



**Politechnika
Śląska**

ROZPRAWA DOKTORSKA

Diagnostyka elektrycznego napędu rogatkowego z wykorzystaniem uczenia
maszynowego

mgr inż. Roman PAWEŁCZYK

PROMOTOR

dr hab. inż. Damiana Grzechca, prof. Pol. Śl.

OPIEKUN PRZEMYSŁOWY

mgr inż. Tomasz Pisarek

GLIWICE 2023

Spis treści

1.	Spis ważniejszych oznaczeń i skrótów	5
2.	Wstęp.....	13
3.	Wprowadzenie.....	21
3.1.	Napęd rogatekowy jako element sygnalizacji przejazdowej	21
3.2.	Budowa elektrycznego napędu rogatekowego	24
3.3.	Analiza aktualnych badań związanych z diagnostyką elektrycznego napędu rogatekowego	28
3.4.	Nowe metody diagnostyczne	39
3.5.	Stanowisko do badania elektrycznego napędu rogatekowego	40
3.5.1.	Konstrukcja stanowiska	40
3.5.2.	Dane pozyskiwane ze stanowiska badawczego.....	43
3.6.	Parametry oceny jakości proponowanych metod	46
4.	Nieinwazyjna metoda detekcji kąta położenia drąga elektrycznego napędu rogatekowego BMAD	48
4.1.	Założenia metody	48
4.2.	Opis metody	49
4.3.	Sposób opracowania metody	51
4.4.	Wytworzenie zestawu danych treningowych i testowych	52
4.5.	Dobór modeli ML	56
4.6.	Badania porównawcze modeli ML	57
4.6.1.	Predykcja kąta nachylenia drąga	57
4.6.2.	Predykcja zajęcia wybranego położenia kąтового drąga	63
4.7.	Podsumowanie	65
5.	Metoda prognozowania całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego BMMT.....	66
5.1.	Założenia metody	66
5.2.	Opis metody	67
5.3.	Sposób opracowania metody	69
5.4.	Dane treningowe i testowe.....	70
5.5.	Dobór modeli ML	76
5.6.	Wyniki wstępne	77
5.7.	Strojenie modeli predykcyjnych	82
5.8.	Wyniki dla modeli zoptymalizowanych	85
5.9.	Modele zespołowe	87
5.10.	Ocena skuteczności modeli z wykorzystaniem danych testowych	89
5.11.	Odporność modeli na uszkodzone dane	90
5.12.	Podsumowanie	93
6.	Metoda detekcji zdarzeń podczas pracy elektrycznego napędu rogatekowego wykrywanych jako usterki BMFD	94

6.1.	Założenia metody	94
6.2.	Modele wybranych zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego	95
6.2.1.	Uderzenie w przeszkodę stałą (<i>FSO</i>)	96
6.2.2.	Współczynnik i_{rise}	98
6.2.3.	Uderzenie w przeszkodę sprężystą (<i>FFO</i>)	99
6.2.4.	Wektor C_{FFO}	100
6.2.5.	Uszkodzenie mechanizmu napędowego (<i>FGF</i>)	102
6.2.6.	Współczynnik m_{FGF}	103
6.3.	Opis metody	104
6.4.	Sposób opracowania metody	105
6.5.	Wytworzenie zestawu danych treningowych i testowych	106
6.6.	Modele bazowe	108
6.7.	Strojenie wybranych modeli	110
6.8.	Ocena skuteczności metody z wykorzystaniem danych rzeczywistych	112
6.9.	Podsumowanie	116
7.	Projekt wdrożeniowy	118
8.	Podsumowanie	121
9.	Dodatki	125
9.1.	Metoda BMAD – wybrane modele	125
9.2.	Metoda BMMT – wybrane modele	127
9.3.	Metoda BMFD – wybrany model	131
	Bibliografia	132

1. Spis ważniejszych oznaczeń i skrótów

ML	Techniki uczenia maszynowego (ang. Machine Learning)
BMAD	Metoda ustalania położenia kąтового drąga elektrycznego napędu rogatkowego (ang. Barrier Machine Angle Detection)
BMMT	Metoda przewidywania całkowitego czasu trwania danej fazy ruchu elektrycznego napędu rogatkowego (ang. Barrier Machine Movement Time)
BMFD	Metoda klasyfikacji wybranych zdarzeń podczas pracy elektrycznego napędu rogatkowego (ang. Barrier Machine Failure Detection)
S _B	Stan bezpieczny systemu sygnalizacji przejazdowej
S _O	Stan oczekiwania systemu sygnalizacji przejazdowej
Cz1 ... Cz8	Czujniki koła
t _d	Czas wstępnego ostrzegania
S _I	Stan wstępnego ostrzegania systemu sygnalizacji przejazdowej
S1 ... S4	Sygnalizatory drogowe
Dz1, Dz2	Sygnalizatory akustyczne (dzwony)
N1 ... N4	Elektryczne napędy rogatkowe
t _{BM}	Charakterystyka czasowa procesu sterowania napędem rogatkowym
α_d	Położenie kątowe drąga
1W, 1N, 2W, 2N	Oznaczenia funkcjonalne tarcz ostrzegawczych przejazdowych
Osp1, Osp2	Sygnaly podawane przez tarcze ostrzegawcze przejazdowe
EEG-3	Elektryczny napęd rogatkowy rodziny <i>EBI Gate 630</i>
ERTMS	Europejski System Zarządzania Ruchem Kolejowym (ang. European Rail Traffic Management System)

V2I	System łączności pojazd – infrastruktura
GSM-R	System łączności cyfrowej oparty na standardzie GSM na potrzeby zastosowań w transporcie kolejowym (ang. GSM for Railways)
LIDAR	Technika pomiaru odległości wykorzystująca światło lasera (ang. Light Detection and Ranging)
FPGA	Bezpośrednio programowalna macierz bramek (ang. field-programmable gate array)
CSV	Wartości rozdzielone przecinkiem (ang. comma-separated values)
$\chi a_{up,i}$ i $\chi a_{down,i}$	Rekordy zbioru danych A składające się z wektorów $u_{i,j}$
α_{min} i α_{max}	Skrajne położenia kątowe drąga elektrycznego napędu rogatekowego. Ruch drąga zawsze rozpoczyna się od położenia α_{min}
$t_{i,j}$	Czas, w którym zarejestrowane zostało j-te zadziałanie enkodera oznaczające zmianę położenia drąga o 1° w danej fazie ruchu w zbiorze danych A i B
$in_down_{i,j}$ i $in_up_{i,j}$	Stan wyłączników krańcowych w napędzie informujących o zajęciu przez drąg pozycji granicznych w zbiorze danych A i B
$i_{i,j}$	Chwilowa wartość prądu zasilającego w zbiorze danych A i B
$dir_{i,j}$	Kierunek ruchu drąga w zbiorze danych A, B oraz C
$\alpha_{i,j}$	Położenie kątowe drąga w zbiorze danych A i B
NA	Liczba próbek w zbiorze danych A
XA_{up} i XA_{down}	Macierze zbioru danych A zawierające odpowiednio wektory $\chi a_{up,i}$ i $\chi a_{down,i}$
χb_i	Rekordy zbioru danych B składające się z wektorów $v_{i,j}$
$\phi_{i,j}$	Kierunek wiatru
$V_{i,j}$	Prędkość wiatru
$tm_{i,j}$	Temperatura powietrza
$h_{i,j}$	Wilgotność względna

$dp_{i,j}$	Temperatura punktu rosy
NB, NB_{up} i NB_{down}	Liczba próbek w zbiorze B, liczba próbek w zbiorze B zawierających zapis ruchu drąga w górę i w dół
XB	Macierz zbioru danych B zawierająca wektory xb_i
TPLC	Okres próbkowania
xc_i	Rekordy zbioru danych C składające się z wektorów w_j
T_j	Czas od rozpoczęcia ruchu drąga, w którym została zarejestrowana j -ta wartość prądu $i_{i,j}$ w zbiorze danych C
yc_j	Etykieta będąca elementem zbioru danych C
NC	Liczba próbek w zbiorze C
XC	Macierz zbioru danych B zawierająca wektory xc_i
YC	Wektor zbioru danych C zawierający etykiety yc_i
$FSO,$ FSO_{up} i FSO_{down}	Zdarzenia polegające na uderzeniu w przeszkodę stałą (niemożliwa jest kontynuacja ruchu), odpowiednio ogólny przypadek oraz dla ruchu w górę i w dół
$FFO,$ FFO_{up} i FFO_{down}	Zdarzenia polegające na uderzeniu w przeszkodę sprężystą (po uderzeniu możliwa jest kontynuacja ruchu), odpowiednio ogólny przypadek oraz dla ruchu w górę i w dół
$FGF,$ FGF_{up} i FGF_{down}	Zdarzenia polegające na zwiększeniu oporów mechanizmu napędu rogatekowego, odpowiednio ogólny przypadek oraz dla ruchu w górę i w dół
TR i PR	Wektor wartości prawdziwych tr_i i wektor wartości predykcji pr_i
N	Liczba próbek
TR_{mean}	Wartość średnia wartości prawdziwych
ACC	Dokładność
MAE	Średni błąd bezwzględny
MSE	Błąd średniokwadratowy
R^2	Współczynnik determinacji
ME	Błąd maksymalny

TP	liczba wyników prawdziwie dodatnich
TN	liczba wyników prawdziwie negatywnych
FP	liczba wyników fałszywie dodatnich
FN	liczba wyników fałszywie negatywnych
PRE	Precyzja
REC	Czułość
SPE	Swoistość
F_1	Współczynnik F_1
σ	Odchylenie standardowe
PLC	Programowalny sterownik logiczny (ang. programmable logic controller)
$MK1 \dots MK4$	Modele wykorzystywane w metodzie BMAD
$FA_{up,n}$ i $FA_{down,n}$	Wektory zawierające informację o przebiegu prądu zasilającego
$\alpha_{pr,n}$	Predykcja położenia kąowego drąga
$b_{pr,n}$	Predykcja zajęcia wybranego położenia kąowego drąga
$round$	Funkcja zaokrąglenia do liczb całkowitych
//	Operator dzielenia całkowitoliczbowego
i_n	Chwilowa wartość prądu zasilającego elektryczny napęd rogatkowy w metodzie BMAD
dir_n	Kierunek ruchu drąga wykorzystywany w metodzie BMAD
$i_{up,n}$ oraz $i_{down,n}$	Pochodne wartości prądu wykorzystywane w metodzie BMAD
S	Długość bufora w metodzie BMAD
$\Delta\alpha$	Rozdzielczość z jaką jest określane położenie kąowe drąga w metodzie BMAD
α_{mid}	Wybrane położenie kąowe drąga w metodzie BMAD
$\chi\alpha'_{up,i}$ i $\chi\alpha'_{down,i}$	Wektory zawierające czasy kolejnych aktywacji enkodera $t_{i,j}$ i chwilowych wartościach prądu $i_{i,j}$ dla ruchu w górę i w dół w metodzie BMAD

$ya'_{up,i}$ i $ya'_{down,i}$	Wektory informacji o położeniu kątowym drąga w trakcie i-tego ruchu w górę i w dół w metodzie BMAD
$xa''_{up,i}$, $xa''_{down,i}$, $ya''_{up,i}$, $ya''_{down,i}$	Ponownie próbkowane wektory $xa'_{up,i}$ i $xa'_{down,i}$ oraz $ya'_{up,i}$ i $ya'_{down,i}$
T_z	Czas przerwy pomiędzy kolejnymi ruchami napędu
z	Wektor zawierający wartości zerowe wykorzystywany w metodzie BMAD
X''_{up} , X''_{down}	Wektory zawierające wartości prądu $I_{up,n}$ dla kierunku ruchu w górę oraz $I_{down,n}$ dla kierunku ruchu w dół w metodzie BMAD. Wektory te są o długości P
Y''_{up} , Y''_{down}	Wektory zawierające wartości położenia kąowego drąga $\alpha_{up,n}$ dla kierunku ruchu w górę oraz $\alpha_{down,n}$ dla kierunku ruchu w dół w metodzie BMAD. Wektory te są o długości Q
$\alpha_{real,n}$	Rzeczywiste położenie drąga w metodzie BMAD wyrażone z rozdzielczością $\Delta\alpha$
$b_{real,n}$	Stan rzeczywistego zajęcia wybranego położenia kąowego drąga α_{mid} wyrażone z rozdzielczością $\Delta\alpha$
α_{mid}	Wybrane położenie kąowe drąga
X_{up} i X_{down}	Treningowe i testowe dane wejściowe w metodzie BMAD o rozmiarze odpowiednio $U1$ i $U2$
$y_{up,\alpha}$ i $y_{up,b}$	Treningowe i testowe dane wyjściowe w metodzie BMAD o rozmiarze odpowiednio $U1$ i $U2$ dla kierunku w górę i w dół
$y_{down,\alpha}$ i $y_{down,b}$	
$U1$ i $U2$	Rozmiar zbioru danych w metodzie BMAD odpowiednio dla kierunku ruchu w górę oraz w dół
α^{Q1} , α^{Q3} , α^{med}	Kolejne kwartyle i mediana w rozkładzie błędów predykcji położenia kąowego w metodzie BMAD
IQR	Różnica pomiędzy wartością kwartyłu trzeciego α^{Q3} i pierwszego α^{Q1} , rozstęp międzykwartyłowy
Gn	Wektor danych wejściowy w metodzie BMMT
$F0_n \dots F15_n$	Kolejne cechy w metodzie BMMT
$t_{n,0} \dots t_{n,5}$	Momenty czasu, w których dochodzi do pierwszych sześciu aktywacji enkodera w metodzie BMMT

$i_{n,0} \dots i_{n,5}$	Pierwsze sześć wartości prądu zasilania mierzonych przy kolejnych aktywacjach enkodera w metodzie BMMT
$tm_{n,0} \dots tm_{n,5}$	Pierwsze sześć wartości temperatury powietrza mierzonych przy kolejnych aktywacjach enkodera w metodzie BMMT
$dp_{n,0} \dots dp_{n,5}$	Pierwsze sześć wartości temperatury punktu rosy mierzonych przy kolejnych aktywacjach enkodera w metodzie BMMT
$\phi_{n,0} \dots \phi_{n,5}$	Pierwsze sześć wartości kierunku wiatru w metodzie BMMT, które podlegają przyporządkowaniu do przedziału $bin_{\phi,n}$
$V_{n,0} \dots V_{n,5}$	Pierwsze sześć wartości prędkości wiatru w metodzie BMMT, które podlegają przyporządkowaniu do przedziału $bin_{V,n}$
$f_bin_{\phi}()$ i $f_bin_{V}()$	Funkcja przyporządkowania do przedziału wartości zmiennej odpowiednio dla kierunku i prędkości wiatru w metodzie BMMT
$t_{pr,n}$	Predykcja całkowitego czasu ruchu drąga w metodzie BMMT
$t_{real,n}$	Rzeczywisty całkowity czas ruchu drąga w metodzie BMMT
MR	Model wykorzystywany w metodzie BMMT
$t_{\alpha_{max}}$	moment, w którym drąg osiąga pozycję skrają powiązaną z położeniem kątowym α_{max}
$t_{\alpha_{min}}$	moment, w którym drąg osiąga pozycję skrają powiązaną z położeniem kątowym α_{min}
t_j	Czas w którym drąg osiągnął dane położenie α_j wykorzystywany w metodzie BMMT
σ_{ϕ} i σ_V	Odpowiednio odchylenie standardowe dla kierunku i prędkości wiatru wykorzystywane w metodzie BMMT
$bin_{\phi,n}$ i $bin_{V,n}$	Podzakres kierunku i prędkości wiatru wykorzystywany w metodzie BMMT
$X_1 \dots X_4$	Kolejno coraz bardziej rozbudowane warianty macierzy cech w metodzie BMMT
f_{FSO}	Funkcja stanowiąca model zdarzenia FSO
i_{stall}	Prąd pobierany przez unieruchomiony silnik w momencie czasu t_2

i_{rise}	Współczynnik szybkości narostu prądu w trakcie wystąpienia zdarzenia FSO_{up} lub FSO_{down}
$i_{rise,up}$ i $i_{rise,down}$	Współczynnik szybkości narostu prądu w trakcie wystąpienia zdarzenia odpowiednio FSO_{up} i FSO_{down}
$i_{min}, i_{marg}, i_{max}$	Wartości prądu wykorzystywane podczas wyznaczania wartości współczynnika i_{rise}
s	Współczynnik rozszerzenia zakresu zmienności zmiennych i_{min}, i_{max} wykorzystywany podczas wyznaczania wartości współczynnika i_{rise}
f_{FFO}	Funkcja stanowiąca model zdarzenia FFO
$f_{C_{FFO}}$	Funkcja służąca do wyznaczenia elementów wektora C_{FFO}
C_{FFO}	Wektor przechowujący wzór kształtu prądu w postaci współczynników $[f_1 \dots f_M]$ dla zdarzenia FFO
i_1, i_{max}, i_2	Wartości prądu występujące w trakcie wystąpienia zdarzenia FFO osiągane w przedziale czasu od t_1 do t_2
i_t	Wartość prądu w trakcie trwania zdarzenia
A	Zmienna określająca względną amplitudę i_{max} względem i_1 i i_2
A_{step}	Zmienna określająca krok zmiany wartości natężenia prądu w trakcie trwania zdarzenia FFO
$A_{up}, M_{up},$ A_{down}, M_{down}	Wartości współczynników A i M odpowiednio dla zdarzeń FFO_{up} i FFO_{down}
f_{FGF}	Funkcja stanowiąca model zdarzenia FGF
m_{FGF}	Współczynnik określający poziom degradacji zmieniającym się w zależności od poziomu zanieczyszczenia napędu rogatekowego
i_{mean} i i_{mean_all}	Odpowiednio średnia wartość prądu dla danego przebiegu i średnia wartość prądu dla wszystkich przebiegów
K i K'	Odpowiednio liczba rekordów stanowiących zapis całej fazy ruchu drąga napędu rogatekowego i liczba rekordów stanowiących zapis fazy aktywnej
FC_n	Wektor wejściowy w metodzie BMFD

MKK	Model wykorzystywany w metodzie BMFD
C_n	Klasyfikacja ruchu w metodzie BMFD
X_{C1} i y_{C1}	Macierz cech i wektor etykiet będący elementem zbioru danych C wykorzystywany w metodzie BMFD
$FMOD$	Funkcja służąca do przekształcenia danych zawartych w X_{C1} z wykorzystaniem funkcji $fsym()$ wykorzystywana w metodzie BMFD
$N_{train}, N_{test1}, N_{test2}$	Rozmiary poszczególnych zbiorów danych wykorzystywanych w metodzie BMFD

2. Wstęp


Sygnalizacja przejazdowa pozostaje kluczowym elementem zapewniającym bezpieczeństwo w obszarze przejazdu kolejowo-drogowego [1] pomimo coraz szerszego stosowania wiaduktów. Decydującymi czynnikami są relatywnie niskie koszty oraz krótszy czas potrzebny na realizację inwestycji oraz możliwość instalacji na ograniczonej powierzchni. Sygnalizacja przejazdowa jest stosowana dla przejazdów kolejowo-drogowych, których obserwowane wartości natężenia ruchu należą do szerokiego spektrum. W konsekwencji konfiguracja sprzętowa jest odpowiednio dobierana dla poszczególnych instalacji systemu. W zakresie urządzeń ostrzegawczych dla użytkowników drogi obok napędów rogatek stosowane są między innymi różne systemy sygnalizatorów świetlnych i akustycznych. W zależności od lokalnych uregulowań podawane jest w wielu wariantach podstawowe ostrzeżenie o nadjeżdżającym pociągu oraz informacja o wejściu sygnalizacji w stan ostrzegania. Stosowane bywa również sygnalizowanie braku nadjeżdżającego pociągu, stan sprawności systemu sygnalizacji, jak i np. kierunek nadjeżdżającego pociągu. Ze względu na ważność podawanych sygnałów działanie urządzeń często jest nagrywane przez specjalizowany system wideo-rejestracji. Na bardziej rozwiniętych rynkach wprowadza się zarówno dodatkowe urządzenia, jak i całe systemy umożliwiające wykrywanie przeszkody na przejeździe. Odpowiedzialne są one za wywołanie właściwej reakcji na poziomie systemu kolejowego, ograniczającej prawdopodobieństwo wystąpienia kolizji, która zazwyczaj wiąże się z powstaniem poważnych strat.

Mając na uwadze intensywność ruchu zarówno na linii kolejowej oraz na przecinającej ją drodze, jak i złożoność sytuacji ruchowej, wyróżniane są w ramach poszczególnych rynków określone kategorie przejazdów kolejowo-drogowych [1]. W większości bardziej wymagających lokalizacji aplikowane są sygnalizacje przejazdowe wyposażone w napędy rogatkowe. Intencją takiego działania jest chęć fizycznego wygradzenia i oznaczenia niebezpiecznego miejsca. Często spotykaną konfiguracją są cztery napędy rogatkowe całkowicie wygradzające wjazd na teren przejazdu na całej szerokości drogi.

Sygnalizacja przejazdowa jest również niejednokrotnie wybieraną opcją dla skrzyżowań z drogami o niskim natężeniu ruchu oraz dla nietypowych przypadków, takich jak np. specjalizowane przejazdy na obszarach rolniczych, przejścia wyłącznie dla pieszych, skrzyżowania z drogami rowerowymi, przejazdy stale zamknięte otwierane na żądanie, specjalizowane rozwiązania dla bocznic zakładów przemysłowych.

Sygnalizacja przejazdowa musi spełniać wymagania związane z najwyższym poziomem bezpieczeństwa SIL-4 (Safety Integrity Level 4) [2], jako że skutki wypadków zazwyczaj są

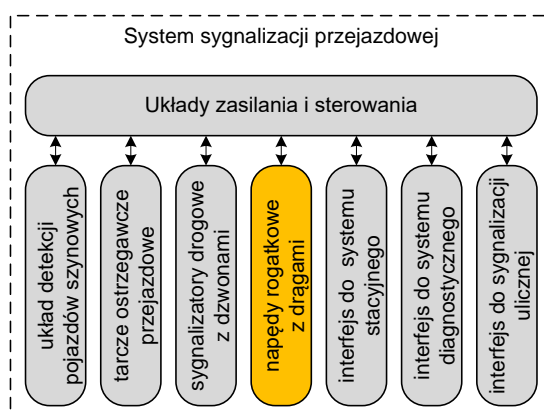
bardzo poważne. Zgodnie z oficjalnymi statystykami [3] w Polsce w roku 2021 doszło do 194 incydentów naruszenia bezpieczeństwa na przejazdach kolejowo-drogowych, w rezultacie których śmierć poniosły 43 osoby, a 16 zostało ciężko rannych. Podsumowanie przedstawione poniżej, (rys. 2.1) pomimo tendencji spadkowej na przestrzeni lat, obrazuje powagę problemu.



Rys. 2.1 Wypadki i kolizje na przejazdach/przejeźciach na przestrzeni lat [3]

Jednym z podstawowych zagrożeń występujących na skrzyżowań linii kolejowych z drogami jest wtargnięcie na obszar przejazdu podczas zamykania napędów rogatkowych co w części przypadków wiąże się z zaburzeniem ruchu drągów. Dlatego pożądane jest pozyskanie informacji o uderzeniu w przeszkodę ze względu na możliwość podjęcia adekwatnej reakcji czy to poprzez odpowiednie powiadomienie służb utrzymania bądź poprzez opracowanie nowych algorytmów sterujących pracą systemu przejazdowego. Drugim problemem jest brak precyzyjnego określenia całkowitego czasu opuszczenia i podniesienia drąga, który w zależności od warunków pogodowych, szczególnie silnego wiatru, zmienia się w znacznym zakresie. Całkowity czas opuszczania i podnoszenia drągów, a w zasadzie jego predykcja jest istotna ze względu na badania, w których wskazano, że optymalizacja czasowa działania systemów kolejowych odgrywa coraz większą rolę [4], [5] ponieważ zaobserwowano, że użytkownicy drogi zniecierpliwieni długim czasem oczekiwania skłonni są do wtargnięcia na obszar przejazdu [6].

Sygnalizacja przejazdowa składa się z urządzeń i układów przedstawionych na rys. 2.2, natomiast widok przykładowego elektrycznego napędu rogatekowego został pokazany na rys. 2.3.



Rys. 2.2 Elementy składowe przykładowego systemu sygnalizacji przejazdowej



Rys. 2.3 Przykładowy elektryczny napęd rogatekowy wyposażony w drąg – materiały firmy ALSTOM ZWUS Sp. z o.o.

Napęd rogatekowy wyposażony jest w następujące elementy:

- drąg z odpowiednimi elementami dodatkowymi, który może być wzmocniony oraz doposażony o przeciwwagę. Jednym z elementów w tej części jest bezpiecznik drąga, który umożliwia nieniszczące wyłamanie w sytuacji kolizji z przeszkodą. Innym elementem powiązany jest układ wykrywający ciągłość drąga,
- układ napędowy, który w zależności od typu napędu najczęściej występuje w wariantach elektrycznym bądź elektryczno-hydraulicznym,
- układ detekcji położenia drąga oparty na zestawie wyłączników krańcowych bądź czujników innego typu, który umożliwia wykrycie wybranych położenia katowych,
- elementy opcjonalne, np. firanki drąga.

Niesprawność napędów rogatekowych prowadzi do poważnych konsekwencji na wielu poziomach, np. opóźnienia w transporcie kolejowym i drogowym, czy bezpieczeństwa poprzez bezpośrednie zagrożenie życia i zdrowia ludzkiego. Dlatego utrzymanie sprawności

napędu i zapobieganie usterkom jest zasadne, ponieważ wprowadzenie nowych funkcjonalności wykrywających zarówno bezpośrednio usterki funkcjonalne, jak i anomalii, które je zapowiadają, podnoszą poziom bezpieczeństwa i zachowują ciągłość utrzymania ruchu. W efekcie informacje wypracowane przez nowe metody, procedury, czy algorytmy są wartościowe zarówno dla procesu konstrukcji, jak i dla diagnostyki predykcyjnej dającej możliwość zapobieżenia zbliżającej się poważnej awarii. Analiza charakterystyk odzwierciedlających kondycję urządzeń i umożliwiających wczesną detekcję usterek są integralnymi elementami programu Przemysł 4.0 [7].

Usterki występujące w systemach kolejowych a mające wpływ na ruch pociągów są przyczyną pojawiających się opóźnień. W związku z wzrastającym natężeniem ruchu kolejowego sumaryczny czas opóźnień ma znaczący wpływ na pojawiające się straty ekonomiczne. Prowadzone badania dowodzą, że w rozliczeniu rocznym straty te są porównywalne z kosztami szkód pojawiających się na torach i w taborze w związku z wykolejeniami. Proponowanym rozwiązaniem są mechanizmy automatycznej diagnostyki ze względu na naturalne ograniczenia, jakie są wpisane w proces inspekcji wizualnej [8]. Jednym ze źródeł powstających opóźnień zarówno w transporcie drogowym, jak i kolejowym są przejazdy kolejowo-drogowe ponieważ zasadą jest, że w przypadku wykrycia usterki system przejazdowy przechodzi do stanu bezpiecznego. Oznacza to spowolnienie ruchu pociągów i zazwyczaj całkowite zatrzymanie ruchu drogowego. Mając na uwadze zwiększenie dostępności systemów sygnalizacji przejazdowej sąsiadujących na jednej linii kolejowej, proponowane jest ich połączenie, co zapewni możliwość utrzymania pracy w trybie aktywnym w oparciu o dane przesyłane przez najbliższe sygnalizacje [5]. W tym zakresie problemem jest brak możliwości odpowiedniej klasyfikacji zdarzeń występujących w trakcie pracy napędów rogatek. Informacja diagnostyczna nowego typu dająca możliwość wyodrębnienia tymczasowych zaburzeń w pracy napędu spowodowanych np. silnym wiatrem bądź nieprawidłowym zachowaniem pieszych jest pożądana ze względu na możliwość uniknięcia opóźnień wynikających z przejścia sygnalizacji przejazdowej w stan bezpieczny S_B . Algorytm działania systemu przejazdu kolejowego jest z góry ustalony i musi być zgodny z określonymi wymaganiami – czas wstępnego ostrzeżenia odliczany od momentu włączenia sygnalizatorów drogowych jest precyzyjnie określony. W związku z tym czas trwania całej sekwencji przejścia w stan ostrzeżenia jest przewidywalny przy założeniu, że w systemie nie pojawią się żadne usterki. Tej cechy w pewnym stopniu nie ma czas ruchu napędów rogatek, gdyż zmienia się on w zależności od czynników wewnętrznych, jak i zewnętrznych. Do czynników wewnętrznych należą, takie zjawiska jak np. opory tarcia zależne od stanu utrzymania wewnętrznego mechanizmu napędowego, wpływ zmian napięcia zasilania, parametrów mechanicznych współpracującego drąga. Do czynników zewnętrznych należą takie zjawiska jak np. zmienna prędkość i kierunek wiatru, aktualnie panująca temperatura oraz wilgotność,

wpływ deszczu np. W skrajnych wypadkach usterki takie jak ta, gdy drąg uderza w przeszkodę lub wewnętrzna przekładnia zostaje zanieczyszczona z powodu np. nieszczelnej obudowy [9], są kolejnymi źródłami nieprzewidywalnego zachowania napędu rogatek. Ponadto istotne jest również to, że napędy rogatkowe instalowane są w wielu lokalizacjach charakteryzujących się dużą rozpiętością wartości poszczególnych czynników środowiskowych [10]. W rezultacie czas potrzebny na przemieszczenie drąga pomiędzy skrajnymi pozycjami nie jest powtarzalny. Obecnie stosowane podejście opiera się na założeniu maksymalnych możliwych i jednocześnie dopuszczalnych wartości czasu dla poszczególnych elementów tworzących pełną sekwencję ruchu. Biorąc pod uwagę powyższe należy zauważyć brak możliwości wyznaczenia predykcji czasu w jakim drąg napędu rogatek przemieści się z położenia otwartego do zamkniętego oraz w przeciwnym kierunku.

Z punktu widzenia systemu sygnalizacji przejazdowej funkcja poprawnego wykrywania położenia drąga jest krytyczna ponieważ przy jej niesprawności dochodzi do zaburzenia i znaczącej degradacji podstawowej funkcji jaką jest zabezpieczenie obszaru przejazdu. Dla dostępnych na rynku rozwiązań można stwierdzić, że w celu zapewnienia tej funkcjonalności stosuje się różne środki techniczne takie jak wyłączniki krańcowe współdziałające z krzywką lub zespołem krzywek. Te urządzenia mechaniczne są podatne na błędy wynikające z niewłaściwej regulacji oraz postępującą degradacją wynikającą z mechanicznego zużycia komponentów. Innym rozwiązaniem są czujniki elektroniczne, takie jak czujniki optyczne lub magnetyczne. Te podzespoły również posiadają istotne słabości, takie jak podatność na osadzające się zanieczyszczenia oraz fałszywe aktywacje spowodowane min. zakłóceniami elektromagnetycznymi. Zakłada się, że rozwiązanie powinno w jak największym stopniu wykorzystywać już istniejącą konstrukcję dostarczając predykcji w zakresie położenia drąga w oparciu o analizę prądu zasilającego [11].

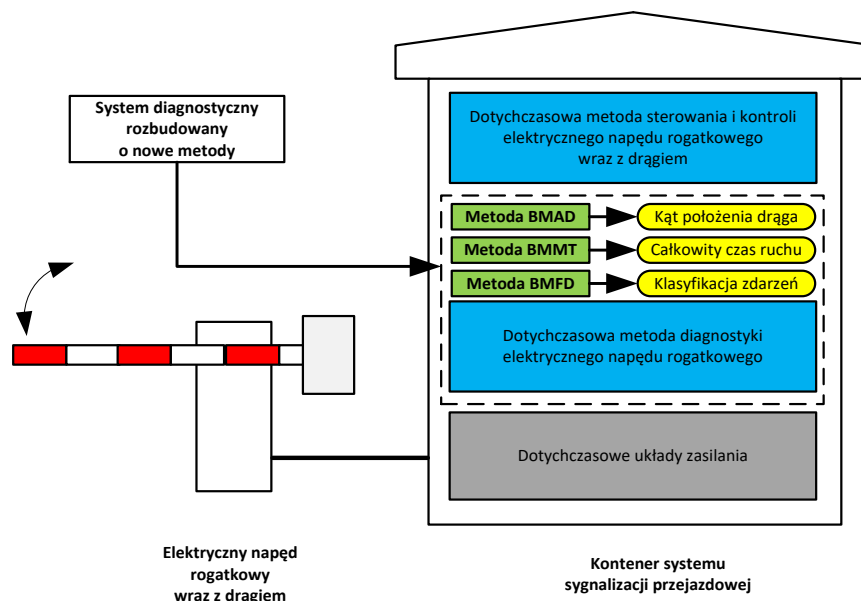
Czynnikiem powiązanim z bezpieczeństwem przejazdu jest całkowity czas jaki upływa od momentu wykrycia nadjeżdżającego pociągu i włączenia stanu ostrzegania t_d do momentu, w którym na przejeździe pojawia się czoło pociągu. Jego pierwszym elementem jest czas wstępnego ostrzegania – sygnalizatory drogowe są aktywne lecz napędy rogatkowe pozostają otwarte. Czas wstępnego ostrzegania umożliwia wszystkim użytkownikom drogi możliwość bezpiecznego opuszczenia terenu przejazdu i jest wyznaczany dla pociągu poruszającego się z maksymalną dopuszczalną prędkością. Ostatecznie realna długość czasu, który upływa do momentu pojawienia się czoła pociągu na przejeździe jest zależna od zakresu prędkości, z jakimi mogą się poruszać pojazdy szynowe daną linią kolejową. Jeśli pojazd szynowy porusza się wolno, rzeczywisty czas jaki upływa do wjazdu pociągu na przejazd ulega znacznemu wydłużeniu. Skrócenie tego czasu jest możliwe poprzez opóźnienie momentu włączenia ostrzegania na przejeździe, tak by czas jaki upłynie do momentu pojawienia się czoła pociągu był równy minimalnemu wymaganemu czasowi

wstępnego ostrzegania. W celu realizacji opóźnienia konieczne jest zapewnienie funkcji punktowego pomiaru prędkości nadjeżdżającego pociągu i znajomość maksymalnego osiągalnego przyspieszania. Alternatywna droga rozwiązania tego problemu wymaga zapewnienia środków technicznych dających ciągłą informację o położeniu i prędkości pociągu. W tym celu wykorzystywane są np. czujniki radarowe.

Celem niniejszej pracy jest opracowanie systemu diagnostycznego dla elektrycznego napędu rogatkowego z wykorzystaniem uczenia maszynowego, z uwzględnieniem ograniczeń wynikających z braku możliwości ingerencji w strukturę sprzętową urządzenia.

Poprzez opracowanie systemu diagnostycznego rozumie się stworzenie nowych metod stanowiących rozszerzenie dotychczasowego rozwiązania jak to zostało przedstawione na rys. 2.4, które umożliwiają wyznaczenie następujących informacji:

- aktualne położenie kątowe drąga elektrycznego napędu rogatkowego dla obu kierunków przemieszczania się drąga,
- predykcja czasu na wykonanie pełnego ruchu drągiem,
- klasyfikacji diagnostycznej, tj. rozróżnienie uderzenia drąga w przeszkodę od przykładowego uszkodzenia mechanizmu napędowego.



Rys. 2.4 System diagnostyczny systemu przejazdowego rozbudowany o nowe metody dla elektrycznego napędu rogatkowego

Procedury te muszą umożliwiać implementację na platformie sterowników PLC próbujących i przetwarzających dane wejściowe z interwałem TPLC=50 ms.

Mając na uwadze cel pracy, postawiono następujące tezy:

1. Analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatekowy z wykorzystaniem algorytmu uczenia maszynowego umożliwia wyznaczenie aktualnego położenia kąta drąga bez konieczności ingerencji w konstrukcję urządzenia jednocześnie zwiększając poziom bezpieczeństwa poprzez wygenerowanie dodatkowej informacji dla systemu sterującego.
2. Algorytm uczenia maszynowego wraz z informacją o aktualnym kącie położenia drąga na podstawie przebiegu prądu zasilającego umożliwia predykcję czasu otwierania i zamykania z zachowaniem wymagań normatywnych w kolejnictwie.
3. Detekcja zaistnienia nieprawidłowości, zaburzenia w trakcie ruchu drąga na podstawie przebiegu prądu zasilającego elektryczny napęd rogatekowy z wykorzystaniem algorytmu uczenia maszynowego pozwala na wypracowanie dodatkowej informacji dla system nadrzędnego.

Niniejsza rozprawa została podzielona na siedem rozdziałów oraz podsumowanie. W rozdziale drugim przedstawiono konstrukcję oraz obszar stosowania elektrycznego napędu rogatekowego, na przykładzie najczęściej stosowanych napędów na rynku krajowym. Następnie opisano stan badań w następujących aspektach: przejazdu kolejowo-drogowe jako element infrastruktury systemu kolejowego, bezpieczeństwo w bezpośrednim otoczeniu przejazdu kolejowo-drogowego, diagnostyka napędów elektrycznych. Następnie opisano sposób pracy dla nowych metod diagnostycznych w zakresie wykorzystywanych danych wejściowych i dostarczanych danych wyjściowych oraz szczegółowo przedstawiono zbudowane stanowisko testowe składające się z układu kontrolno-sterującego, napędu rogatekowego wraz z drągiem. Zostały również opisane zebrane dane oraz parametry wykorzystane do oceny jakości proponowanych metod.

W rozdziale czwartym została przedstawiona nieinwazyjna metoda detekcji kąta położenia drąga elektrycznego napędu rogatekowego (BMAD). W kolejnych podrozdziałach zamieszczono założenia dla metody oraz jej opis. Następnie opisano sposób opracowania metody, proces przygotowania danych treningowych i testowych, dobór modeli ML oraz badania porównawcze tych modeli.

Rozdział piąty zawiera opis metody prognozowania całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego (BMMT). Podobnie jak dla metody BMAD wyspecyfikowano założenia dla metody oraz opisano samą metodę. Następnie przedstawiono dobór modeli ML oraz proces ich dostrajania wraz z analizą dostarczanych wyników przez nie wyników. Rozdział zamyka analiza pracy modeli ML z danymi rzeczywistymi również z uwzględnieniem danych uszkodzonych.

W rozdziale szóstym zostały opisane modele wybranych zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego oraz metoda detekcji zdarzeń podczas pracy elektrycznego napędu rogatekowego wykrywanych jako usterki (BMFD) – przedstawiono założenia do metody, sposób opracowania danych treningowych i testowych, proces doboru i strojenia modeli ML. Rozdział kończy analiza skuteczności metody BMFD z wykorzystaniem danych rzeczywistych.

W rozdziale siódmym zawarto opis zrealizowanego projektu wdrożeniowego będącego praktyczną implementacją metody BMAD wraz z realizacją testów terenowych. Rozdział ósmy zawiera podsumowanie pracy.

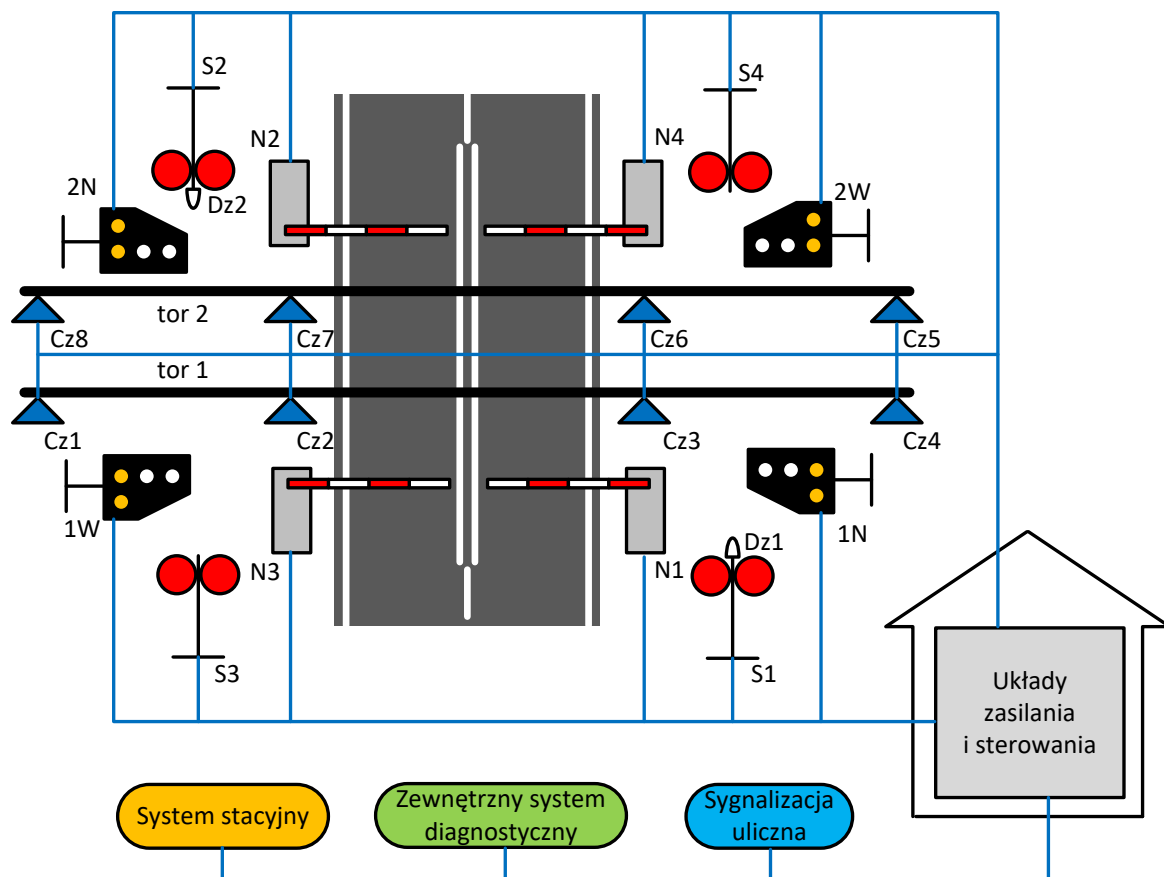
3. Wprowadzenie

W niniejszym rozdziale omówiono miejsce i rolę elektrycznego napędu rogatkowego w systemie sygnalizacji przejazdowej oraz przedstawiono jego budowę i sposób działania. Następnie wykonano analizę aktualnego stanu badań w obszarach związanych z napędem rogatkowym, jako elementem sygnalizacji przejazdowej odpowiedzialnej za zapewnienie bezpieczeństwa oraz rozumianym jako napęd elektryczny wymagający funkcji diagnostycznych realizowanych z wykorzystaniem technik uczenia maszynowego. Opisano proponowane nowe metody diagnostyczne w zakresie wykorzystywanych danych wejściowych oraz dostarczanych danych wyjściowych. W ostatniej części zaprezentowano zbudowane stanowisko testowe oraz parametry oceny jakości proponowanych metod.

3.1. Napęd rogatkowy jako element sygnalizacji przejazdowej

Miejszem pracy elektrycznego napędu rogatkowego jest system sygnalizacji przejazdowej, co przekłada się na zbiór wymagań i ograniczeń kształtujących możliwości opracowania nowych rozwiązań diagnostycznych oraz możliwości ich implementacji w samym napędzie, interfejsie sterującym, czy też w części kontrolno-sterującej systemu przejazdowego. Typowa konfiguracja tego systemu została przedstawiona na rys. 3.1.

W kontenerze zlokalizowanym bezpośrednio przy przejeździe zainstalowane są układy zasilania i sterowania. Są one zbudowane w oparciu o dwukanałowy sterownik mikroprocesorowy oraz zestaw modułów wejściowo-wyjściowych tworzących zespoły interfejsów dla poszczególnych urządzeń i systemów zewnętrznych, dla których rozpatrywane są możliwe scenariusze ich degradacji. Biorąc pod uwagę bezpieczeństwo systemu wyznaczany jest stan bezpieczny S_B , w jakim powinno się znaleźć dane urządzenie w sytuacji jego niesprawności np. dla napędu rogatkowego jest to pozycja, w której drąg zamyka dostęp do obszaru przejazdu. Wybrane urządzenia podlegają również kontroli sprawności w stanie, gdy nie są bezpośrednio aktywowane, np. funkcja kontroli ciągłości drąga napędu rogatkowego.



