

Politechnika Poznańska
Poznań University of Technology



Wydział Automatyki, Robotyki i Elektrotechniki
Instytut Robotyki i Inteligencji Maszynowej

*Faculty of Control, Robotics and Electrical Engineering
Institute of Robotics and Machine Intelligence*

Rozprawa doktorska

Automatyczna diagnostyka uszkodzeń wirników nośnych robota latającego

Automatic fault diagnostics of the aerial robot rotors

Adam Bondyra

Promotor: prof. dr hab. inż. Andrzej Kasiński

Poznań, wrzesień 2022

Adam Bondyra

Automatyczna diagnostyka uszkodzeń wirników nośnych robota latającego

Rozprawa doktorska, Poznań, wrzesień 2022

Promotor: prof. dr hab. inż. Andrzej Kasiński

Politechnika Poznańska

Instytut Robotyki i Inteligencji Maszynowej

Wydział Automatyki, Robotyki i Elektrotechniki

Streszczenie

Zagadnienie zapewnienia bezpieczeństwa eksploatacji bezzałogowych systemów latających stanowi jedno z najważniejszych wyzwań stawianych przed tym szybko rozwijającym się segmentem gospodarki. Dostępne opracowania wskazują, że techniczne przyczyny defektów i awarii są najpowszechniejsze i występują znacznie częściej w porównaniu do lotnictwa załogowego. Wśród szczegółowych kategorii uszkodzeń miniaturowych UAV (ang. *Unmanned Aerial Vehicles*) najczęściej wskazywane są defekty systemów pomiarowych, zakłócenia kanałów komunikacji i sterowania oraz awarie elementów wykonawczych.

Tematyka rozprawy skupiona jest na rozwiązaniu szczególnego problemu technicznego, jakim jest wczesna i wykonywana automatycznie detekcja uszkodzeń rotorów wielowirnikowych jednostek latających. Przedstawiony jest proces badawczy, poczynając od rozpoznania i oszacowania skali problemu, poprzez analizę potencjalnych źródeł informacji diagnostycznej i zaproponowanie wskaźników stanu systemu, kończąc na opracowaniu szeregu metod detekcji, lokalizacji i identyfikacji zdefiniowanej klasy uszkodzeń. Rozwiązania oparte są o analizę i przetwarzanie sygnałów wibroakustycznych rejestrowanych w trakcie lotu oraz inteligentne modele pozwalające na klasyfikowanie uzyskanych sygnatur pod kątem wykrycia i zidentyfikowania defektów.

W początkowych rozdziałach pracy demonstrowany jest wpływ uszkodzeń płatów wirników na osiągi i charakterystyki pracy bezzałogowego systemu latającego. Poczynione obserwacje, rozszerzone następnie w szeregu dalszych eksperymentów, prowadzą do zaproponowania sposobów wykorzystania w diagnostyce informacji zawartej w widmie analizowanych sygnałów. Na ich podstawie opracowano ewolucyjnie cztery metody pozwalające na wykrycie uszkodzenia, określenie jego podtypu oraz wskazanie wadliwego zespołu napędowego. Trzy z nich wykorzystują analizę widma wibracji wpro-

wadzanych do konstrukcji UAV przez uszkodzony element wykonawczy i rejestrowanych z wykorzystaniem czujników inercyjnych. Ostatni algorytm oparty jest o analizę cepstralną sygnałów akustycznych uzyskanych dzięki miniaturowej macierzy mikrofonów. Wspólnym elementem stanowi zastosowanie technik uczenia maszynowego do rozpoznawania wzorców charakterystycznych dla danego stanu wirników.

W rozprawie zawarto również opis prac technicznych, obejmujących konstrukcję stanowisk badawczych oraz wykonanie oprzyrządowania pomiarowego w formie dedykowanych systemów pokładowych prototypowego UAV. Na potrzeby walidacji proponowanych rozwiązań diagnostycznych zebrano kilka zestawów danych wibroakustycznych obejmujących wiele przypadków defektów i rejestrowanych dla możliwie szerokiego spektrum warunków oraz trajektorii lotów. Każdy ze zbiorów opracowano na podstawie kilkudziesięciu rzeczywistych eksperymentów.

Przedstawione w pracy wyniki wskazują na wysoką skuteczność proponowanych metod w postawionym zadaniu diagnostycznym. Najlepsze modele pozwalają na prawidłowe określenie stanu systemu w niemal wszystkich analizowanych przypadkach. W procesie badawczym duży nacisk kładziono na możliwości implementacji rozwiązań w systemach awioniki pokładowej ograniczonych w zakresie mocy obliczeniowej z uwagi na masę, wymiary i pobór energii. Z tego względu proponowane w rozprawie metody charakteryzują się różnymi możliwościami w zależności od zasobów dostępnych dla danej wielkości i klasy docelowej jednostki latającej.

Abstract

The issue of ensuring the safe operation of unmanned aerial vehicles (UAVs) is one of the most important challenges facing this rapidly growing segment of the economy. Available studies indicate that technical causes of defects and failures are the most common and occur much more frequently compared to manned aviation. Among the variety of faults in miniature UAVs, the most common are errors in measurement systems, communication link interferences and actuators faults.

The topic of the dissertation is focused on the solution of a specific technical problem, which is the early and automatic fault detection in the rotors of multi-rotor aerial vehicles. The research process is presented, starting with the estimation of the importance and scale of the problem, through the analysis of potential sources of diagnostic information and the proposal of indicators of system status, ending with the development of a series of methods for detection, localization and identification of a defined class of faults. The solutions are based on the analysis and processing of vibroacoustic signals recorded during flight, as well as intelligent models that allow the classification of the obtained signatures for the fault detection and identification.

In the initial chapters of the thesis, the impact of rotor faults on the performance and operational characteristics of an unmanned aerial system is demonstrated. The observations made, extended in a series of further experiments, lead to the proposal of ways to use the information contained in the spectrum of the analyzed signals in diagnostics. Based on these, four methods have been evolutionarily developed to detect the fault, determine its subtype and indicate the faulty propulsion unit. Three of them use the analysis of the spectrum of vibrations introduced into the UAV structure by the defective actuator and recorded using inertial sensors. The last algorithm is based on cepstral analysis of acoustic signals obtained through a miniature microphone array. A common element is the use of machine learning methods to recognize patterns characteristic for a given rotor condition.

The dissertation includes a description of the technical works, including the construction of test stands and the implementation of measurement instrumentation in the form of dedicated on-board systems of the prototype UAV. For the validation of the proposed diagnostic solutions, several vibro-

acoustic datasets were collected covering multiple fault cases and recorded for wide range of conditions and flight trajectories. Each set was developed based on dozens of real experiments.

The results presented in the thesis indicate the high efficiency of proposed methods in diagnostic task posed. The best models correctly determine the state of the system in almost all analyzed cases. In the research process, great emphasis was placed on the possibility of implementing solutions in on-board avionics systems limited in terms of computing power due to weight, physical dimensions and power consumption. For this reason, the methods proposed in the dissertation are characterized by different capabilities depending on the resources available for the size and class of the target UAV.

Spis treści

Wykaz skrótów i oznaczeń	XI
Spis rysunków	XV
Spis tabel	XIX
1 Wstęp	1
1.1 Znaczenie problematyki badawczej	2
1.1.1 Przyczyny awarii i uszkodzeń bezzałogowych systemów latających	2
1.1.2 Wpływ awarii na lot UAV	3
1.2 Cel pracy	4
1.3 Geneza prac nad problemem	5
1.4 Teza rozprawy	9
1.5 Przegląd zawartości rozprawy	10
2 Stan wiedzy dotyczącej diagnostyki uszkodzeń rotorów UAV	13
2.1 Wstęp	13
2.2 Podstawowe schematy diagnostyczne	14
2.3 Przegląd rozwiązań szczegółowych	16
2.3.1 Kontekst historyczny	16
2.3.2 Diagnostyka UAV	17
2.3.3 Badania stanu wirników nośnych	18
2.4 Dyskusja	21
3 Cechy specyficzne obiektu diagnostyki	23
3.1 Model wielowirnikowego UAV	23
3.1.1 Równania dynamiki	24
3.2 Zjawiska fizyczne towarzyszące pracy uszkodzonych wirników	27
3.2.1 Wibracje generowane przez maszyny wirujące	29
3.2.2 Obserwacje empiryczne	30

4	Implementacja i prace techniczne dotyczące rozwiązań diagnostycznych	39
4.1	Aspekty techniczne diagnozowanych systemów	40
4.1.1	Stan wiedzy	40
4.1.2	Wnioski w kontekście implementacji rozwiązań diagnostycznych	42
4.1.3	Porównanie dostępnych platform sprzętowych	42
4.2	Platforma eksperymentalna - UAV <i>Falcon</i>	44
4.2.1	Cechy szczególne urządzenia	45
4.2.2	Wybrane funkcje oprogramowania pokładowego	49
4.3	Sieć sensorowa oparta o akcelerometry MEMS	51
4.3.1	Założenia techniczne	51
4.3.2	Realizacja sprzętowa	53
4.3.3	Oprogramowanie	55
4.4	Podsystem macierzy mikrofonowej	56
4.4.1	Architektura sprzętowa	57
4.4.2	Oprogramowanie	59
4.5	Pomocnicze stanowiska badawcze	60
4.5.1	Hamownia napędów śmigłowych	60
4.5.2	Urządzenie do lotu na uwięzi o 3 stopniach swobody	62
5	Metody diagnostyczne	65
5.1	Analiza wibrometryczna	65
5.1.1	Wstęp	65
5.1.2	Wstępne przetwarzanie sygnałów	66
5.1.3	Określanie analizowanego zakresu widma	66
5.1.4	Wyznaczanie wskaźników diagnostycznych i wnioskowanie	71
5.1.5	Podsumowanie	72
5.2	Klasyfikacja wzorców widmowych	75
5.2.1	Wstęp	75
5.2.2	Propozycja procedury diagnostycznej	75
5.2.3	Klasyfikator uszkodzeń	78
5.2.4	Podsumowanie	78
5.3	Metoda wykorzystująca sieć sensorową	80
5.3.1	Wstęp	80
5.3.2	Założenia metody	80
5.3.3	Analiza widmowa	82
5.3.4	Przetwarzanie sygnałów wibracyjnych	85

5.3.5	Metoda klasyfikacji	86
5.3.6	Podsumowanie	87
5.4	Metoda oparta o sygnały akustyczne	89
5.4.1	Wstęp	89
5.4.2	Koncepcja metody	90
5.4.3	Przetwarzanie sygnałów akustycznych	92
5.4.4	Klasyfikator uszkodzeń	94
5.4.5	Podsumowanie	95
6	Eksperymenty walidacyjne	97
6.1	Metodyka prowadzenia eksperymentów	97
6.2	Etapy przetwarzania danych eksperymentalnych	98
6.3	Rozpatrywane typy uszkodzeń	100
6.4	Zbiory sygnałów wibracyjnych	102
6.5	Zbiory sygnałów akustycznych	104
6.6	Techniki stosowane do oceny modeli	105
6.6.1	Metody walidacji	106
6.6.2	Podstawowe metryki	106
7	Analiza uzyskanych rezultatów	109
7.1	Ewaluacja metody wibrometrycznej	109
7.1.1	Wstęp	109
7.1.2	Model bazowy	110
7.1.3	Walidacja na zredukowanym zbiorze danych	113
7.1.4	Znaczenie szerokości analizowanego pasma	115
7.1.5	Wpływ czasu rejestracji sygnału	116
7.1.6	Wnioski	117
7.2	Klasyfikacja wzorców widmowych	119
7.2.1	Wstęp	119
7.2.2	Wykrywanie uszkodzeń	120
7.2.3	Klasyfikacja typu uszkodzenia	122
7.2.4	Wpływ szerokości okna sygnałów wibracyjnych	123
7.2.5	Podsumowanie	127
7.3	Metoda wykorzystująca sieć sensorową	128
7.3.1	Wstęp	128
7.3.2	Dobór parametrów modelu	129
7.3.3	Finalny klasyfikator	131
7.3.4	Identyfikacja uszkodzeń wielokrotnych	133
7.3.5	Alternatywna implementacja	136
7.3.6	Podsumowanie	138

7.4	Wyniki uzyskane z wykorzystaniem metody akustycznej . . .	140
7.4.1	Wstęp	140
7.4.2	Dobór rozmiaru warstw sieci	140
7.4.3	Wpływ długości analizowanych sygnałów	142
7.4.4	Czas przetwarzania	143
7.4.5	Podsumowanie	144
8	Podsumowanie	147
8.1	Wnioski	147
8.1.1	Ocena stopnia realizacji przyjętych celów	150
8.1.2	Oryginalność prac	151
8.2	Dalsze kierunki badań	152
	Bibliografia	155

Wykaz skrótów i oznaczeń

A

ADC *ang. Analog to Digital Converter.*

AHRS *ang. Attitude and Heading Reference System.*

AOP *ang. Acoustic Overload Point.*

AUC *ang. Area Under the Curve.*

B

BLDC *ang. BrushLess Direct Current.*

BSP Bezzałogowy Statek Powietrzny.

