011

Współzałożyciel i CEO Efento, firmy zajmującej się projektowaniem, rozwojem i produkcją rejestratorów bezprzewodowych oraz platformy do gromadzenia i przetwarzania danych pomiarowych. Przed założeniem Efento pracował w firmie doradczej (technologicznym i strategicznym). Absolwent Wydziału Fizyki i Informatyki Stosowanej, AGH Akademii Górniczo-Hutniczej, kierunek Fizyka Techniczna.



mgr inż. Karol Zaręba

karol.zareba@efento.pl
ORCID: 0009-0009-7886-5163

Współzałożyciel i CTO Efento, firmy zajmującej się projektowaniem, rozwojem i produkcją rejestratorów bezprzewodowych oraz platformy do gromadzenia i przetwarzania danych pomiarowych. Przed założeniem Efento zajmował różne stanowiska związane z rozwojem oprogramowania (programista, architekt oprogramowania). Absolwent Wydziału Elektrotechniki, Automatyki, Informatyki i Elektroniki, AGH Akademii Górniczo-Hutniczej, kierunek Automatyka i Robotyka.



dr hab. inż. Piotr A. Kowalski, prof. AGH

pkowal@agh.edu.pl
ORCID: 0000-0003-4041-6900

Profesor uczelni na Wydziale Fizyki i Informatyki Stosowanej Akademii Górniczo-Hutniczej oraz w Instytucie Badań Systemowych PAN. Uzyskał tytuł magistra teleinformatyki (z wyróżnieniem) oraz Automatyki (z wyróżnieniem), oba na Politechnice Krakowskiej w 2003 r., następnie stopień doktora informatyki w zakresie Data Science w IBS PAN w 2009 r. W 2018 r. uzyskał stopień doktora habilitowanego, na podstawie badań związanych ze sztucznymi sieciami neuronowymi w IBS PAN. Jego zainteresowania badawcze skupiają się na technologiach informatycznych opartych na metodach inteligentnych, takich jak sieci neuronowe, systemy rozmyte oraz algorytmy inspirowane naturą, z zastosowaniem w złożonych systemach oraz algorytmach odkrywania wiedzy w danych.



mgr inż. Bartosz Kozłowski

bartosz.kozlowski@efento.pl
ORCID: 0009-0004-2289-4110

Programista Python w Efento, firmie zajmującej się projektowaniem, rozwojem i produkcją rejestratorów bezprzewodowych oraz platformy do gromadzenia i przetwarzania danych pomiarowych. Entuzjasta szeroko pojętej elektroniki, druku 3D, technologii AI i fotografii. Absolwent Wydziału Elektroniki Automatyki i Inżynierii Biomedycznej, AGH Akademii Górniczo-Hutniczej, kierunek Automatyka i Robotyka.