Rys. 3.1 System samoczynnej sygnalizacji przejazdowej

Sygnalizacja przejazdowa będąca w stanie oczekiwania S_0 , której napędy rogatkowe znajdują się w położeniu górnym, jest aktywowana poprzez wykrycie nadjeżdżającego pociągu za pomocą czujników koła zabudowanych najdalej od przejazdu (odpowiednio Cz1, Cz8, Cz4 lub Cz5 co przedstawiono na rys. 3.1) lub za pomocą odpowiedniego rozkazu przesyłanego poprzez układ powiązania z nadrzędnym systemem stacyjnym. W odpowiedzi, w ciągu ściśle zdefiniowanego czasu t_d , sygnalizacja przejazdowa realizuje funkcję wstępnego ostrzegania S_I poprzez aktywowanie sygnalizatorów drogowych (S1, S2, S3, S4) oraz dzwonów (Dz1 i Dz2), a następnie rozpoczyna proces zamykania napędów rogatkowych (N1, N2, N3 i N4).

Odległość w jakiej są zabudowane czujniki koła oraz tarcze ostrzegawcze przejazdowe jest bezpośrednio powiązana z długością wymaganego przepisami czasu wstępnego ostrzegania t_d , jak i efektywnością w sterowaniu urządzeniami ostrzegawczymi, w tym głównie charakterystyką czasową procesu t_{BM} sterowania napędem rogatkowym.

Sprawność działania sygnalizacji przejazdowej, a w tym i jej napędów rogatkowych warunkuje przesłanie sygnału potwierdzenia poprawnego przejścia do stanu ostrzegania S_I . Przejazd szlakowy wyposażony w układ czujników koła, z zainstalowaną tarczą ostrzegawczą przejazdową (1W, 1N, 2W, 2N) poprzez podanie sygnału dwóch białych

świateł umieszczonych w linii pionowej (Osp2) [12]. Pociąg może kontynuować jazdę w kierunku przejazdu z maksymalną dopuszczalną prędkością z zachowaniem oczekiwanej przepustowości linii kolejowej. Jeśli w trakcie sekwencji wstępnego ostrzegania S₁ lub podczas próby zamknięcia napędów rogatkowych zostanie stwierdzona usterka, to przekłada się to natychmiast na wyświetlenie sygnału Osp1 na tarczach ostrzegawczych przejazdowych [12] lub przesłanie odpowiedniej informacji do systemu nadrzędnego. W efekcie przepustowość linii kolejowej jest obniżona ze względu na konieczność ograniczenia prędkości przejazdu do 20km/h. Taki sposób działania sygnalizacji przejazdowej uwidacznia kluczową rolę napędów rogatkowych zarówno w realizacji funkcji zapewnienia bezpieczeństwa na obszarze przejazdu, jak i ich bezpośredni wpływ na wydajność całego systemu kolejowego. W tym kontekście pojawia się potrzeba pozyskania informacji zarówno o przewidywanym całkowitym czasie ruchu drąga, jak i o jego aktualnym położeniu kątowym. Pozyskanie tych informacji otwiera drogę zarówno do dalszej optymalizacji czasowej na poziomie całego systemu kolejowego, jak i umożliwia wprowadzenie dokładniejszych mechanizmów diagnostycznych uwzględniających zmienność parametrów czasowych danego zestawu napędów rogatkowych.

Ze względu na konieczność zapewnienia wysokiego poziomu nienaruszalności bezpieczeństwa [2], [13] stosowane są dedykowane rozwiązania zarówno w sposobie budowy części programowej, jak i sprzętowej układów tworzących system sygnalizacji przejazdowej. Analiza bezpieczeństwa systemu sygnalizacji przejazdowej koncentruje się na sposobie realizacji jego ściśle zdefiniowanych funkcji. Dla napędu rogatkowego taką funkcją jest opuszczenie drąga do położenia poziomego i utrzymania tej pozycji aż do momentu opuszczenia strefy przejazdowej przez wszystkie pojazdy szynowe. W rezultacie, mając na uwadze specyfikę tego interfejsu, utrudnione jest wprowadzanie jakichkolwiek modyfikacji ze względu na rozbudowany i kosztowny proces wprowadzania nowego rozwiązania do eksploatacji [13]. Ewentualne rozszerzenie interfejsu w kierunku uzupełnienia o funkcje diagnostyczne powinno zostać zrealizowane z zachowaniem pełnej separacji galwanicznej, możliwie brakiem zmian w konstrukcji napędu oraz pełną niezależnością w warstwie programowej.


Modyfikacje konstrukcji systemu sygnalizacji przejazdowej muszą być realizowane z uwzględnieniem wymagań rozbudowanego zestawu norm definiujących wymagania w zakresie odporności na czynniki środowiskowe, jak i narażenia występujące w środowisku kolejowym [14], [15], ograniczenia dotyczące generowanych zakłóceń [16], bezpieczeństwo porażeniowe [17], [18], mechanizmy zapewnienia bezpiecznej transmisji [19], odporności na przepięcia [20], wymaganych poziomów niezawodności, dostępności, podatności utrzymaniowej i bezpieczeństwa [21], [22], poziomu nienaruszalności bezpieczeństwa [2], sposobu tworzenia oprogramowania [23], sposobu działa wybranych

elementów składowych mających bezpośredni wpływ na bezpieczeństwo [24] wielu innych regulacji i ich zestawów określanych dla poszczególnych rynków [13].

3.2. Budowa elektrycznego napędu rogatkowego

Elektryczny napęd rogatkowy składa się z silnika, przekładni, drąga, układu detekcji położenia drąga i kontroli jego ciągłości. Elektryczny napęd rogatkowy rodziny *EBI Gate 630* typu EEG-3 jest typowym przedstawicielem tej klasy urządzeń ostrzegawczych. Jego wygląd zewnętrzny jest przedstawiony na rys. 2.3, a budowa wewnętrzna na rys. 3.2.

W przypadku napędu EEG-3 układ napędowy wyposażony jest w szczotkowy silnik prądu stałego zablokowany z niezależnie sterowanym hamulcem elektromagnetycznym. Silnik ten napędza przekładnię pasową, która z kolei wprowadza w ruch obrotowy śrubę kulową, po której przemieszcza się odpowiednio ukształtowana nakrętka toczna wraz z zabudowanymi na niej dwoma rolkami nośnymi. Na śrubie kulowej jest zabudowana sprężyna samoopadania. W przypadku zaniku napięcia sterującego hamulcem elektromagnetycznym drąg napędu znajdujący się w położeniu górnym rozpocznie opadanie pod wpływem działania sprężyny oraz momentu niewyważenia układu drąg-przeciwwaga. Rolki napędzają dwa ramiona ruchome wprowadzające w ruch obrotowy wał główny napędu rogatkowego. Położenie drąga w napędzie jest wykrywane poprzez układ dwóch lub trzech wyłączników krańcowych aktywowanych przemieszczającą się nakrętką toczną. W ten sposób układ sterowania kontroluje położenia drąga – górne, dolne oraz pośrednie. Zakres ruchu drąga jest zależny od sposobu regulacji napędu rogatkowego, w czasie którego określane jest zarówno skrajne położenie dolne jak i górne. Napęd występuje w wielu odmianach różniących się szczegółami sposobu pracy oraz wyposażenia. Należy podkreślić, że układ detekcji drąga dostarcza informacji ograniczonej jedynie do wykrycia położen skrajnych i jednej pozycji pośredniej.



Rys. 3.2 Budowa wewnętrzna elektrycznego napędu rogatekowego
EBI Gate 630 (EEG-3) – materiały firmy ALSTOM ZWUS Sp. z o.o.

- a – silnik wraz z hamulcem elektromagnetycznym zasilany napięciem DC24 V,
- b1 – pierwsza przekładnia, b2 – druga przekładnia, c – mechanizm awaryjnego napędu korbowego, d – oś główna napędu wraz z przyłączem służącym do montażu drąga,
- e1, e2 – wyłączniki krańcowe położenia dolnego i górnego

Stosowane są również inne konstrukcje elektrycznych napędów rogatek. Na rys. 3.3 zostały przedstawione trzy inne rozwiązania oferowane na rynku krajowym. Napęd JEGD50M220 to przykład modernizacji wyrobu obecnego na rynku krajowym od wielu lat polegającej, między innymi na wprowadzeniu bezstykowego układu kontroli położenia. W tym wypadku stosowany jest silnik indukcyjny zasilany napięciem AC 230 V.



Rys. 3.3 Elektryczne napędy rogatkowe – od lewej kolejno: zmodernizowany elektryczny napęd rogatkowy JEGD50M220 [25], elektrohydrauliczny napęd rogatkowy RHR-95 [26], elektrohydrauliczny napęd rogatkowy HSM 10E [26]

Stosowane są również rozwiązania elektrohydraulicznych napędów rogatek, np. napęd RHR-95, gdzie silnik elektryczny napędza jedynie agregat hydrauliczny, a sterowanie drągiem odbywa się za pomocą hydraulicznego siłownika. Podobnie napęd HSM 10E jest również rozwiązaniem opartym na połączeniu silnika elektrycznego, pompy hydraulicznej oraz specjalizowanego siłownika.

Interfejs sterujący elektrycznego napędu rogatkowego znajduje się zawsze w jednym z dwóch możliwych stanów – jest skonfigurowany do ruchu w górę lub w dół. Domyślnie, ze względów bezpieczeństwa, znajduje się w trybie ruchu w dół. Drąg napędu pozostaje jednak w bezruchu ponieważ mechanizm napędowy jest nieaktywny oraz bieżące położenie drąga jest utrzymywane poprzez specyficzny dla danej konstrukcji mechanizm ryglowania. Funkcja ustanowienia odpowiedniej konfiguracji interfejsu sterującego oraz samego napędu rogatkowego do ruchu drąga w górę lub w dół jest realizowana w sposób bezpieczny z zapewnieniem najwyższego poziomu nienaruszalności bezpieczeństwa SIL-4. W przypadku rynku polskiego jest to określone instrukcją kolejową Ie-119 [22].

W niniejszej pracy stworzono stanowisko pomiarowe oparte na elektrycznym napędzie rogatkowym typu EEG-3, ponieważ jest szeroko stosowanym rozwiązaniem zarówno

w projektach związanych z rynkiem krajowym, jak i na potrzeby realizowanych adaptacji zagranicznych. Napęd ten uzyskuje dopuszczenia do eksploatacji np. na wymagającym rynku Wielkiej Brytanii. Również przewidywany jest dalszy rozwój tego napędu, co czyni badania wartościowymi w aspekcie wdrożeniowym.

Ze względu na utrudniony dostęp oraz brak możliwości realizacji jakichkolwiek modyfikacji w zabudowanych i działających systemach, w tym również zabudowy sprzętu pomiarowego, nie jest możliwe efektywne realizowanie badań terenowych zarówno napędów EEG-3, jak i napędów innych typów. Mając na uwadze powyższe, została podjęta decyzja o budowie dedykowanego stanowiska testowego, umożliwiającego przeprowadzenie szeroko zakrojonych badań i prób eksploatacyjnych.

3.3. Analiza aktualnych badań związanych z diagnostyką elektrycznego napędu rogatekowego

Elektryczny napęd rogatekowy stanowi integralną część systemu sygnalizacji przejazdowej zaś celem wprowadzenia udoskonalonej diagnostyki elektrycznego napędu rogatekowego jest również podniesienie poziomu dostępności przejazdu kolejowo-drogowym a w efekcie całego systemu kolejowego. W rezultacie koniecznym staje się przeanalizowanie dotychczasowych wysiłków badawczych w tym obszarze. Analiza dostępnych publikacji prowadzi do wniosku, że prowadzone badania pokrywają następujące obszary:

- przejazdy kolejowo-drogowe jako element infrastruktury systemu kolejowego,
- problem bezpieczeństwa w bezpośrednim otoczeniu przejazdu,
- problematyka usterek napędów elektrycznych.

Końcowa część rozdziału została poświęcona publikacjom związanym z dynamicznie rozwijającymi się technikami Machine Learning i ich skutecznymi aplikacjami.

Przejazdy kolejowo-drogowe są elementem systemu kolejowego, w którym często dochodzi do wypadków dlatego prowadzone są prace mające na celu wytworzenie zweryfikowanych mechanizmów dających możliwość oceny ryzyka występującego na konkretnych instalacjach. W jednym z podejść w oparciu o zapisy możliwych scenariuszy prowadzących do niebezpiecznych sytuacji oraz zagregowane parametry rzeczywistych przejazdów budowane są modele funkcjonujące w oparciu o sieci bayesowskie. Tak przygotowane modele są wykorzystywane do ewaluacji poziomu bezpieczeństwa na przejazdach we Francji [27].

W innym podejściu budowany jest – z wykorzystaniem sieci Petriego – szczegółowy model będący złożeniem modeli odwzorowujących poszczególne elementy stanowiące środowisko, w jakim pracuje sygnalizacja przejazdowa. Symulacje wybranych sekwencji zdarzeń realizowane w oparciu o tak wytworzone modele dają wgląd w sytuacje potencjalnie prowadzące do wypadku, otwierając drogę do opracowania rozwiązań zapobiegających niebezpieczeństwu [28]. Należy tu zwrócić uwagę na brak szczegółowej analizy zdarzeń skupiającej się na samym napędzie rogatekowym.

W rozwiniętych administracjach kolejowych mają zastosowanie specjalne procedury, które zapewniają odpowiednią dystrybucję kosztów w zależności od udziału elementów systemu kolejowego danego podmiotu w powstałym opóźnieniu. Obciążenia te są przenoszone zarówno na elementy taboru, jak i na elementy infrastruktury [29]. Przy takim

podziale odpowiedzialności, awaria pojedynczego napędu rogatekowego i dużym obciążeniu linii kolejowej wiąże się z wygenerowaniem znaczących strat.

Konsekwencją pojawiających się opóźnień jest konieczność wprowadzenia modyfikacji do rozkładów jazdy pociągów, co jest zadaniem trudnym ponieważ system kolejowy jest obiektem dynamicznym i znajduje się w ciągłym ruchu. Rozwiązaniem tego problemu może być zastosowanie algorytmów optymalizacji kolonii mrówek (ACO) dla dynamicznego wieloobiektowego problemu (DMOP) [4]. Przeprowadzenie badań jest utrudnione poprzez brak danych dokumentujących zmiany wprowadzane do systemu kolejowego w celu redukcji problemów związanych z występującymi opóźnieniami. Dotychczas zrealizowane próby opierały się na symulacjach systemu kolejowego budowanych w oparciu o analizę ich rzeczywistych odpowiedników. Proponowana technika rozwiązania problemu została porównana z heurystycznymi podejściami stosowanymi przez dyżurnych ruchu. Autorzy proponują techniki minimalizacji strat w zakresie czasu opóźnień dla całego systemu kolejowego, którego integralnym elementem jest system sygnalizacji przejazdowej. Autorzy niestety nie dokonują analizy zależności czasowych występujących w samym systemie sygnalizacji przejazdowej, na które bezpośrednio wpływa sposób pracy napędów rogatekowych.

Inne proponowane rozwiązanie problemu redukcji opóźnień w systemie kolejowym jest oparte na technice sterowania predykcyjnego (MPC). Wyróżnia się ono krótkim czasem potrzebnym do znalezienia rozwiązania z uwzględnieniem występujących ograniczeń [30] [27]. Również w tym wypadku ewaluacja jest realizowana w oparciu o model sieci kolejowej, jednak o złożoności systemu jednego kraju – w tym wypadku Holandii. Podstawowym założeniem zapewniającym skuteczność opracowanych algorytmów jest obecność systemu scentralizowanej kontroli ruchu (CTC) pokrywającej swoim zasięgiem badany obszar.

Jeszcze inny sposób rozwiązania problemu opóźnień, które się propagują w systemie kolejowym, wykorzystuje technikę aproksymacyjnego programowania dynamicznego (ADP). Metoda polega na zdefiniowaniu optymalnych sekwencji pociągów w krytycznych fragmentach sieci kolejowej. Testy zostały wykonane za pomocą symulatora porównując uzyskane efekty z metodą priorytetowej obsługi pociągu, który pojawił się w danym węźle. Największy uzysk został zaobserwowany dla stacji o charakterze terminali towarowych. Zastosowanie technik aproksymacyjnego programowania dynamicznego zmniejsza wymagania w zakresie mocy obliczeniowej w porównaniu z wieloma innymi metodami proponowanymi w literaturze [31]. Niestety optymalizacja sekwencji pociągów w obszarze jednej stacji odbywa się kosztem zwiększenia opóźnień dla stacji sąsiadujących. Jednak autorzy zapewniają, że globalnie, z punktu widzenia całego systemu kolejowego, ostateczny wynik jest pozytywny [31]. Rozważania jednak są ograniczone do poziomu całego systemu

kolejowego bez analizy sposobu pracy jego poszczególnych elementów takich jak system sygnalizacji przejazdowej.

W celu ograniczenia ilości wypadków na przejazdach kolejowo-drogowych przeprowadzane są również próby z wdrożeniem Internetu rzeczy (IoT) oraz techniki uczenia maszynowego (ML) [32]. Jednym z proponowanych rozwiązań w tym nurcie jest projekt autonomicznego systemu przejazdowego. Układ detekcji pociągu składa się z dwóch modułów. Pierwszym modułem jest detektor pociągu aktywowany przetwornikiem piezoelektrycznym wykrywającym wibracje w stopie szyny oraz indukcyjnym czujnikiem zbliżeniowym wykrywającym obręcz koła, który jest zainstalowany na linii kolejowej w oddaleniu od przejazdu. Drugim modułem jest układ przetwarzający obraz rejestrowany przez kamerę za pomocą techniki uczenia maszynowego celem rozpoznania czoła nadjeżdżającego pociągu. Niestety uzyskiwana skuteczność funkcji wykrywania nadjeżdżającego pociągu wymaga poprawy. Nie zmienia to faktu, że rozwiązanie to stanowi jedną z pierwszych prób zastosowania technik uczenia maszynowego w obrębie systemu sygnalizacji przejazdowej.

Wiele wypadków na przejazdach kolejowo-drogowych jest spowodowanych omijaniem półrogatek – jest to przypadek przejazdu wyposażonego w dwa napędy rogatkowe zamykające jedynie połowę jezdni dla kierunków wjazdowych. Dwoma podstawowymi przyczynami są zbyt długie czasy zamknięcia przejazdów lub zbyt krótkie odstępy pomiędzy kolejnymi zamknięciami. Jedną z proponowanych i często stosowanych metod jest wyposażanie w przejeździe w komplet napędów rogatkowych – dwa wjazdowe i dwa wyjazdowe. W takiej konfiguracji pojawia się problem zamknięcia pojazdów pomiędzy drogami. Odpowiedzią na ten problem są systemy wykrywania przeszkody na przejeździe w oparciu o systemy wykorzystujące różnego rodzaju czujniki. W artykule [33] zaproponowano stworzenie modeli behawioralnych z wykorzystaniem sieci Petriego, czyli scenariusz wypadku był odwzorowywany w model dający możliwość znalezienia sposobu uniknięcia niebezpieczeństwa z wykorzystaniem funkcjonalności, jakie zapewnia system zarządzania ruchem kolejowym ERTMS. Inne rozwiązanie zaprezentowane w [34] również wykorzystujące sieci Petriego proponuje budowę modelu z uwzględnieniem szczegółów konstrukcyjnych przejazdu, takich jak obecność napędów rogatkowych, sposób działania sygnalizacji świetlnej czy struktura układu drogowego.

Oddzielnym problemem są zachowania pieszych, którzy pomimo podania im czytelnej informacji o grożącym niebezpieczeństwie, kierując się osobistymi celami i wygodą decydują się na ryzykowne zachowania [35]. Często powtarzające się wypadki w danej lokalizacji powodują, że lokalna społeczność naciska na instalację napędów rogatkowych celem poprawy bezpieczeństwa. Pomimo zainstalowania półzapór w dalszym ciągu dochodzi do wypadków. Najczęstszym błędem ludzkim w tym przypadku jest nieprawidłowe planowanie działania. Sugerowanym wyjaśnieniem takiej przyczyny jest

znudzenie, utrata cierpliwości w oczekiwaniu na ponowne otwarcie przejazdu. W [36] zaproponowano zapewnienie kierowcom dodatkowych aktywności w postaci dedykowanych stron internetowych – dostęp do nich ma być zapewniony poprzez umieszczenie na infrastrukturze przejazdu kodów QR. Wspomniano również o pochodzącym z rosyjskiego rynku urządzeniu UZP będącym uzupełnieniem napędów rogatek, który jest płytą podnoszoną w kierunku nadjeżdżających do przejazdu pojazdów. Jednym z najskuteczniejszych rozwiązań jest jednak zastosowanie kompletu czterech zapór [36], [37]. Badania nie były prowadzone w kierunku analizy zmienności całkowitego czasu ruchu drąga czy też detekcji poszczególnych zdarzeń występujących podczas pracy elektrycznego napędu rogatek.

Jeszcze inne podejście do problemu poprawy bezpieczeństwa na przejeździe kolejowo-drogowym polega na zapewnieniu komunikacji pomiędzy uczestnikami ruchu. Zauważyć należy, że lokalizacja i prędkość pojazdu szynowego jest znana w sposób ciągły, co umożliwia realizację najbardziej optymalnego czasu ostrzegania, jednocześnie przekazując informacje statusowe łączem radiowym użytkownikom drogi. W ten sposób realizowane są łącza typu pojazd-infrastruktura (V2I) dające możliwość wprowadzenia układów sygnalizacji do wnętrza pojazdów. Jest to odpowiedź na jedną z głównych przyczyn wypadków na przejazdach jaką jest rozproszenie uwagi kierowcy. Planowane są również testy systemów sygnalizacji opartych o łącza pojazd-infrastruktura z wykorzystaniem symulatorów dających możliwość sprawdzenia reakcji kierowców na urządzenia ostrzegawcze zamontowane wewnątrz pojazdów [38]. W tym zakresie zostały również zrealizowane praktyczne testy w ramach projektu „SAFER-LC” w Grecji, w mieście Tesaloniki, gdzie urządzenia ostrzegawcze zostały dobrze przyjęte przez zawodowych kierowców taksówek [39]. Jeszcze inne badania zostały zrealizowane z wykorzystaniem urządzeń pokładowych dających możliwość przełączenia trybu pracy i wybór sygnału ostrzegającego przed nadjeżdżającym pociągiem: akustyczny (preferowany) czy wizualny [40]. Autorzy w pracy [41] poruszają temat komunikacji pojazd-infrastruktura oraz komunikacji z pojazdami szynowymi za pomocą sieci GSM-R.


Obiektem badań w zakresie bezpieczeństwa na przejazdach kolejowych jest też skuteczność oddziaływania poszczególnych rodzajów sygnalizacji na przejazdach kolejowo-drogowych w oparciu o obserwowane zachowanie kierowców. W przeprowadzonych testach z wykorzystaniem symulatora badani kierowcy przekraczali dwa rodzaje przejazdów – w pierwszym przypadku wyposażone jedynie w znaki drogowe oraz w drugim również w czerwone światła migowe. Kierowcy częściej ograniczali prędkość pojazdu w przypadku przejazdów wyposażonych w światła [42]. Podobne wnioski zostały sformułowane w badaniach, w których reakcja kierowców była obserwowana poprzez śledzenie ruchów ich oczu oraz inne parametry, takie jak odległość w jakiej pojazd był zatrzymywany przed linią stopu, czy też moment uruchomienia hamulców. Zmianie

podlegała również częstotliwość sygnałów migowych. Wnioski podsumowujące badania kierują uwagę na dobór optymalnych parametrów pracy elementów oddziaływania optycznego sygnalizacji przejazdowej [43].

Istotną rolę odgrywa też długość czasu oczekiwania przed zamkniętym przejazdem [44]. Przy długich czasach oczekiwania u kierowców narasta zniecierpliwienie i frustracja. Badania z wykorzystaniem symulatora dotyczyły następujących zachowań: wjazdu w trakcie trwania stanu ostrzeżenia na przejazd tuż przed zamknięciem napędów rogatek, wjazd na przejazd tuż po przejeździe pociągu, zatrzymanie lub nawracanie w obszarze przejazdu. Deklarowanymi powodami była presja czasu, zniecierpliwienie i zaniżona ocena ryzyka. Ogólnym wnioskiem z badań jest postulat o standaryzacji czasów ostrzeżenia na przejazdach kolejowo-drogowych do wartości krótszych niż trzy minuty [45]. Również i w tym przypadku nie była analizowana zmienność czasu potrzebnego do zmiany położenia drągów czy też sposoby pozyskania informacji o ich bieżącym położeniu.

Alternatywnym miejscem, w którym możliwe jest zabudowanie światła ostrzegawczego jest czoło pociągu. Zostały przeprowadzone badania z wykorzystaniem symulatora mające na celu sprawdzenie, jaki wpływ na poprawę bezpieczeństwa i ergonomii na przejeździe kolejowo-drogowym ma zabudowanie światła stroboskopowego na pojeździe szynowym jako uzupełnienie standardowego oświetlenia. Rozwiązanie to jest przedstawiane jako alternatywa dla scenariusza, w którym urządzenia ostrzegawcze są zabudowywane w pojazdach samochodowych. Również w tym przypadku obok innych miar był obserwowany ruch oczu i czas upływający do skupienia uwagi na nadjeżdżającym pociągu [46].

Badania związane z problematyką przejazdów kolejowych sięgają nawet do takiej problematyki, jak sposób doboru urządzeń i znaków z uwzględnieniem profilu wiekowego osób uczestniczących w ruchu [47]. Agencja Kolejowa Unii Europejskiej (ERA) przedstawia w swoim rocznym raporcie podsumowanie w zakresie poprawy bezpieczeństwa i interoperacyjności stosowanych systemów. Analizy przedstawiają pozycję przejazdów kolejowo-drogowych w zakresie ich udziału w ogólnej liczbie wypadków śmiertelnych wykazując, jak duże znaczenie ma wdrożenie działań mających na celu poprawę bezpieczeństwa właśnie w tym obszarze (rys. 3.4) [48].



Rys. 3.4 Liczebność wypadków śmiertelnych w poszczególnych kategoriach [48]

Zauważyć należy również badania nad stanem bezpieczeństwa bezpośrednio na obszarze przejazdu kolejowo-drogowego, gdzie rozważane są różne aspekty podsystemu sygnalizacji przejazdowej, co może być przydatne do opracowania nowej metody diagnostyki elektrycznego napędu rogatekowego.

Wyniki prowadzonych badań nad zachowaniem pieszych wskazują, że wśród ofiar wypadków, do których doszło na obszarze przejazdów kolejowo-drogowych przeważają osoby młodociane i starsze, głównie płci męskiej. Dokładniejsza analiza wykazuje, że w obu grupach wiekowych pojawia się przekonanie o braku możliwości uniknięcia pewnych negatywnych zdarzeń, jak i wpływ pośpiechu w podejmowaniu ryzykownych zachowań. Młodsza grupa motywowana jest również niewiarą w realność niebezpieczeństwa, impulsywnie podejmuje ryzyko i bywa nieskupiona na otoczeniu. Starsza grupa wskazuje na problemy wynikające z utrudnionej mobilności będące zachętą do podjęcia ryzykownych prób, jak i na obniżoną wrażliwość zmysłów. Rozwiązanie tego zjawiska upatruje się w zabudowaniu napędów rogatekowych i to najlepiej uzupełnionych o odpowiednie ogrodzenia, co wynika z przekonania badanych o skuteczności takich urządzeń w zapobieganiu zarówno intencjonalnym naruszeniom bezpieczeństwa, jak działań wynikających z nieuwagi. Dodatkowo wskazywano, że napędy rogatekowe powinny być ryglowane w położeniu dolnym [6]. Znalezienie skutecznego sposobu wykrywania aktualnego położenia kąтового drąga oraz predykcji całkowitego czasu ruchu otwiera możliwość skrócenia zarówno czasu wstępnego ostrzegania jak i w efekcie całkowitego czasu ostrzegania a poprzez to skrócenia czasu, w którym dochodzi do niebezpiecznych zdarzeń z udziałem pieszych. Na przykład w przypadku napędów rogatekowych

wyposażonych w bardziej rozbudowanych konfiguracje dróg o długościach przekraczających 9m zaobserwowany w praktyce zakres całkowitych czasów ruchów w górę oraz w dół jest zbliżony do przedziału od 10 s do 15 s. W konsekwencji konieczne jest założenie dla tej fazy pracy sygnalizacji przejazdowej przedziału czasu z pewnym marginesem osiągając ostatecznie reprezentatywną wartość 20 s. W przypadku gdy znana jest predykcja całkowitego czasu ruchu droga możliwe jest uzyskanie oszczędności na poziomie od 25% do 50% pierwotnie założonego maksymalnego dopuszczalnego czasu ruchu.

Odbiegające od normy zachowania kierowców można skutecznie wykrywać analizując geometryczne położenie pojazdu na pasie jezdni, co zaprezentowano w [49]. Źródłem danych jest w tym wypadku również monitoring wizyjny. Poprzez analizę obrazu ustalana jest zarówno lokalizacja pojazdu, jak i obrys elementów jezdni. Wyniki wskazują na 80% skuteczność w wykrywaniu nietypowych zachowań kierowców. Takie podejście z wykorzystaniem analizy obrazu na potrzeby przemieszczających się dróg jest niewystarczające ze względu na uzyskiwaną ograniczoną skuteczność, jak i konieczność zainstalowania dodatkowego rozbudowanego i drogiego wyposażenia przejazdu.

Do wykrywania przeszkód na przejazdach kolejowo-drogowych wykorzystywane są skanery laserowe pracujące w technologii LIDAR dające możliwość analizy sytuacji w czasie rzeczywistym [50]. Przetwarzanie danych jest realizowane przez urządzenie brzegowe o ograniczonej mocy obliczeniowej i niskim poborze energii, zainstalowane blisko skanera. Lokalizacja ta jest wybrana celem uniknięcia opóźnień powiązanych z przetwarzaniem danych w chmurze obliczeniowej. W tym wypadku rozwiązanie spełnia kryteria systemu czasu rzeczywistego. Szczególnym przypadkiem są przeszkody znajdujące się bezpośrednio na torach w obszarze przejazdu kolejowo-drogowego, których wykrycie zostało oparte na systemie sensorów składających się z dwóch barier łączących w sobie zarówno elementy fotooptyczne pracujące w zakresie podczerwieni, jak i emitery oraz odbiorniki ultradźwięków [51]. Zastosowanie dwóch różnych technologii otwiera możliwość wzajemnego kompensowania ograniczeń jednego typu czujników przez drugi. Zdarza się, że czujniki światła podczerwonego błędnie sygnalizują obecność przeszkody w warunkach silnego zamglenia. Analogicznie zachowują się czujniki ultradźwiękowe, gdy wieje silny wiatr, a w szczególności gdy przepływ jest turbulentny. Układ sterowania został zrealizowany w oparciu o układ FPGA. Otwiera to dalsze możliwości zwiększające niezawodność działania całego układu detekcji przeszkody – w obu przypadkach nadawane sygnały są kodowane oraz stosowane są techniki fuzji danych [51]. System sensorów może działać również jako uzupełnienie dla innych urządzeń wykrywających przeszkodę na przejeździe, dając możliwość rozróżnienia specyficznych przypadków – np. ustalenia czy przeszkoda znajduje się bezpośrednio na torach, czy przeszkoda się przemieszcza, oszacowanie rozmiaru obiektu [52]. Przedstawione badania nie przewidują wykorzystania

mechanizmu wykrywania zdarzeń występujących podczas pracy napędów rogatek, które dałyby dodatkowy wgląd w bieżącą sytuację na przejeździe.

Techniki sztucznej inteligencji w połączeniu z monitoringiem wizyjnym pracującym jako źródło danych otwierają możliwość skutecznego wykrywania przeszkody na przejeździe – również w obecności wielu sygnałów zakłócających, takich jak poruszające się drągi napędów rogatek, co poruszono w pracy [53]. Dzięki zastosowaniu głębokich sieci neuronowych wprowadzony system jest w stanie w czasie rzeczywistym wykrywać 89% sytuacji niebezpiecznych w przestrzeni przejazdu kolejowo-drogowego. Do wykrywania obiektów zostały wykorzystane modele wytrenowane również do poprawnego wykrywania elementów infrastruktury przejazdu znajdujących się w różnych stanach pracy, takich jak sygnalizatory drogowe, napędy rogatek z drągami, oznakowanie. Dodatkowo dane są przetwarzane i przechowywane zgodnie z obowiązującym na terenie Unii Europejskiej prawem – podlegają anonimizacji celem ochrony prywatności osób przemieszczających się w nadzorowanej przestrzeni [53]. Ograniczeniem jest w tym wypadku konieczność zabudowania odpowiednio rozbudowanego systemu monitoringu wizyjnego.

Rozwiązania oparte o sieci neuronowe są w stanie rozpoznawać sygnały dźwiękowe emitowane przez pojazdy szynowe zbliżające się do przejazdów kolejowo-drogowych stanowiąc alternatywę dla tradycyjnych rozwiązań, takich jak obwody torowe czy czujniki indukcyjne [54]. Niestety skuteczność tego typu rozwiązań poddawana jest krytyce – sygnały nie zawsze są jakościowo dobre, np. w zależności od lokalizacji poziom ich głośności jest silnie zmienny. Dodatkowo coraz częściej wprowadzane są regulacje zabraniające podawania sygnałów dźwiękowych przez pociąg w czasie nocnym lub na wybranych obszarach. W efekcie skuteczność aktualnego podejścia do problemu bezpieczeństwa przejazdu w zakresie powiadomienia użytkowników przejazdu o nadjeżdżającym pociągu z wykorzystaniem podawanych przez niego sygnałów dźwiękowych jest kwestionowana [55]. Innymi czynnikami, które mają wpływ na poziom bezpieczeństwa na przejeździe kolejowo-drogowym są kolizje użytkowników drogi z elementami infrastruktury kolejowej, brak odpowiednich oznaczeń i znaków, prędkość z jaką poruszają się pociągi, betonowa nawierzchnia drogi oraz czynniki pogodowe [56].

Diagnostyka napędów elektrycznych, które są również wykorzystywane m.in. w elektrycznych napędach rogatek, jest kluczowym elementem zapewniającym ciągłość utrzymania ruchu, tj. kosztów utrzymania, dlatego konieczne jest wprowadzenie mechanizmów monitorujących parametry pracy napędów elektrycznych, które umożliwiają wypracowanie dalszych informacji dla algorytmów sterowania oraz wczesnego wykrywania usterek [57]. Nowoczesne mechanizmy diagnostyczne budowane są z wykorzystaniem technik uczenia maszynowego [58]–[60], ponieważ w wielu przypadkach nie pociągają za

sobą konieczności instalowania czujników bądź innych modyfikacji sprzętowych [61]. Należy zauważyć, że przedstawione badania dotyczą jedynie diagnostyki wyizolowanych napędów elektrycznych.

Często w układach zasilania silników występują zakłócenia, takie jak zmiany napięcia, zniekształcenia harmoniczne i impulsowe. W związku z tym oczekuje się, by układy diagnostyczne wykazywały dużą odporność na takie warunki pracy zapobiegając błędnym klasyfikacjom aktualnego stanu silnika. W opracowaniu [62] zaproponowano rozwiązanie, które łączy dane pochodzące z układu monitorującego jakość sieci zasilającej z danymi o prądzie rozruchowym silnika indukcyjnego. W efekcie możliwe jest skuteczne wykrycie uszkodzenia wirnika oraz łożysk za pomocą sztucznej sieci neuronowej. W pracy [63] dane wejściowe oparte są na cechach przebiegów prądu zasilającego dla sprawnych i uszkodzonych silników przy różnych prędkościach obrotowych, a model oparty o uczenie maszynowe umożliwia wykrycie usterek łożysk w ich początkowej fazie, co prowadzi do skrócenia przerw w pracy zespołu napędowego oraz strat finansowych spowodowanych poważną awarią.

Inną koncepcję podejścia do problemu diagnostyki pokazano w [64], gdzie złożony model sztucznej sieci neuronowej realizuje funkcję trzech klasyfikatorów odpowiedzialnych za rozróżnienie poszczególnych stanów – prawidłowego, silnika z uszkodzonym łożyskiem, silnika ze zwarcie w uzwojeniach stojana oraz pęknięciem w rotorze. Zakłócenia występujące w otoczeniu silnika zostały zasymulowane poprzez dodanie szumu białego. Podobną koncepcję diagnostyki napędów elektrycznych pojazdów samochodowych dla warunków pracy przy niskich obciążeniach zaprezentowano w [65]. Ciekawą koncepcję detekcji uszkodzeń łożysk przejeżdżającego pociągu bazującą na uczeniu maszynowym w oparciu o cechy zdefiniowane dla dźwięku zarejestrowanego mikrofonem zaprezentowano w [66]. Zaletą proponowanego podejścia jest brak konieczności wstępnej obróbki sygnału w zakresie np. korekcji efektu Dopplera. Inne metody używane w wykrywaniu uszkodzeń łożysk opierają się na analizie pojawiających się wibracji, wzroście temperatury, zaburzeniach pola elektromagnetycznego, pojawiających się zniekształceniach w kształcie prądu zasilającego [67]. Powyższe badania dotyczą samych napędów elektrycznych i nie są rozszerzane na elektryczne napędy rogatkowe, w których znajdują zastosowanie.

Na potrzeby przemysłu motoryzacyjnego w zakresie testowania wiarygodności modułów tworzących zaawansowane systemy wspomagania kierowcy (ADAS), skutecznym rozwiązaniem jest analiza prądów zasilających z zastosowaniem zestawu sztucznych sieci neuronowych [68], [69]. Analogicznie dostępne są rozwiązania diagnostyki oraz sterowania silników elektrycznych stosowanych w wymagających aplikacjach takich jak procesy przemysłowe [70]–[80]. Jako że wiele napędów rogatkowych jest zrealizowanych właśnie w oparciu o szczotkowe silniki prądu stałego, interesująca jest metoda polegająca na analizie

sygnałów generowanych przez pracujący komutator, do określenia aktualnego położenia wirnika, jak i jego prędkości [81], [82]. Niestety dla systemu sygnalizacji przejazdowej metoda ta nie jest możliwa do zastosowania ze względu na ograniczenia czasowe stosowanego układu sterowania.

W niektórych wykonaniach nowoczesne okręty wojenne opierają działanie wszystkich swoich układów na napędach elektrycznych. Problemem, który się pojawia są krótkotrwałe duże pobory mocy napędów elektrycznych, które trudno jest odróżnić od warunków zwarciovych. Dzięki dokładnej analizie cech obserwowanych przebiegów prądowych w dziedzinie częstotliwości oraz technik uczenia maszynowego możliwe jest zaproponowanie rozwiązania skutecznie działającego systemu nadzoru [83]. Z punktu widzenia systemu sygnalizacji przejazdowej podobny problem występuje w początkowej fazie podnoszenia drągów napędów rogatek, szczególnie w najdłuższych dostępnych konfiguracjach drągów – również w tym wypadku ograniczeniem metody jest konieczność analizy sygnałów szybkozmiennych. Również usterki zlokalizowane bezpośrednio w samym przyłączy silnika mogą być skutecznie wykrywane z zastosowaniem technik uczenia maszynowego [84].

Dynamicznie rozwijająca się technika uczenia maszynowego znajduje zastosowania w różnych obszarach przemysłu i transportu, dostarczając skuteczne rozwiązania dla złożonych problemów [85]–[87]. Duże ilości danych pochodzące ze wzrastającej ilości czujników generują potrzebę przetwarzania tych danych możliwie blisko ich miejsca pozyskania, np. w czasie rzeczywistym, czego ograniczeniem jest moc obliczeniowa dostępnych urządzeń brzegowych [88], [89]. Realizacja rozwiązań diagnostycznych opartych o techniki ML jest często efektywna czasowo, dzięki ogólnodostępnym pakietom oprogramowania umożliwiającym budowę odpowiednich modeli, np. język programowania Python [90] oraz pakiet Scikit-learn [91] i Pandas [92], [93]. Zakres skutecznych zastosowań technik uczenia maszynowego w obszarach mających bezpośrednie zastosowanie w dziedzinie transportu kolejowego dotyczy głównie obszarów diagnostyki i utrzymania, np. uszkodzenia szyn [94], [95] (złamanie, pęknięcie, zużycie boczne, zużycie pionowe, wady konstrukcyjno-zmęczeniowe, zużycie faliste, wyboksowanie, miejscowe wgniecenie powierzchni tocznej). Skuteczność opisanej metody sięga 98,2% [95]. Również w zakresie diagnostyki elementów torowiska istnieją rozwiązania umożliwiające analizę ich stanu z wykorzystaniem technik ML [96], [97] przy rozdzielczościach sięgających 1mm [98]. Podobnie dla elementów taboru osiągnięto dokładność w wykrywaniu i ocenie usterek przekraczającą 94,6% [99]. Zastosowania dla technik ML opierających się na sieciach neuronowych pojawiają się również dla jednego z najnowocześniejszych rodzajów kolei opierających się na mechanizmie lewitacji magnetycznej – Maglev [100]. Kolejnym elementem współczesnej kolei jest układ zasilania trakcyjnego, gdzie sztuczne sieci

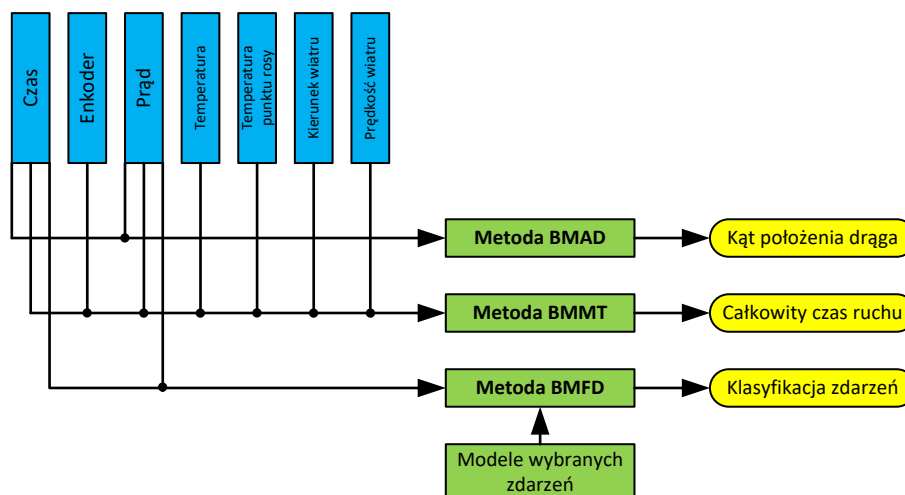
neuronowe znalazły swoje zastosowanie [101]. Analogicznie opracowywane są rozwiązania dla innych układów zasilania [102], [103].

Kolejnym ważnym obszarem transportu kolejowo jest szeroko rozumiane bezpieczeństwo oraz w powiązaniu z nim niezawodność oraz dostępność. Obwody torowe realizują krytyczną dla bezpieczeństwa systemu kolejowego funkcję wykrywania nadjeżdżającego pociągu, jak i umożliwiają stwierdzenie zajętości danego odcinka linii kolejowej. Ich zdegradowane komponenty powinny zostać naprawione zanim usterka doprowadzi do sytuacji niebezpiecznej. Ze względu na specyfikę urządzeń degradacja zazwyczaj postępuje wolno i konieczne jest zapewnienie jej obserwacji na przestrzeni długich odcinków czasu. W tym zastosowaniu najlepsze rezultaty przyniosły rekurencyjne sztuczne sieci neuronowe o strukturze LSTM, które są wyposażone w komórki pamięci [104]. W systemie kolei miejskiej w przypadku wystąpienia zaburzenia skutkującego zagrożeniem bezpieczeństwa dochodzi do wymiany dużej ilości informacji, która jest archiwizowana w postaci tekstowej. Dotychczas stosowane metodologie analizy tych tekstów wymagały dużego wysiłku. Skuteczną pomocą są sztuczne sieci neuronowe o strukturze BiLSTM [105]. Inne rozwiązanie oparte o sztuczne sieci neuronowe umożliwia analizę w czasie rzeczywistym ruchu pociągów na sieci transportu kolejowego „Amtrak” zlokalizowanej w Stanach Zjednoczonych [106]. W kontekście drągu napędu rogatekowego, który w najbardziej rozbudowanych wykonaniach stanowi znaczącą powierzchnię, na którą oddziałuje siła wiatru, inspirujące jest rozwiązanie oparte na sztucznych sieci neuronowych umożliwiające uzyskanie krótkoterminowych prognoz w zakresie kierunku i prędkości wiatru [107]–[109].