C

CFRP *ang. Carbon Fiber Reinforced Polymer.*

COBS *ang. Consistent Overhead Byte Stuffing.*

D

DAQ *ang. Data Acquisition.*

DMA *ang. Direct Memory Access.*

DoA *ang. Direction of Arrival.*

E

ESC *ang. Electronic Speed Controller.*

F

FDI *ang. Fault Detection and Isolation.*

FFT *ang. Fast Fourier Transform.*

FPGA *ang. Field-Programmable Gate Array.*

FPR *ang. False Positive Rate.*

FTC *ang. Fault Tolerant Control.*

G

GCS *ang. Ground Control Station.*

I

I²C *ang. Inter-IC Bus.*

IMU *ang. Inertial Measurement Unit.*

IoT *ang. Internet of Things.*

L

LOE *ang. Loss Of Effectiveness.*

LSTM *ang. Long Short-Term Memory.*

M

MEMS *ang. Micro ElectroMechanical System.*

MFCC *ang. Mel Frequency Cepstrum Coefficients.*

MLP *ang. MultiLayer Perceptron.*

O

OOB *ang. Out-of-Bag.*

P

PWM *ang. Pulse Width Modulation.*

R

RF *ang. Random Forest.*

RNN *ang. Recurrent Neural Network.*

ROC *ang. Receiver Operating Curve.*

S

SBC *ang. Single Board Computer.*

SMO *ang. Sequential Minimal Optimization.*

SPI *ang. Serial Peripheral Interface.*

SSH *ang. Secure Shell.*

SVM *ang. Support Vector Machine.*

T

THD *ang. Total Harmonic Distortion.*

TPR *ang. True Positive Rate.*

U

UART *ang. Universal Asynchronous Receiver-Transmitter.*

UAV *ang. Unmanned Aerial Vehicle.*

Spis rysunków

1.1	Bezzałogowy statek powietrzny <i>Falcon</i> stosowany do rozwijania i ewaluacji metod diagnostycznych przedstawionych w rozprawie	4
1.2	UAV „ <i>Dropter</i> ” opracowany w ramach projektu <i>StarTiger</i> [17]	6
1.3	Widok ogólny hamowni napędów śmigłowych	7
1.4	Przykłady wirników użytych w analizie statycznej - nieuszkodzone (H), z ułamaną końcówką (F), z uszkodzoną krawędzią natarcia (E)	7
1.5	Zestawienie wyników prób wykonanych na hamowni napędów śmigłowych	8
3.1	Schemat kinematyczny i koncepcja wielowirnikowego UAV w konfiguracji X8	25
3.2	Porównanie średniego czasu lotu w przypadku wystąpienia w systemie uszkodzenia wirnika	28
3.3	Spektrogram wibracji zarejestrowanych podczas lotu bez uszkodzeń wirników	32
3.4	Porównanie spektrogramów wibracji dla sprawnego (A) UAV oraz systemu z jednostronnie uszkodzonym pojedynczym wirnikiem (B)	33
3.5	Spektrogramy wibracji dla masy UAV brutto (AGW) wynoszącej 2150g (A) oraz 2650g (B). W obu przypadkach loty wykonywano z uszkodzonymi wirnikami	33
3.6	Porównanie spektrogramów dla uszkodzonego wirnika o wysokiej jakości wykonania (A) oraz zestawu popularnych, nieuszkodzonych rotorów (B)	35
3.7	Widma wibracji uzyskane dla różnego położenia akcelerometru	36
3.8	Zmiana częstotliwości charakterystycznej uszkodzenia w trakcie wykonywania przez <i>BSP</i> gwałtownych manewrów	36
4.1	Wielowirnikowy UAV <i>Falcon V5</i>	45
4.2	Lokalizacja podstawowych elementów awioniki drona <i>Falcon</i>	46
4.3	Przeciwbieżna jednostka napędowa drona <i>Falcon</i>	47
4.4	Czujnik bezwładnościowy <i>ADIS16488</i> połączony z układem <i>AHRS</i>	48

4.5	Schematyczny opis procesu akwizycji danych w awionice drona <i>Falcon</i>	50
4.6	Czujnik wibracji oparty o akcelerometr <i>MMA8452</i>	53
4.7	Elementy systemu sieci sensorowej - <i>DAQ</i> oraz cztery czujniki wibracji	54
4.8	Komputer typu <i>SBC Raspberry Pi Zero W</i>	55
4.9	Moduł macierzy mikrofonowej <i>ReSpeaker</i>	57
4.10	Kompletny podsystem macierzy mikrofonowej: moduł <i>Respeaker</i> (1), <i>SBC Raspberry Pi</i> (2), stelaż (3)	59
4.11	Widok ogólny hamowni napędów śmigłowych	60
4.12	Obwód drukowany układu kontrolno-pomiarowego hamowni napędów śmigłowych	61
4.13	Wygląd rzeczywisty i model CAD stanowiska do lotu na uwięzi	62
4.14	Zasada działania i przepływ danych w stanowisku badawczym	63
5.1	Wielomianowy model jednostek napędowych - dopasowana powierzchnia	68
5.2	Wielomianowy model jednostek napędowych - dokładność dopasowania	69
5.3	Przykładowy przebieg sygnałów sterujących modułami <i>ESC</i> w trakcie 5-sekundowego lotu w zawisie	70
5.4	Weryfikacja działania algorytmu wyznaczania pasma w trakcie lotu w zawisie (A) oraz podczas wykonywania manewru (B)	71
5.5	Schemat blokowy metody diagnostycznej	73
5.6	Schemat procesu przetwarzania sygnałów wibracyjnych dla metody diagnostycznej opartej o wzorce widmowe	76
5.7	Schemat blokowy klasyfikatora uszkodzeń opartego o wzorce widmowe	79
5.8	Rozmieszczenie akcelerometrów w systemie sieci sensorowej. <i>Opracowano na podstawie [97]</i>	81
5.9	Widma sygnałów wibracyjnych uzyskanych z sieci sensorowej przy braku uszkodzeń (1) oraz dla uszkodzonego wirnika w jednostce napędowej A (2). <i>Opracowano na podstawie [97]</i>	83
5.10	Widma sygnałów wibracyjnych przy uszkodzeniu wirnika w jednostce C	84
5.11	Etapy przetwarzania sygnałów wibracyjnych. <i>Opracowano na podstawie [97]</i>	85
5.12	Wizualizacja procesu wyznaczania wzorca częstotliwościowego. <i>Opracowano na podstawie [97]</i>	86

5.13	Próbki sygnałów akustycznych i wyznaczone dla nich wykresy widmowej gęstości mocy [103]	91
5.14	Etapy przetwarzania sygnałów akustycznych [103]	93
5.15	Architektura klasyfikatora LSTM [103]	94
6.1	Przykłady dwóch głównych typów uszkodzeń wirników — złamanie płata (po lewej) oraz deformacja krawędzi (po prawej) .	101
6.2	Deformacja krawędzi profilu lotniczego w 10-calowym wirniku wykonanym z <i>CFRP</i>	101
7.1	Macierze błędów klasyfikatora bazowego dla testu na zbiorze A	111
7.2	Rozkład wielkości decyzyjnych w części treningowej zbioru A .	112
7.3	Macierze błędów klasyfikatora opracowanego na bazie podzbioru B	114
7.4	Rozkład wielkości decyzyjnych dla podzbioru treningowego B .	114
7.5	Wpływ szerokości pasma na skuteczność klasyfikacji uszkodzeń	115
7.6	Skuteczność klasyfikacji uszkodzeń w funkcji czasu akwizycji sygnałów	116
7.7	Porównanie rozkładu wielkości decyzyjnych dla okien o szerokości 500 ms (A) oraz 100 ms (B)	117
7.8	Macierze błędów dla etapu wykrywania uszkodzeń	121
7.9	Krzywa ROC wykreślona dla etapu detekcji uszkodzeń	121
7.10	Macierze błędów dla klasyfikatora określającego typ uszkodzenia	123
7.11	Krzywa ROC wykreślona dla etapu identyfikacji typu uszkodzenia	124
7.12	Ocena jakości detekcji uszkodzeń dla różnych długości sygnałów wibracyjnych	124
7.13	Krzywe ROC wykreślone dla modeli opracowanych dla zmiennej długości próbek sygnałów (etap detekcji uszkodzeń) . . .	125
7.14	Ocena skuteczności identyfikacji typu uszkodzenia dla różnych długości sygnałów wibracyjnych	126
7.15	Krzywe ROC wykreślone dla modeli opracowanych dla zmiennej długości sygnałów (etap identyfikacji typu uszkodzenia) .	126
7.16	Wykres błędu <i>OOB</i> w zależności od długości sygnałów i liczby drzew - zbiór o 5 klasach, pełen zakres	130
7.17	Wykres błędu <i>OOB</i> w zależności od długości sygnałów i liczby drzew - zbiór o 5 klasach, najlepsze z uzyskanych rezultatów . .	130
7.18	Macierz błędów dla zbioru testowego - uszkodzenia jednokrotne	132
7.19	Oszacowanie ważności cech dla klasyfikatora uszkodzeń	133
7.20	Wykres błędu <i>OOB</i> (<i>ang. Out-of-Bag</i>) dla detekcji uszkodzeń wielokrotnych - pełen zakres	134

7.21	Wykres błędu OOB dla detekcji uszkodzeń wielokrotnych - najlepsze uzyskane modele	134
7.22	Macierz błędów dla klasyfikacji zbioru danych zawierających uszkodzenia wielokrotne	135
7.23	Macierz błędów dla najlepszego z modeli opartych o sztuczną sieć neuronową [111]	137
7.24	Macierze błędów dla modelu LSTM [103]	142

Spis tablic

4.1	Porównanie wybranych parametrów niskopoziomowych kontrolerów lotu	44
4.2	Wybrane parametry czujnika bezwładnościowego ADIS16488 .	49
4.3	Wybrane parametry trójosiowego akcelerometru <i>MMA8452</i> . .	53
4.4	Wybrane parametry układu mikrofonu <i>MEMS MSM321A3729H9BP</i>	58
6.1	Podsumowanie ilościowe zbioru sygnałów wibracyjnych	104
6.2	Podsumowanie eksperymentów z rejestracją sygnałów akustycznych oraz liczebność danych dla każdej z klas [103]	105
7.1	Hiperparametry oraz podstawowe metryki bazowego klasyfikatora SVM	111
7.2	Hiperparametry oraz podstawowe metryki jakościowe klasyfikatora SVM wytrenowanego dla podzbioru B	113
7.3	Hiperparametry oraz podstawowe metryki skuteczności klasyfikatora uszkodzeń opartego o wzorce widmowe	120
7.4	Parametry modelu użytego w drugim etapie wnioskowania - identyfikacji typu uszkodzenia	122
7.5	Parametry klasyfikatora uszkodzeń jednokrotnych opartego o algorytm <i>RF</i>	131
7.6	Parametry i podstawowe metryki wyselekcjonowanego klasyfikatora uszkodzeń wielokrotnych	135
7.7	Model oparty o sztuczną sieć neuronową - hiperparametry . . .	137
7.8	Czas przetwarzania algorytmu diagnostycznego w systemie wbudowanym	138
7.9	Wpływ rozmiaru warstwy <i>LSTM</i> na trafność detekcji uszkodzeń [103]	141
7.10	Parametry wybranego klasyfikatora opartego o sieć <i>LSTM</i>	141
7.11	Trafność klasyfikacji uszkodzeń dla różnych długości sygnałów akustycznych	143
7.12	Czas przetwarzania algorytmu diagnostycznego	144

Bezzałogowe pojazdy latające - UAV (*ang. Unmanned Aerial Vehicle*) - są jednymi z najbardziej perspektywicznych rozwiązań współczesnej robotyki mobilnej i systemów autonomicznych. Rozwijane początkowo głównie w celach militarnych, obecnie znajdują szerokie zastosowanie w takich obszarach jak przemysł 4.0 [1], rolnictwo precyzyjne [2] czy technologie miast inteligentnych, tzw. *smart cities* [3]. Do branż coraz szerzej wykorzystujących tę technologię należą również ochrona środowiska, budownictwo oraz górnictwo. Najpowszechniejszym zastosowaniem dronów w dużej mierze pozostają fotografia lotnicza oraz wykorzystanie w celach rozrywkowych i hobbystycznych [4].

Błyskawicznie rosnący, liczony w setkach milionów euro segment gospodarki, jakim jest komercyjne wykorzystanie autonomicznych systemów latających, mierzy się jednak z licznymi wyzwaniem [5]. Jako jedno z najważniejszych podnoszona jest kwestia bezpieczeństwa i niezawodności systemów bezzałogowych operujących niejednokrotnie w środowisku ściśle współdzielonym z ludźmi [6]. Do innych przeszkód rozwojowych zaliczyć można kwestie prywatności i ochrony danych wrażliwych pozyskanych z wykorzystaniem aparatów latających, czy też kwestię unormowania i koordynacji zarządzania ruchem w przestrzeni powietrznej, w której poruszają się zarówno załogowe jak i bezzałogowe statki powietrzne.

W ostatnich latach Unia Europejska wprowadziła szereg rozwiązań legislacyjnych mających na celu zapewnienie bezpieczeństwa w zarządzaniu przestrzenią powietrzną oraz wymuszenie stosowania odpowiednich procedur dotyczących obsługi, pilotażu i prowadzenia operacji z wykorzystaniem UAV [7]. Niemniej, kwestia odporności systemów na zawsze możliwe do zaistnienia defekty i awarie, oraz powiązana z tym zagadnieniem wczesna diagnostyka i detekcja towarzyszących im zjawisk pozostaje w dużej mierze otwartym problemem naukowo-technicznym.