W trakcie analizy dostępnej literatury nie udało się znaleźć publikacji związanych z metodami diagnostyki napędu rogatekowego rozumianego jako kompletne urządzenie realizujące funkcję kontroli dostępu do obszaru przejazdu kolejowo-drogowego. W kontekście realizowanej funkcji kluczowe jest pozyskanie danych diagnostycznych przedstawiających aktualne położenie kątowne drąga, predykcję całkowitego czasu ruchu oraz klasyfikację zdarzeń występujących podczas ruchu drąga. Istnieją nieliczne publikacje, takie jak [26] omawiające budowę i sposób działania napędów w oparciu o rzeczywiste egzemplarze i oficjalną dokumentację producentów przekazywaną zazwyczaj jedynie docelowym użytkownikom. W odpowiedzi na taki stan rzeczy oraz mając na uwadze stwierdzone potrzeby, Autor opracował dedykowane metody diagnostyczne z wykorzystaniem uczenia maszynowego.

3.4. Nowe metody diagnostyczne

Proponowane nowe metody diagnostyczne wykorzystują w zależności od wariantu różne zestawy danych wejściowych tak jak zostało to przedstawione na rys. 3.5.



Rys. 3.5 Nowe metody diagnostyczne – dane wejściowe oraz dane wynikowe

Dane wynikowe to również w zależności od metody: predykcja aktualnego kąta położenia drąga, całkowity czas danej fazy ruchu drąga bądź klasyfikacja dla wybranych zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego.

Potencjalne obszary wykorzystania danych wyjściowych zakładają uwzględnienie ich jako dodatkowe źródło informacji statusowej w systemie sterowania ruchem kolejowym lub jako nowe dane dla stosowanych systemów diagnostycznych.

3.5. Stanowisko do badania elektrycznego napędu rogatekowego

Konstrukcja stanowiska badawczego umożliwia realizację zarówno fazy pozyskiwania danych wejściowych, jak i fazy testowania nowych metod diagnostycznych dla elektrycznego napędu rogatekowego.

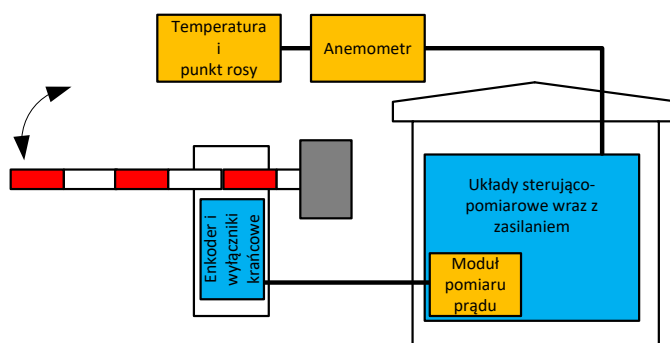
3.5.1. Konstrukcja stanowiska

Ze względu na brak możliwości efektywnej akwizycji danych związanych z parametrami pracy elektrycznego napędu rogatekowego w warunkach docelowej instalacji, zostało zaprojektowane i zbudowane dedykowane stanowisko badawcze, którego warunki pracy będą analogiczne do występujących na rzeczywistym przejeździe kolejowo-drogowym. Ogólny układ stanowiska badawczego oraz jego główne elementy przedstawiono na rys. 3.6. Składa się ono z następujących głównych części:

- elektryczny napęd rogatekowy wyposażony w drąg o długości 9 m,
- układy sterująco-pomiarowe wraz z zasilaniem zlokalizowane wewnątrz kontenera,
- zestawu czujników:
 - zabudowany fabrycznie w napędzie rogatekowym zespół wyłączników krańcowych, które są aktywowane w momencie osiągnięcia przez drąg skrajnego położenia dolnego i górnego,
 - enkoder zabudowany na śrubie kulowej napędu zapewniający ciągłą informację o położeniu kątowym drąga z rozdzielczością jednego stopnia kąтового,
 - moduł pomiaru prądu będący elementem wyposażenia aparatury znajdującej się w kontenerze systemu przejazdowego – w układzie pośrednim o zakresie pomiarowym 30 A i rozdzielczości 0,1 A z dokładnością lepszą niż 0,3 A,
 - czujnik temperatury i punktu rosy umieszczony na zewnętrznej ścianie kontenera o zakresie pomiaru temperatury od -40°C do $+125^{\circ}\text{C}$ oraz rozdzielczości $0,1^{\circ}\text{C}$ i zakresie pomiaru wilgotności względnej od 0% do 100% bez kondensacji oraz rozdzielczości 1%,
 - anemometr umożliwiający pomiar prędkości wiatru w zakresie 0-80 m/s z rozdzielczością 0,1 m/s przy dokładności lepszej niż 1% mierzonej

wartości i kierunku wiatru w zakresie 0° - 360° z rozdzielczością 1° przy dokładności lepszej niż 2° .

Próbkowanie wszystkich sygnałów jest realizowane jest z rozdzielczością 1 ms.

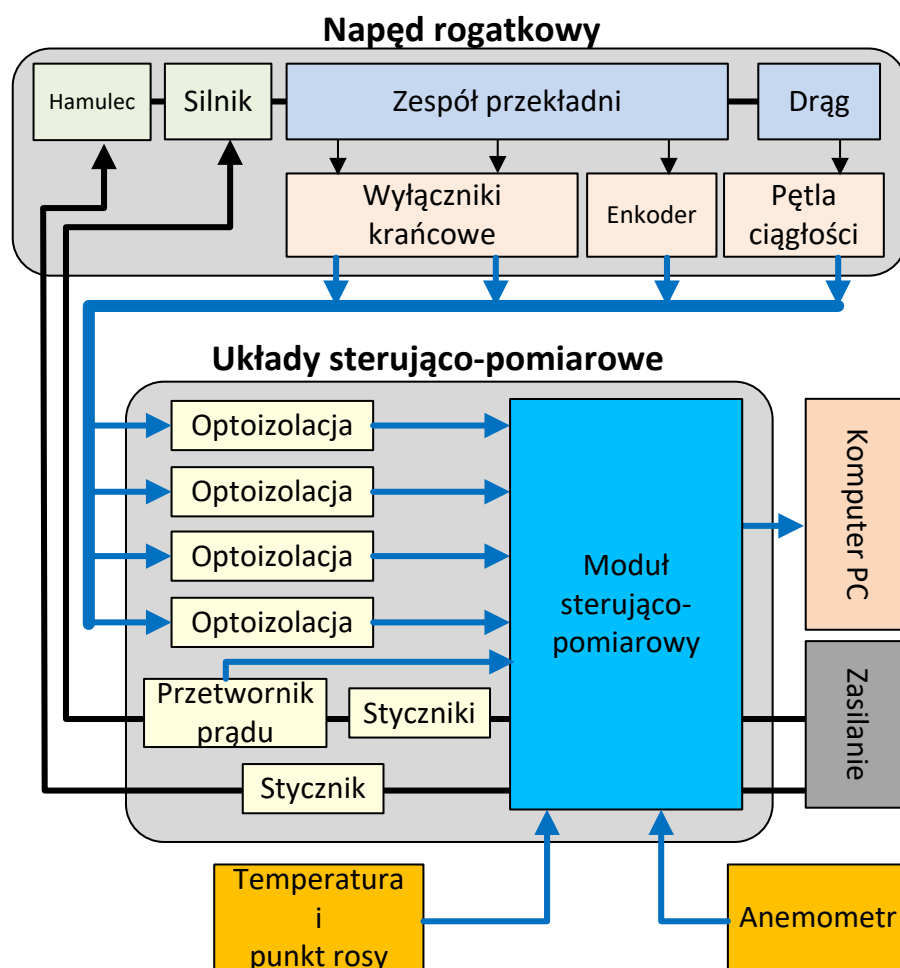


Rys. 3.6 Ogólny układ stanowiska badawczego wraz ze stanowiskiem pomiarowym

Podstawowym elementem stanowiska jest elektryczny napęd rogatekowy EEG-3 wraz z drągiem, którego budowa została szczegółowo omówiona w rozdziale 3.2. Prąd zasilania został wybrany jako źródło danych, które nie wymaga żadnych modyfikacji sprzętowych w istniejących napędach rogatekowych. Pomiar ten można zrealizować stosując powszechnie dostępne izolowane galwanicznie moduły pomiaru prądu (tzw. przekładniki prądowe). Położenie drąga jest wykrywane za pomocą dwóch wyłączników krańcowych wskazujących górne i dolne położenie, oznaczone odpowiednio „e1” i „e2” na rys. 3.2. Dodatkowo na śrubie kulowej zainstalowany jest enkoder umożliwiający obserwację ruchu drąga z rozdzielczością jednego stopnia. Obwód ciągłości drąga jest sygnałem kontrolnym potwierdzającym, że konstrukcja drąga wraz z mocowaniem nie jest uszkodzona i element ten może poprawnie realizować swoją funkcję. Hamulec elektromagnetyczny umożliwia unieruchomienie drąga w dowolnym położeniu kątowym. Schemat wewnętrznej budowy napędu rogatekowego wraz z drągiem jest przedstawiona na rys. 3.7.

Układy sterująco-pomiarowe wraz z zasilaniem są odpowiedzialne za sterowanie pracą napędu rogatekowego za pomocą zestawu dwóch styczników. Pierwszy jest przeznaczony do sterowania pracą silnika prądu stałego, a drugi do załączania hamulca

elektromagnetycznego. Położenie drąga jest monitorowane przez optoizolowane sygnały wyłączników krańcowych oraz enkodera. Parametry środowiskowe – temperatura i punkt rosy oraz prędkość i kierunek wiatru – są rejestrowane za pomocą dedykowanych czujników – wewnętrzna reprezentacja wielkości mierzonych jest realizowana z wykorzystaniem rejestrów o rozmiarze 16 bitów. Dla modułu pomiaru prądu wartości są rejestrowane z wykorzystaniem przetwornika o rozdzielczości 12 bitów. Wygenerowane dane zapisywane są za pomocą komputera PC w postaci zestawu plików CSV. Stanowisko badawcze zasilane jest z układu zasilania składającego się z zestawu akumulatorów kwasowo-ołowiowych DC24 V oraz ładowarek, którego struktura przedstawiona na rys. 3.7.



Rys. 3.7 Budowa wewnętrzna napędu rogatekowego oraz układów sterująco-pomiarowych

3.5.2. Dane pozyskiwane ze stanowiska badawczego

Zbudowane stanowisko badawcze umożliwia pozyskanie danych w trakcie pracy napędu rogatekowego w ruchu w dół i w górę z częstotliwością 1 kHz (z interwałem pomiędzy danymi 1 ms). Ze względów logistycznych dane podzielono na 3 zbiory A, B i C, które są archiwizowane i będą podlegać dalszej analizie w zależności od wymagań i potrzeb diagnostycznych.

Do zbioru A należą wartości zawarte w rekordach $xa_{up,i}$ i $xa_{down,i}$ odpowiednio dla kierunku ruchu w górę (up) i w dół (down), które zawierają dane pobierane co 1° zgodnie z kolejnymi aktywacjami enkodera. Enkoder generuje sygnał odzwierciedlający przesunięcie kątowe drąga od położenia $\alpha_{min}=0^\circ$ do położenia $\alpha_{max}=82^\circ$, gdzie α_{min} stanowi położenie początkowe dla danej fazy ruchu. Skutkuje to tym, że odstęp czasowy pomiędzy kolejnymi rekordami nie jest stały. Ostatecznie rejestrowane są 83 wektory $u_{i,j}$ od momentu uruchomienia silnika w pozycji $\alpha_{min}=0^\circ$ aż do osiągnięcia pozycji końcowej w danym ruchu α_{max} . Stanowią one zapis kompletnego ruchu drąga w krokach co 1° (2.1). Zakres ruchu drąga wynoszący 82° wynika z zastosowanego sposobu regulacji napędu rogatekowego w zakresie nastaw jego położzeń skrajnych:

$$xa_{up,i} = [u_{i,0} \quad \dots \quad u_{i,82}],$$

$$xa_{down,i} = [u_{i,0} \quad \dots \quad u_{i,82}],$$

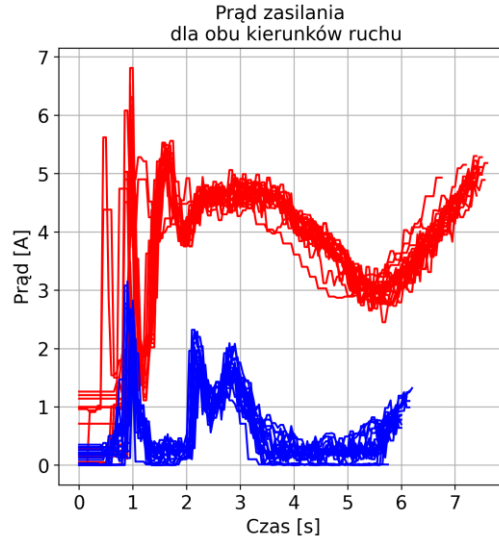
$$\text{gdzie: } u_{i,j} = [t_{i,j}, in_down_{i,j}, in_up_{i,j}, i_{i,j}, dir_{i,j}, \alpha_{i,j}],$$

(2.1)

$$XA_{up} = \begin{bmatrix} xa_{up,1} \\ \vdots \\ xa_{up,NA} \end{bmatrix},$$

$$XA_{down} = \begin{bmatrix} xa_{down,1} \\ \vdots \\ xa_{down,NA} \end{bmatrix},$$

gdzie $t_{i,j}$ [ms] to czas, w którym zarejestrowane zostało j -te zadziałanie enkodera oznaczające zmianę położenia drąga o 1° w danej fazie ruchu, zmienne $in_down_{i,j}$ [] i $in_up_{i,j}$ [] odzwierciedlają stan wyłączników krańcowych w napędzie informujących o zajęciu przez drąg pozycji granicznych, $i_{i,j}$ [A] to chwilowa wartość prądu zasilającego, $dir_{i,j}$ [] wskazuje kierunek ruchu drąga poprzez etykietę „up” dla ruchu w górę, „down” dla ruchu w dół oraz „wait” dla stanu oczekiwania a kąt $\alpha_{i,j}$ [$^\circ$] określa położenie kątowe drąga. Zgodnie z liczbą pozyskanych przebiegów NA wynosi 1000. Kształt zebranych przebiegów prądu zasilającego na rys. 3.8.



Rys. 3.8 Kształty co pięćdziesiątego przebiegu prądu (czerwony – dla kierunku w górę, niebieski – dla kierunku w dół)

W przypadku zbioru B zakres rejestrowanych zmiennych został rozszerzony (2.2):

$$\begin{aligned}
 xb_i &= [v_{i,0} \quad \dots \quad v_{i,82}], \\
 v_{i,j} &= [t_{i,j}, dir_{i,j}, \alpha_{i,j}, i_{i,j}, \phi_{i,j}, V_{i,j}, tm_{i,j}, h_{i,j}, dp_{i,j}], \\
 XB &= \begin{bmatrix} xb_1 \\ \vdots \\ xb_{NB} \end{bmatrix} i NB = NB_{up} + NB_{down}, \\
 NB_{up} &= 2000 \text{ i } NB_{down} = 2000,
 \end{aligned} \tag{2.2}$$

gdzie w porównaniu do $u_{i,j}$ rejestracji podlega kierunek wiatru $\phi_{i,j} [^\circ]$, prędkość wiatru $V_{i,j} [m/s]$ oraz temperatura powietrza $tm_{i,j} [^\circ C]$, wilgotność względna $h_{i,j} [\%]$ i temperatura punktu rosy $dp_{i,j} [^\circ C]$.

Zbiór danych C zawiera zarówno przebiegi oznaczone jako bezusterkowe, jak i usterkowe, np. uderzenie w przeszkodę. Przebiegi usterkowe zawierają zdarzenia takie, jak uderzenie w przeszkodę stałą, sprężystą czy też uszkodzenie mechanizmu napędowego, co zostało szczegółowo opisane w rozdziale 0. W celu umożliwienia ich późniejszej analizy zostały one odpowiednio oznaczone zgodnie ze wzorem (2.3). W odróżnieniu od zbiorów A i B dane w zbiorze C są próbkowane z okresem TPLC=50 ms i tym samym są niezależnie od stanu enkodera. Założono czas akwizycji danych odpowiadający typowemu maksymalnemu dopuszczalnemu czasowi ruchu napędu pomiędzy pozycjami skrajnymi wynoszącymi 10 s. To przekłada się na rejestrację każdorazowo $K=200$ wartości dla każdego przebiegu (2.3):

$$\begin{aligned}
 xc_i &= [w_1 \quad \dots \quad w_K], \\
 \text{gdzie: } w_j &= [t_{i,j}, dir_{i,j}, i_{i,j}], K = 200, \\
 yc_i &= \begin{cases} 0 - \text{ruch w g\u00f3r\u0119}, 4 - \text{ruch w d\u00f3\u0142} \\ 1 - \text{zdarzenie } FSO_{up} \\ 2 - \text{zdarzenie } FFO_{up} \\ 3 - \text{zdarzenie } FGF_{up} \\ 5 - \text{zdarzenie } FSO_{down} \\ 6 - \text{zdarzenie } FFO_{down} \\ 7 - \text{zdarzenie } FGF_{down} \end{cases}, \\
 XC &= \begin{bmatrix} xc_1 \\ \vdots \\ xc_{NC} \end{bmatrix}, \\
 YC &= \begin{bmatrix} yc_1 \\ \vdots \\ yc_{NC} \end{bmatrix} \text{ i } NC = 4136,
 \end{aligned} \tag{2.3}$$

gdzie yc_i to etykieta danego przebiegu umo\u017cliwiaj\u0105ca rozr\u00f3\u017cnienie poszczeg\u00f3lnych przebieg\u00f3w bezusterkowych od przebieg\u00f3w usterkowych:

FSO_{up} i FSO_{down} – zdarzenia polegaj\u0105ce na uderzeniu w przeszkod\u0119 sta\u0142\u0105 (niemo\u017cliwa jest kontynuacja ruchu), odpowiednio dla ruchu w g\u00f3r\u0119 i w d\u00f3\u0142,

FFO_{up} i FFO_{down} – zdarzenia polegaj\u0105ce na uderzeniu w przeszkod\u0119 spr\u0119\u017cyst\u0105 (po uderzeniu mo\u017cliwa jest kontynuacja ruchu), odpowiednio dla ruchu w g\u00f3r\u0119 i w d\u00f3\u0142,

FGF_{up} i FGF_{down} – zdarzenia polegaj\u0105ce na zwi\u0119kszeniu opor\u00f3w mechanizmu nap\u0119du roga\u0142kowego, odpowiednio dla ruchu w g\u00f3r\u0119 i w d\u00f3\u0142.

Powy\u017csze zdarzenia s\u0105 szczeg\u00f3\u0142owo opisane w rozdziale 0.

3.6. Parametry oceny jakości proponowanych metod

Wskaźnik jakości proponowanych w dalszej części pracy metod został oparty o metryki, których definicje są podane poniżej.

Dla poniższych definicji:

$$\begin{aligned} TR &= [tr_1 \dots tr_N] - \text{wektor wartości prawdziwych,} \\ PR &= [pr_1 \dots pr_N] - \text{wektor wartości predykcji,} \\ \text{gdzie: } tr_i &- \text{wartość prawdziwa, } pr_i - \text{wartość predykcji,} \\ N &- \text{ilość próbek,} \end{aligned} \tag{2.4}$$

$$\begin{aligned} TR_{mean} &= \frac{1}{N} \sum_{i=1}^N tr_i - \text{wartość średnia wartości prawdziwych,} \\ i &\in \langle 1, N \rangle. \end{aligned}$$

- Dokładność (*ACC*):

$$ACC(TR, PR) = \frac{1}{N} \sum_{i=0}^{N-1} 1(pr_i = tr_i) \tag{2.5}$$

- Średni błąd bezwzględny (*MAE*):

$$MAE(TR, PR) = \frac{1}{N} \sum_{i=0}^{N-1} |tr_i - pr_i| \tag{2.6}$$

- Błąd średniokwadratowy (*MSE*):

$$MSE(TR, PR) = \frac{1}{N} \sum_{i=0}^{N-1} (tr_i - pr_i)^2 \tag{2.7}$$

- Współczynnik determinacji (R^2):

$$R^2(TR, PR) = 1 - \frac{\sum_{i=1}^N (tr_i - pr_i)^2}{\sum_{i=1}^N (tr_i - TR_{mean})^2} \tag{2.8}$$

- Błąd maksymalny (*ME*):

$$ME(TR, PR) = \max(|tr_i - pr_i|) \tag{2.9}$$

- Metryki dla klasyfikacji:

Dla poniższych definicji:

TP – liczba wyników prawdziwie dodatnich,

TN – liczba wyników prawdziwie negatywnych,

FP – liczba wyników fałszywie dodatnich,

FN – liczba wyników fałszywie negatywnych.

$$\text{Dokładność (ACC)} = \frac{TP + TN}{TN + TP + FN + FP} \quad (2.10)$$

$$\text{Precyzja (PRE)} = \frac{TP}{TP + FP} \quad (2.11)$$

$$\text{Czułość (REC)} = \frac{TP}{TP + FN} \quad (2.12)$$

$$\text{Swoistość (SPE)} = \frac{TN}{TN + FP} \quad (2.13)$$

$$\text{Współczynnik } F_1 = \frac{2 * P * R}{P + R} \quad (2.14)$$

- Odchylenie standardowe (σ):

$$\sigma(x) = \sqrt{\frac{\sum_{i=1}^N (x_i - x_{mean})^2}{N-1}}, \quad (2.15)$$

$$\text{gdzie } x_{mean} = \frac{1}{N} \sum_{i=1}^N x_i$$

4. Nieinwazyjna metoda detekcji kąta położenia drąga elektrycznego napędu rogatekowego BMAD

W tym rozdziale zostanie przedstawiona koncepcja autorskiej metody detekcji kąta położenia drąga elektrycznego napędu rogatekowego (BMAD – Barrier Machine Angle Detection). Autor proponuje wprowadzenie metody powodującej zwiększenie bezpieczeństwa poprzez wykrywanie rzeczywistej pozycji na podstawie przebiegu prądu zasilania oraz technik uczenia maszynowego, w tym sztucznych sieci neuronowych. Obserwowana na rynku ograniczona dostępność napędów rogatekowych wyposażonych w funkcjonalność dostarczenia ciągłej informacji o położeniu drąga jest motywacją do podjęcia badań w tym obszarze.

4.1. Założenia metody

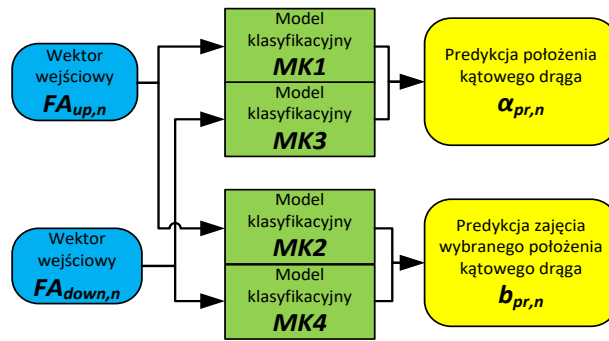
Celem metody jest uzyskanie ciągłej informacji wyjściowej w dwóch formatach – pierwszym jest aktualna wartość położenia kąтового, a drugim informacja o wykryciu wybranego położenia kąтового drąga.

Metoda została opracowana przy następujących założeniach – informacją wejściową jest przebieg wejściowy prądu zasilającego w funkcji czasu zawarty w zbiorze danych A. Takie podejście zapewnia zarówno brak ingerencji w sam napęd rogatekowy, jak i interfejs sterujący. Na podstawie przeglądu zarejestrowanych danych (rys. 3.8) można stwierdzić, że charakterystyki przebiegów prądu otwarcia i zamknięcia napędu są jakościowo różne. W związku z tą obserwacją zdecydowano się na zastosowanie odrębnych modeli uczenia maszynowego w zależności od kierunku ruchu.

Metoda powinna dostarczać informacji o kątowym położeniu drąga $\alpha_{pr,n}$ dla obu kierunków ruchu z rozdzielczością $\Delta\alpha=3^\circ$ z dokładnością ACC lepszą niż 90% - co odpowiada typowej wartości tolerancji dla nastaw aktualnie stosowanych czujników położenia drąga. Alternatywnie metoda powinna dostarczać informację o zajęciu przez drąg wybranego położenia kąтового $b_{pr,n}$ również z rozdzielczością $\Delta\alpha=3^\circ$ z parametrami czułości REC , swoistości SPE i dokładności ACC lepszymi niż 90%.

4.2. Opis metody

Autor proponuje stworzenie czterech modeli $MK1$, $MK2$, $MK3$ i $MK4$ opartych na uczeniu maszynowym, które w zależności od wejściowego wektora $FA_{up,n}$ lub $FA_{down,n}$ zawierającego informację o przebiegu prądu zasilającego, pozwoli uzyskać na wyjściu predykcję położenia kąтового drąga $\alpha_{pr,n}$ lub predykcję zajęcia wybranego położenia kąтового drąga $b_{pr,n}$. Sposób działania metody w poszczególnych wariantach został przedstawiony na rys. 4.1.



Rys. 4.1 Schemat działania metody BMAD

Metoda opiera swoje działanie o chwilową wartość prądu zasilającego elektryczny napęd rogatek i_n [A]. Zmienna ta jest próbkowana w sposób ciągły z okresem $T_{PLC}=50$ ms, a następnie przetwarzana na dwie wartości pochodne $i_{up,n}$ oraz $i_{down,n}$ w zależności od stanu zarówno interfejsu sterującego jak i napędu rogatek dir_n (3.1):

$$i_{up,n} = \begin{cases} i_n & \text{gdy } dir_n = "up" \\ 0 & \text{gdy } dir_n \neq "up" \end{cases}, \quad (3.1)$$

$$i_{down,n} = \begin{cases} i_n & \text{gdy } dir_n = "down" \\ 0 & \text{gdy } dir_n \neq "down" \end{cases}.$$

Tak jak zostało to opisane w 3.2 stan dir_n może przyjmować w trakcie ruchu napędu jedynie dwie wartości „up” i „down” oznaczające odpowiednio konfigurację dla ruchu w górę i w dół. Tak zdefiniowane dwie zmienne umożliwiają konstrukcję dwóch wektorów zawierających informację o ich ostatnich S wartościach. Wektory te są budowane w sposób ciągły zgodnie z zasadami kolejki FIFO (3.2):

$$FA_{up,n} = [i_{up,n}, i_{up,n-1}, \dots, i_{up,n-(S-1)}], \quad (3.2)$$

$$FA_{down,n} = [i_{down,n}, i_{down,n-1}, \dots, i_{down,n-(S-1)}].$$

Wektor $FA_{up,n}$ stanowi informację wejściową dla modelu klasyfikacyjnego $MK1$ zwracającego predykcję położenia kąтового drąga $\alpha_{pr,n}$ z założoną rozdzielczością $\Delta\alpha$ (3.3):

$$\alpha_{pr,n} = MK1(FA_{up,n}),$$

$$\alpha_{pr,n} = \alpha_m \leftrightarrow \alpha_d \in \langle \alpha_m; \alpha_m + (m + 1) * \Delta\alpha \rangle,$$

$$\text{gdzie } \alpha_{pr,n} \in \langle \alpha_0, \alpha_1, \dots, \alpha_k \rangle \text{ i } \alpha_m = \alpha_{m-1} + \Delta\alpha,$$

$$k = (\alpha_{max} - \alpha_{min}) // \Delta\alpha,$$

gdzie operator // oznacza dzielenie całkowitoliczbowe a α_d oznacza rzeczywiste położenie kątowne drąga zmieniające się od wartości $\alpha_{min}=0^\circ$ w momencie rozpoczęcia ruchu zarówno w górę, jak i w dół do wartości α_{max} w momencie zakończenia ruchu w danym kierunku. Wartość α_{max} jest zależna od sposobu regulacji napędu rogatekowego jak to zostało opisane w rozdziale 3.2.

W drugim wariantcie metody wektor $FA_{up,n}$ stanowi informację wejściową dla modelu klasyfikacyjnego $MK2$ zwracającego predykcję $b_{pr,n}$ zajęcia wybranego pośredniego położenia kątownego drąga α_{mid} z założoną rozdzielczością $\Delta\alpha$ (3.4):

$$b_{pr,n} = MK2(FA_{up,n}),$$

$$\text{gdzie } b_{pr,n} = \begin{cases} 1 \leftrightarrow \alpha_d \in \langle \alpha_{mid}; \alpha_{mid} + \Delta\alpha \rangle \\ 0 \leftrightarrow \alpha_d \notin \langle \alpha_{mid}; \alpha_{mid} + \Delta\alpha \rangle \end{cases}.$$

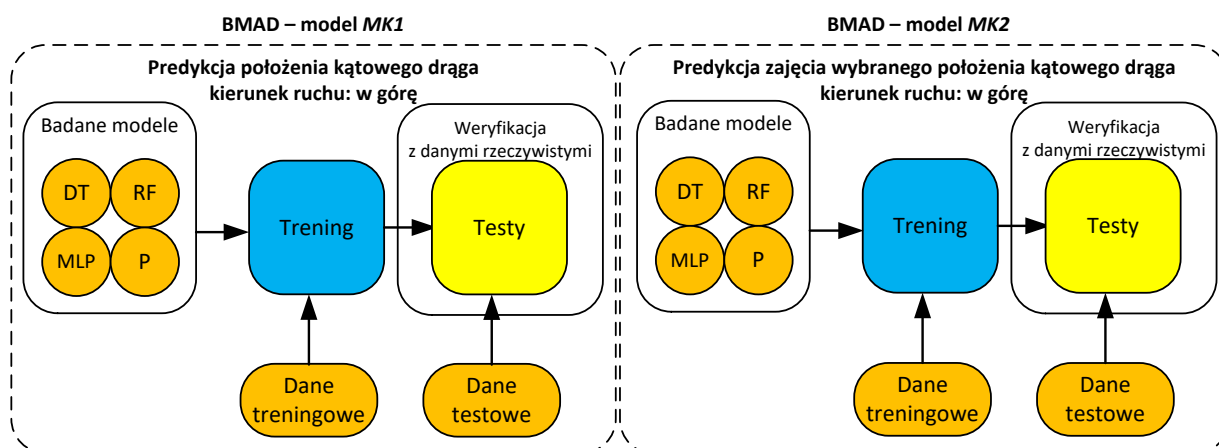
Analogicznie wektor $FA_{down,n}$ jest informacją wejściową dla modeli $MK3$ i $MK4$ jak to przedstawiono w (3.5):

$$\alpha_{pr,n} = MK3(FA_{down,n}),$$

$$b_{pr,n} = MK4(FA_{down,n}).$$

4.3. Sposób opracowania metody

Sposób opracowania metody BMAD w wariancie 1 dostarczającym ciągłej predykcji wartości kąta położenia drąga dla kierunku ruchu w górę, oraz w wariancie 2 – predykcja zajęcia wybranego położenia kąтового drąga dla kierunku ruchu w górę został przedstawiony na rys. 4.2. W analogiczny sposób skonstruowano metodę BMAD dla kierunku ruchu w dół – odpowiednio w wariantach 3 i 4.

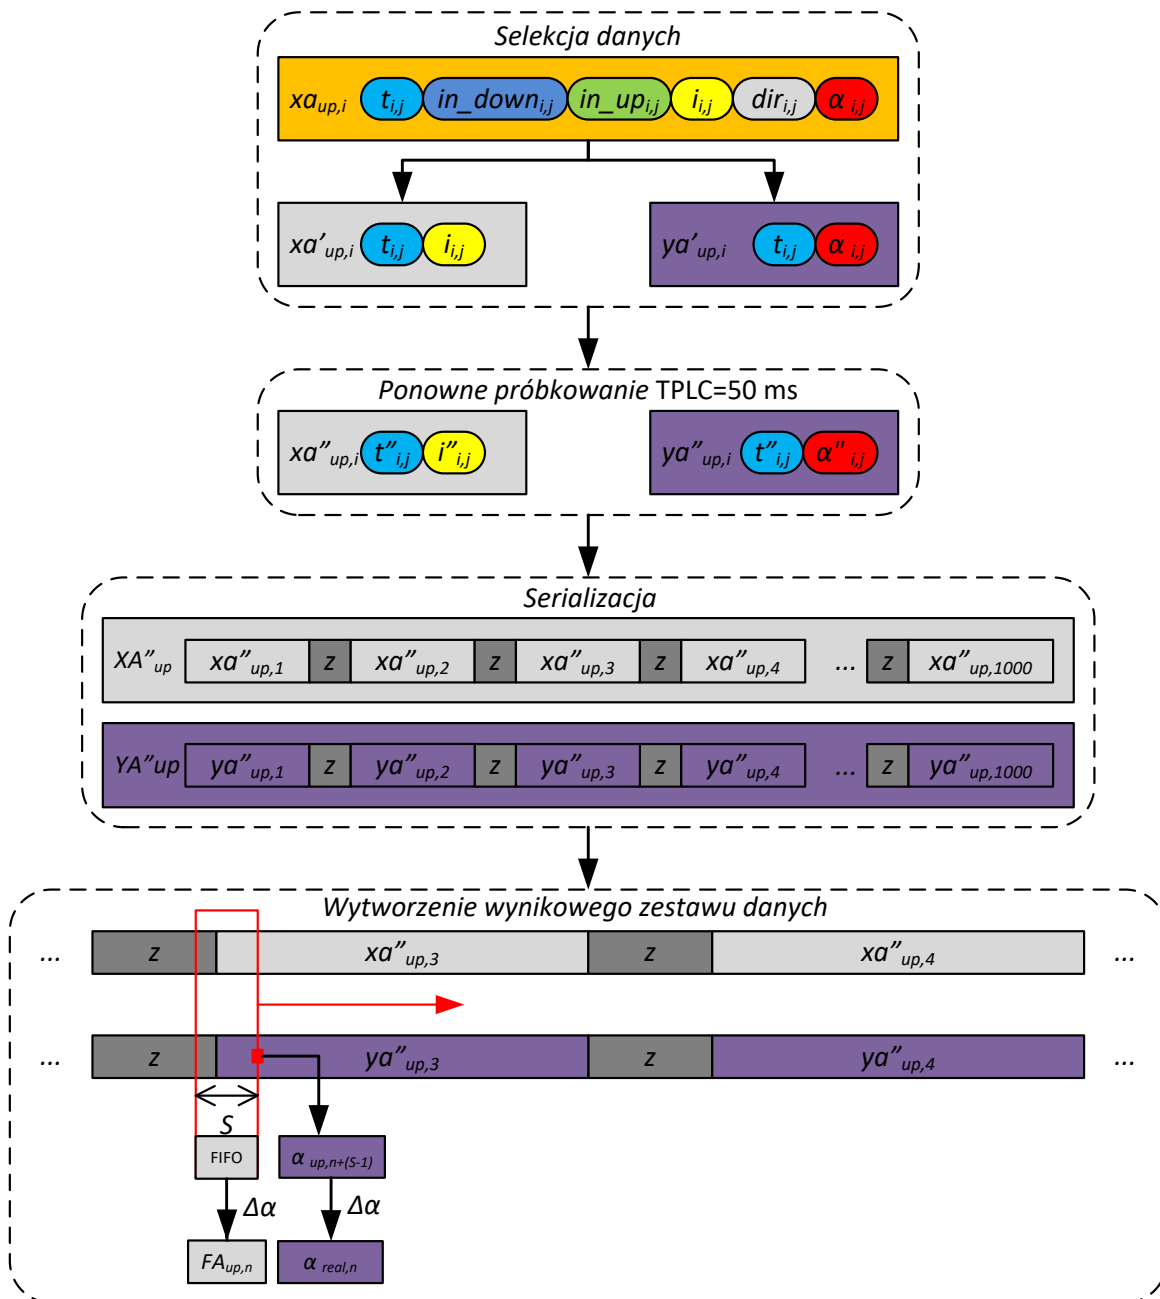


Rys. 4.2 Sposób opracowania metody BMAD – modele MK1 i MK2 dla kierunku ruchu w górę

W przypadku każdego z wariantów metody badaniom porównawczym podlega zestaw następujących modeli ML – Decision Tree Classifier (DT), Random Forest Classifier (RF), MLP Classifier (MLP) oraz Perceptron (P). Modele te podlegają procesowi treningu, a następnie skuteczność ich działania jest sprawdzana.

4.4. Wytworzenie zestawu danych treningowych i testowych

Sposób wytworzenia zestawu danych treningowych i testowych został przedstawiony na rys. 4.3 w zakresie selekcji danych oraz procesu ponownego próbkowania.



Rys. 4.3 Sposób przygotowania danych treningowych i testowych na potrzeby metody BMAD dla kierunku ruchu w górę – pierwszy krok

Na potrzeby metody BMAD została wykorzystana część danych zawartych w zbiorze A (2.1) wyodrębniona w następujący sposób (3.6):

$$\begin{aligned}
 xa'_{up,i} &= \left[[t_{i,0}, i_{i,0}] \dots [t_{i,82}, i_{i,82}] \right], \\
 ya'_{up,i} &= \left[[\alpha_{i,0}, \alpha_{i,0}] \dots [\alpha_{i,82}, \alpha_{i,82}] \right], \\
 xa'_{down,i} &= \left[[t_{i,0}, i_{i,0}] \dots [t_{i,82}, i_{i,82}] \right], \\
 ya'_{down,i} &= \left[[\alpha_{i,0}, \alpha_{i,0}] \dots [\alpha_{i,82}, \alpha_{i,82}] \right], \\
 \alpha_{i,0} &= \alpha_{min} \text{ i } \alpha_{i,82} = \alpha_{max},
 \end{aligned} \tag{3.6}$$

gdzie $xa'_{up,i}$ jest wektorem zawierającym informację zredukowaną do czasów kolejnych aktywacji enkodera $t_{i,j}$ i występujących w tych momentach chwilowych wartościach prądu $i_{i,j}$ a wektor $ya'_{up,i}$ przechowuje informację o zwiększającym się położeniu kątowym w trakcie i-tego ruchu drąga w górę. Analogiczny zestaw danych jest wyodrębniony dla ruchów w dół.

Następnie dane zostały poddane ponownemu próbkowaniu w celu emulacji stałej czasowej próbkowania TPLC=50 ms będącej reprezentatywną wartością dla typowego systemu sterowania przejazdem kolejowym oraz przekształcenia do postaci wektorów zawierających kolejne wartości prądu zasilającego oraz kąta położenia drąga (3.7):

$$\begin{aligned}
 xa''_{up,i} &= [i''_{i,0} \dots i''_{i,n_i}], \\
 ya''_{up,i} &= [\alpha''_{i,0} \dots \alpha''_{i,n_i}], \\
 xa''_{down,i} &= [i''_{i,0} \dots i''_{i,n_i}], \\
 ya''_{down,i} &= [\alpha''_{i,0} \dots \alpha''_{i,n_i}].
 \end{aligned} \tag{3.7}$$

Rezultatem ponownego próbkowania jest zmienna długość wektorów $xa''_{up,i}$, $ya''_{up,i}$, $xa''_{down,i}$ oraz $ya''_{down,i}$. Zmienna długość tych wektorów bezpośrednio odzwierciedla zmienny czas trwania zarejestrowanych całkowitych ruchów drąga – wartości są wyrażone w funkcji czasu, a nie jak do tej pory zmiennego położenia kąowego drąga. W kolejnym kroku zostały zbudowane wektory XA''_{up} , XA''_{down} oraz YA''_{up} , YA''_{down} zawierające ciągły zapis pracy napędu rogatekowego dla danego kierunku ruchu drąga uzupełniony o przerwy pomiędzy kolejnymi ruchami o długości 10 s (3.8). Czas przerwy $T_z=10$ s przy okresie próbkowania TPLC=50 ms i długości bufora $S=100$ powoduje, że w buforze o budowie

FIFO będą się znajdować dane wyłącznie jednego ruchu. Dobór takiej wartości czasu separacji pomiędzy poszczególnymi ruchami uzasadniony jest faktem, że czas wstępnego ostrzegania typowo wynosi co najmniej 13 s [1].

$$z = [0, 0, \dots, 0]; \text{len}(z) = \frac{T_z}{\text{TPLC}},$$

$$\begin{aligned} XA''_{up} &= [x''_{up,1}, z, x''_{up,2}, z, \dots, x''_{up,1000}] = [I_{up,0}, I_{up,1}, \dots, I_{up,P}], \\ YA''_{up} &= [y''_{up,1}, z, y''_{up,2}, z, \dots, y''_{up,1000}] = [\alpha_{up,0}, \alpha_{up,1}, \dots, \alpha_{up,P}], \end{aligned} \quad (3.8)$$

$$\begin{aligned} XA''_{down} &= [x''_{down,1}, z, x''_{down,2}, z, \dots, x''_{down,1000}] = [I_{down,0}, I_{down,1}, \dots, I_{down,Q}], \\ YA''_{down} &= [y''_{down,1}, z, y''_{down,2}, z, \dots, y''_{down,1000}] = [\alpha_{down,0}, \alpha_{down,1}, \dots, \alpha_{down,Q}]. \end{aligned}$$

Przebiegi prądu XA''_{up} , XA''_{down} zostały podzielone na wektory zawierające kolejne $S=100$ próbek z uwzględnieniem by ostatnia próbka prądu była pierwszym elementem nowego wektora zgodnie z zasadą działania mechanizmu FIFO (3.9):

$$\begin{aligned} FA_{up,n} &= [I_{up,n+(S-1)} \quad \dots \quad I_{up,n}], \\ FA_{down,n} &= [I_{down,n+(S-1)} \quad \dots \quad I_{down,n}]. \end{aligned} \quad (3.9)$$

Analogicznie jak zostało to przedstawione w (3.3) i (3.4) każdy z wektorów został oznaczony etykietą (3.11) w oparciu o zawartość wektorów YA''_{up} , YA''_{down} na potrzeby dalszej predykcji położenia kąтового drąga jako $\alpha_{real,n}$ i na potrzeby predykcji zajęcia wybranego położenia kąтового drąga $b_{real,n}$. W tym drugim przypadku przyjęto założenie, że wybrany kąt α_{mid} odpowiada połowie zakresu całego ruchu. Tak wybrana wartość kąta α_{mid} jest często wykorzystywana w systemie przejazdowym jako istotna informacja o osiągnięciu przez drąg położenia środkowego. Sposób wytworzenia etykiet dla kierunku ruchu w górę przedstawiony w (3.10) został zrealizowany w analogiczny sposób dla kierunku ruchu w dół.

$$\begin{aligned} \alpha_{real,n} &= (\alpha_{up,n+(S-1)} // \Delta\alpha) * \Delta\alpha, \\ \alpha_{mid} &= ((\alpha_{max} - \alpha_{min}) // (2 * \Delta\alpha)) * \Delta\alpha, \\ b_{real,0} &= \begin{cases} 1 \leftrightarrow \alpha_{up,n+(S-1)} \in \langle \alpha_{mid}; \alpha_{mid} + \Delta\alpha \rangle \\ 0 \leftrightarrow \alpha_{up,n+(S-1)} \notin \langle \alpha_{mid}; \alpha_{mid} + \Delta\alpha \rangle \end{cases} \end{aligned} \quad (3.10)$$

Kąt $\alpha_{real,n}$ określa rzeczywiste położenie kątowny drąga zaś operator // oznacza dzielenie całkowitoliczbowe. Wszystkie wartości dla obu kierunków ruchu są wyznaczone z rozdzielczością $\Delta\alpha$ jak zostało to pokazane w (3.10). Wartość $\alpha_{up,n+(s-1)}$ oznacza przetworzoną aktualną wartość kąta położenia drąga α_d w momencie gdy zgodnie z zasadami kolejki FIFO jest budowana dana instancja wektora $FA_{up,n}$ bądź $FA_{down,n}$ jak to przedstawiono w (3.8) i (3.9).

Ostatecznie zestaw danych wejściowych X_{up} jest powiązany z dwoma wariantami danych wyjściowych $y_{up,\alpha}$ i $y_{up,b}$ tak jak zostało przedstawione w (3.3), (3.4) oraz na rys. 4.2 (3.11):

$$X_{up} = \begin{bmatrix} F_{up,1} \\ \vdots \\ F_{up,U1} \end{bmatrix}, \tag{3.11}$$
$$y_{up,\alpha} = \begin{bmatrix} \alpha_{real,1} \\ \vdots \\ \alpha_{real,U1} \end{bmatrix} \text{ oraz } y_{up,b} = \begin{bmatrix} b_{real,1} \\ \vdots \\ b_{real,U1} \end{bmatrix}.$$

Utworzony w analogiczny sposób X_{down} jest powiązany z dwoma wariantami danych wyjściowych $y_{down,\alpha}$ i $y_{down,b}$. Wynikowy zbiór danych o rozmiarze $U1 = 185\ 855$ wektorów dla ruchu w górę i $U2 = 185\ 832$ wektorów dla ruchu w dół został podzielony w sposób losowy na podzbiór treningowy (70%) oraz podzbiór walidacyjny (30%).

4.5. Dobór modeli ML

W kolejnym kroku przeanalizowano wybrane klasyfikatory pod kątem ich wydajności z wykorzystaniem walidacji krzyżowej K-Fold: Decision Tree Classifier, Perceptron, MLP Classifier, SGD Classifier, Passive Aggressive Classifier, Random Forest Classifier. Ostatecznie wybrano niżej wymienione cztery klasyfikatory kierując się najlepszymi wynikami w zakresie metryki współczynnika determinacji R^2 :

- Decision Tree Classifier (DT):
 - z domyślnymi wartościami wszystkich parametrów:
criterion='gini', splitter='best', max_depth=None, min_samples_split=2,
min_samples_leaf=1, min_weight_fraction_leaf=0.0,
max_features=None, random_state=None, max_leaf_nodes=None,
min_impurity_decrease=0.0, class_weight=None, ccp_alpha=0.0
- Random Forest Classifier (RF):
 - z parametrami:
n_estimators=50,
random_state=1,
 - pozostałe parametry zostały ustawione następująco:
criterion='gini', max_depth=None, min_samples_split=2,
min_samples_leaf=1, min_weight_fraction_leaf=0.0,
max_features='auto', max_leaf_nodes=None,
min_impurity_decrease=0.0, bootstrap=True, oob_score=False,
n_jobs=None, verbose=0, warm_start=False, class_weight=None,
ccp_alpha=0.0, max_samples=None
- MLP Classifier (MLP)
 - z następującymi parametrami:
parametr regularyzacji L2 (alpha) - 0.1,
liczba neuronów w warstwie ukrytej (hidden_layer_sizes) - (50,),
funkcja adaptacji wag (solver) - 'adam',
maksymalna liczba epok (max_iter) - 100,
random_state=1,
 - pozostałe parametry zostały ustawione następująco:
activation='relu', batch_size='auto', learning_rate='constant',
learning_rate_init=0.001, power_t=0.5, shuffle=True, tol=0.0001,
verbose=False, warm_start=False, momentum=0.9,


```
nesterovs_momentum=True, early_stopping=False,  
validation_fraction=0.1, beta_1=0.9, beta_2=0.999, epsilon=1e-08,  
n_iter_no_change=10, max_fun=15000
```

- Perceptron (P):
 - z wartościami parametrów:
penalty=None, alpha=0.0001, l1_ratio=0.15, fit_intercept=True,
max_iter=1000, tol=0.001, shuffle=True, verbose=0, eta0=1.0,
n_jobs=None, random_state=0, early_stopping=False,
validation_fraction=0.1, n_iter_no_change=5, class_weight=None,
warm_start=False

4.6. Badania porównawcze modeli ML

Metody opisane w rozdziale 4.2 zostały wykorzystane do budowy modeli *MK1*...*MK4* z wykorzystaniem wybranych klasyfikatorów wymienionych powyżej celem porównania jakości dostarczanych predykcji.

4.6.1. Predykcja kąta nachylenia drąga

Metoda w wariantach pierwszym i trzecim została zaimplementowana w Pythonie dla wszystkich wybranych klasyfikatorów – DT, RF, MLP, P. W wyniku otrzymano zestaw klasyfikatorów *MK1* i *MK3* dostarczających odpowiednio predykcji położenia drąga dla ruchu w górę oraz w dół. Fragment kodu realizującego opisane funkcje dla modelu DT został przedstawiony w List. 4.1 – w analogiczny sposób zostało to realizowane dla RF, MLP i P.

```
[...]  
ang_prec = 3  
  
for state in ['UP_GO', 'DOWN_GO']:  
  
    if (state == 'UP_GO'):  
        state_name = 'w górę'  
  
    if (state == 'DOWN_GO'):  
        state_name = 'w dół'  
  
    # wczytanie danych - START  
    X_train = pd.read_csv("X_" + str(state) + "_train.csv", index_col=0)  
    y_train = pd.read_csv("y_" + str(state) + "_train.csv", index_col=0)  
  
    X_test = pd.read_csv("X_" + str(state) + "_test.csv", index_col=0)  
    y_test = pd.read_csv("y_" + str(state) + "_test.csv", index_col=0)  
  
    # wektor wyjściowy z precyzją 3 stopni  
    y_train = y_train // ang_prec
```

```

y_test = y_test // ang_prec

X_train = X_train.to_numpy()
X_test = X_test.to_numpy()
y_train = y_train.to_numpy()
y_test = y_test.to_numpy()

y_train = y_train[:,0]
y_test = y_test[:,0]

# DecisionTree

from sklearn import tree
from sklearn.metrics import accuracy_score
from sklearn.metrics import confusion_matrix

model = tree.DecisionTreeClassifier(random_state = 1)
model_name = 'Decision Tree Classifier'

model.fit(X_train,y_train)
y_pred = model.predict(X_test)

# przeskalanie do oryginalnych wartosci katowych
y_test = y_test * ang_prec
y_pred = y_pred * ang_prec

from sklearn.metrics import mean_absolute_error

print('\n\n=== ' + model_name + ' ===')
print('state=', state_name)

print('Accuracy: {0:.3f}'.format(accuracy_score(y_test,y_pred) * 100))
results_df.at['accuracy', model_name] = round(accuracy_score(y_test,y_pred) * 100, 3)

print('Mean_absolute_error: {0:.3f}'.format(mean_absolute_error(y_test, y_pred)))
results_df.at['mean_absolute_error', model_name] = round(mean_absolute_error(y_test, y_pred), 3)

print('Mean_squared_error: {0:.3f}'.format(mean_squared_error(y_test,y_pred)))
results_df.at['mean_squared_error', model_name] = round(mean_squared_error(y_test,y_pred), 3)

print('R2_score: {0:.3f}'.format(r2_score(y_test,y_pred)))
results_df.at['r2_score', model_name] = round(r2_score(y_test,y_pred), 3)

compare = pd.DataFrame()
compare['test'] = y_test
compare['pred'] = y_pred
compare['error'] = (y_pred - y_test)

all_angle_errors = pd.DataFrame(index = list(range(0,82,3)))

all_angle_errors['error'] = 0.0

for angle in np.sort(compare.test.unique()):

    compare_one_angle = compare[compare['test'] == angle]
    all_angle_errors.at[int(angle), 'error'] = mean_absolute_error(compare_one_angle.test, compare_one_angle.pred)

max_error_angle = all_angle_errors['error'].idxmax()

print('Max_mean_absolute_error: {0:.3f}'.format(all_angle_errors['error'].max()))
results_df.at['max_mean_absolute_error', model_name] = round(all_angle_errors['error'].max(), 3)

print('at_angle:', max_error_angle )
results_df.at['at_angle', model_name] = max_error_angle

print('Mean_absolute_error_percentiles: ', np.percentile(all_angle_errors, [25, 50, 75]))

percentiles = np.percentile(all_angle_errors, [25, 50, 75])

```

```

results_df.at['mean_absolute_error_percentile_first', model_name] = round(percentiles[0], 3)
results_df.at['mean_absolute_error_percentile_second', model_name] = round(percentiles[1], 3)
results_df.at['mean_absolute_error_percentile_third', model_name] = round(percentiles[2], 3)
[...]

```

List. 4.1 Fragment kodu dla metody BMAD

Zebrane dane ilościowe dla poszczególnych klasyfikatorów przedstawiono w Tab. 4-1.

Tab. 4-1 Wyniki działania klasyfikatorów

Miara	DT	RF	MLP	P
Kierunek w górę (model MK1)				
ACC [%]	89,991	93,764	89,023	77,409
MAE [°]	0,652	0,402	0,760	4,116
MSE [deg ²]	29,849	18,599	36,905	197,279
R ² []	0,959	0,975	0,950	0,730
Maksymalny MAE [°]	10,524 dla 81°	5,398 dla 81°	20,159 dla 81°	25,484 dla 69°
MAE w kwartylu: pierwszym/drugim/trzecim [°]	0,304/0,462/0,567	0,194/0,259/0,357	0,314/0,398/0,596	2,498/3,324/5,622
Kierunek w dół (model MK3)				
ACC [%]	91,846	95,651	93,796	76,058
MAE [°]	0,593	0,292	0,397	6,180
MSE [deg ²]	26,935	13,951	17,985	384,635
R ² []	0,962	0,981	0,975	0,463
Maksymalny MAE [°]	10,227 dla 81°	6,271 dla 81°	3,056 dla 81°	54,404 dla 69°
MAE w kwartylu: pierwszym/drugim/trzecim [°]	0,392/0,476/0,577	0,171/0,197/0,251	0,234/0,330/0,420	1,258/2,68/7,646


Dla wybranych klasyfikatorów dane wyjściowe przedstawiono również w postaci graficznej:

- macierzy konfuzji przedstawionych na rys. 4.4 prezentujących zależność pomiędzy kątem rzeczywistym $\alpha_{real,n}$ a kątem wykrytym $\alpha_{pre,n}$ – jest ona przedstawiona w postaci mapy ciepła. Każdy kwadrat reprezentuje jedną komórkę macierzy konfuzji z rozdzielczością $\Delta\alpha = 3^\circ$. Im bielszy jest kolor, tym większą wartość ma odpowiadająca mu komórka macierzy konfuzji,
- rozkładów błędu detekcji $\alpha_{real,n} - \alpha_{pre,n}$ pokazanych na rys. 4.5 z uwzględnieniem zdefiniowanej wcześniej rozdzielczości $\Delta\alpha = 3^\circ$.

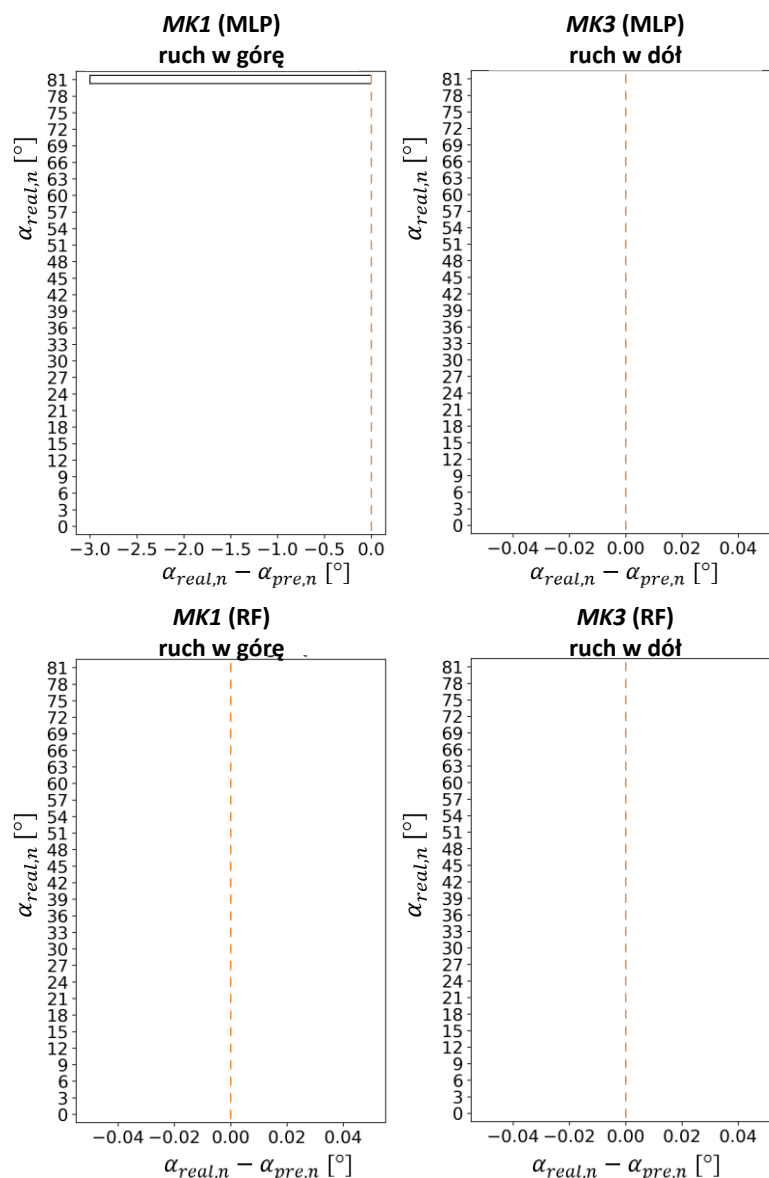
Każdy rozkład błędów składa się z prostokąta reprezentującego rozkład błędów pomiędzy pierwszym kwartylem wartości kąta α^{Q1} a trzecim kwartylem α^{Q3} z dodatkową krótką linią wyznaczającą wartość mediany α^{med} . Linia zakończona dwoma prostopadłymi krótkimi liniami reprezentuje granice B_{min} i B_{max} dla wartości odstających zdefiniowanych jako (3.12):

$$\begin{aligned}
 B_{min} &= (\alpha^{Q1} - 1.5 * IQR), \\
 B_{max} &= (\alpha^{Q3} + 1.5 * IQR), \\
 \text{gdzie } IQR &= \alpha^{Q3} - \alpha^{Q1}.
 \end{aligned}
 \tag{3.12}$$

Wartości odstające nie są pokazane, aby zapewnić lepszą przejrzystość danych.



Rys. 4.4 Predykcja położenia kąowego drąga - macierze konfuzji dla MLP i RF pracujących jako MK1 (ruch w górę) i MK3 (ruch w dół)



Rys. 4.5 Predykcja położenia kątownego drąga
- rozkłady błędów $\alpha_{real,n} - \alpha_{pre,n}$ dla MLP i RF pracujących
jako MK1 (ruch w górę) i MK3 (ruch w dół)

W trybie ciągłej predykcji kąta drąga poruszającego się w górę (MK1), RF nieznacznie przewyższa zarówno DT jak i MLP. Można to stwierdzić na podstawie różnicy średniego błędu bezwzględnego MAE wynoszącą $0,250^\circ$ – odpowiednio dla DT $MAE=0,652^\circ$ podczas, gdy dla RF $MAE=0,402^\circ$. Podobnie różnica średniego błędu bezwzględnego MAE wynosi $0,358^\circ$ w stosunku do MLP - dla MLP $MAE=0,760^\circ$. Należy również zwrócić uwagę, że dokładność wyznaczenia kąta jest niższa dla DT $ACC=89,991\%$ i dla MLP $ACC=89,023\%$ w stosunku do dokładności $ACC=93,764\%$ dla RF. Maksymalny średni błąd bezwzględny MAE predykcji położenia kątownego drąga dla RF jest blisko czterokrotnie mniejszy w porównaniu do MLP – odpowiednio dla MLP jest to $20,159^\circ$ a dla RF $5,398^\circ$ – i około

dwukrotnie niższy w porównaniu do DT – dla DT jest to $10,227^\circ$. Zauważyć można, że wszystkie klasyfikatory prezentują najmniejszą dokładność ACC na samych końcach zakresu ruchu drąga, na co wskazuje lokalizacja (miejsce wystąpienia) maksymalnego średniego błędu bezwzględnego MAE .

Analogicznie dla drąga poruszającego się w dół ($MK3$), RF posiada najlepsze wyniki z jednym tylko wyjątkiem - maksymalnego średniego błędu bezwzględnego $MAE=6,271^\circ$. Różnica w stosunku do MLP jako drugiego najlepszego modelu jest bardziej subtelna niż w przypadku DT – na przykład wartości błędu średniokwadratowego MSE są porównywalne dla RF i MLP – odpowiednio dla RF jest to $13,951 \text{ deg}^2$ a dla MLP $17,985 \text{ deg}^2$ – podczas gdy wartość tego błędu dla DT jest znacznie wyższa i wynosi $26,935 \text{ deg}^2$. Klasyfikatory RF i MLP dostarczają doskonalszych predykcji dla tego kierunku ruchu – wśród innych metryk można to zaobserwować również w odniesieniu do dokładności ACC – dla kierunku w dół dla MLP uzyskano wynik $93,764\%$ a dla RF $95,651\%$. Dla kierunku w górę dla MLP $ACC=89,023\%$ oraz dla RF $ACC=93,764\%$.

Analizując uzyskane wartości charakteryzujące pracę modelu P można stwierdzić, że dla kierunku ruchu w górę ($MK1$) dokładność $ACC=77,409\%$, co stanowi około 85% średniej dokładności ACC wszystkich modeli wynoszącej $90,926\%$ wyliczonej dla pozostałych modeli (DT: $89,991\%$; RF: $93,764\%$; MLP: $89,023\%$). Niestety średni błąd bezwzględny $MAE=4,116^\circ$ jest ponad czterokrotnie większy (DT: $0,652^\circ$; RF: $0,402^\circ$; MLP: $0,760^\circ$). Widać również z rys. 4.4, że dla kierunku ruchu w górę jakość detekcji pogarsza się dla kątów $\alpha_{true,n} > 45^\circ$. Maksymalny średni błąd bezwzględny $MAE=25,484^\circ$ występuje dla kąta 69° i jest porównywalny dla wartości osiągananej przez MLP czyli $20,159^\circ$. Podobnie dla kierunku ruchu w dół ($MK3$) uzyskana dokładność $ACC=76,058\%$ stanowi około 81% średniej dokładności ACC wynoszącej $93,764\%$ a wyliczonej dla pozostałych modeli (DT: $91,846\%$; RF: $95,651\%$; MLP: $93,796\%$). Średni błąd bezwzględny $MAE=6,180^\circ$ jest co najmniej dziesięciokrotnie większy niż dla pozostałych modeli (DT: $0,593^\circ$; RF: $0,292^\circ$; MLP: $0,397^\circ$). Porównując dla tego modelu wykresy przedstawione na rys. 4.4 oraz wartość maksymalnego średniego błędu bezwzględnego MAE dla kierunku w górę $25,484^\circ$ i w dół $54,404^\circ$, można stwierdzić, że jakość modelu dla kierunku w dół jest niższa niż dla kierunku w górę.

Z punktu widzenia bezpieczeństwa funkcjonalnego, bardziej krytycznym ruchem jest ten, w którym drągi są opuszczane. Zgodnie z tym podejściem, nieco bardziej precyzyjny klasyfikator MLP powinien zostać wybrany jako klasyfikator dla metody BMAD ($MK1$ i $MK3$) jako druga opcja dla najlepiej działającego RF (trzeci kwartył średniego błędu bezwzględnego $MAE=0,251^\circ$ w porównaniu z $MAE=0,420^\circ$ dla MLP i $MAE=0,577^\circ$ dla DT).

4.6.2. Predykcja zajęcia wybranego położenia kąowego drąga

Tak jak zostało to opisane w rozdziale 3.2, gdy w związku z realizowaną funkcjonalnością systemu przejazdowego zachodzi potrzeba wykrywania kolejnego położenia kąowego drąga koniecznym staje się wprowadzenie zmian sprzętowych. Alternatywą dla tej komplikacji jest proponowana metoda BMAD w wariantach *MK2* i *MK4* dostarczających predykcji zajęcia wybranego położenia kąowego drąga $b_{pr,n}$. Ponieważ informacja wyjściowa ma postać pojedynczego bitu, macierz konfuzji została zredukowana do macierzy błędów zawierającej cztery wartości:

- Prawdziwie Pozytywna / True Positive (*TP*) - gdy wartość wyjściowa modelu jest równa $b_{pr,n}=1$, a rzeczywisty kąt położenia drąga mieści się w założonej dokładności $\Delta\alpha$ dla wybranego kąta α_{mid} , czyli $b_{real,n}=1$ (3.10),
- Prawdziwie Negatywna / True Negative (*TN*) - gdy wartość wyjściowa modelu jest równa $b_{pr,n}=0$, a rzeczywisty kąt położenia drąga nie mieści się w założonej dokładności $\Delta\alpha$ dla wybranego kąta α_{mid} , czyli $b_{real,n}=0$ (3.10),
- Fałszywie Pozytywna / False Positive (*FP*) - gdy wartość wyjściowa modelu jest równa $b_{pr,n}=1$, a rzeczywisty kąt położenia drąga nie mieści się w założonej dokładności $\Delta\alpha$ dla wybranego kąta α_{mid} , czyli $b_{real,n}=0$ (3.10),
- oraz Fałszywie Negatywna / False Negative (*FN*) - gdy wartość wyjściowa modelu jest równa $b_{pr,n}=0$, a rzeczywisty kąt położenia drąga mieści się w założonej dokładności $\Delta\alpha$ dla wybranego kąta α_{mid} , czyli $b_{real,n}=1$ (3.10),

Szczegółowe wyniki przedstawiono w Tab. 4-2.

Tab. 4-2 Wyniki działania modeli – macierze błędów

Kierunek w górę (model MK2)		
DT	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1364	<i>FP</i> : 246
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 236	<i>TN</i> : 58108
RF	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1450	<i>FP</i> : 111
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 150	<i>TN</i> : 58243
MLP	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1259	<i>FP</i> : 200
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 341	<i>TN</i> : 58154
P	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1198	<i>FP</i> : 243
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 402	<i>TN</i> : 58111

Kierunek w dół (model MK4)		
DT	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1157	<i>FP</i> : 132
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 141	<i>TN</i> : 58516
RF	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1215	<i>FP</i> : 72
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 83	<i>TN</i> : 58576
MLP	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 1155	<i>FP</i> : 90
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 143	<i>TN</i> : 58558
P	Stan pozytywny $b_{real,n}=1$	Stan negatywny $b_{real,n}=0$
Predykcja pozytywna $b_{pr,n}=1$	<i>TP</i> : 551	<i>FP</i> : 92
Predykcja negatywna $b_{pr,n}=0$	<i>FN</i> : 747	<i>TN</i> : 58556

Dodatkowo obliczono wyniki w zakresie czułości *REC*, swoistości *SPE* i dokładności *ACC* dla każdego klasyfikatora i kierunku ruchu i przedstawiono w Tab. 4-3.

Tab. 4-3 Wyniki działania modeli - miary

Miara	DT	RF	MLP	P
Kierunek w górę (model MK2)				
<i>REC</i> [%]	85,25	90,62	78,69	74,88
<i>SPE</i> [%]	99,58	99,81	99,66	99,58
<i>ACC</i> [%]	99,20	99,56	99,10	98,92
Kierunek w dół (model MK4)				
<i>REC</i> [%]	89,14	93,61	88,98	42,45
<i>SPE</i> [%]	99,77	99,88	99,85	99,84
<i>ACC</i> [%]	99,54	99,74	99,61	98,60

Gdy wziąć pod uwagę czułość *ACC* – tym razem dla obu kierunków ruchu (*MK2* i *MK4*) (w górę DT: 85,25%, MLP: 78,69% i w dół DT: 89,14%, MLP: 88,98%) - to można stwierdzić, że wynik DT jest porównywalny z wynikiem MLP dla kierunku w dół z wyraźną przewagą DT dla kierunku ruchu w górę, natomiast swoistość *SPE* (DT: 99,58%; RF: 99,81%; MLP: 99,66%; P: 99,58%) i dokładność *ACC* (DT: 99,20%; RF: 99,56%; MLP: 99,10%; P: 98,92%) dla wszystkich modeli są porównywalne w przypadku kierunku ruchu do góry. Podobną obserwację można odnieść w przypadku kierunku ruchu w dół zarówno dla swoistości *SPE* (DT: 99,77%; RF: 99,88%; MLP: 99,85%; P: 99,84%) jak i dokładności *ACC* (DT: 99,54%; RF: 99,74; MLP: 99,61%; P: 98,60%). Dla obu kierunków obserwowalna jest przewaga RF w zakresie czułości *REC* – odpowiednio 90,62% dla ruchu w górę i 93,61% dla ruchu w dół. Warto wyróżnić czułość *REC* klasyfikatora P dla ruchu w górę wynoszącą 74,88%.

Również i dla tych wariantów metody BMAD (*MK2* i *MK4*) ponownie najlepszym modelem pozostaje RF a modelem drugiego wyboru jest DT ze względu na drugą najlepszą wartość czułości *REC* dla ruchu w górę wynoszącą 85,25%)

4.7. Podsumowanie

Przedstawiona metoda BMAD nie ingeruje zarówno w konstrukcję napędu rogatkowego jak i interfejsu sterującego. Warianty pierwszy i trzeci (*MK1* i *MK3*) dostarczają predykcji położenia kąтового drąga z rozdzielczością $\Delta\alpha=3^\circ$ z dokładnością *ACC* lepszą niż 90% (przy zastosowaniu klasyfikatora RF Tab. 4-1). Warianty drugi i czwarty (*MK2* i *MK4*) dostarczają predykcji zajęcia przez drąg wybranego położenia kąтового również z rozdzielczością $\Delta\alpha=3^\circ$ i parametrami czułości *REC*, swoistości *SPE* i dokładności *ACC* lepszymi niż 90% (również przy zastosowaniu klasyfikatora RF Tab. 4-3). Wszystkie wyniki testów oparte są na danych zebranych w środowisku odpowiadającym typowej instalacji systemu przejazdu kolejowego. Można więc uznać, że uzyskiwane predykcje spełniają wymagania postawione w założeniach dla metody opisane w rozdziale 4.1. W rozdziale wykazano, że analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatkowy z wykorzystaniem algorytmu uczenia maszynowego umożliwia wyznaczenie aktualnego położenia kąta drąga bez konieczności ingerencji w konstrukcję urządzenia.

5. Metoda prognozowania całkowitego czasu ruchu drąga elektrycznego napędu rogatkowego BMMT

W niniejszym rozdziale opisano propozycję autorskiej metody predykcji całkowitego czasu ruchu drąga napędu rogatkowego (BMMT – Barrier Machine Movement Time). Autor przedstawia koncepcję otwierającą drogę do optymalizacji czasu ostrzegania sygnalizacji przejazdowej, a w konsekwencji przyczyniającej się do zwiększenia przepustowości całego systemu kolejowego poprzez dostarczenie predykcji całkowitego czasu ruchu drąga na podstawie przebiegu prądu zasilania oraz wybranych zmiennych środowiskowych. Metoda wykorzystuje techniki uczenia maszynowego, w tym sztuczne sieci neuronowe. Według rozeznania Autora, przeprowadzonego przeglądu literatury w rozdziale 3.3 metoda jest unikalna i aktualnie niedostępna na rynku.

5.1. Założenia metody

Metoda predykcji całkowitego czasu ruchu drąga elektrycznego napędu rogatkowego powinna dostarczyć predykcji obciążonej maksymalnym błędem bezwzględnym *MAE* mniejszym niż 0,5 s, co stanowi 5% typowego maksymalnego dopuszczalnego czasu ruchu drąga pomiędzy położeniami skrajnymi wynoszącego 10 s. Predykcja powinna być wyznaczona w oparciu o dane zebrane w czasie poniżej 1 s od rozpoczęcia ruchu drąga. Czas 1 s odpowiada typowej wartości okresu przetwarzania danych dla kolejowego systemu nadrzędnego. Dla predykcji całkowitego czasu ruchu drąga elektrycznego napędu rogatkowego dopuszczalne jest wykorzystanie sygnału enkodera.

5.2. Opis metody

Autor proponuje metodę opartą na uczeniu maszynowym, która na wejściu ma wektor cech FB_n zawierający informację o parametrach pracy napędu rogatkowego w początkowym fragmencie ruchu drąga w tym i wybranych parametrach środowiskowych, a na wyjściu predykcję całkowitego czasu ruchu drąga elektrycznego napędu rogatkowego $t_{pr,n}$. Sposób działania metody przedstawiony na Rys. 5.1. Metoda jest zaprojektowana do jednoczesnego przetwarzania ruchów drąga w górę oraz w dół.



Rys. 5.1 Schemat działania metody BMMT

Metoda opiera swoje działanie o wektor danych wejściowych FB_n , który posiada następujące składowe (4.1):

$$FB_n = [F0_n \dots F5_n, F6_n \dots F11_n, F12_n, F13_n, F14_n, F15_n], \quad (4.1)$$

odpowiednio:

- $F0_n \dots F5_n = [t_{n,0} \dots t_{n,5}]$ (4.2) – gdzie odpowiednio $t_{n,0} \dots t_{n,5}$ to momenty czasu, w których dochodzi do pierwszych sześciu aktywacji enkodera. Wybór czasu wyznaczonego przez pierwsze sześć aktywacji enkodera został szczegółowo omówiony w rozdziale 5.4,
- $F6_n \dots F11_n = [i_{n,0} \dots i_{n,5}]$ (4.3) – gdzie odpowiednio $i_{n,0} \dots i_{n,5}$ to pierwsze sześć wartości prądu zasilania mierzonych przy kolejnych aktywacjach enkodera,
- $F12_n = mean([tm_{n,0} \dots tm_{n,5}])$ (4.4) – gdzie odpowiednio $tm_{n,0} \dots tm_{n,5}$ to pierwsze sześć wartości temperatury powietrza mierzonych przy kolejnych aktywacjach enkodera a funkcja $mean()$ oznacza funkcję zwracającą wartość średnią,
- $F13_n = mean([dp_{n,0} \dots dp_{n,5}])$ (4.5) – gdzie odpowiednio $dp_{n,0} \dots dp_{n,5}$ to pierwsze sześć wartości temperatury punktu rosy mierzonych przy kolejnych aktywacjach enkodera,
- $F14_n = f_bin_\phi([phi_{n,0} \dots phi_{n,5}]) = bin_{phi,n}$ (4.6) – gdzie odpowiednio $phi_{n,0} \dots phi_{n,5}$ to pierwsze sześć wartości kierunku wiatru oraz funkcja f_bin_ϕ jest określona w następujący sposób (4.7):

$$f_bin_\phi(\phi) = \begin{cases} 0 & \text{gdy } \phi \in (0; 60) [deg] \\ 1 & \text{gdy } \phi \in (60; 120) [deg] \\ \vdots & \\ 5 & \text{gdy } \phi \in (300; 360) [deg] \end{cases}, \quad (4.7)$$

- $F15_n = f_bin_V([V_{n,0} \dots V_{n,5}]) = bin_{V,n}$ (4.8) – gdzie odpowiednio $V_{n,0} \dots V_{n,5}$ to pierwsze sześć wartości prędkości wiatru oraz funkcja f_bin_V jest określona w następujący sposób (4.9):

$$f_bin_V(V) = \begin{cases} 0 & \text{gdy } V \in (0; 0,9) [m/s] \\ 1 & \text{gdy } V \in (0,9; 1,8) [m/s] \\ \vdots & \\ 5 & \text{gdy } V \in (4,5; 5,4) [m/s] \end{cases}. \quad (4.9)$$

Wszystkie zmienne są próbkowane od momentu rozpoczęcia danego ruchu z okresem TPLC=50 ms a następnie przetwarzane na składowe wektora FB_n . Wektor FB_n stanowi informację wejściową dla modelu regresyjnego MR zwracającego predykcję całkowitego czasu ruchu drąga $t_{pr,n}$ (4.10):

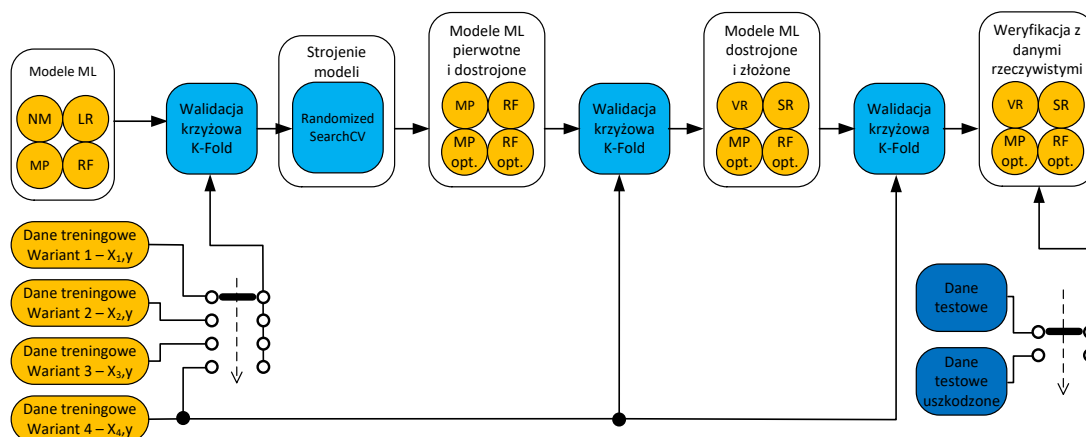
$$t_{pr,n} = MR(FB_n), \quad (4.10)$$

$$\text{gdzie } t_{pr,n} = t_{\alpha_{max}} - t_{\alpha_{min}} = t_{n,82} - t_{n,0}.$$

Czas $t_{\alpha_{max}}$ oznacza moment, w którym drąg osiąga pozycję skrają powiązaną z położeniem kątowym α_{max} . Każdorazowo ruch drąga rozpoczyna się w momencie czasu $t_{\alpha_{min}}$ od położenia kąтового α_{min} .

5.3. Sposób opracowania metody

Sposób opracowania metody BMMT został przedstawiony poniżej na rys. 5.2.



Rys. 5.2 Sposób opracowania metody BMMT


Badaniom porównawczym podlega zestaw następujących modeli ML – Naive Model Mean (NM) działający w trybie zwracania wartości średniej ze zbioru treningowego zrealizowany z wykorzystaniem modelu Dummy Regressor, Linear Regression (LR), MLP Regressor (MLP) oraz Random Forest Regressor (RF). Model NM jest najbliższy aktualnemu podejściu zastosowanemu w algorytmie sterowania napędem rogatek i wyznacza podejście referencyjne. Skuteczność działania tych modeli została zweryfikowana poprzez mechanizm k-krotnej walidacji krzyżowej dla danych treningowych przygotowanych w czterech wariantach – każdy kolejny wariant zawierał szerszy zestaw danych treningowych. Zostały wybrane dwa najlepsze modele – MP i RF.

W kolejnym kroku zrealizowano proces strojenia modeli, którego skuteczność zweryfikowano poprzez porównanie skuteczności modeli z konfiguracjami pierwotnymi (MP, RF) i zoptymalizowanymi (MPopt, RFopt) – również z wykorzystaniem k-krotnej walidacji krzyżowej. W efekcie zostały wybrane dwa najlepsze modele (MPopt, RFopt) oraz zostały zaproponowane dwie struktury modeli złożonych (Voting Regressor - VR i Stacking Regressor - SR). Ponownie cały zestaw tak dobranych modeli został poddany k-krotnej walidacji krzyżowej.

W ostatnich dwóch krokach została zbadana skuteczność działania czterech najlepszych modeli (MPopt, RFopt, VR, SR) z danymi testowymi oraz odporność na dane uszkodzone będące wynikiem uszkodzenia poszczególnych sensorów realizujących funkcję akwizycji danych.

5.4. Dane treningowe i testowe

Zawartość wektora danych wejściowych FB_n jest budowana w oparciu o zbiór danych B szczegółowo opisany w rozdziale 3.5.2. Sposób wyznaczania cech $F0...F15$ został podany w opisie metody omówiony w rozdziale 5.2 a niniejszy rozdział przedstawia proces ich projektowania, który ostatecznie umożliwił wytworzenie zestawu danych treningowych i testowych. Podobnie jak w przypadku metody BMMT przyjęto założenie, że ruch drąga niezależnie od kierunku ruchu rozpoczyna się od położenia kąowego $\alpha_{min} = 0^\circ$ oraz kończy się w położeniu kąowym $\alpha_{max} = 82^\circ$ tak, jak zostało to przedstawione w rozdziale 3.5.2. Histogram całkowitych czasów ruchu drąga elektrycznego napędu rogatekowego został przedstawiony na rys. 5.3.

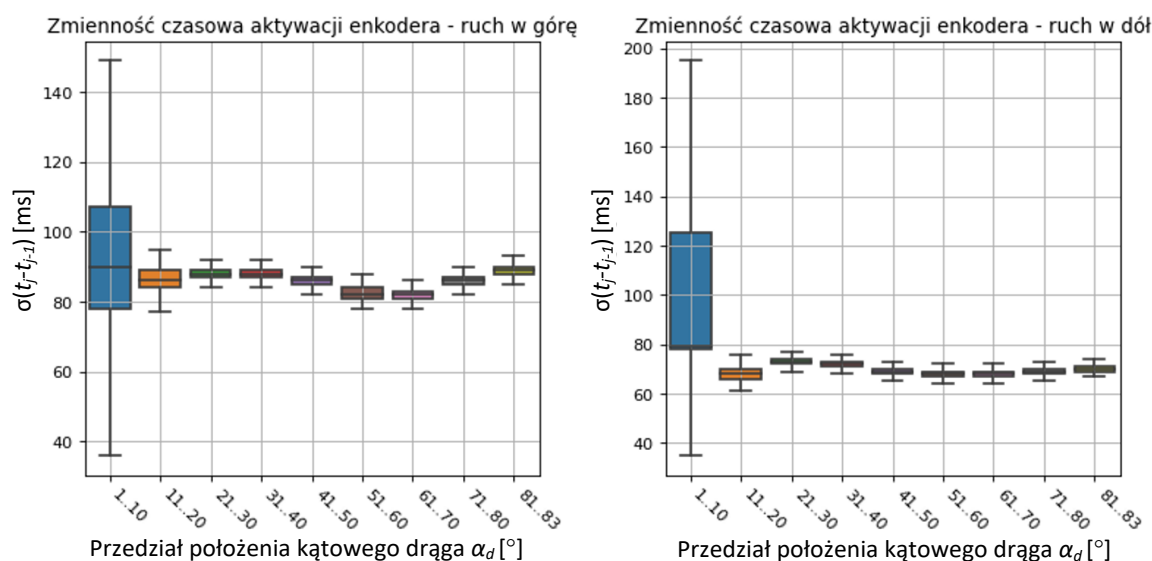


Rys. 5.3 Histogram całkowitych czasów ruchu drąga $t_{real,n}$ dla kierunku w górę (kolor czerwony) oraz w dół (kolor niebieski)

Wszystkie cechy zostały wyznaczone w pierwszej fazie ruchu drąga napędu rogatekowego, która jest określona poprzez wymaganie na maksymalny czas akwizycji danych liczony od momentu rozpoczęcia ruchu drąga podany w rozdziale 5.1.

W konsekwencji analizując zawartość Tab. 5-1 można stwierdzić, że dane z czujników mogą być próbkowane w momentach czasu wyznaczonych przez pierwszych sześć aktywacji enkodera.

Wyniki analizy statystycznej czasu ruchu napędu rogatekowego pokazano na rys. 5.4 oraz w Tab. 5-1.



Rys. 5.4 Zmienność czasowa poszczególnych kroków enkodera $\sigma(t_j - t_{j-1})$ dla ruchu w górę (po prawej) i w dół (po lewej)

W Tab. 5-1 zostało przedstawione zestawienie dwóch metryk dla poszczególnych wartości kąta położenia drąga $\alpha_d = 1..10^\circ$ – odchylenie standardowe czasu pomiędzy daną a poprzednią aktywacją enkodera $\sigma(t_j - t_{j-1})$ oraz maksymalny czas t_j w jakim drąg osiągał dane położenie kątowe α_j oraz zbiorczo dla przedziału 11..83° jedynie odchylenie standardowe czasu pomiędzy 11 a 83 aktywacją enkodera.

Tab. 5-1 Zmienność czasowa poszczególnych kroków enkodera

Położenie kątowe drąga α_j [°]	Odchylenie standardowe $\sigma(t_j - t_{j-1})$ [ms]	Maksymalna wartość czasu t_j [ms]
Kierunek w górę		
1	0	0
2	158	535
3	17	620
4	10	744
5	3	853
6	6	944
7	4	1032
8	2	1115
9	1	1194
10	2	1272
11..83	≤ 3	

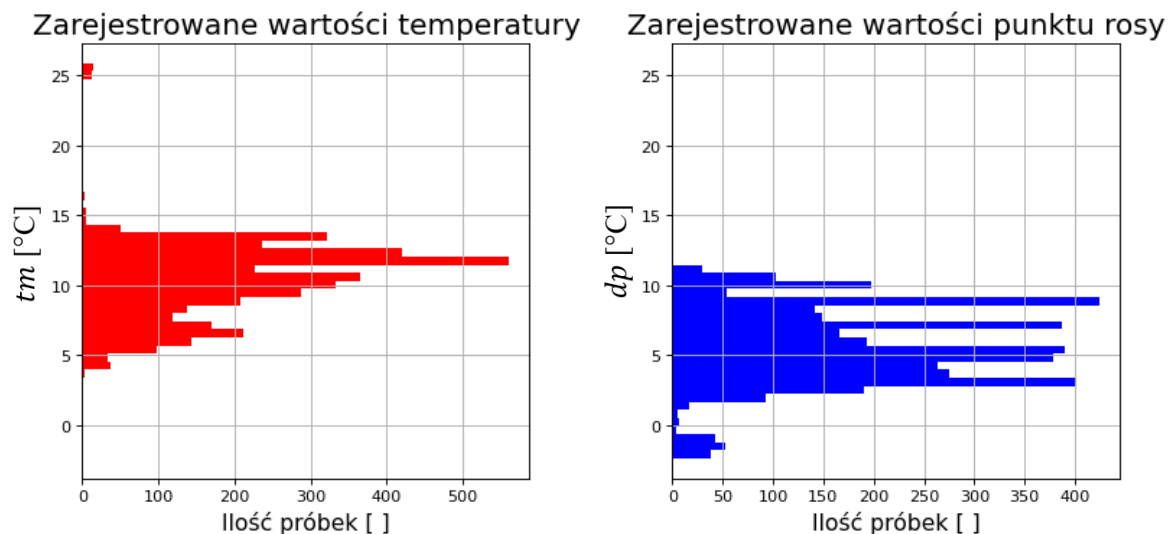
Położenie kątowne draża α_j [°]	Odchylenie standardowe $\sigma(t_j-t_{j-1})$ [ms]	Maksymalna wartość czasu t_j [ms]
Kierunek w dół		
1	0	0
2	35	266
3	14	405
4	11	596
5	12	674
6	1	753
7	1	831
8	1	911
9	1	989
10	1	1064
11..83	≤ 2	

Obserwując wartości w Tab. 5-1 oraz rys. 5.4 można stwierdzić, że przedział czasu wyznaczony przez pierwsze 6 aktywacji enkodera spełnia wymaganie na zarejestrowanie najwyższych wartości odchylenia standardowego $\sigma(t_j-t_{j-1})$, występujących w zakresie całego ruchu draża – odpowiednio 158 ms dla ruchu w górę, jak i 35 ms dla ruchu w dół.

Przyjęte założenie rozpoczęcia analizy zebranych wyników pomiarów bezpośrednio po opóźnieniu określonym przez szóstą aktywację enkodera umożliwiło aktywację modeli predykcyjnych po upływie czasu każdorazowo krótszego od 1 s od momentu aktywacji napędu rogatekowego – wartości maksymalne to 944 ms dla ruchu w górę i 753 ms dla ruchu w dół.