1.1 Znaczenie problematyki badawczej

1.1.1 Przyczyny awarii i uszkodzeń bezzałogowych systemów latających

Wraz z szybko rosnącą liczbą potencjalnych aplikacji, jak i samą liczbą BSP (*Bezzałogowych Statków Powietrznych*) w przestrzeni powietrznej, problem zapewnienia odpowiedniego bezpieczeństwa wykonywanych operacji staje się niebanalny. Liczne prace wskazują na najczęściej występujące przyczyny awarii i katastrof UAV. W artykule [8] dokonano meta analizy ponad 150 wypadków i incydentów zgłoszonych w badanym okresie do Agencji Unii Europejskiej ds. Bezpieczeństwa Lotniczego (*EASA*), porównując je z danymi dotyczącymi lotnictwa załogowego. Największą z wykazywanych różnic jest wzajemna proporcja bezpośrednich przyczyn wypadków. Incydenty zostały podzielone w obrębie kilku głównych kategorii, takich jak czynnik ludzki, awarie techniczne, przyczyny środowiskowe oraz zdarzenia wynikające z organizacji przestrzeni powietrznej. Dla systemów bezzałogowych największy udział mają techniczne źródła wypadków lotniczych (ok. 64%). Stoi to w zupełnym kontraście do lotnictwa załogowego, w którym to błąd ludzki odpowiada za najwięcej katastrof - około 75% przypadków. Alternatywne badania [9], stanowiące analizę znacznej liczby awarii wojskowych UAV, wskazują na dominujący udział uszkodzeń układów napędowych i elementów wykonawczych w przyczynach katastrof i incydentów lotniczych. Spośród innych, najczęściej występujących w eksploatacji bezzałogowych systemów latających problemów wskazuje się defekty związane z łącznością i zdalnym pilotażem drona. Warto wskazać, że UAV w porównaniu do załogowych statków powietrznych w ogólności wykazują się większą podatnością na awarie, szacowaną nawet na stukrotnie większą w odniesieniu do liczby wylatanych przez maszynę godzin [9] [10].

O wadze zjawiska świadczy również praktyka lotnicza stosowana w trakcie wykonywania operacji z wykorzystaniem BSP. Do standardowych procedur wymaganych wobec operatorów UAV należy sprawdzenie stanu technicznego oraz mechanizmów bezpieczeństwa maszyny zarówno przed jak i po zakończonym locie [11]. Nakazy obejmują m.in. sprawdzenie stanu wirników, ale też jakość łącza radiowego czy ogólny stan maszyny.


1.1.2 Wpływ awarii na lot UAV

Rozpatrując pewną szczególną kategorię uszkodzeń elementów wykonawczych wielowirnikowych BSP, do bezpośrednich skutków uszkodzenia jednego lub większej ilości wirników nośnych zaliczyć można:

- Utratę właściwości użytkowych napędu śmigłowego mających bezpośredni wpływ na parametry eksploatacyjne systemu latającego. Ze względu na zmianę geometrii płata i naruszenie nominalnego kształtu profilu lotniczego wśród konsekwencji tej klasy awarii wyróżnić można przede wszystkim utratę części ciągu (siły nośnej) generowanej przez jednostkę napędową z uszkodzonym wirnikiem. Zjawisko to wynika ze zmniejszenia powierzchni płata i/lub zwiększenia oporu aerodynamicznego poprzez naruszenie krawędzi natarcia wirnika. Dalszym skutkiem jest zwiększenie poboru mocy przez napęd w danym punkcie pracy, a co za tym idzie ograniczenie zasięgu działania UAV. Z tych samych powodów wykonania przez drona wielowirnikowego zadanej trajektorii lotu wymagana jest praca na innym, mniej efektywnym energetycznie odcinku charakterystyki zestawu napędowego. Szersza analiza sprawności różnych konfiguracji napędów śmigłowych w odmiennych warunkach pracy zawarta została w jednej z prac autora [12], natomiast potwierdzenie empiryczne przytaczanych zjawisk zawarte jest w dalszej części rozdziału.
- Pogorszenie jakości estymacji stanu platformy latającej rozumiane jako zwiększenie niepewności i szumów w danych otrzymywanych za pośrednictwem pokładowego systemu nawigacji inercyjnej - AHRS (*ang. Attitude and Heading Reference System*). W przypadku takich rozwiązań jednym ze składników fuzji sensorycznej są dane z akcelerometrów wykonanych w technologii MEMS (*ang. Micro ElectroMechanical System*). Uszkodzenie oraz idący za tym brak odpowiedniego wyważenia wirujących elementów zwiększa w oczywisty sposób poziom wibracji konstrukcji mechanicznej platformy i w konsekwencji wpływa na dane odczytywane z sensorów przyspieszenia. Zjawisko zostało szerzej opisane w [13]. Niższa dokładność estymowanego wektora stanu UAV, w szczególności takich parametrów jak orientacja i jej pochodne, prowadzą do szeregu problemów związanych ze sterowaniem jednostką w locie, a nawet z zachowaniem jego stabilności [14].

- Potencjalne ryzyko dalszej degradacji uszkodzonego elementu. Zarówno literatura jak i osobiste doświadczenia autora w pilotażu UAV wskazują na znaczne zagrożenie powstające w przypadku kontynuowania lotu z naruszoną nawet w niewielki stopniu konstrukcją wirnika nośnego. Pomimo że w zależności od materiału uszkodzony płat nie musi natychmiast ulec kompletnemu rozerwaniu [15], dalszy lot w takiej sytuacji stanowi narastające ryzyko całkowitej utraty efektywności elementu wykonawczego poprzez kompletne rozerwanie i zniszczenie wirnika. Z uwagi na fakt, że wiele konstrukcji dronów wirnikowych to układy niedosterowane, utrata ciągu nawet dla jednej jednostki napędowej może prowadzić bezpośrednio do upadku maszyny [16].

1.2 Cel pracy



Rys. 1.1: Bezzałogowy statek powietrzny *Falcon* stosowany do rozwijania i ewaluacji metod diagnostycznych przedstawionych w rozprawie

Badania przedstawione w rozprawie wpisują się w program rozwiązania jednego ze szczególnych problemów i zadań zwiększenia bezpieczeństwa eksploatacji BSP. Celem jest zaproponowanie metod wraz z ich praktycznymi implementacjami pozwalającymi na diagnostykę złożonego systemu, jakim jest wielowirnikowy UAV ze względu na pewną szczególną klasę defektów. W szczególności wyróżnić można następujące cele proponowanych w rozprawie rozwiązań:

- Celem diagnostycznym jest wczesne (następujące niezwłocznie po wystąpieniu defektu) wykrycie fizycznych uszkodzeń wirników nośnych takich jak utrata fragmentu płata czy też odkształcenie jego krawędzi natarcia.
- Docelowa implementacja rozwiązań powinna stanowić dedykowany podsystem pokładowy robota latającego, czy to w formie odpowiedniego algorytmu wykonywanego na sterowniku pokładowym, czy też dedykowanych rozwiązań sprzętowych.
- Istotnym celem jest oparcie metod diagnostycznych jedynie o dane z takich sensorów pokładowych, które już znajdują się na pokładzie platformy latającej lub których dodanie nie spowoduje znacznej ingerencji w konstrukcję i parametry lotu maszyny. Wyklucza się zastosowanie zewnętrznych systemów monitorujących pracę drona, na przykład urządzeń typu *motion capture*.
- Algorytmy akwizycji, przetwarzania i klasyfikacji symptomów diagnostycznych powinny być realizowalne z wykorzystaniem dostępnej na pokładzie UAV jednostki obliczeniowej, wykonywane automatycznie i dostarczać odpowiedzi o stanie wirników w skończonym, odpowiednio krótkim czasie. ¹

1.3 Geneza prac nad problemem

Początki prac dotyczących diagnostyki wirników nośnych wywodzą się z obserwacji przebiegu prób statycznych uszkodzonych napędów śmigłowych. W ramach prac nad projektem badawczym „StarTiger Dropter - Terrestrial Dropship Demonstrator”, realizowanym w ramach konsorcjum pod patronatem *Europejskiej Agencji Kosmicznej* [17, 18], do zadań autora należał projekt i dobór systemów napędowych dla specjalistycznego wielowirnikowego UAV o dużym udźwigu. Pojazd stanowił eksperymentalny demonstrator na potrzeby rozwijania technologii związanych z umieszczeniem łazika na powierzchni Marsa z wykorzystaniem systemu „latającego dźwigu”. W trakcie jednego

¹Pod pojęciem odpowiednio niedługiego czasu od wystąpienia symptomów do zgłoszenia awarii przez system zakłada się taki okres, który pozostawia wystarczającą ilość czasu na reakcję operatora lub uruchomienie rozwiązań sterowania tolerującego uszkodzenia - FTC (*ang. Fault Tolerant Control*).

z eksperymentów doszło do uszkodzenia wirników drona i w następstwie tego, odzyskane śmigła poddane zostały testom na stacjonarnej hamowni w celu oceny możliwości ich dalszego wykorzystania i oszacowania utraty wydajności w sytuacji zaistniałych uszkodzeń. Jednocześnie z udziałem autora prowadzone były prace nad nowymi konstrukcjami wielowirnikowych platform latających o zwiększonej odporności na uszkodzenia wirników nośnych.




Rys. 1.2: UAV „Dropter” opracowany w ramach projektu *StarTiger* [17]


Do oceny stanu wirników wykorzystano stacjonarne stanowisko badawcze nazywane „hamownią”. Jest to konstrukcja odzwierciedlająca sposób montażu napędów śmigłowych w stosowanych dronach poprzez odtworzenie w komplecie jednego z ramion konstrukcji. Głównym zastosowaniem urządzenia jest wykonywanie statycznych testów napędów śmigłowych. Układ pomiarowy będący częścią systemu pozwala na rejestrowanie m.in. takich parametrów jak generowany ciąg, prędkość obrotowa wirników czy pobór energii. Szerszy opis konstrukcji zamieszczono w rozdziale 4.5.1.

W ramach przygotowań do testów pogrupowano uszkodzone wirniki względem dwóch rodzajów uszkodzeń. Do analizy przyjęto dwa najbardziej charakterystyczne rodzaje uszkodzeń płata — śmigło z ułamaną końcówką oraz z naruszoną krawędzią natarcia profilu lotniczego.

Seria prostych eksperymentów obejmowała szereg prób realizowanych według zaprogramowanej sekwencji sygnału sterującego. Podczas testów napędy były stopniowo rozpędzane do maksymalnej prędkości obrotowej. Każde podejście powtarzane było kilkakrotnie dla obu uszkodzonych wirników oraz dla wzorcowego, nieuszkodzonego śmigła. Następnie, przebiegi




Rys. 1.3: Widok ogólny hamowni napędów śmigłowych



Rys. 1.4: Przykłady wirników użytych w analizie statycznej - nieuszkodzone (H), z ułamaną końcówką (F), z uszkodzoną krawędzią natarcia (E)

zostały uśrednione dla uwypuklenia stałych trendów i zależności w charakterystykach. Rejestrowane były trzy podstawowe parametry: ciąg generowany przez jednostkę (F_T), prędkość obrotowa wirnika (Ω) i sprawność (moc) jednostkowa zespołu napędowego, rozumiana jako wartość ciągu wygenerowana z jednego wata mocy elektrycznej pobranej przez napęd (η). Przebiegi wyznaczono w funkcji wartości sygnału sterującego PWM (ang. *Pulse Width Modulation*) podawanego na wejścia regulatorów ESC (ang. *Electronic Speed*

Controller). Na wykresach 1.5 przedstawiono wynik analizy przeprowadzonej dla egzemplarzy oznaczonych na ilustracji 1.4.



Rys. 1.5: Zestawienie wyników prób wykonanych na hamowni napędów śmigłowców

Przeprowadzone próby dostarczają następujących wniosków: po pierwsze, uzasadniają wagę problemu, jakim są uszkodzone powierzchnie nośne wirników w odniesieniu do pracy statku powietrznego. Nawet przy tak niewielkiej skali uszkodzeń, ubytek w generowanym przez napęd ciągu jest wyraźnie widoczny, zarówno w przypadku wartości maksymalnych jak i w poszczególnych punktach charakterystyki. Obserwacja prędkości kątowych wirników wskazuje na niewielkie, ale zauważalne różnice, występujące prawdopodobnie ze względu na sposób sterowania realizowany przez ESC w otwartej pętli regulacji. Najbardziej zauważalnym skutkiem uszkodzeń wirników obserwowanym w zarejestrowanych charakterystykach jest znaczny spadek sprawności energetycznej napędu. Prowadzi to do wniosku, że drobne uszkodzenia płatów śmigieł mogą prowadzić do znacznego obniżenia parametrów eksploatacyjnych drona, zwłaszcza takich jak maksymalny zasięg i udźwieg platformy latającej.

Poboczną, ale niemniej istotną dla przedmiotu rozprawy obserwacją było zachowanie uszkodzonych wirników w trakcie pracy ze zwiększającą się prędkością obrotową. Próbom towarzyszyły dwa zjawiska:

- Zwiększone wibracje pracującego zespołu napędowego spowodowane brakiem odpowiedniego wyważenia śmigieł i dodatkowym oporem aerodynamicznym stawianym przez uszkodzone krawędzie. Zjawisko było na tyle silne, że w pewnym zakresie obrotów doprowadziło do wystąpienia drgań rezonansowych z konstrukcją stanowiska badawczego, co widoczne jest w zarejestrowanych przebiegach dla zakresu sygnału sterującego mieszczącego się w przedziale 40-60%.
- Manifestacja zakłóceń mechanicznych w postaci wyraźnie słyszalnego i charakterystycznego świszczącego pogłosu.