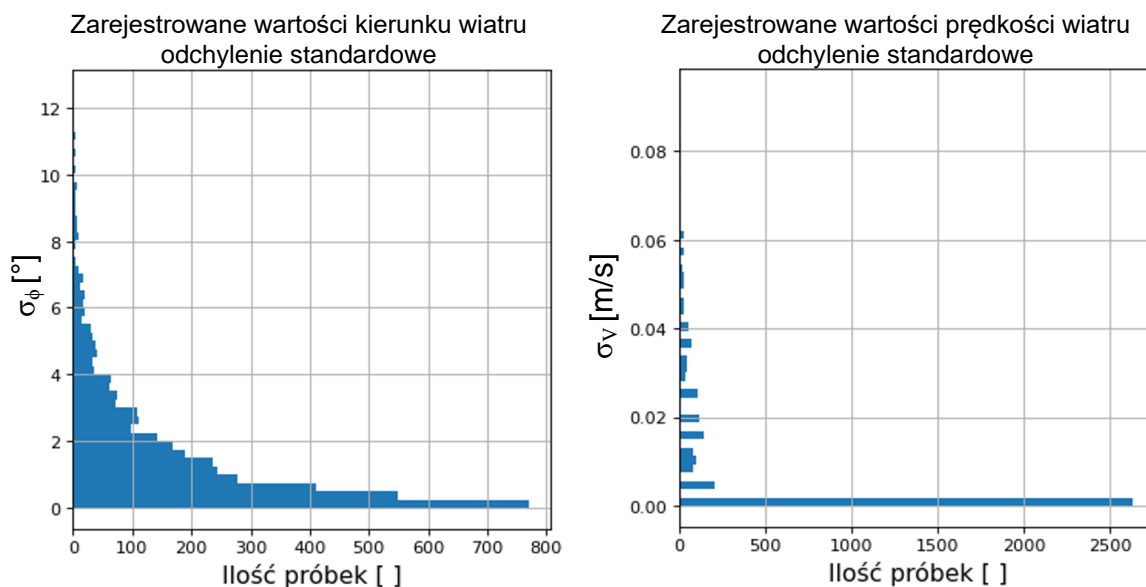
W związku z tym założeniem również odczyty temperatury tm , punktu rosy dp , kierunku ϕ i prędkości wiatru V są przekształcane na cechy z uwzględnieniem tylko pierwszych sześciu rekordów w danym cyklu ruchu. Dodatkowo dla temperatury tm i punktu rosy dp przyjmuje się, że wartości średnie są adekwatną reprezentacją tych zmiennych. Czas trwania procesu obserwacji jest krótszy niż jedna sekunda, a wielkości te są wolnozmiennie, co uzasadnia takie podejście.

Poniższy rysunek - rys. 5.5 - przedstawia histogram zaobserwowanych wartości temperatury t_m i punktu rosy dp .



Rys. 5.5 Histogram zaobserwowanych wartości temperatury t_m (po lewej) i punktu rosy dp (po prawej)


Dla założonego czasu początkowej obserwacji obliczono odchylenie standardowe dla zmiennych kierunku i prędkości wiatru – odpowiednio $\sigma([\phi_{n,0} \dots \phi_{n,5}]) = \sigma_\phi$ i $\sigma([V_{n,0} \dots V_{n,5}]) = \sigma_v$. Wyniki przedstawiono poniżej na rys. 5.6.



Rys. 5.6 Histogram odchylenia standardowego dla kierunku wiatru σ_ϕ (po lewej) i prędkości σ_v (po prawej)

Zauważono, że zmiany kierunku i prędkości wiatru w początkowym momencie ruchu napędu rogatekowego były niewielkie – wskazuje na to średnia wartość odchylenia

standardowego kierunku wiatru σ_ϕ równa $2,480^\circ$, co jest znacznie mniejszą wartością od wymiaru zdefiniowanego przedziału wynoszącego 60° . To samo można powiedzieć o średniej wartości odchylenia standardowego prędkości wiatru σ_V , która wynosi $0,010$ m/s, podczas gdy szerokość przedziału wynosi $0,9$ m/s. W obu przypadkach wartości średnie kierunku i prędkości wiatru zostały przypisane do jednego z sześciu predefiniowanych przedziałów wartości. Granice przedziałów pod względem ich wartości granicznych równomiernie rozdzielają pełny zakres obserwowanych wartości kierunku wiatru ϕ ($0-360^\circ$) i prędkości wiatru V (0 m/s- $5,4$ m/s). Uzyskano następujący rozkład tych zmiennych - rys. 5.7.



Rys. 5.7 Histogram zarejestrowanych wartości kierunku wiatru ϕ (po lewej) i prędkości wiatru V (po prawej) w podziale na podzakresy odpowiednio $bin_{\phi,n}$ i $bin_{V,n}$

W efekcie tych analiz zdecydowano o utworzeniu czterech wariantów wektora cech w celu określenia wpływu dokładności predykcji czasu od liczby zastosowanych parametrów. Można więc stwierdzić, że każdy kolejny wariant zawiera cechy wariantu prostszego i dodatkowe kolejne elementy związane z doposażeniem napędu rogatekowego o kolejne sensory. Wektory te tworzą macierze, które następnie będą stanowić informację wejściową dla wybranych modeli predykcyjnych, których zadaniem jest wyznaczenie całkowitego czasu ruchu drąga (4.10) w bieżących warunkach pogodowych.

Cechy te zostały połączone w zestawy (4.11) tworząc odpowiednio cztery warianty macierzy cech – X_1 , X_2 , X_3 i X_4 :

$$\begin{aligned}
 X_1 &= \begin{bmatrix} F0_1..F5_1 \\ \vdots \\ F0_N..F5_N \end{bmatrix} - \text{variant 1}, \\
 X_2 &= \begin{bmatrix} F0_1..F5_1, F6_1..F11_1 \\ \vdots \\ F0_N..F5_N, F6_N..F11_N \end{bmatrix} - \text{variant 2}, \\
 X_3 &= \begin{bmatrix} F0_1..F5_1, F6_1..F11_1, F12_1, F13_1 \\ \vdots \\ F0_N..F5_N, F6_N..F11_N, F12_N, F13_N \end{bmatrix} - \text{variant 3}, \\
 X_4 &= \begin{bmatrix} F0_1..F5_1, F6_1..F11_1, F12_1, F13_1, F14_1, F15_1 \\ \vdots \\ F0_N..F5_N, F6_N..F11_N, F12_N, F13_N, F14_N, F15_N \end{bmatrix} - \text{variant 4}, \\
 y &= \begin{bmatrix} t_{real,1} \\ \vdots \\ t_{real,N} \end{bmatrix} \text{ gdzie } N = 4000.
 \end{aligned} \tag{4.11}$$

Model *MR* będzie trenowany i testowany na podstawie wektora etykiet zawierającego wartości $t_{real,n}$ oznaczające rzeczywisty całkowity czas trwania danej fazy ruchu drąga. Obserwacji będzie podlegać jakość dostarczanych predykcji przez poszczególne modele w oparciu o macierze cech o rosnącej złożoności. Wzrost złożoności wynika z uwzględniania kolejnych zmiennych odzwierciedlających parametry pracy napędu w początkowej fazie ruchu, bądź też stan parametrów środowiskowych. Oczekuje się, że w efekcie będą uzyskiwane coraz doskonalsze predykcje w konsekwencji instalacji kolejnych czujników na przejeździe.

Cały tak utworzony zbiór danych zawierający wyżej opisane cechy został podzielony na dwie części – 70% jako dane treningowe i 30% jako dane testowe.

5.5. Dobór modeli ML

W ramach pracy postanowiono wykorzystać następujące modele predykcyjne:

- Naive Model Mean (NM) w oparciu o model Dummy Regressor:
 - z domyślnymi wartościami wszystkich parametrów:
strategy='mean', constant=None, quantile=None
- Linear Regression (LR):
 - z domyślnymi wartościami wszystkich parametrów:
fit_intercept=True, copy_X=True, n_jobs=None, positive=False
- MLP Regressor (MP):
 - z parametrami:
solver='lbfgs', alpha=0.01, max_iter=10000, hidden_layer_sizes=(5),
random_state=11
 - pozostałe parametry zostały ustawione zgodnie z ich wartościami domyślnymi:
activation='relu', batch_size='auto', learning_rate='constant',
learning_rate_init=0.001, power_t=0.5, shuffle=True, tol=0.0001,
verbose=False, warm_start=False, momentum=0.9,
nesterovs_momentum=True, early_stopping=False,
validation_fraction=0.1, beta_1=0.9, beta_2=0.999, epsilon=1e-08,
n_iter_no_change=10, max_fun=15000
- Random Forest Regressor (RF):
 - z parametrem:
n_estimators=200
 - pozostałe parametry zostały ustawione zgodnie z ich wartościami domyślnymi:
criterion='squared_error', max_depth=None, min_samples_split=2,
min_samples_leaf=1, min_weight_fraction_leaf=0.0,
max_features='auto', max_leaf_nodes=None,
min_impurity_decrease=0.0, bootstrap=True, oob_score=False,
n_jobs=None, random_state=None, verbose=0, warm_start=False,
ccp_alpha=0.0, max_samples=None

5.6. Wyniki wstępne

Wszystkie modele zostały ocenione przy użyciu algorytmu k-krotnej walidacji krzyżowej (K-Fold cross-validation) w następującej konfiguracji - zaimplementowano pięciokrotny podział danych treningowych i wykonano 10 testów dla każdego bloku danych (fold). W ten sposób uzyskano 50 wyników testów każdego modelu. Zastosowano dwie metryki błędów – błąd średniokwadratowy MSE oraz błąd maksymalny ME . Kod programu realizujący te funkcje został przedstawiony w List. 5.1.

```

"""
Ewaluacja modelu
"""
def ewaluacja(model, X, y):
    cv = RepeatedKFold(n_splits=5, n_repeats=10, random_state=42)
    scoring = ['neg_mean_squared_error', 'max_error', 'r2']
    scores = cross_validate(model, X, y, scoring=scoring, cv=cv, n_jobs=-1, error_score='raise')
    return scores

"""
Ewaluacja modeli
"""
def ewaluacja_modeli(modele, X, y):

    wyniki = dict()

    # właściwa ewaluacja
    for nazwa, model in modele.items():
        print('Ewaluacja: ', nazwa)
        wynik = ewaluacja(model, X, y)
        wyniki[nazwa] = wynik

    wyniki_raw_df = pd.DataFrame(wyniki)

    # wyliczenie mediany z całej serii dokonanych predykcji
    wyniki_df = wyniki_raw_df.applymap(lambda x: np.median(x))

    # obrobka wyników
    # zaplikowanie lambda dla wszystkich kolejnych kolumn celem
    # przemnożenia przez -1 ze względu na domyślnie stosowane ujemne miary błędów
    wyniki_df = wyniki_df.applymap(lambda x: (-1) * x)
    wyniki_raw_df = wyniki_raw_df.applymap(lambda x: (-1) * x)

    # przywrócenie wartości dodatnich dla miary R2
    wyniki_df.loc['test_r2'] = wyniki_df.loc['test_r2'].apply(lambda x: x * (-1))
    wyniki_raw_df.loc['test_r2'] = wyniki_raw_df.loc['test_r2'].apply(lambda x: x * (-1))

    wyniki_df.loc['test_neg_mean_squared_error'] = \
        wyniki_df.loc['test_neg_mean_squared_error'].apply(lambda x: '{:.0f}'.format(x))

    wyniki_df.loc['test_r2'] = \
        wyniki_df.loc['test_r2'].apply(lambda x: '{:.6f}'.format(x))

    wyniki_df.loc['test_max_error'] = \
        wyniki_df.loc['test_max_error'].apply(lambda x: '{:.0f}'.format(x))

    # usunięcie dwóch niepotrzebnych wierszy
    wyniki_df = wyniki_df.drop(['fit_time', 'score_time'])
    wyniki_raw_df = wyniki_raw_df.drop(['fit_time', 'score_time'])

    # aktualizacja indeksu do oficjalnych nazw miar błędów
    # opracowanie słownika
    klucz_do_indeksu = {'test_neg_mean_absolute_error': 'Mean Absolute Error',
                       'test_neg_mean_squared_error': 'Mean Squared Error',
                       'test_r2': 'R2',

```

```

        'test_max_error':'Maximum Error'}

# pobranie aktualnego indeksu do listy
indeks = wyniki_df.index.to_list()

# zamiana poszczegolnych elementow w liscie utworzonej z indeksu
# za pomoca list comprehension
indeks = [klucz_do_indeksu[x] for x in indeks]

# wpisanie do df zaktualizowanego indeksu
wyniki_df.index = indeks
wyniki_raw_df.index = indeks

print('>>> Ewaluacja gotowa')
return wyniki_raw_df, wyniki_df

"""
Analiza dla modeli pierwotnych
"""
def analiza_dla_modeli_pierwotnych(X_train_scaled_in, y_train_in):

# wczytanie danych
X_train_scaled = X_train_scaled_in
y_train = y_train_in

# zdefiniowanie kolejnych rozmiarow macierzy cech
feat_list = [6,12,14,16]

# df z wynikami
wyniki_df = pd.DataFrame()
wyniki_raw_df = pd.DataFrame()

for i in feat_list:

# wygenerowanie nowych zbiorow danych treningowych
X_train_i = X_train_scaled[:,i]
y_train_i = y_train

# modele pierwotne
modele = modele_pierwotne()

# ewaluacja modeli
wyniki, wyniki_median = ewaluacja_modeli(modele, X_train_i, y_train_i)

# zebranie wynikow po przetworzeniu do mediany i surowych
for col in wyniki.columns:
    print(col)

# dopisanie wynikow powiazanych z aktualnym zestawem cech
wyniki_df[col + '{:02d}'.format(i)] = wyniki_median[col]
wyniki_raw_df[col + '{:02d}'.format(i)] = wyniki[col]

# zapisanie wynikow
wyniki_df.to_excel('Fig\\1200 Analiza dla modeli pierwotnych.xlsx')
dump(wyniki_raw_df, 'Fig\\1200 Analiza dla modeli pierwotnych.bin', compress=True)

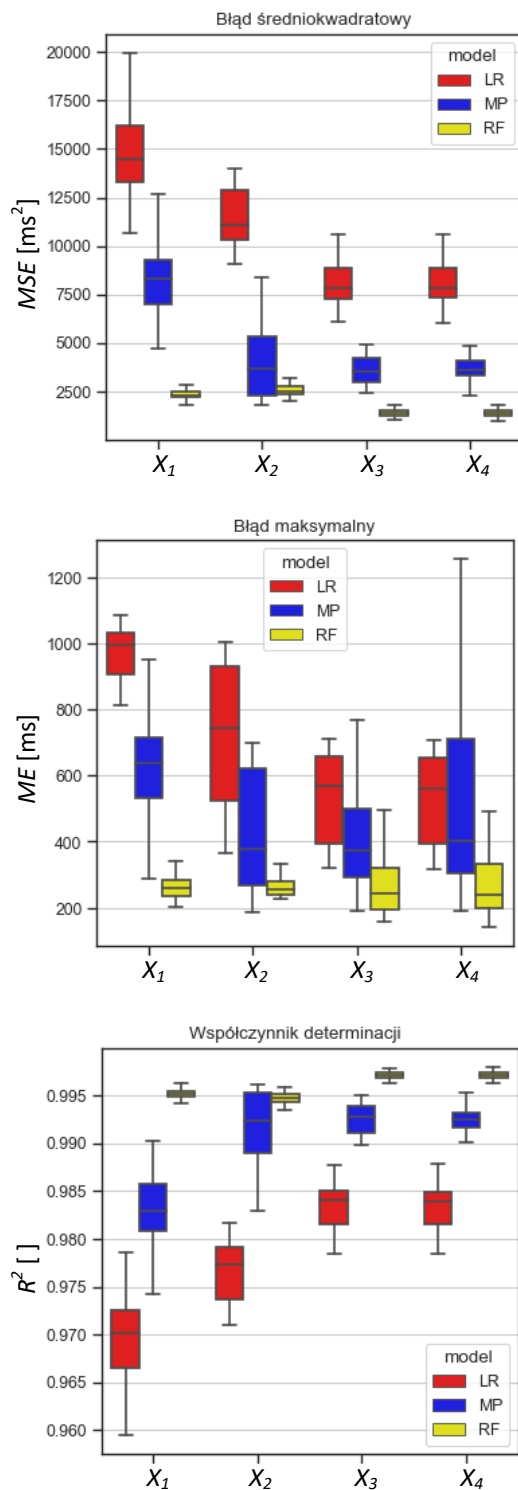
print('>>> Analiza dla modeli pierwotnych gotowa')
return wyniki_raw_df, wyniki_df

```

List. 5.1 Ewaluacja modeli NM, LR, MP i RF

W ramach pierwszego etapu prac badano jakość predykcji $t_{pr,n}$ dostarczanych przez modele pierwotne w oparciu o cztery warianty wektora cech X_1 , X_2 , X_3 i X_4 . Uzyskane metryki weryfikują na ile rozbudowa wektora cech przynosi poprawę dostarczanych predykcji lub alternatywnie informują, jakie są ich maksymalne poziomy dla systemów przejazdowych wyposażonych w ograniczony zestaw czujników.

Wyniki przedstawione na rys. 5.8 oraz w tabeli Tab. 5-2 obrazują ilościowy opis dostarczanych predykcji całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego dla wszystkich czterech wariantów macierzy cech w podziale na wszystkie badane warianty modeli.



Rys. 5.8 Wyniki działania modeli LR, MP i RF z wykorzystaniem czterech wariantów macierzy cech $X_1 \dots X_4$ – błąd średniokwadratowy MSE (u góry), błąd maksymalny ME (w środku) i współczynnik determinacji R^2 (na dole)

Dla każdej metryki błędu, która zawiera 50 wartości, obliczono wartość mediany, aby umożliwić prostszą ocenę modelu.

Tab. 5-2 Wyniki działania modeli NM, LR, MP i RF – mediany metryk błędów

Macierz cech X_1 – zestaw cech ($F0_n..F5_n$)				
Metryka błędu	NM	LR	MP	RF
MSE [ms^2]	488572	14468	8341	2321
ME [ms]	1020	997	636	259
R^2 []	-0,001628	0,970182	0,982927	0,995210
Macierz cech X_2 – zestaw cech ($F0_n..F11_n$)				
Metryka błędu	NM	LR	MP	RF
MSE [ms^2]	488572	11051	3689	2532
ME [ms]	1020	744	377	257
R^2 []	-0,001628	0,977324	0,992424	0,994803
Macierz cech X_3 – zestaw cech ($F0_n..F13_n$)				
Metryka błędu	NM	LR	MP	RF
MSE [ms^2]	488572	7832	3544	1410
ME [ms]	1020	566	373	242
R^2 []	-0,001628	0,984052	0,992763	0,997103
Macierz cech X_4 – zestaw cech ($F0_n..F15_n$)				
Metryka błędu	NM	LR	MP	RF
MSE [ms^2]	488572	7837	3645	1397
ME [ms]	1020	562	403	238
R^2 []	-0,001628	0,983987	0,992548	0,997134

Dla wyników dostarczonych z wykorzystaniem wektora cech X_1 można zauważyć, że wartość błędu średniokwadratowego dla modelu NM jest znacznie wyższa $MSE=488572 ms^2$ niż wartości występujące w przypadku wszystkich pozostałych modeli. Inną charakterystykę ma rozkład błędu maksymalnego ME – jest porównywalny dla modelu NM $ME=1020 ms$ i modelu LR $ME=997 ms$. Błąd maksymalny jest najmniejszy najniższy dla modelu RF $ME=259 ms$, w przypadku MP ten błąd jest ponad dwukrotnie wyższy $ME=636 ms$. Podobnie MSE jest znacznie niższy dla RF – $MSE=2321 ms^2$ – niż w przypadku modelu MP gdzie $MSE=8341 ms^2$. Dla przejrzystości wyniki dla NM nie są pokazane na rys. 5.8 – jednak każdorazowo komplet wartości jest podany w formie tabelarycznej, aby umożliwić porównanie. Współczynnik determinacji R^2 nieznacznie się różni dla trzech najlepszych modeli. Jednak można wskazać na najlepszy model RF dla którego $R^2=0,995210$, drugi w kolejności MP gdzie $R^2=0,982927$ i trzeci LR z $R^2=0,970182$. W przypadku modelu NM uzyskana metryka $R^2=0,001628$ znacznie odbiega od pozostałych wartości.

W drugim podejściu z wykorzystaniem macierzy X_2 uzupełniono zestaw cech o kolejne elementy $F6_n..F11_n$ – są to pomiary prądu zasilania wykonywane w momentach aktywacji enkodera w zakresie pierwszych sześciu kroków. Główną różnicę można zaobserwować

w przypadku MP, gdzie MSE zmniejsza się z 8341 ms^2 do 3689 ms^2 i również następuje znaczne zmniejszenie ME z 636 ms do 377 ms . Obserwowalna jest również poprawa dla modelu LR, gdzie MSE zmniejsza się z 14468 ms^2 do 11051 ms^2 , a ME z początkowej wartości 997 ms redukuje się do 744 ms . Metryki RF pozostały prawie niezmiennione – $MSE=2321 \text{ ms}^2$, a teraz nieznacznie wzrosło do 2532 ms^2 i $ME=259 \text{ ms}$ wobec 257 ms . W tym wypadku współczynnik determinacji R^2 dla dwóch najlepszych modeli MP i RF jest praktycznie równy – odpowiednio $R^2=0,992424$ i $R^2=0,994803$.

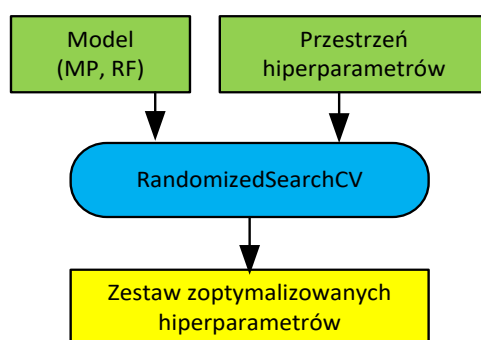
Dla wektora wejściowego wyposażonego w informacje o temperaturze i wartości punktu rosy ($F12_n..F13_n$) główną różnicę można zaobserwować dla modelu RF - MSE znacząco zmniejsza się z 2532 ms^2 do 1410 ms^2 oraz obserwowalna jest niewielka poprawa dla ME z 257 ms do 242 ms . Metryka dla modelu MP pozostała prawie niezmienniona - dla MSE zmiana następuje z 3689 ms^2 na 3544 ms^2 i dla metryki ME z 377 ms na 373 ms . MSE dla LR zmniejszył się z 11051 ms^2 do 7832 ms^2 . Mimo, że ME poprawił się z 744 ms do 566 ms to pozostał znacznie wyższy niż ME dla MP czy RF. Obserwowalna zmiana współczynnika determinacji wystąpiła dla modelu LR, gdzie została osiągnięta wartość $R^2=0,984052$ już tylko nieznacznie różniąc się od metryk dwóch najlepszych modeli MP i RF gdzie odpowiednio $R^2=0,992763$ i $R^2=0,997103$.

W czwartym podejściu dodano cechy $F14_n..F15_n$) zawierające informację o kierunku i prędkości wiatru w postaci zagregowanej do przedziałów wartości. Można stwierdzić, że poprawa, jeśli jest obserwowana to jest niewielka – tak jak MSE dla modelu RF obniża się z wartości 1410 ms^2 jedynie do 1397 ms^2 czy też ME obniżający się również nieznacznie z 242 ms do 238 ms . W zakresie współczynnika determinacji R^2 również nie doszło do znaczącej zmiany – wartości dla poszczególnych modeli są nieznacznie różne od wartości w poprzednim przypadku ($-0,001628$; $0,983987$; $0,992548$; $0,997134$ w porównaniu do $-0,001628$; $0,984052$; $0,992763$; $0,997103$).

Modele RF i MP w każdym z wariantów, tj. zarówno dla najprostszego wektora cech X_1 , jak i dla najbardziej rozbudowanego wektora cech X_4 oferują najdokładniejsze rezultaty i dlatego w dalszym etapie postanowiono wykonać proces strojenia (optymalizacji) modeli wyłącznie z ich wykorzystaniem.

5.7. Strojenie modeli predykcyjnych

W ślad za innymi publikacjami [4], [102] zdecydowano się na optymalizację modeli w celu poprawy jakości uzyskiwanych predykcji. Do dalszych prac mających na celu optymalizację wybrano dwa modele charakteryzujące się najlepszymi wynikami - RF i MP. Przebieg strojenia modeli predykcyjnych przedstawiono na rys. 5.9 poniżej:



Rys. 5.9 Proces optymalizacji modeli

W Tab. 5-3 przedstawiono badaną przestrzeń hiperparametrów podczas optymalizacji modeli RF i MP.

Tab. 5-3 Strojenie modeli predykcyjnych

Parametr	Opis	Zakres strojenia	Wartość optymalna
Model RF			
'n_estimators'	Liczba drzew	[100, 200, 300, ..., 1900]	100
'max_depth'	Maksymalna głębokość drzew	[20, 40, 60, ..., 180, None]	20
'min_samples_split'	Minimalna liczba próbek wymagana do podzielenia węzła wewnętrznego	[2, 3, 4, ..., 9]	2
'min_samples_leaf'	Minimalna liczba próbek w węźle liścia	[1, 2, 3, 4]	2
'max_features'	Liczba cech, które należy wziąć pod uwagę, szukając najlepszego podziału	["auto", "sqrt", "log2"]	'auto'
'bootstrap'	Wykorzystanie próbek typu "bootstrap"	[False, True]	'True'

Parametr	Opis	Zakres strojenia	Wartość optymalna
Model MP			
'hidden_layer_sizes'	Liczba neuronów w warstwie ukrytej	[(3), (10), (15), (20)]	(20)
'activation'	Funkcja aktywacji dla warstwy ukrytej	["identity", "logistic", "tanh", "relu"]	'logistic'
'solver'	Funkcja optymalizacji wag	['lbfgs', 'sgd', 'adam']	'lbfgs'
'alpha'	Nastawa regularyzacji L ₂	[0.00001, 0.0001, 0.001, 0.01]	0.0001
'learning_rate'	Sposób doboru współczynnika uczenia	['constant', 'invscaling', 'adaptive']	'constant'
'max_iter'	Maksymalna liczba iteracji	[100, 200, 1000, 2000, 4000, 8000, 12000]	4000

Podany zakres strojenia hiperparametrów dla modelu RF umożliwia wygenerowanie 36480 modeli o unikalnych konfiguracjach. Optymalizacja została przeprowadzona z wykorzystaniem mechanizmu dostarczonego przez funkcję `RandomizedSearchCV`, która została wywołana z następującymi parametrami:

- `n_iter=500` – liczba badanych nastaw hiperparametrów,
- `cv=5` – liczba podziałów w walidacji krzyżowej.

W efekcie został wyznaczony zestaw wartości optymalnych dla poszczególnych hiperparametrów znajdujących się w wyznaczonej przestrzeni poszukiwań.

Podobne podejście zostało zrealizowane dla modelu MP – zakres hiperparametrów pozwala na wygenerowanie 4032 modeli o unikalnych konfiguracjach. Optymalizacja została zainicjowana z następującymi parametrami:

- `n_iter=1000` – liczba badanych nastaw hiperparametrów,
- `cv=5` - liczba podziałów w walidacji krzyżowej.

Fragment kodu odpowiedzialny za optymalizację modelu RF został przedstawiony w List. 5.2. W analogiczny sposób optymalizowany model MP.

```

"""
Optymalizacja hiperparametrów - RandomizedSearchCV - RandomForestRegressor
"""
def optymalizacja_modelu_RandomizedSearchCV_RF(X_train_in, y_train_in):

    # skopiowanie danych
    X_train = X_train_in
    y_train = y_train_in

    # wydruk parametrów, n_jobs=-1 to praca z wykorzystaniem wszystkich rdzeni
    model = RandomForestRegressor(n_jobs = -1, random_state=42)

    # wydrukowanie wszystkich parametrów modelu
    pprint(model.get_params())

    # *** Hyperparameters that will be modified ***

```

```

# The number of trees in the forest.
n_estimators = list(range(100,2000,100))

# The maximum depth of the tree.
max_depth = list(range(20,200,20))
# If None, then nodes are expanded until all leaves are pure or until all leaves contain less than min_samples_split samples.
max_depth.append(None)

# The minimum number of samples required to split an internal node:
min_samples_split = list(range(2,10,1))

# The minimum number of samples required to be at a leaf node.
# A split point at any depth will only be considered if
# it leaves at least min_samples_leaf training samples in each
# of the left and right branches.
# This may have the effect of smoothing the model, especially in regression.
min_samples_leaf = list(range(1,5,1))

# The number of features to consider when looking for the best split:
max_features = ['auto', 'sqrt', 'log2']

# Whether bootstrap samples are used when building trees. If False, the whole dataset is used to build each tree.
bootstrap = [False, True]

# Wydrukowanie liczby kombinacji mozliwych do sprawdzenia
grid_size =
len(n_estimators)*len(max_depth)*len(min_samples_leaf)*len(min_samples_split)*len(max_features)*len(bootstrap)
print('!licz wszystkich mozliwych kombinacji to: ', grid_size)

# *** Random grid - zestawienie wszystkich hyperparametrów ***
random_grid = {'n_estimators':n_estimators,
               'max_depth':max_depth,
               'min_samples_split':min_samples_split,
               'min_samples_leaf':min_samples_leaf,
               'max_features':max_features,
               'bootstrap':bootstrap
              }

# rozpoczęcie pomiaru czasu
start_time = time.time()

model_random = RandomizedSearchCV(estimator=model,
                                  param_distributions=random_grid,
                                  n_iter=500,
                                  cv=5,
                                  verbose=2,
                                  n_jobs=-1,
                                  random_state=42
                                  )
model_random.fit(X_train, y_train)

print('Najlepsze hyperparametry:\n', model_random.best_params_)
print('Best score:\n', model_random.best_score_)

# koniec pomiaru czasu
print("--- %s seconds ---" % (time.time() - start_time))

```

List. 5.2 Optymalizacja modelu RF

5.8. Wyniki dla modeli zoptymalizowanych

Wyniki modeli zoptymalizowanych dostarczonych w oparciu o najbardziej rozbudowany wariant macierzy cech X_4 porównano z ich pierwotnymi wersjami, co przedstawiono na rys. 5.10 i w Tab. 5-4, stosując jak uprzednio algorytm k-krotnej walidacji krzyżowej.

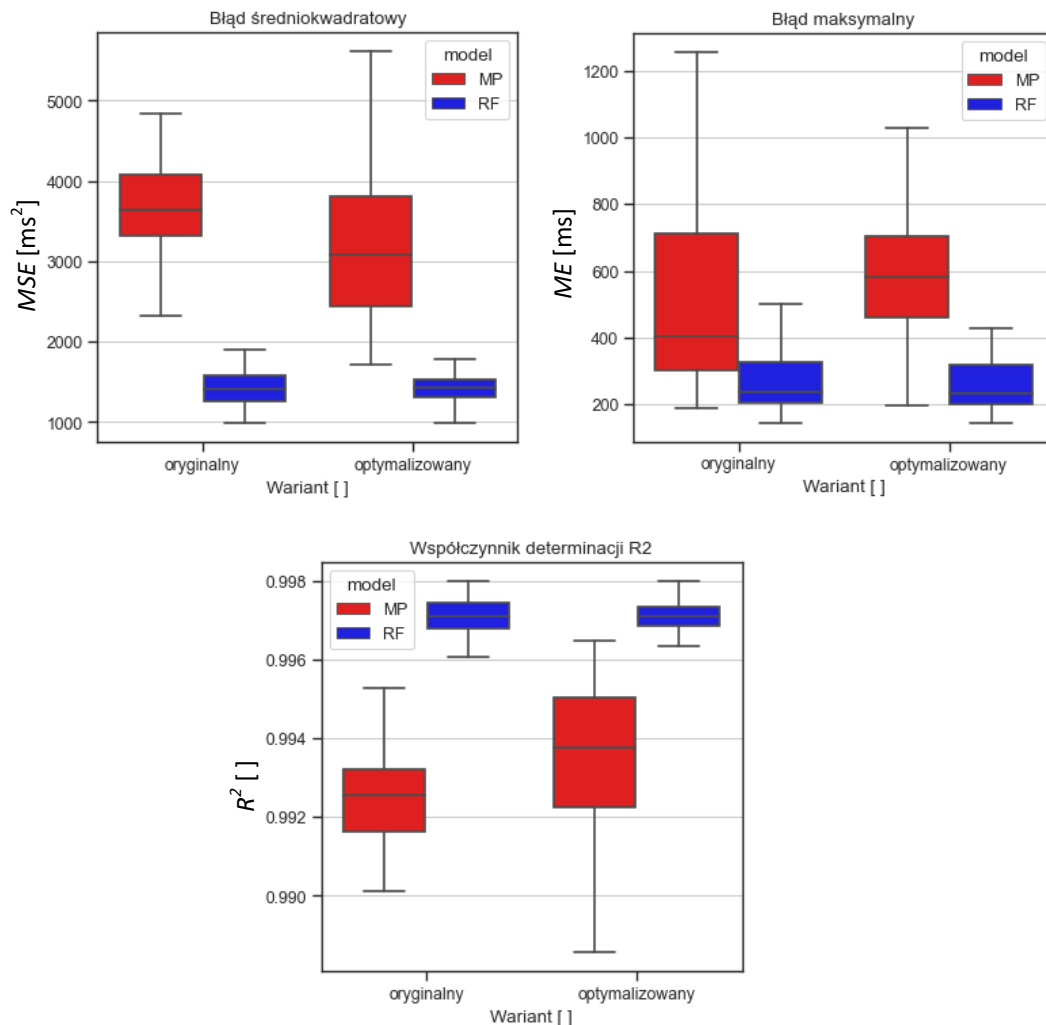
Również tym razem obliczono wartość mediany dla każdej metryki błędu, która obejmowała 50 wartości, tak aby usprawnić ocenę modeli.

Tab. 5-4 Porównanie modeli zoptymalizowanych z pierwotnymi dla macierzy cech X_4

Metryka błędu	MP	MP optymalizowany	RF	RF optymalizowany
MSE [ms^2]	3645	3082	1406	1419
ME [ms]	403	583	238	233
R^2 []	0,992548	0,993757	0,997091	0,997106

Obserwowana w przypadku MP poprawa w metryce MSE z $3645 ms^2$ na $3082 ms^2$ odbywa się kosztem pogorszenia w metryce ME z $403 ms$ do $583 ms$. Metryki RF pozostały w większości bez zmian – $MSE=1406 ms^2$ i po optymalizacji $MSE=1419 ms^2$, $ME=238 ms$ i odpowiednio $ME=233 ms$.

Mając na uwadze, że wartości w Tab. 5-4 reprezentują jedynie mediany metryk błędów, to analiza rys. 5.10 daje możliwość przeprowadzenia dalszych porównań.



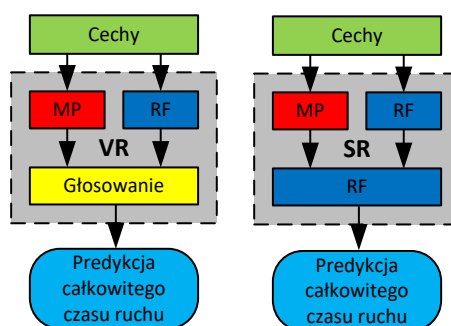
Rys. 5.10 Porównanie modeli zoptymalizowanych z pierwotnymi – błąd średniokwadratowy MSE (u góry po lewej), błąd maksymalny ME (u góry po prawej) i współczynnik determinacji R^2 (na dole)

Można zaobserwować, że po optymalizacji metryki ME (wartości maksymalne na wykresie świecowym) uległy obniżeniu zarówno dla MP jak i RF. Odbywa się to kosztem wzrostu MSE (wartości maksymalne na wykresie świecowym) dla MP. W przypadku RF wartości maksymalne zarówno MSE jak i ME ulegają zmniejszeniu (wartości maksymalne na wykresie świecowym). Dla wszystkich modeli współczynnik determinacji R^2 jest bliski jedności z nieznaczną poprawą dla modeli zoptymalizowanych – odpowiednio dla MP pierwotnego $R^2=0,992548$ i optymalizowanego $R^2=0,993757$ oraz dla RF pierwotnego $R^2=0,997091$ i optymalizowanego $R^2=0,997106$. Ze względu na fakt, że ME jest główną metryką braną pod uwagę przy ocenie modelu w przewidywanym zastosowaniu, ta poprawa (zmniejszone wartości maksymalne) jest istotna. Systemy o wysokich wymaganiach

bezpieczeństwa i niezawodnościowych, takie jak systemy przejazdów kolejowych wymagają, by w procesie projektowania został uwzględniony najgorszy znany scenariusz celem dobrania skutecznych sposobów radzenia sobie z taką potencjalną sytuacją.

5.9. Modele zespołowe

Wyniki optymalizacji modeli stały się inspiracją do stworzenia modeli zespołowych z wykorzystaniem dwóch najlepszych modeli uzyskanych w poprzednim kroku. Ocenie poddano dwie nowe architektury modeli – VotingRegressor (VR) oraz StackingRegressor (SR), które przedstawiono na rys. 5.11.



Rys. 5.11 Architektury modeli VotingRegressor (VR) oraz StackingRegressor (SR)

Modele zostały zbudowane i skonfigurowane z wykorzystaniem kodu przedstawionego w List. 5.3:

```

"""
Modele optymalizowane i złożone
"""
def modele_optymalizowane_i_zlozone():
    mlp_opt = nowy_mlp()
    rf_opt = nowy_rf()

    vr = VotingRegressor(estimators=[('rf', nowy_rf()), ('mlp', nowy_mlp())])

    sr = StackingRegressor(estimators=[('rf', nowy_rf()), ('mlp', nowy_mlp())],
                           final_estimator=RandomForestRegressor(n_estimators=10,
                                                                    random_state=42))

    ## utworzenie słownika z modelami
    modele = {'MP1':mlp_opt, 'RF1':rf_opt, 'VR0': vr, 'SR0':sr}

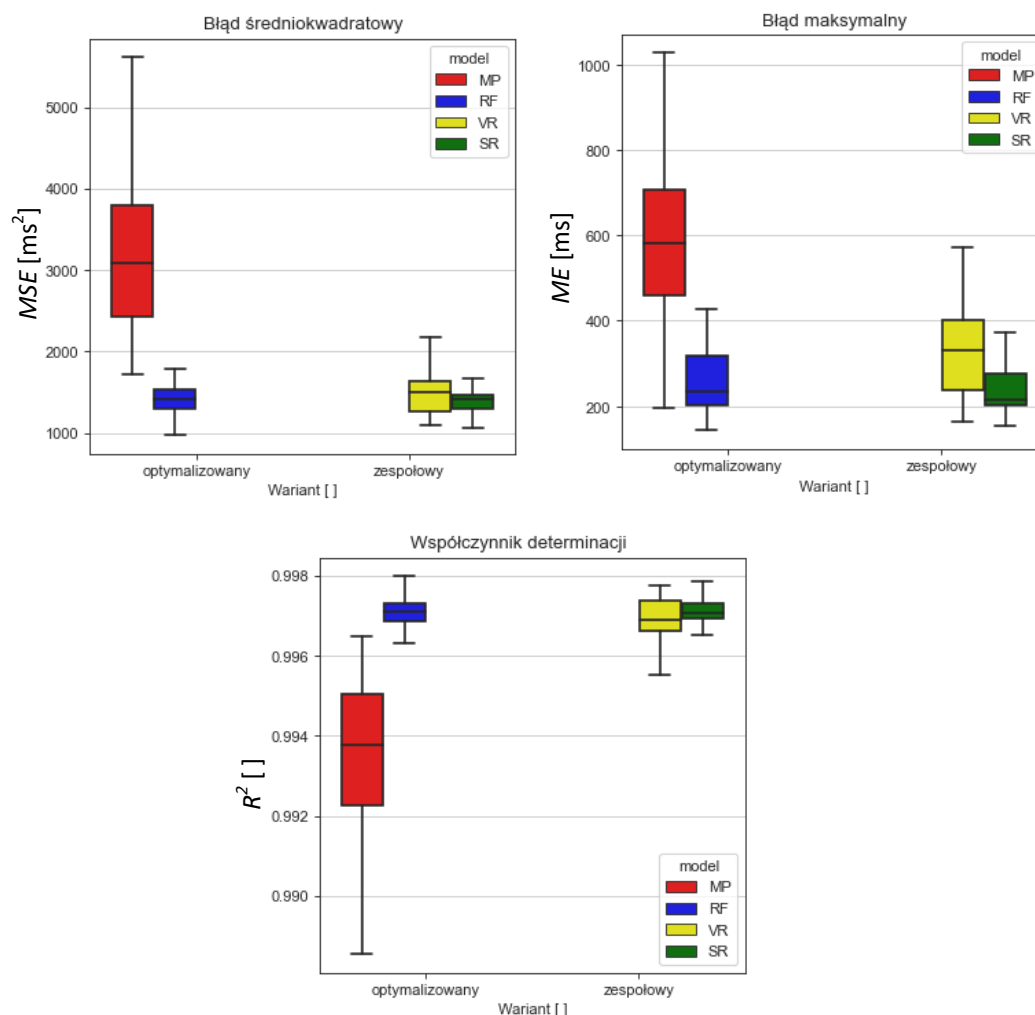
    print('>>> Modele optymalizowane i złożone gotowe')

    return modele

```

List. 5.3 Modele VR i SR.

Ponownie wykonano k-krotną walidację krzyżową dla wszystkich czterech modeli z wykorzystaniem najbardziej rozbudowanej macierzy cech X_4 . Wyniki przedstawiono na rys. 5.12 oraz w tabeli VI.



Rys. 5.12 Porównanie modeli zoptymalizowanych z modelami zespołowymi – błąd średniokwadratowy MSE (u góry po lewej),

błąd maksymalny ME (u góry po prawej) i współczynnik determinacji R^2 (na dole)

W Tab. 5-5 dla przejrzystości przedstawiono wartości median metryk błęd. Wyniki dostarczone przez VR są wyraźnie gorsze od wyników dostarczonych przez zoptymalizowany model RF - podczas gdy mediana wartości MSE pozostała prawie niezmienną – zmiana z 1419 ms^2 na 1497 ms^2 , mediana ME wzrosła z 233 ms do 332 ms .

Tab. 5-5 Porównanie modeli zoptymalizowanych z modelami zespołowymi

Metryka błęd	MP optymalizowany	RF optymalizowany	VR	SR
$MSE \text{ [ms}^2\text{]}$	3082	1419	1497	1414
$ME \text{ [ms]}$	583	233	332	215
$R^2 \text{ []}$	0,993757	0,997106	0,996911	0,997087

Wyniki dostarczone przez SR są ważnym krokiem naprzód – mediana MSE dla SR jest najmniejsza i wynosi 1414 ms^2 (dla wartości mediany i najniższa wartość maksymalna na rys. 5.12 – górny wykres) i najniższy ME (215 ms dla wartości mediany i najniższa wartość maksymalna na rys. 5.12 – dolny wykres). Współczynnik determinacji dla VR i SR – odpowiednio $R^2=0,996911$ i $R^2=0,997087$ – nieznacznie się różni, a dla RF optymalizowanego osiąga wartość $R^2=0,997106$.

5.10. Ocena skuteczności modeli z wykorzystaniem danych testowych

Następnie przeprowadzono walidację przedstawionej metody BMMT z wykorzystaniem wyizolowanego zbioru danych testowych, który stanowi 30% oryginalnego zbioru i tym razem nie zastosowano k-krotnej walidacji krzyżowej, gdyż testy dotyczyły już wytrenowanych modeli. W konsekwencji metryki błędów nie były już reprezentowane przez wartości ich median – sprawność modelu była każdorazowo określana za pomocą pojedynczego testu. Wyniki zostały przedstawione w Tab. 5-6:

Tab. 5-6 Porównanie modeli zoptymalizowanych z modelami zespołowymi z wykorzystaniem danych testowych

Metryka błędu	MP optymalizowany	RF optymalizowany	VR	SR
MSE [ms^2]	2158	1311	1239	1350
ME [ms]	372	401	276	362
R^2 []	0,995539	0,997291	0,997438	0,997209

Model VR dostarczył najlepszych wyników predykcji z wynikiem MSE wynoszącym 1239 ms^2 i $ME=276 \text{ ms}$. Drugi w kolejności jest model SR, który jest bardzo zbliżony pod względem wyników do modelu RF – MSE dla VR to 1350 ms^2 a dla RF to 1311 ms^2 oraz ME dla VR wynoszącym 362 ms gdy dla RF jest to 401 ms . Uzyskane wartości metryki R^2 to odpowiednio dla MP $0,995539$, dla RF $0,997291$, dla VR: $0,997438$ oraz dla SR $0,997209$ są nieznacznie wyższe niż te dla danych treningowych gdzie R^2 wynosi odpowiednio dla MP $0,993757$, dla RF $0,997106$, dla VR $0,996911$ oraz dla SR $0,997087$.

5.11. Odporność modeli na uszkodzone dane

Powyższe próby wskazują na to, że modele zoptymalizowane i zespołowe zapewniają dużą dokładność predykcji czasu całkowitego ruchu drąga elektrycznego napędu rogatekowego $t_{pr,n}$. Jednak ta wiedza nie jest wystarczająca przy założeniu praktycznego wdrożenia zaproponowanych algorytmów. Należy wziąć również pod uwagę szereg czynników występujących w rzeczywistym systemie, a mających bezpośredni wpływ na skuteczność jego działania, takich jak między innymi czasowy brak danych wejściowych lub postępująca ich degradacja np. czujniki są bliskie awarii lub czujniki nie przesyłają żadnych danych w wyniku uszkodzenia okablowania. Ważne jest uzyskanie informacji jaki wpływ te uszkodzenia mają na jakość dostarczanych przez modele predykcji. Dla osiągnięcia tego celu konieczne jest zrealizowanie badań z uwzględnieniem następujących założeń:

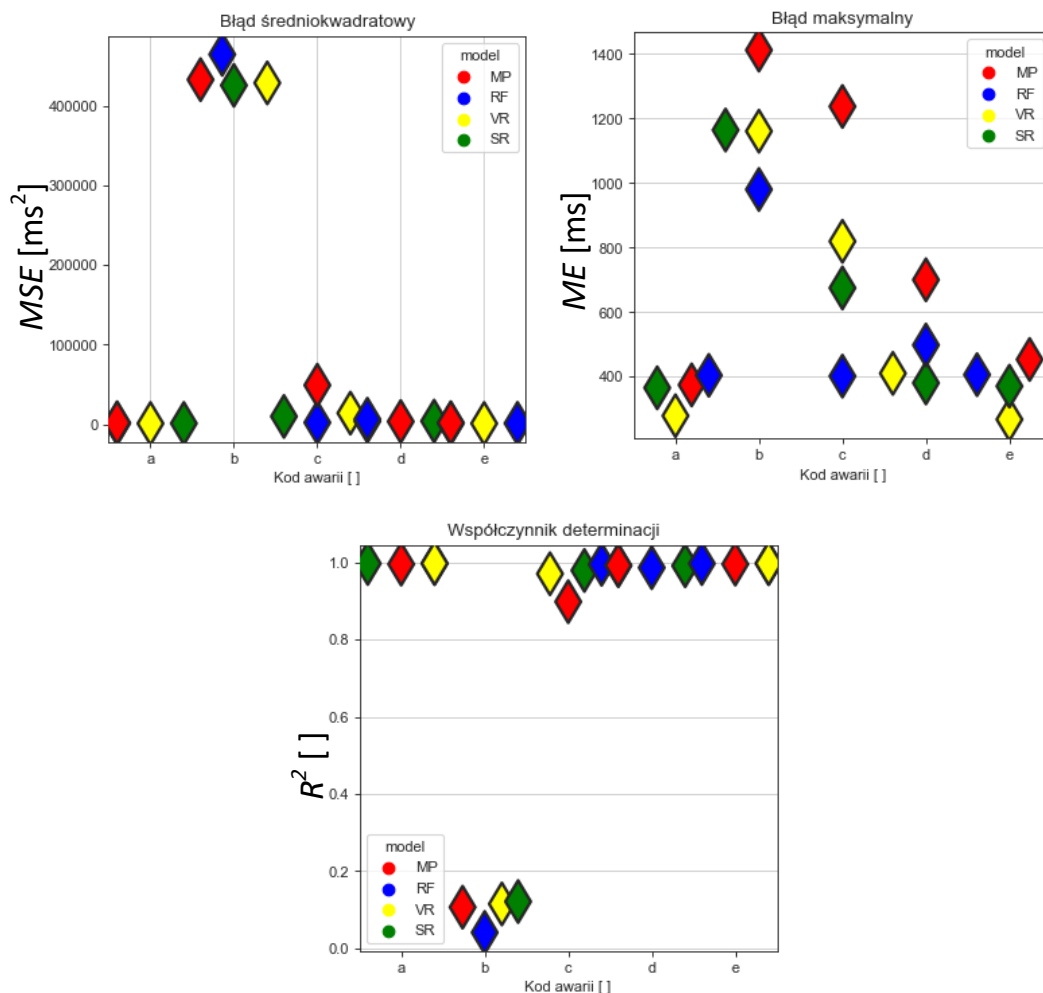
- jednocześnie może wystąpić tylko pojedyncza awaria czujnika ponieważ system przejazdu kolejowego podlega regularnym przeglądom konserwacyjnym, można więc założyć, że – uszkodzony jest tylko jeden czujnik. Oznacza to, że liczba możliwych awarii jest równa liczbie zainstalowanych czujników, tj. w prezentowanym systemie są cztery awarie, ponieważ do zbierania danych wykorzystywane są cztery czujniki:
 - znacznik czasu $F0_n..F5_n$ – kod awarii "b",
 - czujnik prądu $F6_n..F11_n$ – kod awarii "c",
 - czujnik temperatury i wilgotności $F12_n..F13_n$ – kod awarii "d",
 - czujnik prędkości i kierunku wiatru $F14_n..F15_n$ – kod awarii "e",
- brak awarii sygnalizowany jest za pomocą kodu „a”

Przyjęto model awarii czujnika (4.12) polegający na tym, że poszczególne usterki będą reprezentowane przez zresetowanie powiązanych wartości wejściowych do ich wartości domyślnych – wartości średnich obliczonych podczas fazy treningu modelu. Innymi słowy, wektor startowy cech jest zaprezentowany wartościami (4.12), a odczytywane bieżące wartości uaktualniają poszczególne elementy tego wektora:

$$\begin{aligned} F0_n..F5_n &= [0,000; 318,2; 435,8; 546,1; 645,7; 737,8] \text{ [ms]}, \\ F6_n..F11_n &= [0,412; 0,413; 0,413; 0,419; 0,491; 0,873] \text{ [A]}, \\ F12_n..F13_n &= [10,318; 5,667] \text{ [}^\circ\text{C]}, \\ F14_n..F15_n &= [4,4; 1,8] \text{ []}. \end{aligned} \tag{4.12}$$

Założenie to jest zgodne z występującym już podejściem dla procesów o zmiennym czasie trwania w systemie sygnalizacji przejazdowej.

Wyniki badań przedstawiono na rys. 15. oraz w tabelach IX-XII.



Rys. 5.13 Odporność modeli na uszkodzone dane – błąd średniokwadratowy MSE (u góry po lewej), błąd maksymalny ME (u góry po prawej) i współczynnik determinacji R^2 (na dole)

Jak widać na rys. 5.13 i w Tab. 5-7 awaria "b" danych znacznika czasu ma najbardziej niszczący wpływ – dla wszystkich modeli wartość błędu MSE przekracza 400000 ms^2 . Zauważalna jest również obniżenie wartości współczynnika determinacji R^2 do wartości bliskich zeru odpowiednio dla MP 0,105985, dla RF:0,040475, dla VR:0,114419 oraz dla SR 0,120666, co prowadzi do wniosku, że predykcja dla awarii „b” jest niemożliwa, ale z drugiej strony powinna być łatwa do wykrycia, a reakcja serwisu powinna być natychmiastowa.

Awaria czujnika prądu – usterka „c” – powoduje również znaczące pogorszenie jakości predykcji - szczególnie widać to w przypadku MP, gdzie ME znacząco wzrasta do 1236 ms.

Obniża się również wartość metryki R^2 odpowiednio dla MP do 0,898182, dla RF do 0,995011, dla VR do 0,970585 oraz dla SR do 0,979159.

W przypadkach wystąpienia awarii „b” i „c” największą odporność wykazuje zoptymalizowany model RF – uzyskuje odpowiednio najniższe metryki ME odpowiednio 979 ms i 399 ms.

Tab. 5-7 Metryki błędów – kod awarii „b” (znacznik czasu)

Metryka błędu	MP optymalizowany	RF optymalizowany	VR	SR
$MSE [ms^2]$	432449	464137	428369	425347
$ME [ms]$	1411	979	1160	1163
$R^2 []$	0,105985	0,040475	0,114419	0,120666

Tab. 5-8 Metryki błędów – kod awarii „c” (czujnik prądu)

Metryka błędu	MP optymalizowany	RF optymalizowany	VR	SR
$MSE [ms^2]$	49251	2413	14229	10081
$ME [ms]$	1236	399	818	673
$R^2 []$	0,898182	0,995011	0,970585	0,979159

Tab. 5-9 Metryki błędów – kod awarii „d” (czujnik temperatury i temperatury punktu rosy)

Metryka błędu	MP optymalizowany	RF optymalizowany	VR	SR
$MSE [ms^2]$	3687	6572	4002	4212
$ME [ms]$	698	495	407	378
$R^2 []$	0,992377	0,986413	0,991726	0,991293

Tab. 5-10 Metryki błędów – kod awarii „e” (czujnik prędkości i kierunku wiatru)

Metryka błędu	MP optymalizowany	RF optymalizowany	VR	SR
$MSE [ms^2]$	2166	1414	1269	1389
$ME [ms]$	451	403	264	368
$R^2 []$	0,995522	0,997076	0,997378	0,997129

Wpływ awarii „d” czujnika temperatury i temperatury punktu rosy jest mniejszy i prowadzi do predykcji obciążonych zwiększonym błędem ME . Odpowiednio dla MP jest to 698 ms, dla RF 495 ms, dla VR 407 ms oraz dla SR 378 ms. Biorąc pod uwagę postawione wymaganie dla metody mówiące, że błąd predykcji powinien być mniejszy niż 0,5 s można stwierdzić, że w warunkach zaistnienia awarii „d” akceptowalne są rezultaty dostarczane przez VR i SR oraz progowo RF. Zdecydowanie najlepsze działanie prezentuje SR, biorąc pod uwagę metrykę $ME=378$ ms. Wpływ awarii „d” czujnika prędkości i kierunku wiatru jest niewielki. Jedynie w przypadku modelu MP metryka ME znacząco wzrosła z 372 ms do 451 ms). W dwóch ostatnich scenariuszach awarii współczynnik determinacji R^2 pozostaje bliski jedności – dla wszystkich modeli jest wyższy niż 0,980000.

5.12. Podsumowanie

Znajomość całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego będącego wynikiem działania metody BMMT otwiera drogę zarówno do zwiększenia dostępności systemu kolejowego, jak i poziomu bezpieczeństwa na obszarze przejazdu kolejowo-drogowego.

W trakcie opracowywania metody BMMT były analizowane predykcje dostarczane przez poszczególne modele – w szczególności obserwując błąd maksymalny ME jako metrykę o największej wadze. W efekcie należy wskazać na model StackingRegressor (SR), jako ten który jest w stanie zapewnić nieco bardziej dokładne predykcje, niż drugi w kolejności model Random Forest Regressor (RF).

Wpływ zmieniających się parametrów środowiskowych jest w większości przypadków elementem wariacji obserwowanych próbek czasu enkodera i prądu zasilania. Jest to widoczne podczas oceny działania modelu z uszkodzonymi danymi testowymi. Modele zapewniają precyzyjne predykcje nawet wtedy, gdy dwa ostatnie zestawy cech z powodu uszkodzenia powiązanych czujników są zastępowane ich wartościami domyślnymi. Co nie zmienia faktu, że gdy dane te są dostępne, to przyczyniają się do poprawy jakości dostarczanych predykcji.

Obserwowany maksymalny błąd predykcji opartej na danych zebranych w czasie krótszym niż 1 s od rozpoczęcia danej fazy ruchu jest niższy niż 0,5 s – zostało to zweryfikowane przy użyciu wyizolowanych danych testowych. Metoda BMMT zbudowana z wykorzystaniem najlepszego modelu – StackingRegressor (SR) – zapewnia przewidywania z dokładnością lepszą nawet niż 0,4 s. Tak więc uzyskiwane predykcje spełniają wymagania postawione w rozdziale 5.1, tj. predykcja całkowitego czasu ruchu drąga jest wyznaczona w oparciu o dane zebrane w czasie nie dłuższym niż 1 s od jego rozpoczęcia oraz jest wyznaczona z maksymalnym błędem bezwzględnym mniejszym niż 0,5 s.

Jakość predykcji czasu ruchu drąga elektrycznego napędu rogatekowego jest zadawalająca i może stanowić podstawę do dalszej optymalizacji algorytmów sterowania przejazdem kolejowym oraz rozszerzenia funkcji diagnostycznych. Na podstawie otrzymanych wyników można stwierdzić, że z wykorzystaniem algorytmu uczenia maszynowego możliwe jest wyznaczenie predykcji całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego w oparciu o przebieg prądu zasilającego oraz informację o położeniu kątowym drąga.

6. Metoda detekcji zdarzeń podczas pracy elektrycznego napędu rogatekowego wykrywanych jako usterki BMFD

W rozdziale tym przedstawiona zostanie propozycja dla metody detekcji wybranych zdarzeń pojawiających się w trakcie pracy napędu rogatekowego BMFD (Barrier Machine Failure Detection). W pierwszej części opisane zostaną modele zaproponowanych zdarzeń wykorzystywane w procesie opracowywania metody BMFD, a w drugiej części właściwa metoda BMFD oparta na metodach uczenia maszynowego.

6.1. Założenia metody

Mając na uwadze minimalizację zmian w warstwie sprzętowej zarówno samego elektrycznego napędu wraz z drągiem, jak i interfejsu sterującego została zaproponowana metoda BMFD (Barrier Machine Failure Detection) wykorzystująca jedynie przebieg prądu zasilającego w funkcji czasu.

Celem stosowania metody jest zapewnienie funkcji wykrycia i poprawnej klasyfikacji wybranych zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego, takich jak uderzenie w przeszkodę stałą (*FSO*), sprężystą (*FFO*) czy też uszkodzenie mechanizmu napędowego (*FGF*). Metoda powinna spełniać następujące wymagania – bezbłędne wykrycie wszystkich przebiegów bezusterkowych oraz wartość współczynnika F_1 powinna być większa od 0,8.

6.2. Modele wybranych zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego

Podstawą dla wprowadzenia funkcji diagnostycznych nowego typu jest odpowiednio rozbudowana baza danych zawierająca sklasyfikowane przebiegi przedstawiające różnorodne scenariusze zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego, które są wykrywane jako usterki przez system diagnostyczny systemu sygnalizacji przejazdowej. Zakładając dostępność przebiegu czasowego prądu zasilającego elektrycznego napędu rogatekowego postanowiono wprowadzić kilka wybranych, ale typowych zdarzeń, które podlegać będą klasyfikacji za pomocą odpowiedniej metody uczenia maszynowego.

Konieczność przygotowania danych treningowych o tak dużym zakresie poprzez rzeczywistą ich akwizycję stanowi dużą trudność, a proces taki byłby czasochłonny i wymagał opracowania dużej liczby wariantów każdego ze zdarzeń oraz konieczność oczekiwania na dogodne warunki środowiskowe. Rozwiązaniem jest opracowanie modeli typowych zdarzeń umożliwiających odwzorowanie w przebieg prądu zasilającego.

Zakłada się, że oznaczone jako bezusterkowe przebiegi prądu ze zbioru C (2.3) zawierające zarówno ruchy w górę, jak i w dół stanowią punkt wyjściowy do wprowadzenia odpowiedniego zdarzenia. Zakłada się również, że moment zaistnienia zdarzenia jest losowy i może wystąpić w dowolnym momencie, gdy trwa aktywny ruch drąga czyli $dir_{i,j}="up"$ lub $dir_{i,j}="down"$ zgodnie z (2.3).

Na podstawie dotychczasowego doświadczenia z eksploatacją elektrycznego napędu rogatekowego wyposażonego w drąg został określony zestaw zdarzeń najczęściej wykrywanych jako usterki:

- uderzenie drąga w przeszkodę stałą (FSO_{up} i FSO_{down}),
- uderzenie drąga w przeszkodę sprężystą (FFO_{up} i FFO_{down}),
- uszkodzenie mechanizmu napędowego (FGF_{up} i FGF_{down}).

Podstawą do opracowania modeli dla wszystkich trzech zdarzeń jest niezniekształcony przebieg prądu zasilającego silnik elektrycznego napędu. Modele te zostały zdefiniowane w dziedzinie czasu. Zakresy parametrów dla wszystkich rodzajów modeli zdarzeń zostały wyznaczone niezależnie w zależności od kierunku ruchu drąga.

Wprowadzenie poszczególnych zdarzeń (ewentualnie zaburzeń) bazuje na przebiegach prądu zasilającego dla niezakłóconych ruchów drąga, które zostały wyodrębnione z części zbioru danych C (2.3) w następujący sposób:

$$xc'_i = [i_{i,1} \dots i_{i,K}],$$

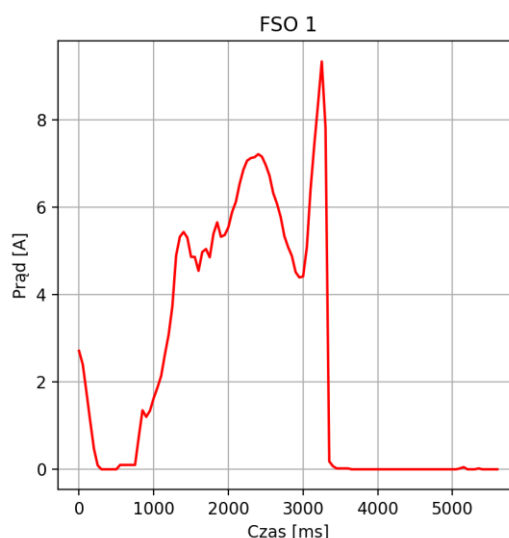
gdzie: $yc_i = 0$ lub $yc_i = 4$ a $K = 200$ (5.1)

oraz $i \in \langle 1, N_{train} \rangle$, $N_{train} = 1000$

gdzie $xc'_{up,i}$ oznacza wektor wartości prądu dla ruchu drąga w górę, a $xc'_{down,i}$ wektor wartości prądu dla ruchu drąga w dół.

6.2.1. Uderzenie w przeszkodę stałą (FSO)

Model zdarzenia występujący w sytuacji, kiedy drąg uderza w przeszkodę stałą, np. podczas ruchu w dół następuje uderzenia w dach pojazdu lub podczas ruchu w górę drąg uderza w wystającą część pojazdu, np. wysięgnik, co uniemożliwia dalszy ruch w odpowiednią stronę. Ten typ zdarzenia został oznaczony jako uderzenie w przeszkodę stałą – FSO (ang. Failure Solid Obstacle). Prąd zasilający silnik napędu rogatkowego rośnie w ślad za rosnącym odkształceniem drąga, a następnie w zależności od struktury interfejsu sterującego, aktywowany jest bezpiecznik nadprądowy lub elektroniczny obwód zabezpieczający, co zazwyczaj wymaga interwencji personelu utrzymania i w konsekwencji opóźnienie. Przykładowy przebieg prądu dla zdarzenia FSO_{up} jest przedstawiony na rys. 6.1.



Rys. 6.1 Przykładowy przebieg prądu zasilającego dla zdarzenia FSO_{up}

Elektroniczny obwód zabezpieczający stanowić może w pełni automatyczne rozwiązanie problemu adekwatnej reakcji systemu przejazdowego na zdarzenie FSO , ponieważ po wystąpieniu prądu przeciążeniowego napęd rogatekowy choć zostaje tymczasowo zatrzymany, to po upływie określonego czasu może zostać podjęta kolejna próba kontynuowania rozpoczętego ruchu. Jednak w takim ograniczonym podejściu przyczyna zadziałania zabezpieczenia pozostaje nieznana.

Konstrukcja modelu została zdefiniowana w sposób opisany poniższym równaniem (5.2):

$$i_{FSO,t} = f_{FSO}(i_t, t_{FSO}, i_{rise}, i_{stall}),$$

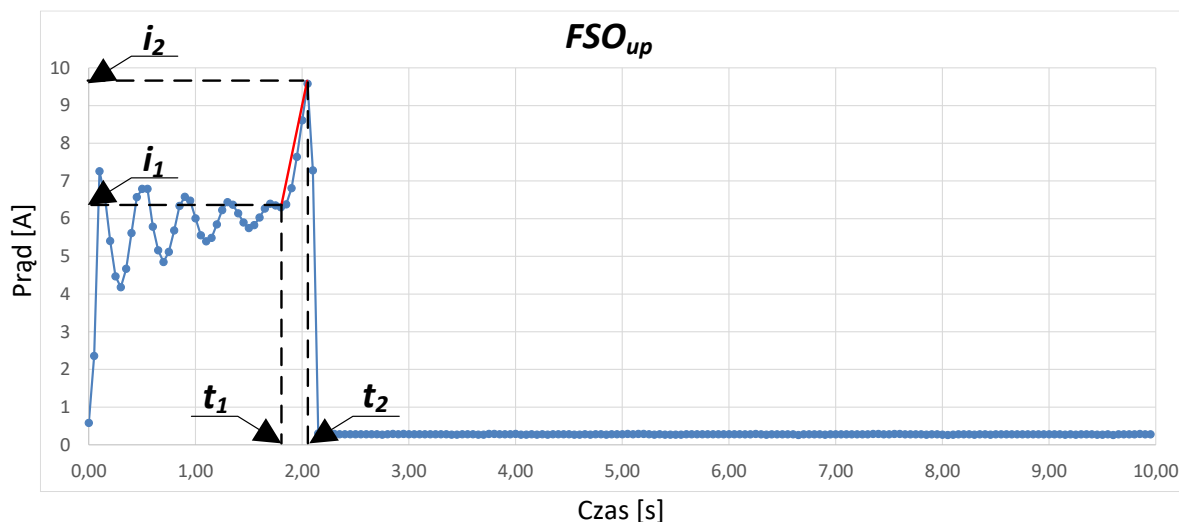
$$i_{FSO,t} = \begin{cases} i_{rand_int(1,N),t} & \text{jeżeli } t < t_{FSO} \\ \min(i_{rand_int(1,N),t} + i_{rise} * (t - t_{FSO}), i_{stall}) & \text{jeżeli } t \geq t_{FSO} \text{ i } t \leq t_{stall}, \\ 0 & \text{jeżeli } t \geq t_{stall} \end{cases} \quad (5.2)$$

gdzie:

- t to moment czasu w trakcie ruchu drąga czyli $t \in \langle 1; K \rangle$,
- $i_{FSO,t}$ to chwilowy prąd silnika dla zdarzenia FSO ,
- $rand_int(1, N)$ przechowuje tę samą wartość całkowitą dla całego wektora $x_c'_i$ i określa wybrany przebieg, który będzie podlegał modyfikacji,
- t_{FSO} czas przy którym drąg uderza w przeszkodę w trakcie aktywnego ruchu, czyli gdy $dir_{rand_int(1,N),t} = "up"$ lub $"down"$. W efekcie $t_{FSO} \in \langle 1; K' \rangle$ i $K' \leq K$,
- t_{stall} oznacza moment czasu, dla którego zadziała zabezpieczenie nadprądowe,
- i_{stall} to prąd pobierany przez unieruchomiony silnik, np. $i_{stall} = 9$ A
- i_{rise} to współczynnik szybkości narostu prądu w czasie - szczegółowo opisany w poniższym rozdziale.

6.2.2. Współczynnik i_{rise}

Współczynnik i_{rise} określa prędkość z jaką narasta prąd w przypadku wystąpienia zdarzenia FSO . Jego pomiar został zrealizowany w sposób przedstawiony na rys. 6.2 i opisany równaniem (5.3). Współczynnik ten jest wyznaczany w ten sam sposób dla obu kierunków ruchu drąga.



Rys. 6.2 Sposób pomiaru parametru i_{rise} dla przypadku zdarzenia FSO_{up}

Czas t_1 to moment zderzenia się drąga z przeszkodą. W tym momencie chwilowa wartość prądu zasilającego wynosi i_1 . W momencie t_2 prąd wzrasta do wartości $i_2 \geq i_{stall}$. W efekcie wartość i_{rise} można wyznaczyć w następujący sposób (5.3):

$$i_{rise} = \frac{i_2 - i_1}{t_2 - t_1} \quad (5.3)$$

W oparciu o wszystkie zebrane przebiegi prądu przedstawiające zdarzenia FSO_{up} lub FSO_{down} zostały wyznaczone wartości skrajne $\max(i_{rise})$ i $\min(i_{rise})$, określające zakres zmienności parametru dla przebiegów rzeczywistych. Dodatkowo zakres ten został rozszerzony z wykorzystaniem współczynnika $s = 0,1$. Przyczyną takiego postępowania jest chęć skompensowania sytuacji, w której relatywnie niewielka liczba zebranych przebiegów rzeczywistych skutkuje pozyskaniem ograniczonej wiedzy o zmienności zaburzonego przebiegu prądu. W efekcie zakres zmienności został określony w następujący sposób (5.4):

$$i_{rise} \in \langle i_{min} - s * i_{marg}; i_{max} + s * i_{marg} \rangle,$$

$$\text{gdzie: } i_{min} = \min(i_{rise}), i_{max} = \max(i_{rise}), \quad (5.4)$$

$$i_{marg} = i_{max} - i_{min}.$$

Proces został przeprowadzony niezależnie dla obu kierunków ruchu i zostały wyznaczone dwa dedykowane im zakresy (5.5):

$$i_{rise,up} \in \langle 1,09; 2,19 \rangle \left[\frac{A}{s} \right], \quad (5.5)$$

$$i_{rise,down} \in \langle 1,80; 3,68 \rangle \left[\frac{A}{s} \right].$$

Ostatecznie uwzględniając (5.2) zostały zdefiniowane dwie funkcje stanowiące modele zdarzeń FSO odpowiednio dla kierunku ruchu drąga w górę FSO_{up} (5.6):

$$t_{FSO} = rand_int \langle 1; K' \rangle,$$

$$i_{rise} = rand_real \langle i_{rise,up_min}; i_{rise,up_max} \rangle,$$

$$i_{stall} = 9[A], \quad (5.6)$$

$$FSO_{up}(i_t) = f_{FSO}(i_t, t_{FSO}, i_{stall})$$

i w dół FSO_{down} (5.7), która jest wyznaczona w analogicznym procesie jak FSO_{up} :

$$t_{FSO} = rand_int \langle 1; K' \rangle,$$

$$i_{rise} = rand_real \langle i_{rise,down_min}; i_{rise,down_max} \rangle,$$

$$i_{stall} = 9[A], \quad (5.7)$$

$$FSO_{down}(i_t) = f_{FSO}(i_t, t_{FSO}, i_{stall}).$$

6.2.3. Uderzenie w przeszkodę sprężystą (FFO)

Ten model zdarzenia jest w pewnym stopniu podobny do poprzedniego. Zasadnicza różnica polega na mechanicznej charakterystyce przeszkody. Reprezentatywnym przykładem mogą być gałęzie drzewa, element uszkodzonej infrastruktury lub celowe, chwilowe, przytrzymanie bariery przez człowieka. Dla takiej sytuacji został zaproponowany model zdarzenia polegającego na kolizji z przeszkodą sprężystą – FFO (Failure Flexible Obstacle). Przebieg prądu zasilania silnika ulega lokalnemu zniekształceniu w momencie zaistnienia zdarzenia FFO . W tym scenariuszu stan mechaniczny drąga może ulec szybkiej degradacji. Proponowany model usterki takiego rodzaju opisuje poniższe równanie (5.8):

$$i_{FFO,t} = f_{FFO}(i_t, t_{FFO}, F),$$

$$i_{FFO,t} = \begin{cases} i_{rand_int(1,N),t} & \text{if } t \leq t_{FFO} \text{ lub } t > k_{FFO} + len(F) \\ i_{rand_int(1,N),t} * F(t - t_{FFO}) & \text{jeżeli } t_{FFO} < t \leq t_{FFO} + len(F) \end{cases} \quad (5.8)$$

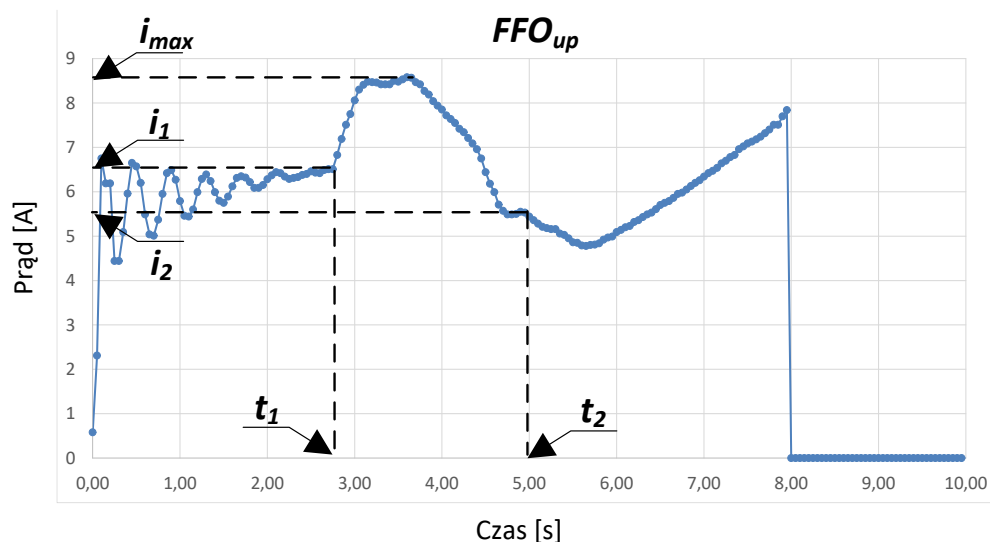
gdzie:

- t to moment czasu w trakcie ruchu drąga czyli $t \in \langle 1; K \rangle$,
- $i_{FFO,t}$ jest chwilowym prądem silnika dla zdarzenia FFO ,
- $rand_int(1, N)$ przechowuje tę samą wartość całkowitą dla całego wektora xc'_i i określa wybrany przebieg, który będzie podlegał modyfikacji,

- t_{FFO} oznacza moment czasu, przy którym drąg uderza w przeszkodę w trakcie aktywnego ruchu, czyli gdy $dir_{rand_int(1,N),t} = "up"$ lub $"down"$. W efekcie $t_{FSO} \in < K' > i K' \leq K$,
- $C_{FFO} = [f_1 \dots f_M]$ jest wektorem przechowującym wzór kształtu prądu dla zdarzenia FFO . Wektor C_{FFO} został szczegółowo omówiony w poniższym rozdziale.

6.2.4. Wektor C_{FFO}

Wektor C_{FFO} określa kształt zaburzenia prądu zasilającego napęd rogatek w przypadku wystąpienia zdarzenia FFO . Pomiar współczynników wektora C_{FFO} został zrealizowany w sposób przedstawiony na rys. 6.3 i jest opisany równaniami (5.13). Wektor ten jest wyznaczany w ten sam sposób dla obu kierunków ruchu drąga.



Rys. 6.3 Sposób pomiaru parametrów wektora C_{FFO} dla przypadku zdarzenia FFO_{up}

Czas t_1 to moment zderzenia się drąga z przeszkodą, czas t_2 to moment zakończenia zderzenia. W momencie rozpoczęcia zderzenia chwilowa wartość prądu zasilającego wynosi i_1 , w jego trakcie osiąga wartość maksymalną i_{max} , a w momencie zakończenia zderzenia ma wartość i_2 (5.9):

$$M = t_2 - t_1,$$

$$A = \frac{2 \cdot i_{max}}{i_2 + i_1}. \quad (5.9)$$

Następnie konstruowany jest wektor C_{FFO} w następujący sposób (5.10):

$$C_{FFO} = [f_1 \dots f_M] = f_{C_{FFO}}(M, A), \quad (5.10)$$

gdzie poszczególne elementy mają następujące wartości (5.11):

$$\begin{aligned}
f_1 &= f_M = 1, \\
A_{step} &= \frac{2*(A-1)}{M-1}, \\
f_i &= f_{(M+1)-i} = (1 + (i-1) * A_{step}), \\
&\text{gdzie } i \in \langle 1; \text{round}\left(\frac{M+1}{2}\right) - 1 \rangle, \\
f_{\text{round}\left(\frac{M+1}{2}\right)} &= A.
\end{aligned} \tag{5.11}$$

W oparciu o wszystkie zebrane przebiegi prądu przedstawiające zdarzenie *FFO* zostały wyznaczone wartości skrajne określające zakres zmienności parametrów dla przebiegów rzeczywistych w sposób analogiczny, jak zostało to opisane dla parametru i_{rise} , a następnie zakresy te zostały tą samą metodą rozszerzone (5.4). W rezultacie uzyskano następujący wynik przedstawiający zakresy parametrów osobno dla obu kierunków ruchu drąga (5.12):

$$\begin{aligned}
A_{up} &\in \langle 1,10; 1,13 \rangle [], \\
M_{up} &\in \langle 3; 41 \rangle [], \\
A_{down} &\in \langle 1,13; 1,37 \rangle [], \\
M_{down} &\in \langle 11; 48 \rangle [].
\end{aligned} \tag{5.12}$$

Ostatecznie uwzględniając (5.8) zostały zdefiniowane dwie funkcje stanowiące modele zdarzeń *FFO* odpowiednio dla kierunku ruchu drąga w górę FFO_{up} (5.13):

$$\begin{aligned}
t_{FFO} &= \text{rand_int} \langle 1; K' \rangle, \\
A &= \text{rand_real} \langle A_{up_min}; A_{up_max} \rangle, \\
M &= \text{rand_int} \langle M_{up_min}; M_{up_max} \rangle, \\
C_{FFO} &= f_{C_{FFO}}(M, A), \\
FFO_{up}(i_t) &= f_{FFO}(i_t, t_{FFO}, F)
\end{aligned} \tag{5.13}$$

i w dół FFO_{down} (5.14):

$$\begin{aligned}
t_{FFO} &= \text{rand_int} \langle 1; K' \rangle, \\
A &= \text{rand_real} \langle A_{down_min}; A_{down_max} \rangle, \\
M &= \text{rand_int} \langle M_{down_min}; M_{down_max} \rangle, \\
C_{FFO} &= f_{C_{FFO}}(M, A), \\
FFO_{down}(i_t) &= f_{FFO}(i_t, t_{FFO}, F).
\end{aligned} \tag{5.14}$$

6.2.5. Uszkodzenie mechanizmu napędowego (*FGF*)

W tym przypadku model zdarzenia odzwierciedla sytuację, w której zwiększone tarcie występujące w napędzie rogatkowym zaburza prąd pobierany z zasilania. Uszkodzenie to może być efektem nieszczelności obudowy lub zaniedbaniem personelu utrzymania skutkującym wygiętymi lub nieprawidłowo zamontowanymi osłonami. W rezultacie straty wynikające ze zwiększonego tarcia występującego w przekładni mechanicznej napędu wzrastają w miarę gromadzenia się zanieczyszczeń. W efekcie wzrasta natężenie prądu zasilania silnika. Sytuacja ta pozostaje niewykrywalna dla konwencjonalnej diagnostyki tak długo, jak poszczególne czasy pracy napędu rogatkowego nie przekraczają dopuszczalnych wartości maksymalnych. Model zdarzenia dla uszkodzenia mechanizmu napędowego *FGF* (Failure Gear Fault) jest zdefiniowany jako (5.15):

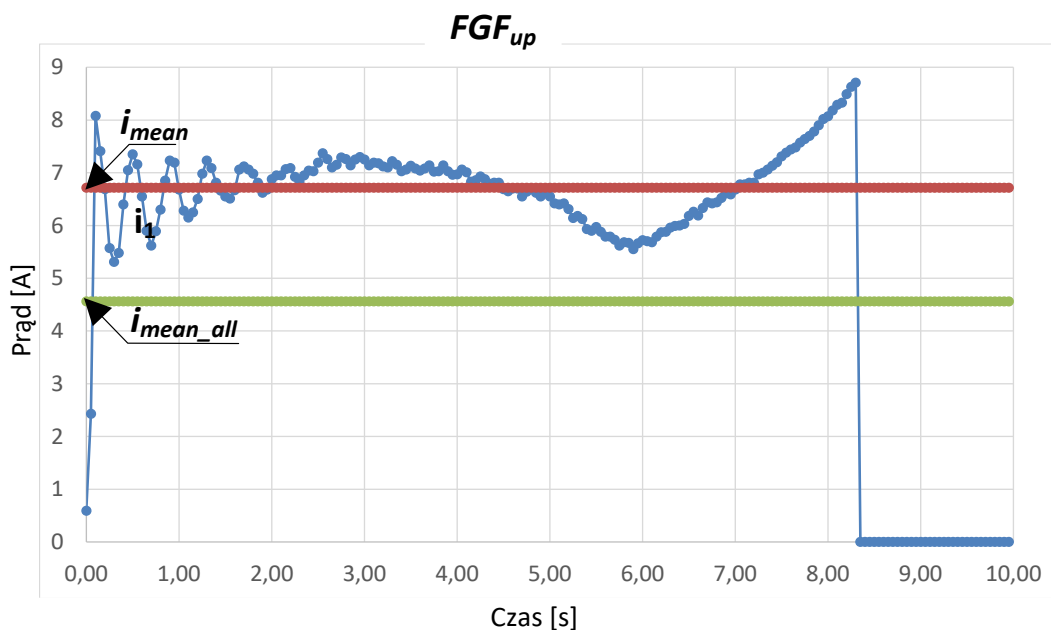
$$\begin{aligned} i_{FGF,t} &= f_{FGF}(i_t, m_{FGF}), \\ i_{FGF,t} &= m_{FGF} * i_{rand_int(1,N),t}, \end{aligned} \tag{5.15}$$

gdzie:

- t to moment czasu w trakcie ruchu drąga czyli $t \in \langle 1; K \rangle$,
- $i_{FGF,t}$ jest chwilowym prądem silnika o zniekształconym przebiegu,
- $rand_int(1, N)$ przechowuje tę samą wartość całkowitą dla całego wektora xc'_i i określa wybrany przebieg, który będzie podlegał modyfikacji,
- m_{FGF} jest współczynnikiem określającym poziom degradacji zmieniającym się w zależności od poziomu zanieczyszczenia. Współczynnik m_{FGF} został szczegółowo omówiony w poniższym rozdziale.

6.2.6. Współczynnik m_{FGF}

Współczynnik m_{FGF} określa w jakim stopniu wzrasta pobór prądu w przypadku wystąpienia zdarzenia FGF . Jego pomiar został zrealizowany w sposób przedstawiony na rys. 6.4 i opisany równaniem (5.16). Współczynnik ten jest wyznaczany w ten sam sposób dla obu kierunków ruchu drąga.



Rys. 6.4 Sposób pomiaru parametru m_{FGF} dla przypadku zdarzenia FGF_{up}

Prąd i_{mean} to średnia wartość prądu dla danego przebiegu, prąd i_{mean_all} to średnia wartość prądu dla wszystkich przebiegów.

$$m_{FGF} = \frac{i_{mean}}{i_{mean_all}}. \quad (5.16)$$

6.3. Opis metody

Autor proponuje metodę opartą na uczeniu maszynowym, która na wejściu ma wektor cech FC_n zawierający informację o chwilowych wartościach prądu zasilającego elektryczny napęd rogatekowy, zebranych w maksymalnym dopuszczalnym czasie pracy dla pojedynczej fazy ruchu, a na wyjściu informację o klasie C_n dla danego stanu elektrycznego napędu rogatekowego. Pełna lista etykiet dla poszczególnych klas C_n została przedstawiona w opisie zbioru danych C w rozdziale 3.5.2. Schemat działania metody został przedstawiony na rys. 6.5.



Rys. 6.5 Schemat działania metody BMFD

Informację wejściową w metodzie stanowi wektor FC_n zawierający $K=200$ próbek stanowiący zapis jednego cyklu ruchu drąga elektrycznego napędu rogatekowego w postaci kolejnych chwilowych wartości prądu zasilającego (5.17):

$$FC_n = [i_1, i_2, \dots, i_K]. \quad (5.17)$$

Zawartość wektora FC_n jest analizowana przez model klasyfikacyjny MKK zwracający klasyfikację danego ruchu C_n (5.18):

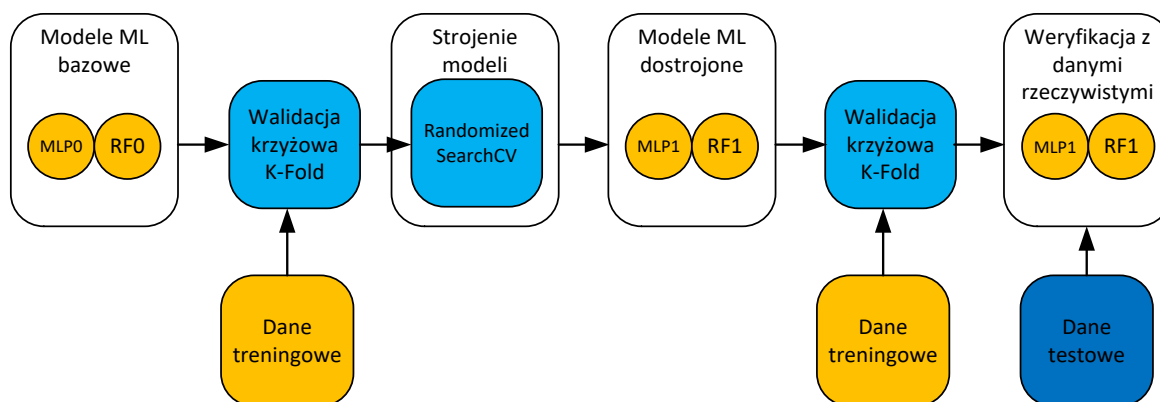
$$C_n = MKK(FC_n), \quad (5.18)$$

gdzie $C_n \in \{0; 1; \dots; 7\}$.

Klasy C_n przyporządkowane dla poszczególnych wartości od 0 do 7 oznaczają odpowiednio: ruch w górę, zdarzenie FSO_{up} , zdarzenie FFO_{up} , zdarzenie FGF_{up} , ruch w dół, zdarzenie FSO_{down} , zdarzenie FFO_{down} , zdarzenie FGF_{down} .

6.4. Sposób opracowania metody

Sposób opracowania metody BMFD został przedstawiony na rys. 6.6.

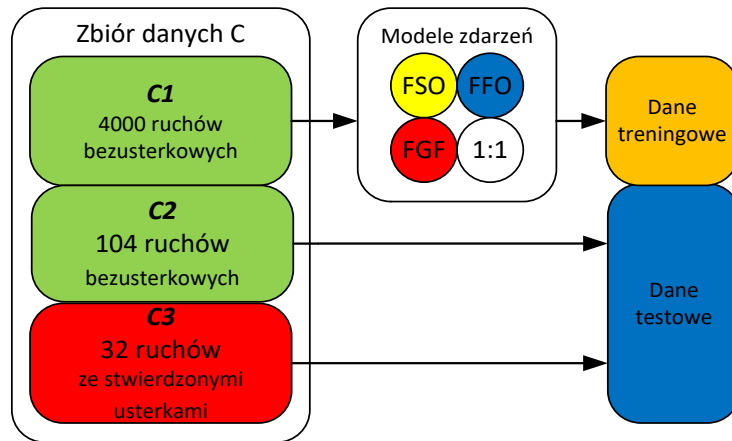


Rys. 6.6 Sposób opracowania metody BMFD

Wybrane modele bazowe MLP Classifier (MLP0) oraz Random Forrest Classifier (RF0) są analizowane pod kątem poprawności dostarczanych klasyfikacji z wykorzystaniem k-krotnej walidacji krzyżowej. Następnie podlegają strojeniu z wykorzystaniem mechanizmu RandomizedSearchCV. W kolejnym kroku postęp uzyskany w procesie dostrajania jest oceniany ponownie z wykorzystaniem k-krotnej walidacji krzyżowej. Ostatecznie dostrójone modele MLP1 i RF1 są zastosowane do sklasyfikowania przebiegów prądu ze zbioru danych testowych.