Pewne cechy obserwowanych zjawisk, takie jak łatwość ich rejestracji oraz powszechność występowania dla wszystkich uszkodzonych próbek skłoniły autora do dalszych badań nad wykorzystaniem opisanych zjawisk jako źródła informacji pozwalającej na detekcję uszkodzeń wirników nośnych z wykorzystaniem sensorów pokładowych UAV.

1.4 Teza rozprawy

Opisana w punkcie 1.1 problematyka oraz empiryczne obserwacje autora opisane w części 1.3 prowadzą do sformułowania następujących hipotez:

- *Analiza online sygnałów sensorów pokładowych umożliwia wczesne wykrycie i lokalizację uszkodzenia wirnika nośnego robota latającego (platformy wielowirnikowej).*
- *Sygnał wibroakustyczny pochodzący z pracującego wirnika jest wystarczającym źródłem informacji pozwalającym na stwierdzenie uszkodzenia oraz jego identyfikację.*
- *Charakter propagowania się w konstrukcji UAV wibracji generowanych przez uszkodzony wirnik pozwala na zlokalizowanie miejsca wystąpienia uszkodzenia z dokładnością do ramienia konstrukcji.*

1.5 Przegląd zawartości rozprawy

Rozprawa podzielona została na osiem rozdziałów prezentujących w sposób ewolucyjny prace badawcze w tematyce detekcji uszkodzeń wirników nośnych robota latającego.

W pierwszym rozdziale przedstawiono krótki opis problematyki rozprawy, przyczyny jej podjęcia oraz genezę prac autora nad problemem. Zawarte zostały również główne tezy rozprawy, a także streszczenie jej zawartości.

W kolejnym, drugim rozdziale, zamieszczono przegląd bieżących osiągnięć nauki i techniki dotyczących problematyki rozprawy. Opisano stan wiedzy zarówno w szerszym kontekście, dotyczącym problematyki diagnostyki BSP, jak i wskazano obecne obszary poszukiwań rozwiązań diagnostycznych dla różnych klas uszkodzeń elementów wykonawczych. Wskazane zostały prace dotyczące porównywalnych rozwiązań szczegółowych dla problemu technicznego będącego sednem rozprawy.

Rozdział trzeci opisuje charakter i aspekty techniczne rozpatrywanego problemu. W tej części zawarto najpierw teoretyczne rozważania na temat zjawisk towarzyszących lotom z uszkodzonymi wirnikami. W dalszej części rozdziału przedstawiono potwierdzenie hipotez na podstawie eksperymentów wykonanych na rzeczywistym obiekcie oraz wysunięto szereg wniosków i założeń będących podstawą prezentowanych rozwiązań diagnostycznych.

W czwartej części rozprawy opisano prace techniczne wykonane na potrzeby opracowania i walidacji metod diagnostycznych. W pierwszej części omówiony został bieżący stan rozwoju techniki dotyczącej systemów awioniki dla miniaturowych platform latających wraz z analizą możliwości dostosowania wyposażenia BSP do eksperymentów diagnostycznych. Dalsza część rozdziału opisuje w zwięzły sposób zarówno robota latającego będącego główną platformą eksperymentalną, jak i szereg dodatkowych rozwiązań sprzętowych i programistycznych stworzonych przez autora.

W piątym rozdziale zamieszczono opis czterech proponowanych metod diagnostycznych. Zastosowano ewolucyjną kolejność prezentacji, od najprostszego algorytmu wibrometrycznego do najbardziej skutecznej, opar-

tej o sygnały akustyczne metody. Wnioski wyciągane na każdym z etapów posłużyły do ulepszania kolejnych rozwiązań. Opisy zawierają wstępne założenia oraz cząstkowe analizy i eksperymenty uzasadniające podejmowanie poszczególnych decyzji na etapie projektowym. Przedstawione są kolejne etapy przetwarzania sygnałów wibroakustycznych i modele stosowanych klasyfikatorów.

Szósta część rozprawy stanowi zwięzły opis serii przeprowadzonych eksperymentów walidacyjnych. Omówione zostały rozpatrywane typy i klasy uszkodzeń, metodyka prowadzenia badań i liczebność zebranych zbiorów danych.

W rozdziale siódmym szeroko omawiane są uzyskane rezultaty. Wyniki prezentowane są kolejno dla każdej z proponowanych metod i dokonywane jest porównanie możliwości i skuteczności poszczególnych algorytmów.

Rozdział ósmy stanowi podsumowanie rozprawy. W jego ramach zebrano kluczowe wnioski dotyczące rozwiązań sformułowanego problemu diagnostycznego i odniesiono je do postawionych hipotez badawczych. Omówiono również potencjalne możliwości rozwoju i implementacji omawianych metod.

Stan wiedzy dotyczącej diagnostyki uszkodzeń rotorów UAV

2.1 Wstęp

Problem automatycznej diagnostyki uszkodzeń elementów wykonawczych w odniesieniu do BSP spotkał się w ostatnich latach z zainteresowaniem zarówno ze strony środowisk naukowych, jak i sektora komercyjnego. Jednym z niewielu oferowanych na rynku przykładów jest rozwiązanie wprowadzone w najbardziej zaawansowanych konstrukcjach przodującego producenta wielowirnikowych UAV *DJI Technology Ltd.* Model *Matrice 300 RTX* i pokrewne mu platformy latające wyposażone są w mechanizm pozwalający w przypadku wykrycia utraty wirnika na rekonfigurację układu napędowego i awaryjne, ale kontrolowane lądowanie. Trajektoria wykonywana jest z wykorzystaniem jedynie trzech z czterech wirników. Niemniej, w przytoczonym rozwiązaniu algorytm detekcji jest maksymalnie uproszczony i skupia się na progowym wykryciu zmiany prędkości obrotowej rotora [19]. Nie zapewnia też wczesnej diagnostyki w przypadku częściowego zniszczenia wirnika. Inne rozwiązania podobnej kategorii bardzo rzadko wychodzą poza stadium koncepcji.

Zagadnienie jest dużo szerzej dyskutowane w obszarze badań naukowych i tworzenia eksperymentalnych prototypów [20]. W szerszym kontekście wpisuje się w ideę sterowania tolerującego uszkodzenia (FTC), którego podstawowym zadaniem jest zapewnienie pewnej minimalnej wydajności systemu i kontynuowanie jego działania w przypadku wystąpienia różnorodnych uszkodzeń i błędów — zarówno w oprogramowaniu, jak i komponentach sprzętowych [21]. Takie systemy dzielą się na dwa podstawowe typy: pasywne i aktywne. Pierwsza kategoria oznacza projektowanie takich układów sterowania, które są wystarczająco odporne, aby spełnić kryteria FTC w przypadku wystąpienia uszkodzeń. Do tych metod zaliczyć można przykładowo zastosowanie redundantnych sensorów i elementów wykonawczych czy mechanizmy sterowania odpornego [22]. Drugi rodzaj rozwiązań jest

niejednokrotnie bardziej złożony i opiera się na dwóch zasadniczych fazach: wykryciu uszkodzenia i odpowiedniej reakcji na wystąpienie awarii. Funkcje pierwszej fazy dekomponuje się powszechnie na dwa lub trzy zadania szczegółowe [23, 24]:

- Detekcję — wykrycie wystąpienia uszkodzenia w sposób jednoznaczny, z wykluczeniem zakłóceń wynikających np. z szumów czy nietypowych warunków pracy.
- Lokalizację — precyzyjne wskazanie miejsca wystąpienia awarii i/lub jego momentu. Termin może odnosić się zarówno do wskazania konkretnego, wadliwego podzespołu, jak i fragmentu całego procesu.
- Identyfikację (klasyfikację) — określenie rozmiaru i typu zaistniałej awarii.

Warto zaznaczyć, że znaczna część prac z zakresu technik diagnostycznych w sterowaniu łączy dwa ostatnie etapy w jeden, wprowadzając termin *separacji* uszkodzenia i niejako dzieląc proces na wstępne wykrycie oraz szczegółową identyfikację wszystkich parametrów zaistniałej wady procesu. Powszechnie przyjęte jest oznaczanie systemów tego typu jako FDI (*ang. Fault Detection and Isolation*).

2.2 Podstawowe schematy diagnostyczne

Badania dotyczące metod wczesnej diagnostyki uszkodzeń skupiają się w dwóch głównych obszarach [25]. Pierwsza grupa rozwiązań, historycznie starsza i będąca niejako podejściem klasycznym to metody oparte o modele matematyczne procesów. Sednem algorytmu FDI jest w takim wypadku porównanie fizycznych obserwacji wyjść procesu z estymatami uzyskanymi za pomocą modelu obiektu, a następnie wygenerowanie sygnałów, które odzwierciedlają potencjalną nieprawidłową pracę systemu [26]. Sygnały te, zwane residuami, stanowią następnie podstawę do wnioskania o wystąpieniu uszkodzenia. W kolejnym etapie procesu otrzymane wartości są porównywane z predefiniowanymi parametrami progowymi charakteryzującymi nominalny zakres pracy. Ostatecznie, na podstawie określonego zestawu

reguł, w wyniku ewaluacji residuów system podejmuje decyzję o zgłoszeniu uszkodzenia o określonym charakterze.

W wielu aplikacjach w charakterze modelu obiektu z powodzeniem stosowano modele analityczne, relacje parzystości, różnego rodzaju obserwatory stanu czy odmiany filtru Kalmana [27, 28]. Jednakże możliwość zastosowania tej kategorii metod diagnostycznych ogranicza często wymóg opracowania dokładnego modelu procesu i konieczność szczegółowego doboru zasad ewaluacji residuów. Dla wielu złożonych lub ograniczonych co do możliwości pomiaru zmiennych stanu procesów takie rozwiązanie nie jest możliwe do zastosowania lub nie dostarcza informacji o wystarczającej jakości [25, 27].

Wraz z rozwojem technik inteligencji maszynowej popularność zyskało zastosowanie takich mechanizmów jak klasyczne i głębokie sztuczne sieci neuronowe [29, 30], logika rozmyta [31, 32], systemy eksperckie czy też rozwiązania hybrydowe. Stosowane są one zarówno do modelowania procesu, jak i w części wnioskującej oraz klasyfikującej uszkodzenia. Z jednej strony, uczenie maszynowe może stanowić część podejścia opartego o model matematyczny, z drugiej — stanowić podstawę drugiej kategorii rozwiązań, tj. systemów diagnostycznych opartych na wiedzy i danych (ang. *data-driven*) [33].

W tym drugim przypadku analiza poprawności przebiegu procesu pod kątem diagnostycznym zazwyczaj dokonywana jest z wykorzystaniem szeroko rozumianego modelu statystycznego opartego na długotrwałej obserwacji zachowania systemu [34]. Na podstawie wiedzy uzyskanej zarówno w warunkach pracy nominalnej, jak i przy wystąpieniu określonych klas uszkodzeń, tworzony jest statystyczny wzorzec symptomów dla każdej z sytuacji. Uczenie maszynowe pozwala nie tylko na modelowanie badanego procesu, ale też na samoczynne wyznaczanie wartości charakterystycznych i wskaźników potrzebnych w diagnostyce [28, 27]. Zaletą tego podejścia jest możliwość analizy obiektów przy niewielkiej lub nawet zerowej znajomości ich struktury wewnętrznej [28]. Źródłem informacji o uszkodzeniach nierzadko stają się cechy statystyczne uzyskane za pomocą analizy i przetwarzania sygnałów niezwiązanych bezpośrednio z wyjściami obiektu, takich jak na przykład wibracje.

Systemy diagnostyczne tej kategorii wykorzystują największe zalety uczenia maszynowego — zdolność do samouczenia i generalizacji. Zasadniczo, wyróżnić można dwa, analogiczne do ogólnej kategoryzacji uczenia maszynowego podejścia: diagnostyka z wykorzystaniem uczenia nadzorowanego i nienadzorowanego [35, 36]. W przypadku pierwszego z nich rejestrowany jest szeroki zbiór danych uczących, a proces tworzenia modelu statystycznego odbywa się za pomocą predefiniowanych etykiet i klas narzucanych odgórnie dla każdego przypadku. Istnieją też skuteczne podejścia do diagnostyki nienadzorowanej [37], gdzie celem algorytmu jest samoczynne, inteligentne grupowanie symptomów uzyskanych przy różnych stanach uszkodzeń.

Odnosząc przedmiot rozprawy do przedstawionego kontekstu, prace autora wnoszą szereg propozycji schematów FDI opartych o podejście *data driven* ze szczególnym wykorzystaniem technik uczenia maszynowego i analizy sygnałów dla rozwiązania opisanego w rozdziale 1 konkretnego problemu technicznego.

2.3 Przegląd rozwiązań szczegółowych

2.3.1 Kontekst historyczny

Przeгляд rozwiązań w zakresie diagnostyki uszkodzeń wirników dronów warto rozpocząć od nakreślenia aktualnego kontekstu badań w powiązanych obszarach. Historycznie, pierwsze prace dotyczące metod FDI i FTC dla statków powietrznych zaczęto publikować i wdrażać już w latach 70. i 80. Moment ten wyznaczany jest poprzez upowszechnienie się w lotnictwie cyfrowych systemów sterowania i technologii *fly-by-wire* [38]. Należy jednak zaznaczyć, że teoretyczne prace w obszarze diagnostyki od początku obejmowały między innymi statki powietrzne jako urządzenia o wysokim wymaganym stopniu niezawodności [39]. Dzięki przejęciu zadania bezpośredniej realizacji sterowania statkiem powietrznym z pilota na kontrolowane komputerowo układy elektromechaniczne i hydrauliczne możliwa stała się implementacja teoretycznych modeli diagnostycznych. Oczywiście pasywne rozwiązania sterowania tolerującego uszkodzenia, takie jak redundantne sensory czy zwielokrotnione drogi sterowania elementami wykonawczymi, są obecne od początku istnienia nowoczesnego lotnictwa.