6.5. Wytworzenie zestawu danych treningowych i testowych

Zestaw danych treningowych został opracowany bazując na zbiorze danych C (2.3) opisanym w rozdziale 3.5.2 i z wykorzystaniem modeli zdarzeń rozpoznawanych jako usterki opisanych w rozdziale 0 w sposób przedstawiony na rys. 6.7.



Rys. 6.7 Sposób przygotowania zestawu danych treningowych

W pierwszym kroku wybrano pierwsze $N_{train} = 4000$ rekordów przedstawiających (5.19) przebiegi prądu zasilającego bezusterkowo działającego elektrycznego napędu rogatekowego X_{C1} z oznaczonym kierunkiem ruchu y_{C1} (5.20):

$$X_{C1} = \begin{bmatrix} t_{1,1}, i_{1,1} & \cdots & t_{1,200}, i_{1,200} \\ \vdots & \ddots & \vdots \\ t_{N_{train},1}, i_{N_{train},1} & \cdots & t_{N_{train},200}, i_{N_{train},200} \end{bmatrix}, \quad (5.19)$$

$$y_{C1} = \begin{bmatrix} y_1 \\ \vdots \\ y_{N_{train}} \end{bmatrix}. \quad (5.20)$$

Następnie w sposób losowy (5.21) z wykorzystaniem sześciu modeli zdarzeń (5.22) wszystkie przebiegi zostają przekształcone na docelowy zbiór treningowy – macierz cech X_{train} i wektor etykiet y_{train} (5.23). Każdy przebieg zostaje odpowiednio oznaczony w sposób umożliwiający identyfikację czy przedstawia symulację danego typu zdarzenia czy też pozostał niezmodyfikowany.

$$f_{sym}(y_i) = \begin{cases} y_i = 0: rand_{int}(0; 3) - \text{dla ruchu w górę} \\ y_i = 4: rand_{int}(4; 7) - \text{dla ruchu w dół} \end{cases}, \quad (5.21)$$

$f_{sym}(y_i)$ zwraca tę samą wartość całkowitą dla danego y_i ,

$$FMOD(x, y_i) = \begin{cases} x & \text{jeżeli } fsym(y_i) = 0 \text{ lub } fsym(y_i) = 4 \\ FSO_{up}(x) & \text{jeżeli } fsym(y_i) = 1 \\ FFO_{up}(x) & \text{jeżeli } fsym(y_i) = 2 \\ FGF_{up}(x) & \text{jeżeli } fsym(y_i) = 3 \\ FSO_{down}(x) & \text{jeżeli } fsym(y_i) = 5 \\ FFO_{down}(x) & \text{jeżeli } fsym(y_i) = 6 \\ FGF_{down}(x) & \text{jeżeli } fsym(y_i) = 7 \end{cases}, \quad (5.22)$$

$$X_{train,i} = FMOD(X_{C1,i}, y_i), \quad (5.23)$$

$$y_{train,i} = fsym(y_i).$$

W kolejnym kroku został zbudowany zbiór danych testowych w oparciu o kolejnych $N_{test1}=104$ rekordów przedstawiających przebiegi bezusterkowe X_{C2} (5.24) oraz $N_{test2}=32$ rekordów przebiegów usterkowych X_{C3} . W każdym przypadków w analogiczny sposób zostały uwzględnione wektory etykiet y_{C2} i y_{C3} (5.25):

$$X_{C2} = \begin{bmatrix} t_{N_{train}+1,1}, i_{N_{train}+1,1} & \cdots & t_{N_{train}+1,200}, i_{N_{train}+1,200} \\ \vdots & \ddots & \vdots \\ t_{N_{train}+N_{test1},1}, i_{N_{train}+1,1} & \cdots & t_{N_{train}+N_{test1},200}, i_{N_{train}+N_{test1},200} \end{bmatrix}, \quad (5.24)$$

$$y_{C2} = \begin{bmatrix} y_{N_{train}+1} \\ \vdots \\ y_{N_{train}+N_{train}} \end{bmatrix},$$

$$X_{C3} = \begin{bmatrix} t_{1,1}, i_{1,1} & \cdots & t_{1,200}, i_{1,200} \\ \vdots & \ddots & \vdots \\ t_{N_{test2},1}, i_{N_{test2},1} & \cdots & t_{N_{test2},200}, i_{N_{test2},200} \end{bmatrix}, \quad (5.25)$$

$$y_{C3} = \begin{bmatrix} y_1 \\ \vdots \\ y_{N_{test2}} \end{bmatrix}.$$

Ostatecznie po połączeniu elementów składowych zbiór testowy jest postaci (5.26):

$$X_{test} = \begin{bmatrix} X_{C2} \\ X_{C3} \end{bmatrix}, \quad (5.26)$$

$$y_{test} = \begin{bmatrix} y_{C2} \\ y_{C3} \end{bmatrix}.$$

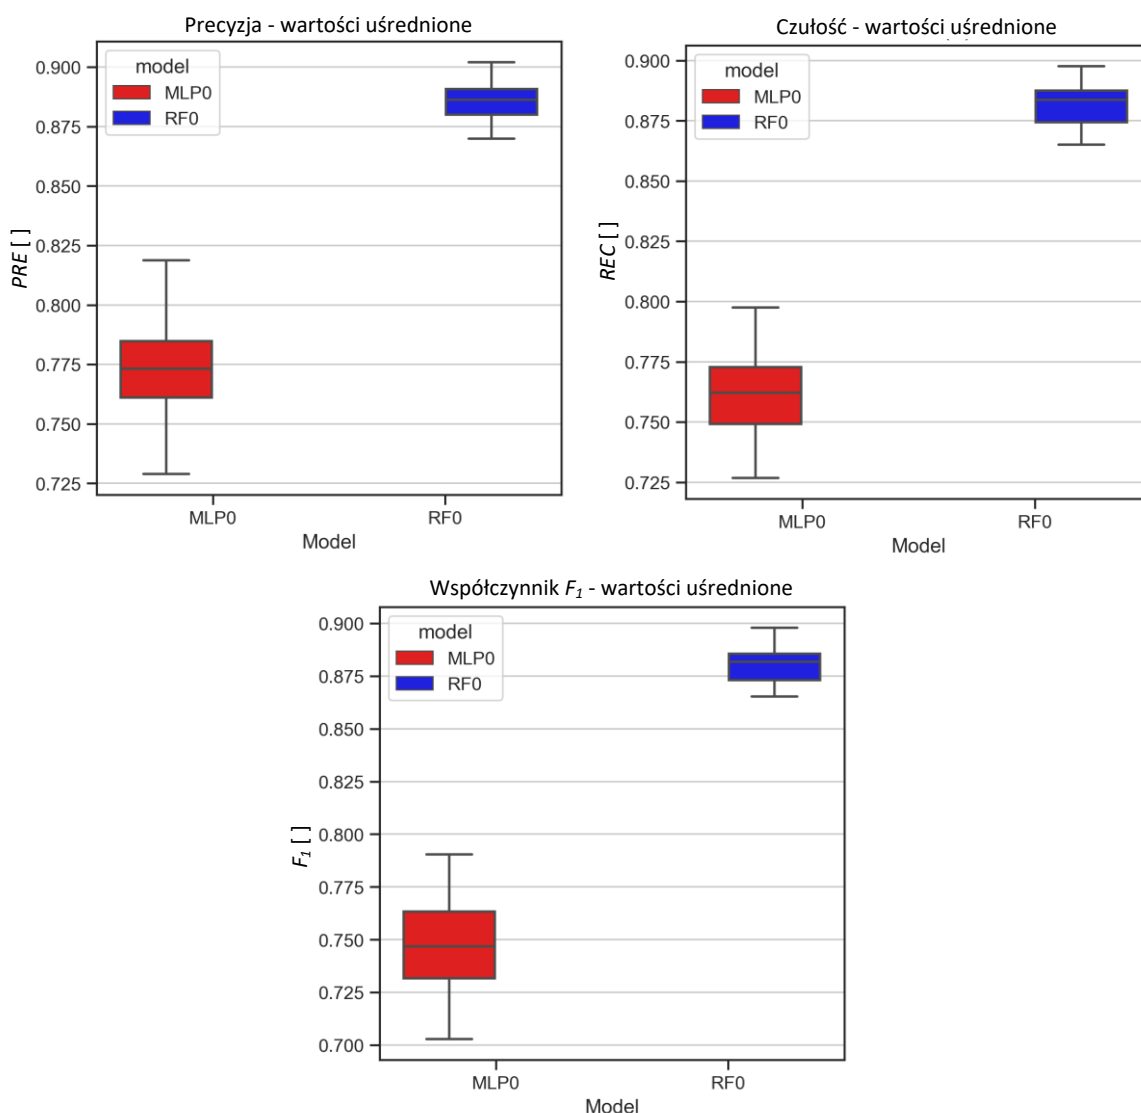
6.6. Modele bazowe

Wybór modeli bazowych oparto na:

- MLPClassifier (MLP0):
 - z parametrem:
random_state=42,
 - pozostałe parametry zostały ustawione zgodnie z ich wartościami domyślnymi:
hidden_layer_sizes=(100,), activation='relu', solver='adam',
alpha=0.0001, batch_size='auto', learning_rate='constant',
learning_rate_init=0.001, power_t=0.5, max_iter=200, shuffle=True,
tol=0.0001, verbose=False, warm_start=False, momentum=0.9,
nesterovs_momentum=True, early_stopping=False,
validation_fraction=0.1, beta_1=0.9, beta_2=0.999, epsilon=1e-08,
n_iter_no_change=10, max_fun=15000
- Random Forrest Classifier (RF0):
 - z parametrem:
random_state=42,
 - pozostałe parametry zostały ustawione zgodnie z ich wartościami domyślnymi:
n_estimators=100, criterion='gini', max_depth=None,
min_samples_split=2, min_samples_leaf=1,
min_weight_fraction_leaf=0.0, max_features='auto',
max_leaf_nodes=None, min_impurity_decrease=0.0, bootstrap=True,
oob_score=False, n_jobs=None, verbose=0, warm_start=False,
class_weight=None, ccp_alpha=0.0, max_samples=None

Skuteczność tak wybranych modeli jako model *MKK* została zweryfikowana za pomocą *k*-krotnej walidacji krzyżowej. Uzyskano następujące wyniki przedstawione na rys. 6.8 i w Tab. 6-1.

Wartości przedstawione w Tab. 6-1 to mediany dla całego uzyskanego zbioru wyników uśrednionych zobrazowanych na rys. 6.8 dla wszystkich klas będące wynikiem walidacji.



Rys. 6.8 Wyniki walidacji krzyżowej modeli bazowych

Tab. 6-1 Wyniki działania modeli bazowych

Miara	MLP0	RF0
PRE []	0,7731	0,8862
REC []	0,7622	0,8837
F_1 []	0,7468	0,8817

Można stwierdzić, że dla wszystkich miar wyższe wyniki uzyskuje RF0 w porównaniu do MLP0. Podsumowaniem w tym zakresie jest miara współczynnika F_1 wynosząca dla MLP0 0,7468 w odniesieniu do wartości 0,8817 osiągniętej przez RF0.

6.7. Strojenie wybranych modeli

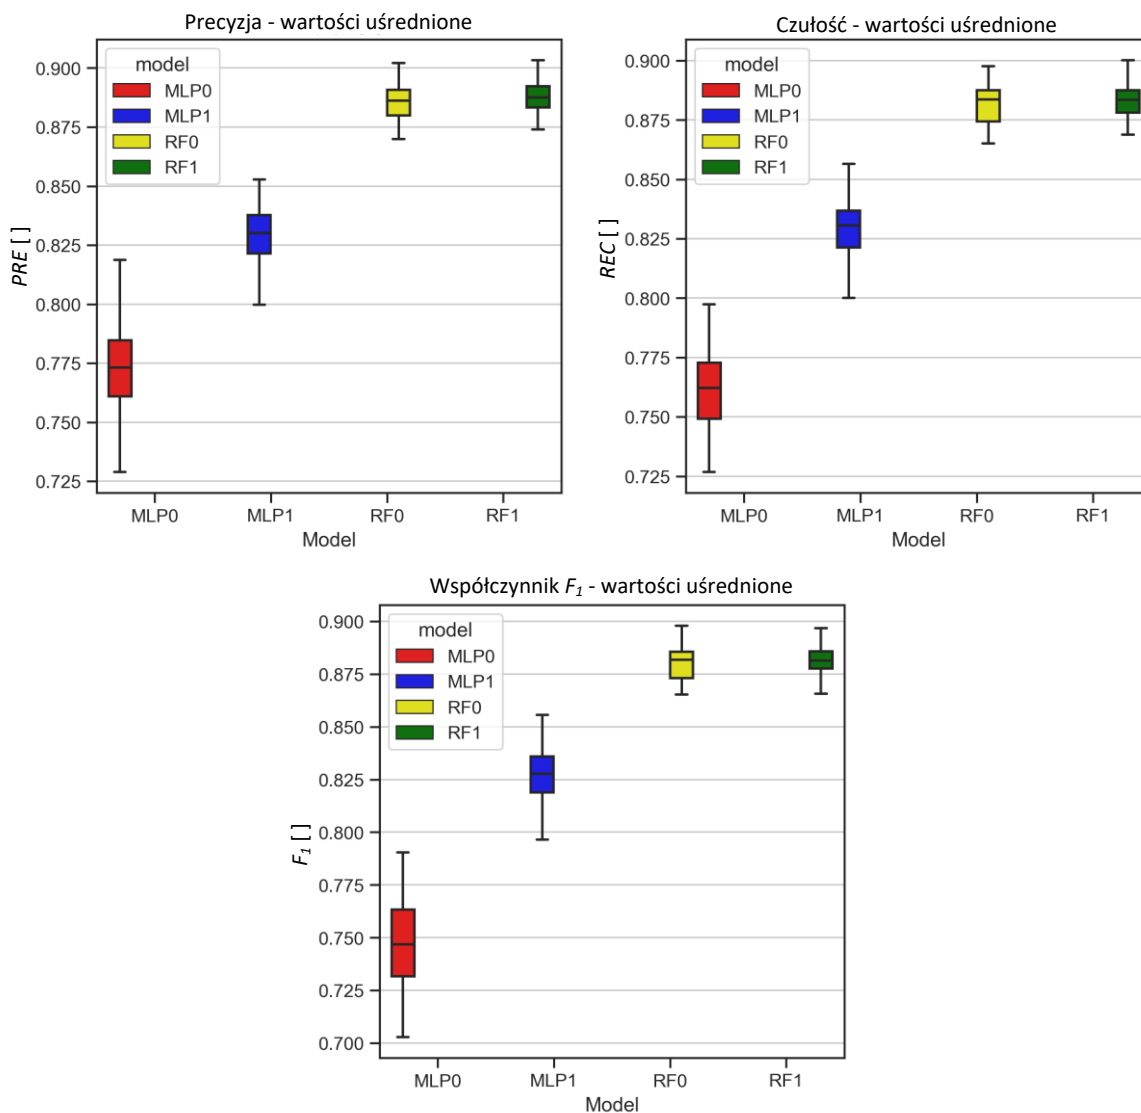
W kolejnym kroku wykonano strojenie modeli z wykorzystaniem algorytmu RandomizedSearchCV w przestrzeni możliwych wartości hiperparametrów podanej w tabeli Tab. 6-2.

Tab. 6-2 Zakres zmian parametrów strojonych

Parametr	Opis	Zakres strojenia	Wartość optymalna
Model RF1			
'n_estimators'	Liczba drzew	[20, 40, 60, ..., 200]	40
'max_depth'	Maksymalna głębokość drzew	[10, 20, 30, ..., 100, None]	30
'min_samples_split'	Minimalna liczba próbek wymagana do podzielenia węzła wewnętrznego	[2, 3, 4]	2
'min_samples_leaf'	Minimalna liczba próbek w węźle liścia	[1, 2]	1
'max_features'	Liczba cech, które należy wziąć pod uwagę, szukając najlepszego podziału	[„auto”, „sqrt”, „log2”]	„log2”
'bootstrap'	Wykorzystanie próbek typu "bootstrap"	[False, True]	False
Model MLP1			
'hidden_layer_sizes'	Liczba neuronów w warstwie ukrytej	[(50,), (100,), (150,)]	(100,)
'activation'	Funkcja aktywacji dla warstwy ukrytej	[„identity”, „logistic”, „tanh”, „relu”]	„relu”
'solver'	Funkcja optymalizacji wag	[‘lbfgs’]	[‘lbfgs’]
'alpha'	Nastawa regularyzacji L ₂	[0.00001, 0.0001, 0.001]	0.0001
'learning_rate'	Sposób doboru współczynnika uczenia	[‘constant’, ‘invscaling’, ‘adaptive’]	‘invscaling’
'max_iter'	Maksymalna liczba iteracji	[200, 400, 800]	800

Z powyższej tabeli wynika, że dla modelu MLP1 były to 324 unikalne konfiguracje, a dla modelu RF1 3240 unikalne konfiguracje. W trakcie procesu dla MLP1 zostało wybranych losowo 100 konfiguracji, a dla RF1 1000 konfiguracji. Każda z testowanych konfiguracji podlegała 5-cio krotnej weryfikacji krzyżowej – kryterium oceny najlepszej konfiguracji stanowiła miara współczynnika F_1 . W oparciu o najlepsze wynikowe konfiguracje parametrów utworzono modele MLP1 i RF1. Ostateczne konfiguracje modeli MLP1 i RF1 zawarte są w kolumnie „Wartość optymalna” w Tab. 6-2. Od strony programowej zadanie to zostało zrealizowane w zbliżony sposób, jak to zostało przedstawione na List. 5.2 dla metody BMNT.

Analizując modele przed i po procesie strojenia pracujące w roli *MKK* (poszczególne wyniki zebrano w Tab. 6-3 oraz zobrazowano na rys. 6.9) widać, że proces strojenia umożliwił zwiększenie precyzji *PRE*, czułości *REC* oraz współczynnika F_1 . Również i tym razem wszystkie wartości przedstawione na rys. 4.4 dotyczą wartości średnich poszczególnych miar, których wartości median zawarte są w Tab. 6-3



Rys. 6.9 Wyniki walidacji krzyżowej modeli dostrojonych

Tab. 6-3 Wyniki działania modeli dostrojonych

Miara	MLP0	MLP1	RF0	RF1
<i>PRE</i> []	0,7731	0,8301	0,8862	0,8875
<i>REC</i> []	0,7622	0,8306	0,8837	0,8834
F_1 []	0,7468	0,8277	0,8817	0,8815

O ile poprawa jest zauważalna porównując MLP0 z MLP1 – miara współczynnika F_1 zwiększa swoją wartość z 0,7468 do 0,8277 – to dla RF1 poprawa jest ograniczona. Dotyczy ona tylko nieznacznej poprawy precyzji PRE z 0,8862 do 0,8875 kosztem małego obniżenia czułości REC z 0,8837 do 0,8834. Podjęto decyzję, że do dalszych działań będą wykorzystywane modele MLP1 i RF1.

6.8. Ocena skuteczności metody z wykorzystaniem danych rzeczywistych

Ocenę skuteczności metody BMFD oparto na rzeczywistych usterkach, wprowadzonych intencjonalnie na stanowisku badawczym opisanym w rozdziale 3.4. Klasyfikację wraz z podaniem liczby przebiegów danego rodzaju zawiera Tab. 6-4 obok szczegółowych wyników dla MLP1 i RF1.

Tab. 6-4 Wyniki działania modeli z danymi rzeczywistymi

Rodzaj przebiegu	Precyzja PRE []	Czułość REC []	F_1 []	Liczba przebiegów danej klasy C_n
MLP1				
0 – ruch w górę	0,96	0,92	0,94	53
1 – FSO_{up}	0,83	1,00	0,91	5
2 – FFO_{up}	0,43	0,50	0,46	6
3 – FGF_{up}	0,25	0,25	0,25	4
4 – ruch w dół	0,97	0,75	0,84	51
5 – FSO_{down}	0,80	1,00	0,89	4
6 – FFO_{down}	0,21	0,50	0,30	8
7 – FGF_{down}	0,40	0,40	0,40	5
Wartości średnie:	0,61	0,66	0,62	
RF1				
0 – ruch w górę	1,00	1,00	1,00	53
1 – FSO_{up}	1,00	1,00	1,00	5
2 – FFO_{up}	0,67	1,00	0,80	6
3 – FGF_{up}	1,00	0,25	0,40	4
4 – ruch w dół	1,00	1,00	1,00	51
5 – FSO_{down}	1,00	1,00	1,00	4
6 – FFO_{down}	1,00	0,88	0,93	8
7 – FGF_{down}	0,83	1,00	0,91	5
Wartości średnie:	0,94	0,89	0,88	

Pierwszą obserwacją jest stwierdzenie, że lepsze wyniki po dostrojeniu w dalszym ciągu uzyskuje RF1 czego potwierdzeniem jest średnia wartość współczynnika F_1 wynosząca dla MLP1 0,62 wobec wartości 0,88 dla MLP1.

W zakresie klasyfikacji przebiegów bezusterkowych ($C_n=0$ i $C_n=4$) to RF1 podaje w każdym przypadku poprawne wyniki. Model MLP1 skuteczniej klasyfikował przebiegi w górę uzyskując wartość współczynnika F_1 równą 0,94 natomiast dla przebiegów w dół z powodu znacznie mniejszej metryki czułości REC wynoszącej tylko 0,75 pomimo wysokiej precyzji PRE na poziomie 0,97 to wynikowa wartość współczynnika F_1 spada do 0,84.

Wykrywanie zdarzenia FSO ($C_n=1$ i $C_n=5$): ponownie najlepszą jakość klasyfikacji wykazał model RF1 osiągając wartość 1,00 dla metryk precyzji PRE , czułości REC i współczynnika F_1 dla obu kierunków ruchu. Model MLP1 wykazuje zbliżone wyniki w zakresie tego zdarzenia dla obu kierunków ruchu – precyzja PRE to odpowiednio 0,83 i 0,80. Dzięki czułości REC równej 1,00 osiągnięta wartość współczynnika F_1 sięga odpowiednio 0,91 i 0,89.

Wykrywanie zdarzenia typu FFO ($C_n=2$ i $C_n=6$): model MLP1 uzyskał wartość współczynnika F_1 równą 0,46 dla ruchu w górę i 0,30 dla ruchu w dół, a RF1 odpowiednio 0,80 i 0,93. I dla tego zdarzenia obserwowalna jest przewaga modelu RF1. Porównując wyniki dla zdarzeń FSO i FFO stwierdzić należy, że FFO jest trudniejszy do wykrycia, ponieważ zmiana prądu zasilającego ulega mniejszym zniekształceniom – w przypadku FSO każdorazowo dochodzi do wzrostu wartości prądu zasilającego do granicy określonej przez i_{stall} .

Zdarzenia FGF_{up} dla model MLP1 jest najtrudniej rozpoznawalne na co wskazuje wartość metryki współczynnika F_1 wynosząca jedynie 0,25. Podobnie dla ruchu w dół FGF_{down} wartość F_1 wynosi 0,4. Model RF1 dla zdarzenia FGF_{up} osiąga wartość precyzji PRE równą 1,00 jednak ze względu na degradujący wpływ czułości REC wynoszącego tylko 0,25 uzyskana wartość metryki współczynnika F_1 to tylko 0,40. Zdecydowanie lepiej model RF1 klasyfikuje zdarzenie FGF_{down} pomimo precyzji PRE wynoszącego 0,83 to dzięki czułości REC równej 1,00 współczynnik F_1 osiąga wartość 0,91.

Specyfika działania modeli została zebrana w Tab. 6-5.

Tab. 6-5 Zestawienie błędów klasyfikacji

Rodzaj błędu (wartość prawdziwa → wartość fałszywa)	Liczba wystąpień MLP1	Liczba wystąpień RF1
3 → 2 ($FGF_{up} \rightarrow FFO_{up}$)	-	3
6 → 7 ($FFO_{down} \rightarrow FGF_{down}$)	3	1
6 → 4 ($FFO_{down} \rightarrow$ ruch w dół)	1	-
7 → 5 ($FGF_{down} \rightarrow FSO_{down}$)	1	-
7 → 6 ($FGF_{down} \rightarrow FFO_{down}$)	2	-
4 → 6 (ruch w dół → FFO_{down})	13	-

Najczęściej występujący błąd modelu MLP1 polegający na sklasyfikowaniu niezakłóconego ruchu w dół jako FFO_{down} i biorąc pod uwagę ogólną liczbę 51 niezakłóconych ruchów w dół, występujących w zbiorze testowym oraz istotność dla bezpieczeństwa przejazdu kolejowo-drogowego akurat tego kierunku ruchu drąga jest sporym wyzwaniem. Podobny problem choć nie występuje dla ruchu do góry to pojawia się w przeciwnym kierunku przyporządkowania – jednokrotnie zdarzenie FFO_{down} jest rozpoznawane jako niezakłócony ruch w dół. Zaobserwowano zdecydowanie mniej wystąpień wszelkich pozostałych typów błędów klasyfikacyjnych – ich liczba nie przekracza trzech.

Skuteczną odpowiedzią na problemy zaobserwowane w pracy modelu MLP1 jest model RF1. W przypadku modelu RF1 pojawiły się tylko dwa błędy klasyfikacji – trzykrotnie zdarzenie FGF_{up} zostało oznaczone jako FFO_{up} oraz jednokrotnie FFO_{down} zostało wskazane jako FGF_{down} . Biorąc pod uwagę powyższe błędy kluczową pozostaje obserwacja, że model RF1 jest w stanie dostarczyć klasyfikacji zgodnych z postawionymi wymaganiami określonymi w rozdziale 6.1 również w warunkach, gdy proces przygotowania metody zakładał zbliżenie się do przypadków granicznych – tak jak m.in. zostało to zrealizowane dla parametru i_{rise} (5.4).

Fragment kodu prezentujący sposób przeprowadzenia próby z danymi rzeczywistymi został zawarty w List. 6.1.

```
def modele_ewaluacja_cm(modele, X_test, y_test):
    print('>>> modele ewaluacja cm')

    # df do zebrania predykcji dla poszczególnych modeli
    y_pred_df = pd.DataFrame()
    y_pred_df['y_test'] = y_test

    for nazwa, model in modele.items():

        y_pred = model.predict(X_test)

        # dopisanie w kolumnie wyników dla danego modelu
```

```
y_pred_df[nazwa] = y_pred

# wykaz błędnych predykcji

# UP
print('>>> UP:')
test = y_pred_df[y_pred_df[nazwa] != y_pred_df['y_test']] [['y_test', nazwa]][y_pred_df['y_test'].isin([0,1,2,3])]
print(test)

# DOWN
print('>>> DOWN:')
test = y_pred_df[y_pred_df[nazwa] != y_pred_df['y_test']] [['y_test', nazwa]][y_pred_df['y_test'].isin([4,5,6,7])]
print(test)

cr = classification_report(y_test, y_pred)
print('classification_report:')
print(cr)

return y_pred_df

# %% sprawdzenie z danymi rzeczywistymi

X_train, y_train, X_test, y_test, scaler = dane()

modele = generuj_modele('modele_optymalizowane')

modele = modele_trenuj(modele, X_train, y_train)

y_pred_df = modele_ewaluacja_cm(modele, X_test, y_test)
```

List. 6.1 Weryfikacja metody BMFD z wykorzystaniem danych rzeczywistych.

6.9. Podsumowanie

Diagnostyka systemu sygnalizacji przejazdowej - opisaną metodą BMFD - dostarcza bardzo istotnego rozszerzenia dotychczas stosowanego mechanizmu, opierającego się jedynie na obserwacji realizacji oczekiwanych faz ruchu napędu rogatkowego w dopuszczalnych przedziałach czasu. Metoda BMFD niezależnie dla dwóch kierunków ruchu drąga elektrycznego napędu rogatkowego klasyfikuje trzy typy zdarzeń, spośród których część oznacza przebiegi usterkowe dla systemu diagnostycznego systemu przejazdowego. Tak doprecyzowana informacja diagnostyczna nie tylko daje możliwość zapewnienia adekwatnej reakcji służb utrzymania na pojawiające się wykrycia zaburzeń ruchu drąga, ale co istotne sygnalizuje problem zanim zostanie przekroczony dopuszczalny maksymalny czas ruchu drąga pomiędzy położeniami skrajnymi.

Przedstawione wyniki zachęcają do zastosowania modelu RF1 jako podstawowego modelu dla metody BMFD, ponieważ klasyfikacja stanu bez usterek jest zawsze poprawna, a uchwycone błędy w zakresie klasyfikacji przebiegów usterkowych są tolerowalne ze względu na ich charakter – dotyczą one zdarzeń *FGF* i *FFO* dla mniej krytycznego kierunku ruchu drąga, jakim jest kierunek w górę. Dla kierunku w dół pojawił się jeden błąd, gdy zdarzenie *FFO_{down}* zostało oznaczone jako *FGF_{down}*.


Należy zwrócić uwagę, że wymagania postawione przed metodą BMFD były szczególnie wymagające – została podjęta decyzja, że wszelkie zdarzenia niezależnie od stopnia ich intensywności mają być wykrywane. Co więcej – granice zakresów parametrów dla modeli zdarzeń zostały powiększone o 10% względem obserwowanych zakresów dla rzeczywistych przypadków. Celem takiego postępowania było zaobserwowanie skuteczności metody dla przypadku granicznego. Na etapie wdrożenia planowane jest przeprowadzenie ponownej analizy poszczególnych przypadków rzeczywistych zdarzeń pod kątem ich dalszej klasyfikacji jako usterek. Niezbędne jest przeanalizowanie ich wpływu na bezpieczeństwo przejazdu kolejowo-drogowego oraz na degradację elektrycznego napędu rogatkowego wraz z drągiem. Z pewnością takie działanie doprowadzi do ponownego określenia zakresu parametrów granicznych dla modeli zdarzeń, które powinny być rozpoznawane jako usterek, biorąc pod uwagę uwarunkowania wynikające z występujących na danym rynku wymagań normatywnych oraz specyfiki eksploatacji – w tym rodzaju stosowanych drągów i ich wyposażenia dodatkowego, realizowany poziom utrzymania technicznego, występujące zachowania pieszych oraz kierowców, a nade wszystko wymagania bezpieczeństwa.

Na podstawie przeprowadzonych prób z rzeczywistymi zdarzeniami można stwierdzić, że metoda BMFD wykazała się dużą skutecznością w klasyfikacji wybranych zdarzeń na podstawie przebiegu prądu zasilającego w funkcji czasu, co spełnia postawione jej

wymagania określone w rozdziale 6.1. Wykazano, że wykorzystanie metod uczenia maszynowego umożliwia detekcję zaistnienia nieprawidłowości, zaburzenia w trakcie ruchu drąga na podstawie przebiegu prądu zasilającego elektryczny napęd rogatkowy.

7. Projekt wdrożeniowy

Obiecujące wyniki przeprowadzonych badań stały się podstawą do podjęcia innowacyjnego projektu wdrożeniowego. Zgodnie z obowiązującymi zasadami celem takiego projektu musi być dojrzałe rozwiązanie możliwe do wykorzystania w realizowanych projektach adaptacyjnych. Bezpośrednim efektem projektów adaptacyjnych są już usługi i produkty dostarczane do klienta końcowego. W oparciu o ocenę sytuacji rynkowej, obserwację zmieniających się wymagań przedstawianych w postępowaniach przetargowych oraz analizę najnowszych rozwiązań pojawiających się na rynku automatyki kolejowej do praktycznego opracowania została wybrana nieinwazyjna metoda detekcji kąta położenia drąga. Propozycja była również obiektem tzw. analizy biznesowej skupiającej się na aspektach ekonomicznych proponowanych działań. Na etapie złożenia wniosku o otwarcie projektu i oceny jego zasadności przyjęto tytuł „Improvement of Functional Safety of the Level Crossing Barrier Machine by a Noninvasive Angle Detection Method (#10997)” – fragment strony intranetowej projektu przedstawiono na rys. 7.1.



Improvement of Functional Safety of the Level Crossing Barrier Machine by a Noninvasive Angle Detection Method (#10997)

By PAWELCZYK Roman Poland 25/01/2022 - 11:25 120 reads



The main task is to ensure safety at the level crossing area – for all people involved – passengers, drivers, pedestrians, etc. To provide safety behavior of a level crossing system the angular position of the boom must be known.

The opportunity is to detect electrical barrier machine boom position without the need to install additional detection devices. This idea is applicable for any device

of a similar type e.g., point machine.

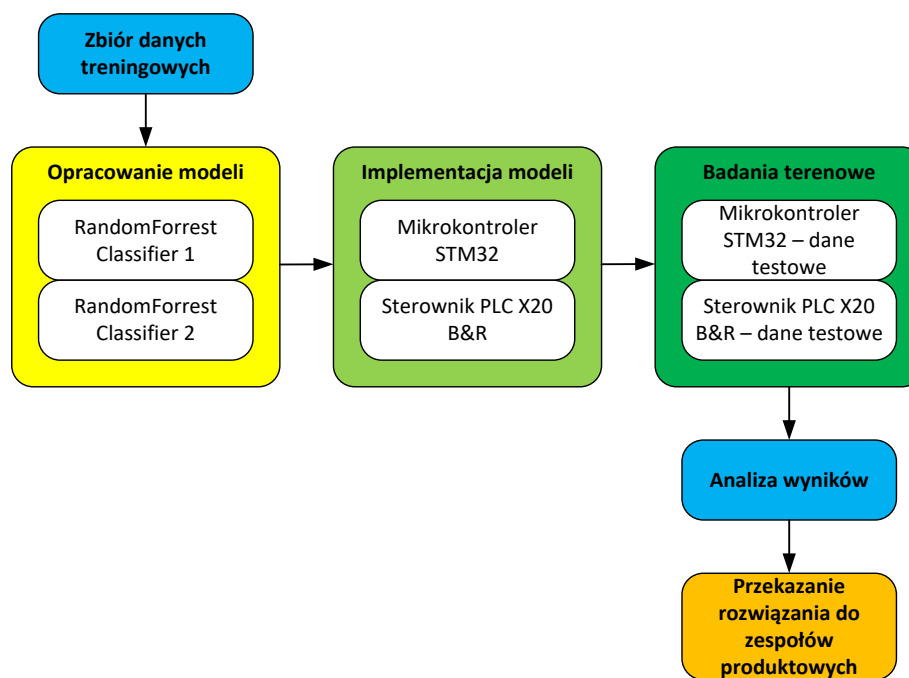
Rys. 7.1 Fragment strony intranetowej projektu innowacyjnego – materiały firmy ALSTOM ZWUS Sp. z o.o.

W związku z uzyskaną aprobatą projekt został formalnie uruchomiony w dniu 20 czerwca 2022r pod nazwą „Diagnostyka elektrycznego napędu rogatek EEG-3”. W trakcie realizacji projektu została bezpośrednio wykorzystana wcześniej już opracowana metoda przygotowania modeli, która została szczegółowo opisana w rozdziale 4. Zostały

wprowadzone pewne zmiany w zakresie rozszerzenia platformy odpowiedzialnej zarówno za rejestrowanie danych, jak i realizację funkcji modelu predykcyjnego. Obok rozwiązania opartego o mikrokontroler rodziny STM32 firmy STMicroelectronics zostało równoległe uruchomione nowe rozwiązanie skonstruowane w oparciu o przemysłowy sterownik PLC rodziny X20 firmy Bernecker und Rainer.

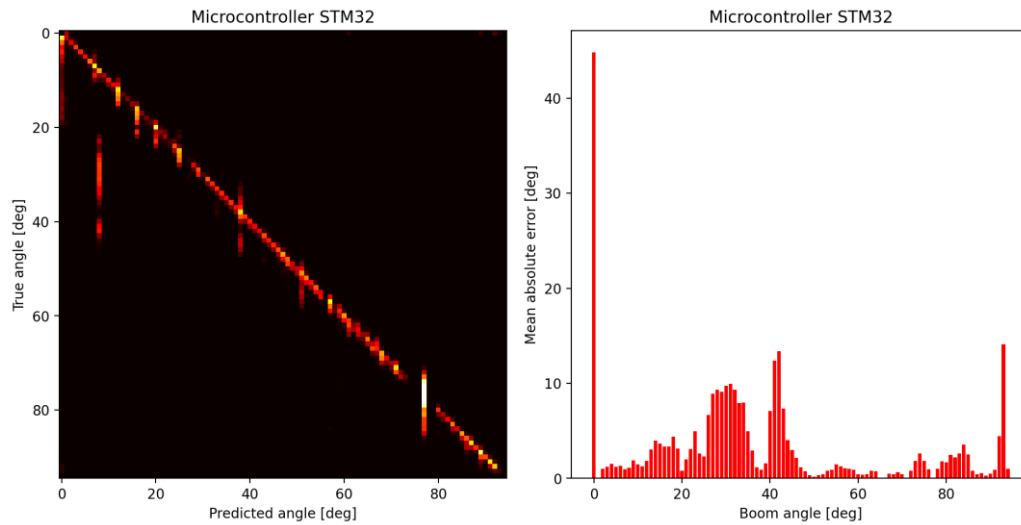
W pierwszym kroku został znacznie rozbudowany zbiór danych ilustrujących pracę napędu rogatekowego, a będący podstawą opracowania docelowych modeli. Rejestracja była realizowana w dłuższym przedziale czasu celem pozyskania danych uwzględniających możliwie szeroki zakres zmian parametrów zarówno środowiskowych, jak stanów charakteryzujących sam napęd rogatekowy wraz z drągiem.

Ze względu na relatywnie prosty sposób konstrukcji wewnętrznej struktury jako model predykcyjny został wybrany RandomForestClassifier zaimplementowany w języku C. Dodatkowym argumentem na rzecz takiego wyboru jest aspekt zapewnienia możliwie łatwego sposobu interpretacji mechanizmu działania modelu. Czynnikiem dodatkowo wspomagającym interpretowalność jest ograniczenie złożoności klasyfikatora. Kierując się takimi przesłankami, i w oparciu o wyniki wcześniejszych badań, została podjęta decyzja o realizacji dwóch klasyfikatorów – jeden (o parametrach ‘n_estimators’=3, ‘max_depth’=10) został przeznaczony dla platformy opartej o mikrokontroler STM32 (STM32F103C8T6 o pojemności pamięci 64 kB), a drugi o podobnej strukturze został w zbliżony sposób przygotowany dla sterownika PLC X20. Proces ten został przedstawiony na poniższym rysunku.



Rys. 7.2 Projekt wdrożeniowy – sposób realizacji

Na rys. 7.3 pokazano osiągnięte wyniki dla modelu zaimplementowanego z wykorzystaniem mikrokontrolera STM32.



Rys. 7.3 Predykcja położenia drąga z rozdzielczością jednego stopnia kąowego, model działający z wykorzystaniem mikrokontrolera STM32 – macierz konfuzji (z lewej) i średni błąd bezwzględny w funkcji kąta (z prawej)

Wszystkie zaplanowane prace zostały ukończone terminowo z dniem 31 marca 2023r. Ostatnim działaniem w projekcie było przedstawienie i formalne przekazanie do zespołów produktowych wytworzonych rozwiązań. Zostały one ocenione pozytywnie przez osoby odpowiedzialne za rozwój produktów związanych z systemem automatycznej sygnalizacji przejazdowej. Zostały również zgłoszone uwagi i propozycje odnośnie ich dalszego rozwoju oraz potencjalnych nowych obszarów zastosowania.

8. Podsumowanie

W ramach niniejszej rozprawy doktorskiej opracowano nowy typ diagnostyki elektrycznego napędu rogatekowego z wykorzystaniem uczenia maszynowego. Zostały opracowane metody BMAD, BMMT i BMFD oraz modele zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego. Dostęp do szczegółowych danych dostarczanych przez metody BMAD, BMMT i BMFD oznacza znaczące podniesienie jakości systemu diagnostyki w porównaniu z dotychczas stosowanym, a opierającym się w głównej mierze na kryteriach maksymalnych dopuszczalnych przedziałów czasu, przeznaczonych na daną fazę ruchu napędu rogatekowego. Wyzwaniem z jakim musiał się zmierzyć Autor była konieczność pozostawienia nienaruszonymi wszystkich dotychczas stosowanych elementów sterowania napędem rogatekowym, zarówno w zakresie warstwy oprogramowania, jak i sprzętowej. Nowe rozwiązania diagnostyczne charakteryzują się budową modułową umożliwiającą ich stosowanie niezależnie od siebie, a nawet mogą być realizowane na zewnętrznej jednostce obliczeniowej względem głównego układu sterowania sygnalizacją przejazdową. Od strony sprzętowej możliwa jest implementacja z zachowaniem pełnej separacji galwanicznej.

Jako pierwszą stworzono metodę BMAD (Barrier Machine Angle Detection). W pierwszym zestawie odmian (*MK1* i *MK3*) dostarcza ona skutecznego rozwiązania dla problemu nadzoru nad ruchem drąga w sposób ciągły, zapewniając predykcję jego bieżącego położenia kąтового. Metoda BMAD jest znaczącym rozwinięciem dla dotychczas stosowanego rozwiązania, opierającego się jedynie na zestawie informacji pochodzących od wyłączników krańcowych informujących o osiągnięciu przez drąg wybranych położzeń kątowych. Dla wszystkich pozostałych położzeń kątowych dokładna pozycja drąga pozostawała dotychczas nieznana – mechanizm kontrolny opierał się na zestawie maksymalnych dopuszczalnych czasów dla poszczególnych faz ruchu. W drugim zestawie odmian (*MK2* i *MK4*) metoda BMAD rozwiązuje problem występujący w sytuacji, gdy konieczna jest rozbudowa napędu rogatekowego o mechanizm detekcji wybranego nowego położenia kąтового drąga. Dotychczas oznaczało to nieuniknioną konieczność wprowadzenia zmian sprzętowych zarówno w samym elektrycznym napędzie rogatekowym, okablowaniu oraz interfejsie kontrolno-sterującym. Alternatywą jest metoda BMAD, która zapewnia ekwiwalentną funkcjonalność a zakres zmian ogranicza się jedynie do wprowadzenia kolejnego modułu w warstwie oprogramowania.

Następnie zaproponowano metodę BMMT (Barrier Machine Movement Time), która w oparciu o zestaw danych zebranych w początkowej fazie ruchu napędu rogatekowego oraz informację o parametrach środowiskowych dostarcza predykcji całkowitego czasu ruchu

między pozycjami skrajnymi. W aktualnie wykorzystywanym układzie kontrolno-sterującym taki rodzaj informacji nie był dostępny – w każdym przypadku zakładano maksymalny dopuszczalny czas ruchu, który jednocześnie spełnia postawione wymagania. Takie podejście nie daje możliwości optymalizacji czasu trwania poszczególnych faz pracy systemu sygnalizacji przejazdowych jak i w konsekwencji całego systemu kolejowego, którego efektywność pracy jest uzależniona od powiązanych sygnalizacji. Nowy rodzaj informacji dostarczany przez metodę BMMT otwiera nowe możliwości w zakresie m.in. optymalizacji czasu ostrzegania. Również został zbadany problem reakcji proponowanego algorytmu na awarie poszczególnych czujników.

Trzecią stworzoną metodą jest BMFD (Barrier Machine Failure Detection), w ramach której stworzono modele zdarzeń występujących podczas pracy elektrycznego napędu rogatekowego z podziałem na dwa kierunki ruchu drąga elektrycznego napędu rogatekowego oraz podstawowe warianty – ruch bez zakłóceń, zderzenie z przeszkodą stałą (*FSO*), sprężystą (*FFO*) i uszkodzenie mechanizmu napędowego (*FGF*). Wytworzone modele zdarzeń umożliwiły opracowanie mechanizmu detekcji wystąpienia powyższych rodzajów zdarzeń. Również i tym razem w sytuacji znacznego zaburzenia ruchu drąga reakcja dotychczas stosowanego rozwiązania ograniczała się do stwierdzenia niesprawności danej części systemu. Jako, że metoda BMFD dostarcza informacji o rodzaju zdarzenia to otwiera to drogę do opracowania bardziej optymalnych scenariuszy reakcji zarówno na poziomie samego systemu sygnalizacji przejazdowej jak i całego systemu kolejowego.

Wszystkie przedstawione metody należy traktować jako modułowe rozszerzenia istniejącej koncepcji sterowania elektrycznym napędem rogatekowym, co ma istotne znaczenie ze względu na specyfikę przewidywanego obszaru zastosowania jakim są kolejowe systemy sterowania. Biorąc pod uwagę obowiązujące wymagania w zakresie bezpieczeństwa, zmiany powiązane ze znaczącą ingerencją w dotychczas przyjęte koncepcje działania urządzeń są wyjątkowo trudne i kosztowne w procesie ich dopuszczenia do eksploatacji. Dlatego przyjęte podejście w zakresie nowo opracowanych metod wykrywania położenia drąga, jak i detekcji zdarzeń w czasie ruchu drąga nie wymusza zmian w dotychczasowej strukturze, zarówno w warstwie oprogramowania, jak i sprzętu – nowe elementy pojawiają się jedynie jako wydzielone bloki w warstwie oprogramowania. Dzięki temu można wykazać, że zapewniony jest wymagany poziom nienaruszalności bezpieczeństwa SIL4 poprzez pozostawienie aktywnych niezmiennych dotychczasowych kluczowych funkcji systemu. W przypadku metody predykcji czasu ruchu napędu rogatekowego zakłada się, że w napędzie zostanie zabudowany enkoder. W pierwszym zastosowaniu mogą być one wykorzystywane jedynie jako funkcje wyłącznie diagnostyczne. W drugim kroku można w oparciu o nie rozwinąć dotychczas stosowany system utrzymania systemów sygnalizacji przejazdowych. W kolejnym kroku otwiera się droga do stworzenia zaawansowanej diagnostyki predykcyjnej.

Proponowane rozwiązania wykorzystujące modele uczenia maszynowego zostały opracowane ze świadomością specyficznych ograniczeń narzucanych przez normy regulujące wytwarzanie systemów sterowania dla kolei. Przede wszystkim pod uwagę brano wymagania związane z koniecznością wyizolowania nowych modułów oprogramowania, ograniczenia wykorzystywanej mocy obliczeniowej oraz rozmiar dostępnej pamięci występującej w kolejowych systemach sterowania. Są one atrakcyjne również pod względem ekonomicznym, gdyż stanowią rozwiązanie lepiej wykorzystujące istniejącą architekturę sprzętową. Kompletny system sygnalizacji przejazdowej, w tym wypadku zawierający nowe funkcje diagnostyczne, będzie dopuszczany do eksploatacji na danym rynku po wykazaniu spełnienia specyficznego dla danego projektu i rynku zestawu wymagań. Ostateczne rozstrzygnięcie w każdym przypadku dostarczy niezależna ocena bezpieczeństwa.

Opracowane modele zdarzeń, występujących podczas ruchu drąga elektrycznego napędu rogatekowego, dostarczają rozwiązanie dla problemu niewystarczającej ilości danych obrazujących stany awaryjne na potrzeby opracowania nowoczesnych mechanizmów diagnostycznych. Dzięki ich zastosowaniu zgromadzony zbiór ilustrujący poprawną pracę napędów rogatekowych może być przekształcony w zróżnicowany zbiór przebiegów, które powinny zostać rozpoznane jako usterkowe dla szerokiego zakresu zmienności parametrów środowiskowych, w jakich pracują elektryczne napędy rogatekowe.

W związku z tym do oryginalnych osiągnięć Autora zaliczyć można:

- Opracowanie nieinwazyjnej metody detekcji kąta położenia drąga elektrycznego napędu rogatekowego BMAD w oparciu o analizę przebiegu prądu zasilającego, opartej na wprowadzeniu dodatkowego elementu w warstwie oprogramowania, w postaci modelu uczenia maszynowego z zachowaniem zarówno oryginalnej struktury sprzętowej interfejsu kontrolno-sterującego dla napędu wraz z warstwą okablowania, jak i budową samego napędu,
- Opracowanie metody prognozowania całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego BMMT pomiędzy położeniami skrajnymi, opartej na uczeniu maszynowym poprzez wprowadzenie w warstwie oprogramowania modelu uczenia maszynowego, pracującego w oparciu o wybrane dane odzwierciedlające parametry elektryczne, czasowe oraz środowiskowe występujące w czasie początkowej fazy ruchu napędu rogatekowego. Metoda zakłada wyposażenie elektrycznego napędu rogatekowego w enkoder,
- Implementacja, analiza i dostrojenie modeli wybranych typów zdarzeń dla elektrycznego napędu rogatekowego, dających możliwość wytworzenia symulowanych przebiegów usterkowych prądu zasilającego poprzez

przekształcenie zebranych przebiegów poprawnych, tj. modelu uderzenia w przeszkodę stałą (zdarzenie 1), modelu uderzenia w przeszkodę sprężystą (zdarzenia 2), modelu uszkodzenia mechanizmu napędowego (zdarzenie 3).

- Opracowanie nieinwazyjnej metody umożliwiającej identyfikację trzech typów zdarzeń tj. uderzenia w przeszkodę stałą (zdarzenie 1), uderzenia w przeszkodę sprężystą (zdarzenia 2), uszkodzenia mechanizmu napędowego (zdarzenie 3) w oparciu o analizę przebiegu prądu zasilającego opartej na wprowadzeniu dodatkowego elementu w warstwie oprogramowania w postaci modelu uczenia maszynowego z zachowaniem zarówno oryginalnej struktury sprzętowej interfejsu kontrolno-sterującego dla napędu wraz z warstwą okablowania, jak i budową samego napędu.

Istotnym elementem podjętych działań jest również realizacja części wdrożeniowej. Wiedza zdobyta na etapie badawczym przełożyła się na praktyczne rozwiązanie udoskonalające zaawansowany produkt, jakim jest system automatycznej sygnalizacji przejazdowej.

Zaproponowane metody oraz analiza zebranych danych pozwalają stwierdzić, że:

- analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatekowy z wykorzystaniem algorytmu uczenia maszynowego umożliwia wyznaczenie aktualnego położenia kąta drąga bez konieczności ingerencji w konstrukcję urządzenia, jednocześnie zwiększając poziom bezpieczeństwa poprzez wygenerowanie dodatkowej informacji dla systemu sterującego,
- algorytm uczenia maszynowego zbudowany na podstawie zmiennych środowiskowych, informacji o kątowym położeniu drąga oraz kształcie prądu zasilającego umożliwia predykcję czasu otwierania i zamykania z zachowaniem wymagań czasowych systemu czasu rzeczywistego,
- analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatekowy z wykorzystaniem algorytmu uczenia maszynowego umożliwia ocenę wystąpienia zdarzeń w trakcie ruchu drąga, takich jak zderzenie z przeszkodą stałą, sprężystą oraz uszkodzenie mechanizmu napędowego.

W związku z powyższym stwierdzić można, że tezy pracy zostały udowodnione i w konsekwencji wyznaczony cel - jakim było opracowanie diagnostyki elektrycznego napędu rogatekowego z wykorzystaniem uczenia maszynowego - został osiągnięty.

9. Dodatki

9.1. Metoda BMAD – wybrane modele

Model Random Forest Classifier (RF) skonfigurowany jak wyspecyfikowano poniżej jest zgodnie z przeprowadzonymi badaniami najlepszym wyborem dla wszystkich modeli MK1...MK4 metody BMAD:

- **Random Forest Classifier (RF):**
 - n_estimators=50,
 - criterion='gini',
 - max_depth=None,
 - min_samples_split=2,
 - min_samples_leaf=1,
 - min_weight_fraction_leaf=0.0,
 - max_features='auto',
 - max_leaf_nodes=None,
 - min_impurity_decrease=0.0,
 - bootstrap=True,
 - oob_score=False,
 - n_jobs=None,
 - random_state=1,
 - verbose=0,
 - warm_start=False,
 - class_weight=None,
 - ccp_alpha=0.0,
 - max_samples=None.

Każdy z wytrenowanych modeli *MK1...MK4* został zarchiwizowany na dołączonym nośniku z wykorzystaniem biblioteki Joblib w wersji 1.1.0 a utworzony z wykorzystaniem biblioteki Scikit-learn w wersji 1.0.2 [91] w postaci następujących plików:

- MK1_RF.joblib,
- MK2_RF.joblib,
- MK3_RF.joblib,
- MK4_RF.joblib.

9.2. Metoda BMMT – wybrane modele

Modele `StackingRegressor` (SR) oraz `Random Forest Regressor` (RF) skonfigurowane jak wyspecyfikowano poniżej są zgodnie z przeprowadzonymi badaniami kolejno dwoma najlepszymi wyborami dla modelu *MR* metody BMMT:

- **StackingRegressor (SR) – część RandomForestRegressor:**

- `n_estimators=100,`
- `criterion='squared_error',`
- `max_depth=20,`
- `min_samples_split=2,`
- `min_samples_leaf=2,`
- `min_weight_fraction_leaf=0.0,`
- `max_features='auto',`
- `max_leaf_nodes=None,`
- `min_impurity_decrease=0.0,`
- `bootstrap=True,`
- `oob_score=False,`
- `n_jobs=None,`
- `random_state=42,`
- `verbose=0,`
- `warm_start=False,`
- `ccp_alpha=0.0,`
- `max_samples=None`

- **StackingRegressor (SR) – część MLP Regressor:**

- `solver='lbfgs',`
- `alpha=0.0001,`
- `max_iter=4000,`
- `hidden_layer_sizes=(20),`
- `random_state=42,`
- `activation='logistic',`

-
- `batch_size='auto'`,
 - `learning_rate='constant'`,
 - `learning_rate_init=0.001`,
 - `power_t=0.5`,
 - `shuffle=True`,
 - `tol=0.0001`,
 - `verbose=False`,
 - `warm_start=False`,
 - `momentum=0.9`,
 - `nesterovs_momentum=True`,
 - `early_stopping=False`,
 - `validation_fraction=0.1`,
 - `beta_1=0.9`,
 - `beta_2=0.999`,
 - `epsilon=1e-08`,
 - `n_iter_no_change=10`,
 - `max_fun=15000`

- **StackingRegressor (SR) – część “final_estimator”
to RandomForestRegressor:**

- `n_estimators=10`,
- `criterion='squared_error'`,
- `max_depth=None`,
- `min_samples_split=2`,
- `min_samples_leaf=1`,
- `min_weight_fraction_leaf=0.0`,
- `max_features='auto'`,
- `max_leaf_nodes=None`,
- `min_impurity_decrease=0.0`,
- `bootstrap=True`,

- oob_score=False,
- n_jobs=None,
- random_state=42,
- verbose=0,
- warm_start=False,
- ccp_alpha=0.0,
- max_samples=None

-
- **Random Forest Regressor (RF):**
 - `n_estimators=100`,
 - `criterion='squared_error'`,
 - `max_depth=20`,
 - `min_samples_split=2`,
 - `min_samples_leaf=2`,
 - `min_weight_fraction_leaf=0.0`,
 - `max_features='auto'`,
 - `max_leaf_nodes=None`,
 - `min_impurity_decrease=0.0`,
 - `bootstrap=True`,
 - `oob_score=False`,
 - `n_jobs=None`,
 - `random_state=42`,
 - `verbose=0`,
 - `warm_start=False`,
 - `ccp_alpha=0.0`,
 - `max_samples=None`

Każdy z wytrenowanych modeli *MR* został zarchiwizowany na dołączonym nośniku z wykorzystaniem biblioteki Joblib w wersji 1.1.0 a utworzony z wykorzystaniem biblioteki Scikit-learn w wersji 1.0.2 [91] w postaci następujących plików:

- `MR_SR.joblib`,
- `MR_RFopt.joblib`,

9.3. Metoda BMFD – wybrany model

Model Random Forrest Classifier (RF1) skonfigurowany jak wyspecyfikowano poniżej jest zgodnie z przeprowadzonymi badaniami najlepszym wyborem dla modelu *MKK* metody BMFD:

- **Random Forest Classifier (RF):**
 - `n_estimators=40,`
 - `criterion='gini',`
 - `max_depth=30,`
 - `min_samples_split=2,`
 - `min_samples_leaf=1,`
 - `min_weight_fraction_leaf=0.0,`
 - `max_features='log2',`
 - `max_leaf_nodes=None,`
 - `min_impurity_decrease=0.0,`
 - `bootstrap=False,`
 - `oob_score=False,`
 - `n_jobs=None,`
 - `random_state=42,`
 - `verbose=0,`
 - `warm_start=False,`
 - `class_weight=None,`
 - `ccp_alpha=0.0,`
 - `max_samples=None.`

Wytrenowany modeli *MKK* został zarchiwizowany na dołączonym nośniku z wykorzystaniem biblioteki Joblib w wersji 1.1.0 a utworzony z wykorzystaniem biblioteki Scikit-learn w wersji 1.0.2 [91] w postaci następującego pliku:

- `MKK_RF1.joblib.`

Bibliografia

- [1] „Rozporządzenie Ministra Infrastruktury i Rozwoju z dnia 20 października 2015 r. w sprawie warunków technicznych, jakim powinny odpowiadać skrzyżowania linii kolejowych oraz bocznic kolejowych z drogami i ich usytuowanie”. <https://isap.sejm.gov.pl/isap.nsf/DocDetails.xsp?id=WDU20150001744> (dostęp 20 listopad 2022).
- [2] „PN-EN 50129:2019-01 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50129-2019-01e.html> (dostęp 2 listopad 2022).
- [3] „Statystyki”. <https://bezpieczny-przejazd.pl/o-kampanii/statystyki/> (dostęp 2 listopad 2022).
- [4] J. Eaton, S. Yang, i M. Gongora, „Ant Colony Optimization for Simulated Dynamic Multi-Objective Railway Junction Rescheduling”, *IEEE Trans. Intell. Transp. Syst.*, t. 18, nr 11, s. 2980–2992, lis. 2017, doi: 10.1109/TITS.2017.2665042.
- [5] S. Kitamura, M. Teramoto, S. Itoya, i Y. Fukuta, „Improvement of Availability of Level Crossing System by Autonomous Decentralized Technology”, w *2017 IEEE 13th International Symposium on Autonomous Decentralized System (ISADS)*, Bangkok, Thailand: IEEE, mar. 2017, s. 143–148. doi: 10.1109/ISADS.2017.35.
- [6] J. Freeman, M. McMaster, i A. Rakotonirainy, „An Exploration into Younger and Older Pedestrians’ Risky Behaviours at Train Level Crossings”, *Safety*, t. 1, nr 1, s. 16–27, sie. 2015, doi: 10.3390/safety1010016.
- [7] E. Oztemel i S. Gursev, „Literature review of Industry 4.0 and related technologies”, *J. Intell. Manuf.*, t. 31, nr 1, s. 127–182, sty. 2020, doi: 10.1007/s10845-018-1433-8.
- [8] B. W. Schlake, C. P. L. Barkan, i J. R. Edwards, „Train Delay and Economic Impact of In-Service Failures of Railroad Rolling Stock”, *Transp. Res. Rec. J. Transp. Res. Board*, t. 2261, nr 1, s. 124–133, sty. 2011, doi: 10.3141/2261-14.
- [9] D. Grzechca, P. Rybka, i R. Pawełczyk, „Level Crossing Barrier Machine Faults and Anomaly Detection with the Use of Motor Current Waveform Analysis”, *Energies*, t. 14, nr 11, s. 3206, maj 2021, doi: 10.3390/en14113206.
- [10] „NR BR 843 : Standard Lifting Barrier Mk II for Level Crossings”. https://global.ihs.com/doc_detail.cfm?document_name=NR%20BR%20843&item_s_key=00807296 (dostęp 17 listopad 2022).
- [11] R. Pawełczyk i D. Grzechca, „Improvement of Functional Safety of the Level-Crossing Barrier Machine by a Noninvasive Angle-Detection Method”, *IEEE Des. Test*, t. 39, nr 5, s. 43–53, paź. 2022, doi: 10.1109/MDAT.2022.3156010.
- [12] „Instrukcja sygnalizacji Ie-1 (E-1)”, s. 136.
- [13] B.-U. T. Kolejowego, „Lista Prezesa UTK (instalacje stałe) z 23 grudnia 2021 r.”, *BIP - Urząd Transportu Kolejowego*. <https://bip.utk.gov.pl/bip/lista-prezesa-utk/818,Lista-Prezesa-UTK-instalacje-stale-z-23-grudnia-2021-r.html> (dostęp 20 listopad 2022).
- [14] „PN-EN IEC 61000-6-2:2019-04 - wersja angielska”. <https://sklep.pkn.pl/pn-en-iec-61000-6-2-2019-04e.html> (dostęp 20 listopad 2022).

- [15] „PN-EN 50125-1:2002 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50125-1-2002e.html> (dostęp 20 listopad 2022).
- [16] „PN-EN IEC 61000-6-4:2019-12 - wersja angielska”. <https://sklep.pkn.pl/pn-en-iec-61000-6-4-2019-12e.html> (dostęp 20 listopad 2022).
- [17] „PN-EN 50124-1:2017-09 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50124-1-2017-09e.html> (dostęp 20 listopad 2022).
- [18] „PN-EN 50122-1:2011/A4:2017-03 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50122-1-2011-a4-2017-03e.html> (dostęp 20 listopad 2022).
- [19] „PN-EN 50159:2011 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50159-2011e.html> (dostęp 20 listopad 2022).
- [20] „PN-HD 60364-4-443:2016-03 - wersja polska”. <https://sklep.pkn.pl/pn-hd-60364-4-443-2016-03p.html> (dostęp 20 listopad 2022).
- [21] „PN-EN 50126-1:2018-02 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50126-1-2018-02e.html> (dostęp 16 listopad 2022).
- [22] „Automatyka i telekomunikacja”, *PKP Polskie Linie Kolejowe S.A.* <https://www.plk-sa.pl/klienci-i-kontrahenci/akty-prawne-i-przepisy/instrukcje-pkp-polskich-linii-kolejowych-sa/automatyka-i-telekomunikacja> (dostęp 16 listopad 2022).
- [23] „PN-EN 50128:2011/A1:2020-07 - wersja angielska”. <https://sklep.pkn.pl/pn-en-50128-2011-a1-2020-07e.html> (dostęp 16 listopad 2022).
- [24] „IEC 62912-2:2019 | IEC Webstore”. <https://webstore.iec.ch/publication/28692> (dostęp 20 listopad 2022).
- [25] „Zmodernizowany napęd rogatek JEGD50M220 |”. <https://spai.com.pl/?p=209> (dostęp 29 listopad 2022).
- [26] M. Kornaszewski i A. Nowak, „Analiza techniczna napędów rogatek stosowanych na przejazdach kolejowo-drogowych w Polsce”, *Autobusy Tech. Eksploat. Syst. Transp.*, t. R. 18, nr 12, 2017, Dostęp: 29 listopad 2022. [Online]. Dostępne na: <http://yadda.icm.edu.pl/baztech/element/bwmeta1.element/baztech-b3e8ae8b-fbf4-490f-b601-58c7eb19a8bd>
- [27] C. Liang, M. Ghazel, O. Cazier, i L. Bouillaut, „Advanced model-based risk reasoning on automatic railway level crossings”, *Saf. Sci.*, t. 124, s. 104592, kwi. 2020, doi: 10.1016/j.ssci.2019.104592.
- [28] M. Ghazel, „Using Stochastic Petri Nets for Level-Crossing Collision Risk Assessment”, *IEEE Trans. Intell. Transp. Syst.*, t. 10, nr 4, s. 668–677, grudz. 2009, doi: 10.1109/TITS.2009.2026310.
- [29] „Payments for disruption on the railway”, *Network Rail*. <https://www.networkrail.co.uk/industry-and-commercial/information-for-operators/payments-for-disruption-on-the-railway/> (dostęp 2 listopad 2022).
- [30] G. Cavone, T. van den Boom, L. Blenkers, M. Dotoli, C. Seatzu, i B. De Schutter, „An MPC-Based Rescheduling Algorithm for Disruptions and Disturbances in Large-Scale Railway Networks”, *IEEE Trans. Autom. Sci. Eng.*, t. 19, nr 1, s. 99–112, sty. 2022, doi: 10.1109/TASE.2020.3040940.
- [31] T. Ghasempour, G. L. Nicholson, D. Kirkwood, T. Fujiyama, i B. Heydecker, „Distributed Approximate Dynamic Control for Traffic Management of Busy Railway Networks”, *IEEE Trans. Intell. Transp. Syst.*, t. 21, nr 9, s. 3788–3798, wrz. 2020, doi: 10.1109/TITS.2019.2934083.
- [32] M. I. M. Amjath i T. Kartheeswaran, „An Automated Railway Level Crossing System”, w *2020 International Conference on Image Processing and Robotics (ICIP)*, Negombo, Sri Lanka: IEEE, mar. 2020, s. 1–7. doi: 10.1109/ICIP48927.2020.9367346.

-
- [33] M. Ghazel, „A Control Scheme for Automatic Level Crossings Under the ERTMS/ETCS Level 2/3 Operation”, *IEEE Trans. Intell. Transp. Syst.*, t. 18, nr 10, s. 2667–2680, paź. 2017, doi: 10.1109/TITS.2017.2657695.
- [34] Y.-S. Huang, Y.-S. Weng, i M. Zhou, „Critical Scenarios and Their Identification in Parallel Railroad Level Crossing Traffic Control Systems”, *IEEE Trans. Intell. Transp. Syst.*, t. 11, nr 4, s. 968–977, grudz. 2010, doi: 10.1109/TITS.2010.2076390.
- [35] G. Huntley-Fenner, „Warnings and Pedestrian Behavior: A Case Study of Unintended Effects”, *Proc. Hum. Factors Ergon. Soc. Annu. Meet.*, t. 50, nr 19, s. 2202–2206, paź. 2006, doi: 10.1177/154193120605001903.
- [36] J. Gripenkoven, S. Giesemann, i S. Dietsch, „THE ROLE OF HUMAN ERROR IN ACCIDENTS AT GERMAN HALF-BARRIER LEVEL CROSSINGS”, s. 11.
- [37] „Final Report Summary - SELCAT (Safer European Level Crossing Appraisal and Technology) | FP6 | CORDIS | European Commission”.
<https://cordis.europa.eu/project/id/31487/reporting> (dostęp 15 listopad 2022).
- [38] V. Taillandier, „Smart level crossing”, w *2018 16th International Conference on Intelligent Transportation Systems Telecommunications (ITST)*, Lisboa: IEEE, paź. 2018, s. 1–5. doi: 10.1109/ITST.2018.8566824.
- [39] A. Skoufas, N. Boufidis, J. M. Salanova Grau, G. Ayfantopoulou, i S. Basbas, „Ex-Post Evaluation of an In-Vehicle Warning System for Rail-Road Level Crossings: The Case of Taxi Drivers”, w *Advances in Mobility-as-a-Service Systems*, E. G. Nathanail, G. Adamos, i I. Karakikes, Red., w *Advances in Intelligent Systems and Computing*. Cham: Springer International Publishing, 2021, s. 243–252. doi: 10.1007/978-3-030-61075-3_24.
- [40] R. F. Benekohal i C. G. Rawls, „An Analyses of Drivers’ Responses to In-Vehicle Receiver (IVR) after Experiencing Two Modes of Operation”, *FHWA-ILUI-TOL-12*, mar. 2004, Dostęp: 16 listopad 2022. [Online]. Dostęp na:
<https://hdl.handle.net/2142/46062>
- [41] L. Khoudour, M. Ghazel, F. Boukour, M. Heddebaut, i E.-M. El-Koursi, „Towards safer level crossings: existing recommendations, new applicable technologies and a proposed simulation model”, *Eur. Transp. Res. Rev.*, t. 1, nr 1, Art. nr 1, mar. 2009, doi: 10.1007/s12544-008-0004-z.
- [42] M. G. Lenné, C. M. Rudin-Brown, J. Navarro, J. Edquist, M. Trotter, i N. Tomasevic, „Driver behaviour at rail level crossings: Responses to flashing lights, traffic signals and stop signs in simulated rural driving”, *Appl. Ergon.*, t. 42, nr 4, s. 548–554, maj 2011, doi: 10.1016/j.apergo.2010.08.011.
- [43] S. Ma i X. Yan, „Examining the efficacy of improved traffic signs and markings at flashing-light-controlled grade crossings based on driving simulation and eye tracking systems”, *Transp. Res. Part F Traffic Psychol. Behav.*, t. 81, s. 173–189, sie. 2021, doi: 10.1016/j.trf.2021.05.019.
- [44] A. Nikolajevs i M. Mezitis, „Level crossing time prediction”, w *2016 57th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON)*, Riga, Latvia: IEEE, paź. 2016, s. 1–3. doi: 10.1109/RTUCON.2016.7763105.
- [45] G. S. Larue, R. A. Blackman, i J. Freeman, „Frustration at congested railway level crossings: How long before extended closures result in risky behaviours?”, *Appl. Ergon.*, t. 82, s. 102943, sty. 2020, doi: 10.1016/j.apergo.2019.102943.
- [46] A. Silla, A. Dressler, E. Lehtonen, A. Virtanen, J. Mesimäki, i J. Gripenkoven, „Potential of auxiliary strobe lights on train locomotives to improve level crossing safety”, *Appl. Ergon.*, t. 103, s. 103767, wrz. 2022, doi: 10.1016/j.apergo.2022.103767.

- [47] National Research Council (U.S.), Red., *Traffic and grade crossing control devices*. w Transportation research record, no. 1244. Washington, D.C: Transportation Research Board, National Research Council, 1989.
- [48] „Report on Railway Safety and Interoperability in the EU - 2022”, s. 124.
- [49] Y. Zhang, S. Pan, i Y. Ding, „Recognition method for abnormal driving behaviors of road traffic based on lane-level positioning.”, *Adv. Transp. Stud.*, t. 4, 2022.
- [50] C. Wisultschew, G. Mujica, J. M. Lanza-Gutierrez, i J. Portilla, „3D-LIDAR Based Object Detection and Tracking on the Edge of IoT for Railway Level Crossing”, *IEEE Access*, t. 9, s. 35718–35729, 2021, doi: 10.1109/ACCESS.2021.3062220.
- [51] J. J. García *i in.*, „Efficient Multisensory Barrier for Obstacle Detection on Railways”, *IEEE Trans. Intell. Transp. Syst.*, t. 11, nr 3, s. 702–713, wrz. 2010, doi: 10.1109/TITS.2010.2052101.
- [52] J. J. Garcia, A. Hernandez, J. Urena, i E. Garcia, „FPGA-Based Architecture for a Multisensory Barrier to Enhance Railway Safety”, *IEEE Trans. Instrum. Meas.*, t. 65, nr 6, s. 1352–1363, cze. 2016, doi: 10.1109/TIM.2016.2534238.
- [53] P. Sikora *i in.*, „Artificial Intelligence-Based Surveillance System for Railway Crossing Traffic”, *IEEE Sens. J.*, t. 21, nr 14, s. 15515–15526, lip. 2021, doi: 10.1109/JSEN.2020.3031861.
- [54] V.-T. Tran i W.-H. Tsai, „Acoustic-Based Train Arrival Detection Using Convolutional Neural Networks With Attention”, *IEEE Access*, t. 10, s. 72120–72131, 2022, doi: 10.1109/ACCESS.2022.3185224.
- [55] G. S. Larue, S. G. Dehkordi, C. N. Watling, i A. Naweed, „Loud and clear? Train horn practice at railway level crossings in Australia”, *Appl. Ergon.*, t. 95, s. 103433, wrz. 2021, doi: 10.1016/j.apergo.2021.103433.
- [56] K. Haleem, „Investigating risk factors of traffic casualties at private highway-railroad grade crossings in the United States”, *Accid. Anal. Prev.*, t. 95, s. 274–283, paź. 2016, doi: 10.1016/j.aap.2016.07.024.
- [57] T. Garcia-Calva, D. Morinigo-Sotelo, V. Fernandez-Cavero, i R. Romero-Troncoso, „Early Detection of Faults in Induction Motors—A Review”, *Energies*, t. 15, nr 21, s. 7855, paź. 2022, doi: 10.3390/en15217855.
- [58] M. Skowron, C. T. Kowalski, i T. Orłowska-Kowalska, „Impact of the Convolutional Neural Network Structure and Training Parameters on the Effectiveness of the Diagnostic Systems of Modern AC Motor Drives”, *Energies*, t. 15, nr 19, s. 7008, wrz. 2022, doi: 10.3390/en15197008.
- [59] C. N. Okwuosa i J. Hur, „A Filter-Based Feature-Engineering-Assisted SVC Fault Classification for SCIM at Minor-Load Conditions”, *Energies*, t. 15, nr 20, s. 7597, paź. 2022, doi: 10.3390/en15207597.
- [60] M. A. Buettner, N. Monzen, i C. M. Hackl, „Artificial Neural Network Based Optimal Feedforward Torque Control of Interior Permanent Magnet Synchronous Machines: A Feasibility Study and Comparison with the State-of-the-Art”, *Energies*, t. 15, nr 5, s. 1838, mar. 2022, doi: 10.3390/en15051838.
- [61] F. Gargiulo, A. Liccardo, i R. Schiano Lo Moriello, „A Non-Invasive Method Based on AI and Current Measurements for the Detection of Faults in Three-Phase Motors”, *Energies*, t. 15, nr 12, s. 4407, cze. 2022, doi: 10.3390/en15124407.
- [62] S. Ganesan, P. W. David, P. K. Balachandran, i D. Samithas, „Intelligent Starting Current-Based Fault Identification of an Induction Motor Operating under Various Power Quality Issues”, *Energies*, t. 14, nr 2, s. 304, sty. 2021, doi: 10.3390/en14020304.

-
- [63] H. Nakamura i Y. Mizuno, „Diagnosis for Slight Bearing Fault in Induction Motor Based on Combination of Selective Features and Machine Learning”, *Energies*, t. 15, nr 2, s. 453, sty. 2022, doi: 10.3390/en15020453.
- [64] C.-Y. Lee i Y.-H. Cheng, „Motor Fault Detection Using Wavelet Transform and Improved PSO-BP Neural Network”, *Processes*, t. 8, nr 10, s. 1322, paź. 2020, doi: 10.3390/pr8101322.
- [65] W. Lang, Y. Hu, C. Gong, X. Zhang, H. Xu, i J. Deng, „Artificial Intelligence-Based Technique for Fault Detection and Diagnosis of EV Motors: A Review”, *IEEE Trans. Transp. Electrification*, t. 8, nr 1, s. 384–406, mar. 2022, doi: 10.1109/TTE.2021.3110318.
- [66] F. Liu i in., „A Two-Stage Learning Model for Track-Side Acoustic Bearing Fault Diagnosis”, *IEEE Trans. Instrum. Meas.*, t. 70, s. 1–12, 2021, doi: 10.1109/TIM.2021.3075751.
- [67] S. Esakimuthu Pandarakone, Y. Mizuno, i H. Nakamura, „A Comparative Study between Machine Learning Algorithm and Artificial Intelligence Neural Network in Detecting Minor Bearing Fault of Induction Motors”, *Energies*, t. 12, nr 11, s. 2105, cze. 2019, doi: 10.3390/en12112105.
- [68] D. Grzechca, A. Ziębiński, i P. Rybka, „Enhanced Reliability of ADAS Sensors Based on the Observation of the Power Supply Current and Neural Network Application”, w *Computational Collective Intelligence*, N. T. Nguyen, G. A. Papadopoulos, P. Jędrzejowicz, B. Trawiński, i G. Vossen, Red., w *Lecture Notes in Computer Science*, vol. 10449. Cham: Springer International Publishing, 2017, s. 215–226. doi: 10.1007/978-3-319-67077-5_21.
- [69] „Profesorowie Damian Grzechca, Adam Ziębiński, Rafał Cupek oraz mgr inż. Paweł Rybka twórcami opatentowanego wynalazku”, *Wydział Automatyki, Elektroniki i Informatyki*. <https://www.polsl.pl/rau/aktualnosci/12718/profesorowie-damian-grzechca-adam-ziebinski-rafal-cupek-oraz-mgr-inz-pawel-rybka-tworcami-opatentowanego-wynalazku> (dostęp 20 maj 2023).
- [70] M. Azamfar, X. Jia, V. Pandhare, J. Singh, H. Davari, i J. Lee, „Detection and diagnosis of bottle capping failures based on motor current signature analysis”, *Procedia Manuf.*, t. 34, s. 840–846, 2019, doi: 10.1016/j.promfg.2019.06.165.
- [71] H. Song i S. Doki, „Position Sensorless Control based on Pattern Matching Method using Multiple Template Data Sets to Improve Position Control Error”, w *2018 20th European Conference on Power Electronics and Applications (EPE'18 ECCE Europe)*, wrz. 2018, s. P.1-P.6.
- [72] H. Kubota i Y. Shibano, „Initial Pole Position Estimation of IPMSM with DC Link Current Measurement - Approach for Weak Saturation Effect Machines”, w *2007 Power Conversion Conference - Nagoya*, Nagoya, Japan: IEEE, kwi. 2007, s. 302–307. doi: 10.1109/PCCON.2007.372984.
- [73] M. S. Mubarak i T.-H. Liu, „Implementation of Predictive Controllers for Matrix-Converter-Based Interior Permanent Magnet Synchronous Motor Position Control Systems”, *IEEE J. Emerg. Sel. Top. Power Electron.*, t. 7, nr 1, s. 261–273, mar. 2019, doi: 10.1109/JESTPE.2018.2873151.
- [74] W. Kim i C. Choo Chung, „Novel Position Detection Method for Permanent Magnet Stepper Motors Using Only Current Feedback”, *IEEE Trans. Magn.*, t. 47, nr 10, s. 3590–3593, paź. 2011, doi: 10.1109/TMAG.2011.2144573.
- [75] A. Rubaai, M. J. Castro-Sitiriche, M. Garuba, i L. Burge, III, „Implementation of Artificial Neural Network-Based Tracking Controller for High-Performance Stepper Motor Drives”, *IEEE Trans. Ind. Electron.*, t. 54, nr 1, s. 218–227, luty 2007, doi: 10.1109/TIE.2006.888785.

- [76] Faa-Jeng Lin, Rong-Jong Wai, i Rou-Yong Duan, „Neural-network controller for parallel-resonant ultrasonic motor drive”, *IEEE Trans. Control Syst. Technol.*, t. 7, nr 4, s. 494–501, lip. 1999, doi: 10.1109/87.772165.
- [77] B. Wang, C. Liu, S. Chen, S. Dong, i J. Hu, „Data-Driven Digital Direct Position Servo Control by Neural Network With Implicit Optimal Control Law Learned From Discrete Optimal Position Tracking Data”, *IEEE Access*, t. 7, s. 126962–126972, 2019, doi: 10.1109/ACCESS.2019.2937993.
- [78] C. Yan, W. Yu, X. Hainan, S. Siyuan, W. Chenhui, i S. Liubin, „Research on Rotor Position Model for Switched Reluctance Motor Using Neural Network”, *IEEEASME Trans. Mechatron.*, s. 1–1, 2018, doi: 10.1109/TMECH.2018.2870892.
- [79] P. Meier, K. Rohrmann, M. Sandner, i M. Prochaska, „Compensation of Measurement Errors for a Magnetoresistive Angular Sensor Array Using Artificial Neuronal Networks”, *IEEE Access*, t. 8, s. 142956–142976, 2020, doi: 10.1109/ACCESS.2020.3012064.
- [80] R. Silva-Ortigoza *i in.*, „Sensorless Tracking Control for a “Full-Bridge Buck Inverter–DC Motor” System: Passivity and Flatness-Based Design”, *IEEE Access*, t. 9, s. 132191–132204, 2021, doi: 10.1109/ACCESS.2021.3112575.
- [81] E. Vazquez-Sanchez, J. Gomez-Gil, J. C. Gamazo-Real, i J. F. Diez-Higuera, „A New Method for Sensorless Estimation of the Speed and Position in Brushed DC Motors Using Support Vector Machines”, *IEEE Trans. Ind. Electron.*, t. 59, nr 3, s. 1397–1408, mar. 2012, doi: 10.1109/TIE.2011.2161651.
- [82] J. M. Knezevic, „Low-Cost Low-Resolution Sensorless Positioning of DC Motor Drives for Vehicle Auxiliary Applications”, *IEEE Trans. Veh. Technol.*, t. 62, nr 9, s. 4328–4335, lis. 2013, doi: 10.1109/TVT.2013.2268716.
- [83] Y. Ma, A. Maqsood, D. Oslebo, i K. Corzine, „Wavelet Transform Data-Driven Machine Learning-Based Real-Time Fault Detection for Naval DC Pulsating Loads”, *IEEE Trans. Transp. Electrification*, t. 8, nr 2, s. 1956–1965, cze. 2022, doi: 10.1109/TTE.2021.3130044.
- [84] D. Gonzalez-Jimenez, J. del-Olmo, J. Poza, F. Garramiola, i I. Sarasola, „Machine Learning-Based Fault Detection and Diagnosis of Faulty Power Connections of Induction Machines”, *Energies*, t. 14, nr 16, s. 4886, sie. 2021, doi: 10.3390/en14164886.
- [85] M. Szeliga, *Data science i uczenie maszynowe*. Warszawa: Wydawnictwo Naukowe PWN, 2017.
- [86] M. Gągolewski, M. Bartoszek, i A. Cena, *Przetwarzanie i analiza danych w języku Python*, Wydanie I. Warszawa: Wydawnictwo Naukowe PWN, 2020.
- [87] M. Szeliga, *Praktyczne uczenie maszynowe*, Wydanie 1. Warszawa: PWN, 2020.
- [88] T. Theodorides, M. Shafique, J. Choi, i O. Mutlu, „Guest Editorial: Robust Resource-Constrained Systems for Machine Learning”, *IEEE Des. Test*, t. 37, nr 2, s. 5–7, kwi. 2020, doi: 10.1109/MDAT.2020.2971201.
- [89] S. Wang, A. Pathania, i T. Mitra, „Neural Network Inference on Mobile SoCs”, *IEEE Des. Test*, t. 37, nr 5, s. 50–57, paź. 2020, doi: 10.1109/MDAT.2020.2968258.
- [90] K. J. Millman i M. Aivazis, „Python for Scientists and Engineers”, *Comput. Sci. Eng.*, t. 13, nr 2, s. 9–12, mar. 2011, doi: 10.1109/MCSE.2011.36.
- [91] F. Pedregosa *i in.*, „Scikit-learn: Machine Learning in Python”, *J. Mach. Learn. Res.*, t. 12, nr 85, s. 2825–2830, 2011.
- [92] T. P. D. Team, „pandas-dev/pandas: Pandas”. Zenodo, 19 październik 2022. doi: 10.5281/ZENODO.3509134.

-
- [93] W. McKinney, „Data Structures for Statistical Computing in Python”, zaprezentowano na Python in Science Conference, Austin, Texas, 2010, s. 56–61. doi: 10.25080/Majora-92bf1922-00a.
- [94] „Artykuły z IMiG 5/2014 – Inżynieria Morska i Geotechnika”.
<https://imig.pl/archiwalia/artykuly-z-imig-5-2014/> (dostęp 23 luty 2023).
- [95] L. Zhuang, H. Qi, i Z. Zhang, „The Automatic Rail Surface Multi-Flaw Identification Based on a Deep Learning Powered Framework”, *IEEE Trans. Intell. Transp. Syst.*, t. 23, nr 8, s. 12133–12143, sie. 2022, doi: 10.1109/TITS.2021.3109949.
- [96] Ying Li, Hoang Trinh, N. Haas, C. Otto, i S. Pankanti, „Rail Component Detection, Optimization, and Assessment for Automatic Rail Track Inspection”, *IEEE Trans. Intell. Transp. Syst.*, t. 15, nr 2, s. 760–770, kwi. 2014, doi: 10.1109/TITS.2013.2287155.
- [97] T. Wang, Z. Zhang, F. Yang, i K.-L. Tsui, „Automatic Rail Component Detection Based on AttnConv-Net”, *IEEE Sens. J.*, t. 22, nr 3, s. 2379–2388, luty 2022, doi: 10.1109/JSEN.2021.3132460.
- [98] H. Yin, Z. Liu, Z. Xu, i L. Gao, „An Automatic Visual Monitoring System for Expansion Displacement of Switch Rail”, *IEEE Trans. Instrum. Meas.*, t. 69, nr 6, s. 3015–3025, cze. 2020, doi: 10.1109/TIM.2019.2927547.
- [99] N. Qin, K. Liang, D. Huang, L. Ma, i A. H. Kemp, „Multiple Convolutional Recurrent Neural Networks for Fault Identification and Performance Degradation Evaluation of High-Speed Train Bogie”, *IEEE Trans. Neural Netw. Learn. Syst.*, t. 31, nr 12, s. 5363–5376, grudz. 2020, doi: 10.1109/TNNLS.2020.2966744.
- [100] Rong-Jong Wai i Jeng-Dao Lee, „Robust Levitation Control for Linear Maglev Rail System Using Fuzzy Neural Network”, *IEEE Trans. Control Syst. Technol.*, t. 17, nr 1, s. 4–14, sty. 2009, doi: 10.1109/TCST.2008.908205.
- [101] G. Kang, S. Gao, L. Yu, D. Zhang, X. Wei, i D. Zhan, „Contact Wire Support Defect Detection Using Deep Bayesian Segmentation Neural Networks and Prior Geometric Knowledge”, *IEEE Access*, t. 7, s. 173366–173376, 2019, doi: 10.1109/ACCESS.2019.2955753.
- [102] X. Hu, Y. Che, X. Lin, i S. Onori, „Battery Health Prediction Using Fusion-Based Feature Selection and Machine Learning”, *IEEE Trans. Transp. Electrification*, t. 7, nr 2, s. 382–398, cze. 2021, doi: 10.1109/TTE.2020.3017090.
- [103] C. Yao, Q. Zhao, Z. Ma, W. Zhou, i T. Yao, „Design and Simulation of an Intelligent Current Monitoring System for Urban Rail Transit”, *IEEE Access*, t. 8, s. 35973–35978, 2020, doi: 10.1109/ACCESS.2020.2975009.
- [104] T. de Bruin, K. Verbert, i R. Babuska, „Railway Track Circuit Fault Diagnosis Using Recurrent Neural Networks”, *IEEE Trans. Neural Netw. Learn. Syst.*, t. 28, nr 3, s. 523–533, mar. 2017, doi: 10.1109/TNNLS.2016.2551940.
- [105] G. Zhu, X. Huang, R. Yang, i R. Sun, „Relationship Extraction Method for Urban Rail Transit Operation Emergencies Records”, *IEEE Trans. Intell. Veh.*, s. 1–1, 2022, doi: 10.1109/TIV.2022.3160502.
- [106] A. Rubaai, „A neural-net-based device for monitoring amtrak railroad track system”, *IEEE Trans. Ind. Appl.*, t. 39, nr 2, s. 374–381, mar. 2003, doi: 10.1109/TIA.2003.809443.
- [107] Y. Su, S. Wang, Z. Xiao, M. Tan, i M. Wang, „An Ultra-Short-Term Wind Power Forecasting Approach Based on Wind Speed Decomposition, Wind Direction and Elman Neural Networks”, w *2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2)*, Beijing: IEEE, paź. 2018, s. 1–9. doi: 10.1109/EI2.2018.8582514.

- [108] K. B. Navas R, J. Banu K, R. Katyal, S. B, P. S, i J. K. Reddy, „A Novel Short Term Wind Speed Forecasting based on Hybrid Neural Network: A Case Study on Smart City in India”, w *7th Iran Wind Energy Conference (IWEC2021)*, Shahrood, Iran: IEEE, maj 2021, s. 1–4. doi: 10.1109/IWEC52400.2021.9466972.
- [109] R. L. Welch, S. M. Ruffing, i G. K. Venayagamoorthy, „Comparison of feedforward and feedback neural network architectures for short term wind speed prediction”, w *2009 International Joint Conference on Neural Networks*, Atlanta, Ga, USA: IEEE, cze. 2009, s. 3335–3340. doi: 10.1109/IJCNN.2009.5179034.