Wraz z rozwojem całej gałęzi nauki, wzrostem mocy obliczeniowej komputerów pokładowych oraz rosnącą świadomością i wymogami co do bezpieczeństwa lotów, inteligentne systemy diagnostyczne stały się powszechnym elementem składowym współczesnych statków powietrznych. Na przestrzeni ostatniej dekady miał miejsce gwałtowny rozwój sektora lotnictwa bezzałogowego. Otworzyło to nowe pole badawcze, w którym prowadzi się próby zarówno adaptacji pełnoskalowych rozwiązań dla mniejszych, jak i niejednokrotnie prostszych konstrukcyjnie maszyn lub tworzy się metody nowe, dedykowane dla odmiennych konstrukcji, miniaturowych sensorów i innej klasy aktuatorów [40]. UAV charakteryzują się prostszą budową i zdecydowanie niższym stopniem redundancji sprzętowej. Jest to często wymuszone poprzez ograniczenia rozmiaru, maksymalnej masy startowej i kosztu tego typu maszyn. Również jednostki obliczeniowe, pomimo rosnącej dostępnej mocy, ograniczone są ze względu na udźwig i rozmiar drona. Pewne podobieństwa, ale i znaczące różnice spowodowały, że opracowywanie nowych metod diagnostycznych musiało zostać dostosowane do innego typu danych, skupiać się na innej klasie i typie uszkodzeń oraz charakteryzować się złożonością obliczeniową możliwą do praktycznej implementacji [23].

2.3.2 Diagnostyka UAV

Publikowane w literaturze opisy metod FDI dla bezzałogowych pojazdów latających koncentrują się głównie na diagnostyce sensorów oraz elementów wykonawczych [23]. Pierwsza z kategorii jest dość obszernie reprezentowana w literaturze naukowej [41]. Prace skupiają się na wykrywaniu kilku głównych kategorii defektów, takich jak czasowy dryft mierzonej wartości, niepożądana składowa stała czy nagły zanik sygnału pomiarowego [42, 43]. Analizowane sensory to głównie jednostki nawigacji inercyjnej IMU (*ang. Inertial Measurement Unit*) wyposażone w czujniki MEMS, ale publikowane są też prace dotyczące detekcji błędów systemów nawigacji satelitarnej [44]. Z drugiej strony, liczne artykuły opisują schematy diagnostyczne ukierunkowane na wykrywanie uszkodzeń aktuatorów. Najwięcej źródeł dotyczy UAV zbudowanych jako płatowce i opisuje diagnostykę takich defektów jak wadliwe działanie powierzchni sterowych (*offset*, *zablokowanie*) [45, 46, 47] czy też uszkodzenia napędów śmigłowych [48]. Nieliczne prace opisujące aplikacje na wielowirnikowych bezzałogowych statkach powietrznych zostały szczegółowo przytoczone w dalszej części rozdziału.

Zauważalnym zjawiskiem jest bardzo częste opieranie badań na danych pozyskanych z wykorzystaniem symulacji komputerowych. W wielu pracach autorzy wskazują, że jest to spowodowane między innymi sporą trudnością w odtworzeniu i zebraniu odpowiednich pomiarów na rzeczywistych UAV ze względu na oczywiste ryzyko utraty maszyny. W rezultacie, do symulowanych sygnałów dodawane są sztuczne modele uszkodzeń (tzw. *fault injection* [49]) w postaci predefiniowanych przebiegów zmiennych stanu opisywanych funkcjami matematycznymi.

Znaczącym problemem jest znacznie mniejsza proporcja prac stanowiących połączenie metod FDI i mechanizmów FTC w jeden sekwencyjny proces. Wskazywane są potencjalnie problematyczne obszary w praktycznym współdziałaniu obu etapów [50]. Niejednokrotnie, prace z obszaru sterowania tolerującego uszkodzenia traktują temat diagnostyki pobieżnie, ograniczając się jedynie do prostego symulowania uszkodzeń do celu ewaluacji rozwiązań FTC.

2.3.3 Badania stanu wirników nośnych

Publikowane prace dotyczące ściśle diagnostyki wirników nośnych latającego robota wielowirnikowego rozpatrywać można w kilku kategoriach, w zależności od założeń, metod i typu wykrywanego uszkodzenia. Szeroko reprezentowane są badania wykorzystujące podejście oparte o modele matematyczne obiektu [51, 52]. Warto w tym miejscu wyróżnić serię powiązanych prac, w których w kompleksowy sposób zademonstrowano skuteczność rozwiązania z tej kategorii. Artykuły opisują najpierw propozycję rozwiązania diagnostycznego opartą o nieliniowy obserwator i analityczną ewaluację residuów [53], a następnie przedstawiają próby optymalizacji i ulepszania metody z wykorzystaniem mechanizmów adaptacyjnych i dodatkowych filtrów strumienia danych sensorycznych [54]. W ostatniej pracy [55] pokazana jest praktyczna implementacja i ewaluacja metody, nieodbiegająca znacznie od wstępnych analiz symulacyjnych. Warto spostrzec, że sam model uszkodzenia jest mocno uproszczony — jest to sztuczne modyfikowanie sygnału sterującego dla napędu śmigłowego, co skutkuje dodaniem predefiniowanej składowej stałej lub liniowe ograniczenie sygnału zadanego. Technika ta nazywana jest symulowaną utratą efektywności, LOE (*ang. Loss Of Effectiveness*).

Innym przykładem badań połączonych z praktyczną implementacją jest praca [56]. W artykule przedstawiono z jednej strony znane podejście z modelem analitycznym i nieliniowym obserwatorem, z drugiej — kompletną implementację systemu diagnostycznego wraz z towarzyszącym mechanizmem FTC. Na uwagę zasługuje badany obiekt będący dronem o 8 wirnikach zgrupowanych w cztery podwójne, przeciwbieżne napędy śmigłowe. Wykrywane uszkodzenia to kompletny zanik ciągu jednej z jednostek, a strategia sterowania tolerującego uszkodzenia to rekonfiguracja praw sterowania w celu wykorzystania redundantnych wirników. Niemniej, dzięki podejściu opartemu o wykorzystanie platformy latającej o dużym zapasie stabilności, możliwe było pełne przetestowanie i zaimplementowanie rozwiązania w rzeczywistym scenariuszu.

Nieliczne prace dotyczą innych typów uszkodzeń wirników. Przykładowo, w artykule [57] wykorzystanie klasycznego podejścia opartego o obserwator i ewaluację residuów pozwala na wykrycie zablokowania sygnału sterującego na stałej wartości. Bardziej szczegółowej analizy defektów samego napędu dostarcza z kolei praca [58]. Przedstawia metody wykrywania zużycia łożysk w silniku lub wzrostu rezystancji uzwojenia. Artykuł opisuje następnie wykorzystanie sterowania predykcyjnego opartego o zestaw modeli w postaci instancji filtra Kalmana predefiniowanego dla różnych stanów uszkodzeń. Interesujący wydają się zwłaszcza ostatni aspekt, tj. probabilistyczne przełączanie większej liczby modeli obiektu w zależności od wyniku ewaluacji residuów i dobranie takiego, który najlepiej opisuje zaistniałe uszkodzenie i pozwala na najlepsze sterowanie w bieżącej sytuacji awaryjnej.

Dla zagadnienia oceny LOE wirnika robota latającego opracowano także metody hybrydowe. Przykładem jest praca [59], w której do diagnostyki wykorzystano inteligentny, samouczący się obserwator. W artykule przedstawiono również zakończoną sukcesem implementację rozwiązania na platformie latającej *Quanser QBall X4*.

Przegląd zawartości literatury wskazuje, że nie istnieją metody oparte o model obiektu, które pozwalałyby na skuteczną diagnostykę w zastosowaniu do problemu stawianego w rozprawie. Nieco szerzej temat poruszany jest w obszarach FDI wykorzystujących algorytmy *data driven*, a zwłaszcza oparte o przetwarzanie sygnałów. W pracy [60] opisany jest złożony system oparty o metody uczenia głębokiego, a w szczególności o sieci z komórkami LSTM

(ang. *Long Short-Term Memory*). W tej metodzie klasyfikator uczony jest na podstawie wartości zmiennych stanu, takich jak orientacja, prędkości kątowe statku powietrznego i sygnały sterujące dla napędów. W dalszej kolejności prowadzone jest wnioskowanie, które pozwala wykryć występowanie na dronie jednego, znacznie uszkodzonego wirnika ze skutecznością około 92%.

W przypadku metod wykorzystujących przetwarzanie sygnałów spotkać można dwa główne źródła informacji o uszkodzeniu: wibracje konstrukcji UAV oraz zapis sygnałów akustycznych — pogłosu emitowanego przez pracujące wirniki. W tej pierwszej grupie wyróżnić można dwie publikacje. W jednej z nich [61] przedstawiono rozbudowany system diagnostyczny oparty o kilka sensorów IMU oraz układy rejestrujące prąd uzwojeń silników BLDC (ang. *BrushLess Direct Current*). Następnie, wieloetapowy algorytm, oparty m.in. o logikę rozmytą, klasyczne sztuczne sieci neuronowe i algorytmy genetyczne pozwala na wykrycie uszkodzenia pojedynczego wirnika ze skutecznością powyżej 94%. Jako wektor cech wykorzystywane jest zestawienie wybranych harmonicznym prądu uzwojeń oraz cechy statystyczne sygnału wibracyjnego. Rozwiązanie oparte jest o dane z rzeczywistych lotów cztero-wirnikowego UAV. W drugiej z prac [62] przedstawiony jest system, który na podstawie pomiarów z pokładowego akcelerometru i ich analizę z wykorzystaniem filtru Kalmana pozwala na wykrycie braku poprawnego wyważenia konkretnego wirnika. Przyjęto założenie, że takie zjawisko jest tożsame z jego uszkodzeniem. Metodę zweryfikowano z sukcesem w warunkach pracy w czasie rzeczywistym dla kilku różnych dronów o odmiennej liczbie wirników. Widoczną cechą rozwiązania jest bardzo długi czas estymacji i zgłoszenia uszkodzenia, wynoszący od kilkunastu do ponad kilkudziesięciu sekund dla największego, sześciowirnikowego UAV.

W ciągu dwóch ostatnich lat w literaturze pojawił się szereg artykułów opisujących wykorzystanie sygnału akustycznego do diagnostyki omawianego problemu. Publikowane badania obejmują różne kategorie rozwiązań, dla których wyróżnić można wspólną, trój etapową konstrukcję algorytmu. Pierwszym krokiem jest rejestrowanie odgłosu wydawanego przez pracujące wirniki. Następnie, proponuje się wykorzystanie narzędzi statystycznych do ekstrakcji charakterystycznych cech sygnału dla różnych stanów uszkodzeń. Ostateczne wnioskowanie w kroku trzecim wykonywane jest najczęściej z wykorzystaniem algorytmów uczenia maszynowego. Proste podejście z wykorzystaniem jedynie pomiaru natężenia fali akustycznej zaprezentowano

w [63]. Eksperyment polegał na umieszczeniu nieruchomego, pracującego drona na statywie i rejestrowaniu dźwięku zewnętrznym urządzeniem. Do symulowania uszkodzenia ponownie wykorzystano zmianę wyważenia wirnika. W dalszej kolejności do klasyfikacji użyto klasycznej sztucznej sieci neuronowej typu MLP (*ang. MultiLayer Perceptron*). Autorzy deklarują skuteczność detekcji na poziomie ponad 98%, jest to jednak rozwiązanie bardzo prototypowe ze względu na wspomnianą metodykę eksperymentu. Pokazuje jednak spory potencjał w tego typu źródle informacji o uszkodzeniu. Inne, bardziej rozbudowane podejście analizujące faktyczne uszkodzenia wirników, zewnętrzny system akwizycji i drona w locie zaprezentowano w [64]. W tym przypadku skuteczność klasyfikacji uszkodzenia z wykorzystaniem konwolucyjnej sieci neuronowej wynosiła jedynie około 90%. Dużo bardziej rozbudowana jest praca [65]. Omawiana w niej metoda polega na stacjonarnych testach samych jednostek napędowych wielowirnikowego UAV. Analizie poddane zostało kilka różnych silników o odmiennej mocy i zakresie obrotów. Dźwięk rejestrowany jest ponownie za pomocą urządzenia zewnętrznego w długich oknach czasowych wnoszących niejednokrotnie ponad 1 sekundę. Następnie opracowano szereg klasyfikatorów opartych o cechy statystyczne sygnału i różne metody klasycznego uczenia maszynowego. Prezentowane rozwiązanie pozwala na wykrycie czterech klas uszkodzeń — ułamanie wirnika, przemieszczenie magnesów stałych w silniku, uszkodzenia łożysk oraz defekty uzwojenia stojana. Deklarowana skuteczność metody jest bardzo wysoka i w wybranych konfiguracjach silnika i algorytmu klasyfikacji sięga blisko 100%.

2.4 Dyskusja

Analiza obecnego stanu wiedzy dotyczącej rozwiązań omawianego w rozprawie problemu technicznego prowadzi do szeregu wniosków:

- Do praktycznej detekcji i identyfikacji uszkodzeń polegających na fizycznym zniszczeniu fragmentu płata wirnika nośnego UAV zastosowanie znajdują w pierwszej kolejności metody oparte o analizę sygnałów i uczenie maszynowe. Schematy diagnostyczne oparte o techniki modelowania matematycznego przeważnie skupione są jedynie na symptomie rzeczonoego uszkodzenia, jakim jest utrata efektywności elementu wykonawczego. Symulowane są znaczne spadki ciągu, niejednokrotnie na poziomie 20-50% wartości maksymalnej. Tymczasem doświadczenia

omawiane w sekcji 1.3 rozprawy pokazują, że wirniki z wydajnością ograniczoną w znacznie mniejszym stopniu stanowią ryzyko dla dalszej eksploatacji maszyny oraz znacznie zmniejszają jej osiągi.

- Zawarte w literaturze opisy metod *data-driven* charakteryzują się powszechnie bardzo syntetycznymi zbiorami danych uzyskiwanymi w trakcie eksperymentów. Do przykładów stosowanych praktyk należy zaliczyć przede wszystkim wykorzystanie zewnętrznych, zaawansowanych systemów pomiarowych (mikrofonów, akcelerometrów), których montaż i praca na pokładzie BSP w locie jest niemożliwa ze względu na wymiary, wagę czy dostępną moc obliczeniową. Wiele eksperymentów wykonywanych jest przy bardzo wąskim studium przypadków, na przykład dla wirnika pracującego ze stałą prędkością lub drona pozostającego w zawisie. Tymczasem charakter sterowania wielowirnikowego drona zakłada częste i agresywne sterowanie prędkością kątową napędów dla stabilizacji lotu.
- Dostrzegalny jest pewien kompromis pomiędzy czasem zadziałania metody diagnostycznej oraz sposobem akwizycji danych, a jej skutecznością. Literatura przytacza rozwiązania oparte zarówno o analizę wibracji, jak i sygnałów akustycznych osiągające blisko 100% poprawnych klasyfikacji. Charakteryzują się jednak one albo długim czasem działania [62, 63], albo wykorzystaniem wspomnianych już zewnętrznych sensorów [65]. Prace oparte o sensory pokładowe i dane rejestrowane w długim oknie czasowym dla szerszego wachlarza przypadków osiągają dokładność detekcji na znacznie mniejszym poziomie, sięgającym 90-94% [62, 61, 60].
- Prezentowane w literaturze prace rzadko odnoszą się do zagadnienia lokalizacji uszkodzenia lub identyfikacji jego typu. Jeszcze rzadziej algorytmy realizują obydwa te etapy równocześnie.

Cechy specyficzne obiektu diagnostyki

W poniższym rozdziale omówione są charakterystyczne właściwości obiektu diagnostyki. Opisywane są aspekty techniczne wielowirnikowego, bezzałogowego statku powietrznego oraz jego opis na podstawie modelu matematycznego. W dalszej części zawarto rozważania na temat zjawisk fizycznych towarzyszących uszkodzeniom wirników nośnych. Przytaczane są przykłady literatury dotyczącej zbliżonych tematycznie zagadnień diagnostycznych. Opisana jest próba oszacowania spadku osiągnięć wielowirnikowej maszyny latającej na podstawie wykonanych eksperymentów. Ostatnia i zasadnicza część rozdziału zawiera empiryczne obserwacje widm sygnałów wibracyjnych zarejestrowanych w trakcie lotów przy różnych parametrach uszkodzeń. Kluczowymi wnioskami z analizy jest szereg obserwacji definiujących podstawowe mechanizmy i potencjalne ograniczenia planowanych rozwiązań diagnostycznych.

3.1 Model wielowirnikowego UAV

Koncepcja wielowirnikowego statku powietrznego opiera się na założeniu wykorzystania zwielokrotnionych jednostek napędowych do zastąpienia charakterystycznego dla klasycznych śmigłowców układu napędowego. Oznacza to znaczne uproszczenie konstrukcji mechanicznej rotora. Skomplikowany system cięgien i przegubów, pozwalający na sterowanie kątem natarcia łopat i pochyleniem płaszczyzny wirnika, zastępowany jest bezpośrednim montażem śmigła o stałym skoku na sztywnym wale. Ogranicza to znacznie liczbę ruchomych części, co przekłada się na zyski zarówno pod względem kosztów konstrukcji, jak i jej niezawodności [66]. Sterowanie UAV o większej liczbie wirników opiera się na różnicowaniu ciągu poszczególnych jednostek napędowych, co z kolei poprzez zmianę momentów działających na konstrukcję drona skutkuje zmianą orientacji. Z uwagi na fakt, że typowy wielowirnikowy dron jest układem niedosterowanym [67], ruch postępowy w płaszczyźnie poziomej realizowany jest dzięki zmianie orientacji i co za tym idzie — wypadkowego wektora ciągu. Wraz ze wzrostem zainteresowania


statkami powietrznymi tej klasy opracowano szereg modeli dla szerokiej gamy różnych odmian wielowirnikowców [67, 68, 69]. Charakterystyki pracy wirników nośnych są w nich jednym z kluczowych czynników wpływających na sterowanie obiektem. Analiza parametrów modelu związanych z rotorem stanowi potencjalne źródło informacji dla celów diagnostyki jego uszkodzeń.

3.1.1 Równania dynamiki

Na potrzeby rozprawy przytacza się jeden z powszechnie dostępnych modeli opisujący statek powietrzny w konfiguracji X8 [70]. Oznacza to maszynę o symetrycznej budowie i czterech ramionach. Wyposażona jest w 8 jednostek napędowych zgrupowanych parami w przeciwbieżne układy współosiowe. Jest to jednocześnie wariant konstrukcyjny UAV wykorzystywany do weryfikacji prezentowanych w dalszej części pracy rozwiązań. Szczegółowy opis wykorzystanej w eksperymentach maszyny zawarto w podrozdziale 4.2.

Konstrukcje tej klasy cechują się dużym udźwigiem i dynamiką przy zachowaniu niewielkich gabarytów platformy [12, 71]. Niezaprzeczalnie użyteczną cechą jest zwiększona niezawodność omawianej konfiguracji kinematycznej. Zapewnia ją nadmiarowa liczba wirników. Pod pojęciem niezawodności rozumiana jest zarówno zdolność do kontynuacji lotu w przypadku utraty jednego z wirników, jak i ogólnie zwiększona odporność na zewnętrzne zakłócenia w locie [72].

Podstawowy schemat kinematyczny wielowirnikowego drona w konfiguracji X8 przedstawiono na rysunku 3.1. Opis oparty jest na powszechnie stosowanej w lotnictwie konwencji kątów *roll-pitch-yaw*, w globalnym układzie współrzędnych odnoszonym do układu kierunków *North-East-Down*. W ujęciu klasycznym są to kąty Eulera w sekwencji obrotów wokół osi Z-Y-X. Bazowymi zmiennymi sterującymi lotem są prędkości kątowe wirników oznaczane Ω_i , odpowiednio dla i-tej jednostki. Napędy w górnej płaszczyźnie oznaczone są numerami nieparzystymi, analogicznie dolne cztery przypisane mają numery parzyste. W obrębie każdej pary kierunek wirowania jest przeciwny. W podobny sposób, każde dwa przyległe do siebie napędy również pracują przeciwbieżnie. Ma to na celu kompensację momentu reakcyjnego ge-



Rys. 3.1: Schemat kinematyczny i koncepcja wielowirnikowego UAV w konfiguracji X8

nerowanego przez każdy z wirników. Dla tak opisanej kinematyki platformy zdefiniować można następujące prawa sterowania:

$$U_1 = K_T \sum_{i=1}^8 \Omega_i^2 \quad (3.1)$$

$$U_2 = dK_T(\Omega_7^2 + \Omega_8^2 - \Omega_3^2 - \Omega_4^2) \quad (3.2)$$

$$U_3 = dK_T(\Omega_5^2 + \Omega_6^2 - \Omega_1^2 - \Omega_2^2) \quad (3.3)$$

$$U_4 = K_D(\Omega_2^2 + \Omega_4^2 + \Omega_6^2 + \Omega_8^2 - \Omega_1^2 - \Omega_3^2 - \Omega_5^2 - \Omega_7^2) \quad (3.4)$$

Gdzie U_1 jest to całkowity generowany ciąg, U_2 - sterowanie obrotem w kącie *roll*, U_3 - analogiczne wymuszenie dla *pitch*, natomiast U_4 opisuje wymuszenie dla obrotu w *yaw*. $K_T[Nm.s^2]$ jest wyznaczaną przeważnie empirycznie stałą wyrażającą stosunek generowanego ciągu do kwadratu prędkości kątowej wirnika, natomiast $d[m]$ odległością między osią wału wirnika a geometrycznym środkiem wielowirnikowca. Pierwszy z tych parametrów omawiany jest szerzej w dalszej części rozdziału. Ostatni wspomniany współczynnik

K_D opisuje opór aerodynamiczny. Tym samym, konfiguracja kinematyczna tego konkretnego wielowirnikowca może zostać opisana w czytelnej postaci macierzowej:

$$\begin{bmatrix} U_1 \\ U_2 \\ U_3 \\ U_4 \end{bmatrix} = \begin{bmatrix} K_T & K_T & K_T & K_T & K_T & K_T & K_T & K_T \\ 0 & 0 & -dK_T & -dK_T & 0 & 0 & dK_T & dK_T \\ -dK_T & -dK_T & 0 & 0 & dK_T & dK_T & 0 & 0 \\ -d & d & -d & d & -d & d & -d & d \end{bmatrix} \begin{bmatrix} \omega_1^2 \\ \omega_2^2 \\ \omega_3^2 \\ \omega_4^2 \\ \omega_5^2 \\ \omega_6^2 \\ \omega_7^2 \\ \omega_8^2 \end{bmatrix} \quad (3.5)$$

Na podstawie powyższego opisu i przy założeniu sztywnej, symetrycznej budowy UAV o odpowiednio ułożonym lokalnym układzie współrzędnych wyprowadzić można następujące równania dynamiki ruchu dla sześciu stopni swobody:

$$\ddot{x} = \frac{U_1}{m}(\sin \psi \sin \phi + \sin \psi \sin \theta \cos \phi) \quad (3.6)$$

$$\ddot{y} = \frac{U_1}{m}(-\cos \psi \sin \phi + \sin \psi \sin \theta \cos \phi) \quad (3.7)$$

$$\ddot{z} = -g + \frac{U_1}{m}(\sin \theta \cos \phi) \quad (3.8)$$

Równania 3.5, 3.6 oraz 3.7 opisują dynamikę ruchu postępowego przy założeniu, że $m[kg]$ jest to całkowita masa drona, natomiast $g[m/s^2]$ oznacza przyspieszenie ziemskie. Równania dynamiki ruchu określające rotację statku powietrznego przedstawiają się następująco:

$$\ddot{\phi} = \dot{\theta}\dot{\psi}\left(\frac{I_{yy} - I_{zz}}{I_{xx}}\right) - \frac{J_x}{I_{xx}}\dot{\theta}\Omega + \frac{d}{I_{xx}}U_2 \quad (3.9)$$

$$\ddot{\theta} = \dot{\phi}\dot{\psi}\left(\frac{I_{zz} - I_{xx}}{I_{yy}}\right) - \frac{J_x}{I_{yy}}\dot{\phi}\Omega + \frac{d}{I_{yy}}U_3 \quad (3.10)$$

$$\ddot{\psi} = \dot{\phi}\dot{\theta}\left(\frac{I_{xx} - I_{yy}}{I_{zz}}\right) + \frac{1}{I_{zz}}U_4 \quad (3.11)$$

Gdzie $I_{xx,yy,zz}$ oznaczają odpowiednio główne momenty bezwładności wokół kolejnych osi, a J całkowity moment bezwładności statku powietrznego. Parametr Ω oznacza bilans ciągu dla platformy latającej, opisywany dla drona w konfiguracji X8 równaniem:

$$\Omega = -\Omega_1 + \Omega_2 - \Omega_3 + \Omega_4 - \Omega_5 + \Omega_6 - \Omega_7 + \Omega_8 \quad (3.12)$$

3.2 Zjawiska fizyczne towarzyszące pracy uszkodzonych wirników

Wprowadzony w równaniach 3.1 - 3.4 współczynnik K_T definiowany jest następująco [73]:


$$K_T = C_T \rho A_r r^2, \quad (3.13)$$

gdzie ρ oznacza gęstość powietrza, A_r jest to powierzchnia dysku wirującego śmigła, r to jego promień, natomiast C_T jest to nieujemny współczynnik związany z parametrami geometrycznymi płatów wirnika, takimi jak skok czy kształt profilu lotniczego. Powszechnie stosowana jest eksperymentalna metoda jego wyznaczania [66], jako że przy okazji uwzględniana jest utrata części ciągu ze względu na aerodynamiczny wpływ kolizji generowanego strumienia powietrza z konstrukcją ramienia drona.

Analiza modelu matematycznego wielowirnikowego UAV dostarcza wyraźnych wskazówek do interpretacji wyników eksperymentów wykonanych na hamowni napędów śmigłowych. Z jednej strony, utrata fragmentu płata zmniejsza efektywny promień i powierzchnię dysku wirującego śmigła. Z drugiej, zarówno uszkodzenie tego rodzaju, jak i naruszenie krawędzi natarcia profilu powoduje jego odkształcenie oraz zwiększenie oporu aerodynamicznego.

nego w trakcie wirowania. Skutkuje to dalszym pogorszeniem właściwości użytkowych napędu.

Zjawiska te zostały następnie zaobserwowane w trakcie pilotażu platform latających z uszkodzonymi wirnikami. Efektem było m.in. skrócenie czasu lotu przy identycznym początkowym stopniu naładowania akumulatorów. Na rysunku 3.2 przedstawiono porównanie wartości średnich dla drona *Falcon V5*. Dane zebrano przy okazji lotów eksperymentalnych wykonywanych zarówno z uszkodzonym, jak i w pełni sprawnym kompletem wirników. Pomiary realizowane były od momentu startu do momentu lądowania w chwili osiągnięcia ustalonego, minimalnego poziomu naładowania pakietu akumulatorów. Mierzone czasy zaprezentowano dla dwóch przypadków: lotu bez obciążenia ($AGW = 2150g$) oraz prób wykonywanych ze zwiększoną o 500 gramów masą BSP. Na wykresach przedstawiono również odchylenie standardowe wyznaczonych średnich. Szerszy opis platformy latającej, przeprowadzanych eksperymentów oraz zarejestrowanych danych zawarto w rozdziałach 4 oraz 6.



Rys. 3.2: Porównanie średniego czasu lotu w przypadku wystąpienia w systemie uszkodzenia wirnika

Prezentowane charakterystyki potwierdzają wstępną ocenę utraty osiągnięć wykonaną podczas prób statycznych. Podczas eksperymentów jeden lub dwa wirniki były uszkodzone poprzez utratę około 5-10 mm końcowej części jednej z łopat. Nawet tak niewielka degradacja powoduje skrócenie czasu lotu średnio o około 10%.

Do pozostałych obserwowanych w trakcie lotów zjawisk zaliczyć można:

- Trudności w utrzymaniu pozycji maszyny w locie ze względu na stały dryf na stronę uszkodzonego wirnika.
- Zwiększony hałas i świszczący pogłos.
- Pracę napędów na wyższym przedziale charakterystyki prędkości obrotowej i idące za tym zmniejszenie maksymalnych osiągnięć platformy latającej (dynamiki, prędkości lotu).

3.2.1 Wibracje generowane przez maszyny wirujące

Zjawiskiem towarzyszącym pracy uszkodzonych rotorów jest zwiększony poziom i odmienny charakter generowanych wibracji. Stanowi to szczególny przypadek opisywanej w literaturze pracy maszyny wirującej o niesymetrycznym obciążeniu wału silnika. Utrata fragmentu płata prowadzi do zaburzenia nominalnie symetrycznego rozkładu masy wirnika wokół punktu obrotu. W ogólnym przypadku każda wirująca masa powoduje powstawanie pewnej siły odśrodkowej o kierunku zgodnym z promieniem i zwrocie skierowanym od osi obrotu. W przypadku wirników o wielu łopatach rozmieszczonych równomiernie po obwodzie okręgu, powstałe w ten sposób siły równoważą się w punkcie centralnym. Zasada ta jest zachowana przy założeniu pracy rotora w płaszczyźnie horyzontalnej względem wektora grawitacji [74].

Utrata fragmentu jednego z płatów i idący za tym zaburzenie rozkładu masy prowadzi do powstania wypadkowej siły odśrodkowej będącej źródłem wibracji propagujących się po całej konstrukcji statku powietrznego [75]. Przy pomiarze drgań w ustalonej osi położonej w płaszczyźnie pracy wirników rejestrowany jest sygnał będący przebiegiem sinusoidalnym, w którym podstawowa częstotliwość odpowiada bezpośrednio pulsacji wirującego śmigła. W przypadku zastosowania opisanego zjawiska dla celów diagnostycznych, składowa ta nazywana jest jedną z *częstotliwości charakterystycznych dla uszkodzenia* i opisywany jest wzorem:

$$f_o = \frac{\Omega}{60}, \quad (3.14)$$

gdzie Ω oznacza prędkość kątową wirnika wyrażoną w *obr/min*. Podstawowej częstotliwości charakterystycznej towarzyszą kolejne jej harmoniczne.

Nieliczne przykłady z literatury opisują zjawisko z wykorzystaniem praktycznych, empirycznych danych. Wyróżnić można w tym miejscu odtajniony raport jednej z agencji badawczych armii Stanów Zjednoczonych, w którym analizie poddano wibracje generowane przez uszkodzone wirniki pełnoskalowych, załogowych śmigłowców [76]. Opisane tam obserwacje potwierdzają teoretyczny model uszkodzenia oparty o zaburzenie rozkładu masy i powstawanie wypadkowej siły odśrodkowej. Dodatkowym efektem niepożądanym wskazywanym w pracy jest odchylenie płaszczyzny wirowania od nominalnego poziomu, co skutkuje stałym dryftem statku powietrznego. Wniosek ten jest zgodny z obserwacjami autora. Ponadto większość analizowanych prac dotyczących wibrodiagnostyki maszyn wirujących wskazuje, że podstawowa harmoniczna sygnału skupia przeważającą część mocy obserwowanej w widmie.

3.2.2 Obserwacje empiryczne

Pomimo dość jasnego wyjaśnienia zjawisk fizycznych towarzyszących wirowaniu uszkodzonych rotorów, niejasnym było, jak dalece rzeczywiste obserwacje pozwolą na jednoznaczną identyfikację wystąpienia zjawiska i wykorzystanie danych w procesie diagnostycznym. Dla zweryfikowania hipotez wykonano szereg lotów próbnych z wykorzystaniem drona *Falcon V5* i zestawu sprawnych oraz uszkodzonych wirników. W trakcie eksperymentów rejestrowano dane na dwa sposoby: z wykorzystaniem akcelerometrów MEMS pokładowego systemu AHRS oraz oddzielnego układu pomiarowego umieszczonego bezpośrednio przy niesprawnym napędzie. Szerszy opis platformy badawczej i stosowanego osprzętu pomiarowego 4.


Dla zobrazowania występowania częstotliwości charakterystycznej uszkodzenia w systemie posłużono się następującą procedurą:

1. Opracowano dedykowane oprogramowanie do akwizycji i rejestracji danych z trójosiowych akcelerometrów MEMS. Program wykonywany był na opartym o mikrokontroler sterownika pokładowym. Przy każdej z prób rejestrowano wektory o czasie akwizycji od kilkunastu do kilkudziesięciu sekund.

2. Wykonano serie eksperymentów obejmujące po kilkanaście lotów testowych dla dwóch ogólnych przypadków: sprawnych wirników oraz uszkodzenia jednego z nich. Defekt polegał na utracie końcówki pojedynczego płata. Pomiedzy próbami zmieniano takie parametry pracy maszyny jak: masa własna, stopień naładowania akumulatora, trajektorię lotu, miejsce montażu akcelerometru, materiał i producenta zestawu wirników.
3. Na podstawie uzyskanych danych wykreślono spektrogramy ukazujące w kolejnych przedziałach czasowych rozkład widma amplitudowego sygnałów wibracyjnych. Próbki rejestrowane były dla jednej z osi położonych w płaszczyźnie pracy wirników. Zarejestrowane przebiegi dzielone były na odcinki o długości około 500ms z wykorzystaniem funkcji okna *Kaisera*. Pozwala to, przy częstotliwości próbkowania wynoszącej 400Hz , na osiągnięcie rozdzielczości widma wynoszącej około 2Hz . Ograniczenie próbkowania wynika z maksymalnych możliwości zastosowanego czujnika IMU *MMA8452*. Ostatecznie, spektrogramy wyznaczone były z wykorzystaniem krótkookresowej transformaty Fouriera. Do obliczeń wykorzystano pakiet *MATLAB* w wersji R2017a.

Na ilustracji 3.3 przedstawiono pierwszy z wykreślonych spektrogramów. Wyznaczony został na podstawie sygnału zarejestrowanego w trakcie lotu w warunkach nominalnych — bez uszkodzeń wirników nośnych. Na potrzeby próby wykorzystano fabrycznie nowe wirniki jednego z wiodących na rynku producentów. Rejestracji dokonywano z wykorzystaniem pokładowego czujnika IMU zamontowanego w geometrycznym środku ramy nośnej drona.

Wyznaczane dla kolejnych okien widma największe wartości przyjmują w okolicach składowej stałej oraz niskich częstotliwości do zakresu pojedynczych herców. Związane jest to z pomiarami przyspieszeń wynikających z ruchów postępowych drona w trakcie lotu. Zgodnie z przewidywaniami, w spektrogramie dość wyraźnie widoczna jest składowa częstotliwościowa związana z pracą wirników nośnych. Obiekt latający wyposażony był w 8 wirników o osiąganych w trakcie lotu prędkościach obrotowych w zakresie od 3500 do $9000 \frac{\text{obr}}{\text{min}}$. Dla jednostronnego zaburzenia rozkładu masy wirnika te prędkości odpowiadają przechodzeniu wektora siły odśrodkowej przez oś układu współrzędnych akcelerometru z częstotliwościami rzędu 60-150Hz. W wykreślonym spektrogramie zaobserwować można kilka nakładających się



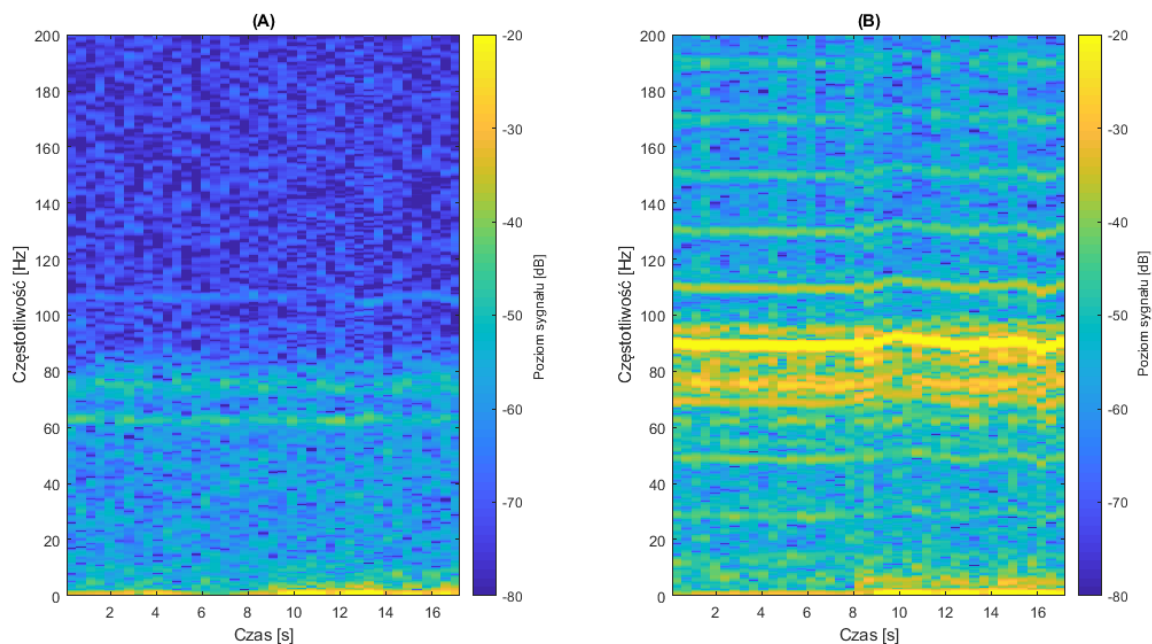
Rys. 3.3: Spektrogram wibracji zarejestrowanych podczas lotu bez uszkodzeń wirników

na siebie składowych o częstotliwościach z rzeczonoego zakresu. Prowadzi to do wniosku, że nawet całkowicie sprawne wirniki dobrej jakości cechują się pewnym brakiem wyważenia, co prowadzi do generowania zauważalnych wibracje. Kolejna obserwacja to większa zawartość szumów w paśmie pomiędzy składową stałą a wibracjami wprowadzanymi przez wirniki.

W kolejnym kroku porównano spektrogramy dla dwóch podstawowych przypadków — braku uszkodzeń oraz wibracji generowanych przez pojedynczy uszkodzony wirnik. Zestawienie przedstawiono na ilustracji 3.4.

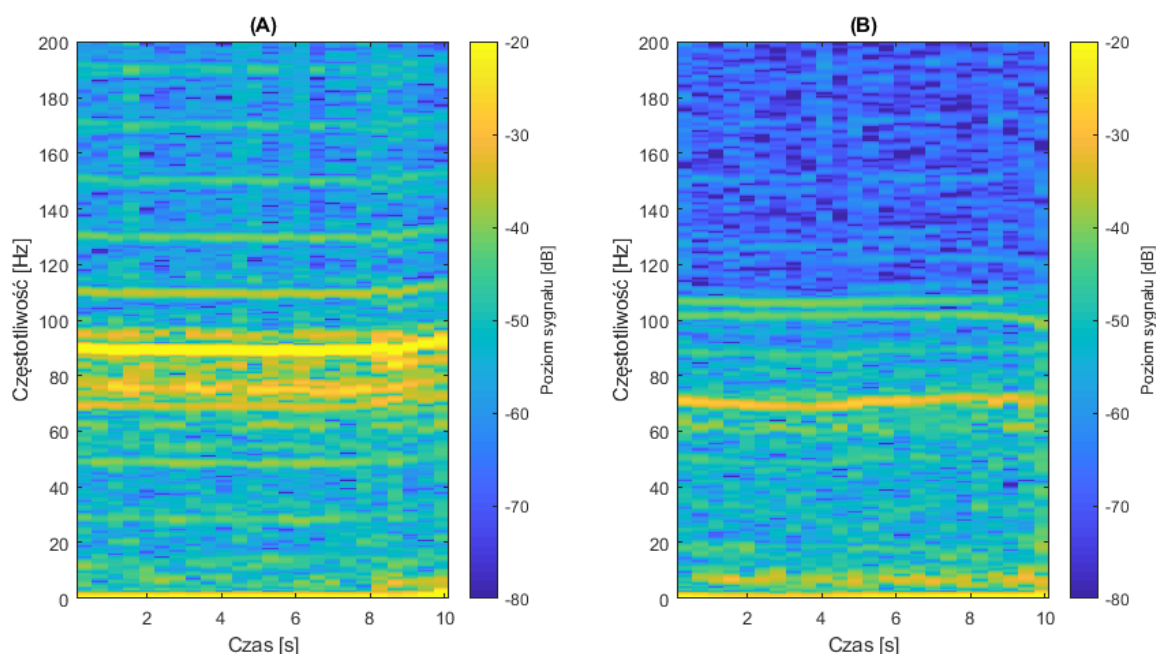
Wystąpienie w systemie uszkodzonego wirnika wyraźnie zwiększa amplitudę wibracji praktycznie w całym paśmie pomiarowym. Wzmocnieniu uległ też ogólny poziom szumów. Obserwacja zestawienia dwóch spektrogramów prowadzi do wniosku, że uzasadnione jest interpretowanie głównej składowej częstotliwościowej rejestrowanych wibracji jako częstotliwości charakterystycznej dla uszkodzenia. Oprócz jej podstawowej, głównej składowej, obserwowane są również kolejne harmoniczne, prawdopodobnie o przekłamanym ze względu na zjawisko aliasingu położeniu w widmie.

Prezentowane powyżej zestawienie zostało oparte o dwa celowo wybrane i skrajnie obrazowe zapisy. W kolejnych krokach analizy porównano



Rys. 3.4: Porównanie spektrogramów wibracji dla sprawnego (A) UAV oraz systemu z jednostronnie uszkodzonym pojedynczym wirnikiem (B)

m.in. rozkład widma wibracji przy różnej masie platformy i występowaniu w obu sytuacjach analogicznego uszkodzenia. Rezultaty przedstawiono na ilustracji 3.5.



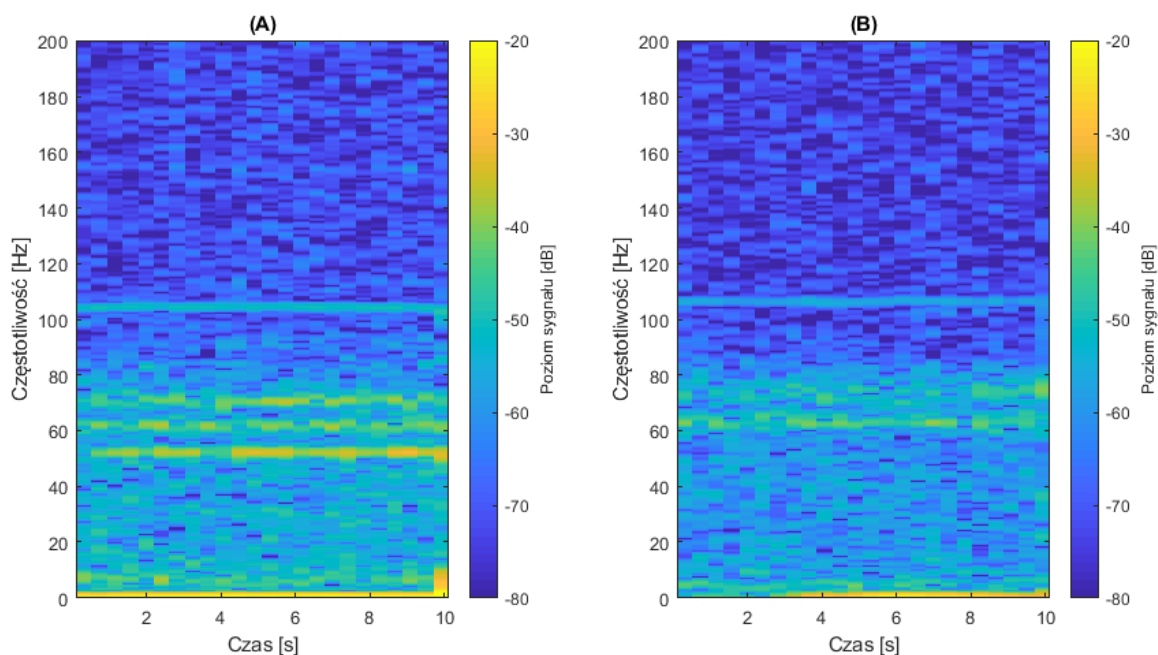
Rys. 3.5: Spektrogramy wibracji dla masy UAV brutto (AGW) wynoszącej 2150g (A) oraz 2650g (B). W obu przypadkach loty wykonywano z uszkodzonymi wirnikami

Analiza spektrogramów prowadzi do dwóch zasadniczych wniosków. Po pierwsze, zwiększona masa w oczywisty sposób wymusza inny zakres prędkości obrotowych napędów śmigłowych. Jest to widoczne w przesunięciu na spektrogramie **B** grupy składowych częstotliwościowych generowanych przez nieuszkodzone wirniki z zakresu 70-90Hz do pasma 100-110Hz. Z drugiej strony, najsilniejsza składowa generowana przez uszkodzony wirnik charakteryzuje się niższą częstotliwością. Drugą kluczową obserwacją jest zmniejszona amplituda wibracji w praktycznie całym analizowanym spektrogramie **B**. Przymuszczalnie przyczyną jest zwiększona masa statku powietrznego oraz inny jej rozkład, a co za tym idzie — poprawiona zdolność do tłumienia drgań.

W kolejnym etapie analizy skupiono się na zmienności amplitudy wibracji generowanych przez uszkodzony wirnik. W przypadku, gdyby udało się ustalić jednoznaczny próg pozwalający rozgraniczyć dwa stany systemu — nominalny i awaryjny — zadanie diagnostyczne zostałoby sprowadzone do nieskomplikowanego detektora opartego o poziom rejestrowanych wibracji. Porównano więc widma wibracji generowane przez więcej egzemplarzy uszkodzonych wirników, testując różny stopień deformacji płata przy odmiennie jakości wykonania całego rotora. Na ilustracji 3.6 przedstawiono najbardziej niejednoznaczne spośród uzyskanych zestawień. Jest to porównanie rozkładu widmowego wibracji dla lotu UAV z zestawem nieuszkodzonych, słabo wyważonych wirników oraz drugiego scenariusza, w którym zastosowano sprawny zestaw jednych z najlepszych dostępnych na rynku rotorów. Jako kryterium jakości stosowanych elementów przyjęto subiektywną kombinację ceny rynkowej, poziomu głośności i osiągnięć platformy testowej w trakcie korzystania z obu kategorii wirników.

Analiza porównawcza dwóch opisanych przypadków praktycznie przekreśla możliwość detekcji uszkodzenia na podstawie progowego pomiaru amplitudy wibracji. Różnice są niewielkie, a dla licznych okien czasowych praktycznie niezauważalne. Słabe wyważenie rotorów o niskiej jakości wprowadza do systemu drgania o porównywalnej amplitudzie jak nieznaczne uszkodzenia lepszych egzemplarzy.

Kolejnym aspektem ograniczającym możliwość zastosowania progowego wnioskowania o uszkodzeniu jest wpływ miejsca montażu czujnika na moc rejestrowanego sygnału. W szerszym rozumieniu jest to parametr zależny również od wymiarów UAV, jako że jednostki IMU instalowane są powszech-

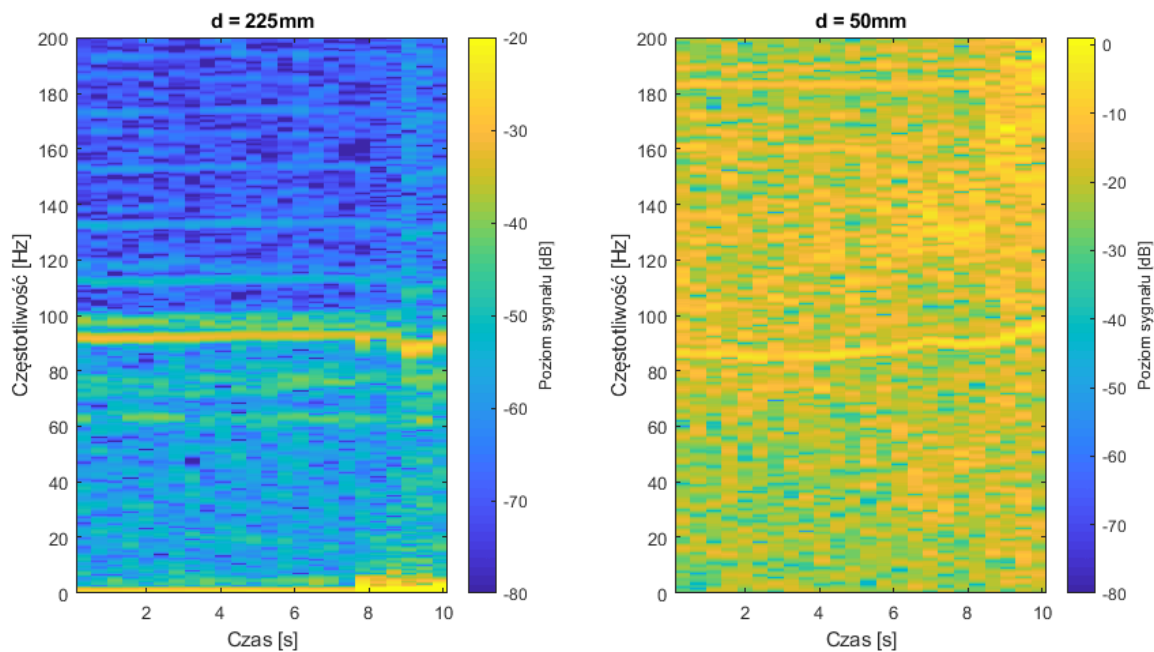


Rys. 3.6: Porównanie spektrogramów dla uszkodzonego wirnika o wysokiej jakości wykonania (A) oraz zestawu popularnych, nieuszkodzonych rotorów (B)

nie w centralnym punkcie BSP, a ramiona wielowirnikowej konstrukcji mają różną długość. Na rysunku 3.7 porównano spektrogramy wibracji otrzymanych z wykorzystaniem czujnika IMU zamocowanego w odległości 225 mm od osi uszkodzonego napędu (w geometrycznym środku symetrycznej konstrukcji czteroramiennej drona) oraz dla sensora umieszczonego na ramieniu w bezpośredniej bliskości wirnika.

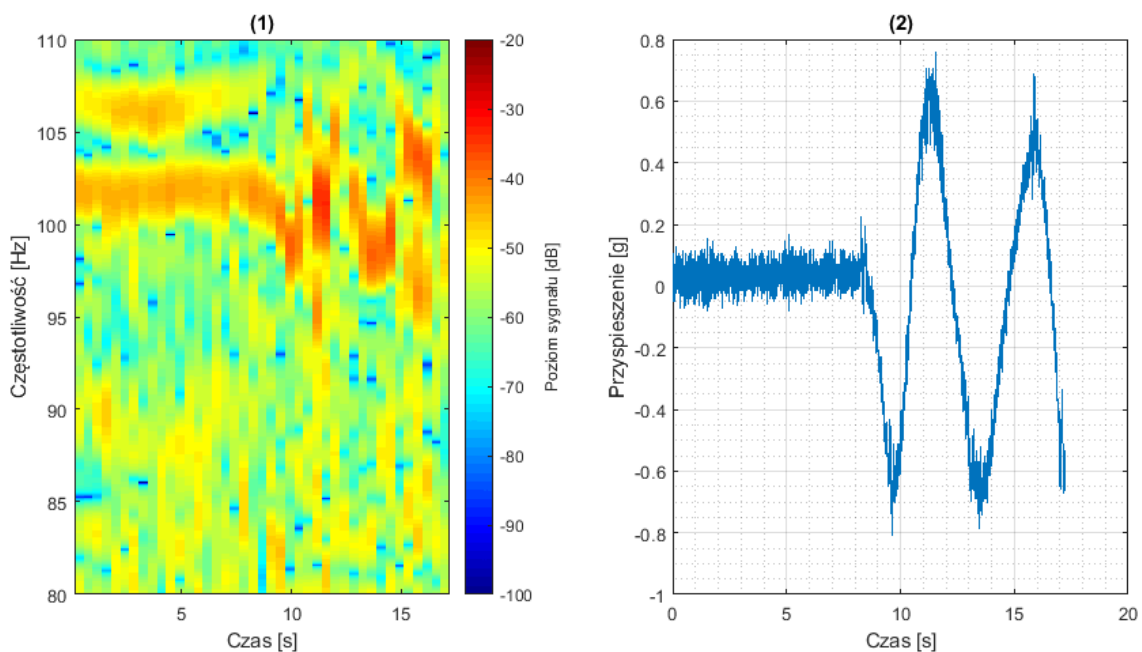
Obserwacja uzyskanych spektrogramów potwierdza dość oczywiste przewidywania. Umieszczenie sensora bliżej źródła wibracji skutkuje uzyskaniem pomiarów o wyższej amplitudzie. Warto jednak zaznaczyć, że nawet w bardziej intensywnych drganiach dość jasno widoczna jest składowa o częstotliwości charakterystycznej dla uszkodzenia. Potwierdza to zdolność do wykorzystania w algorytmach detekcji uszkodzeń danych uzyskanych za pomocą stosowanej klasy sensorów. Wskazuje to również na uniwersalny charakter źródła informacji o uszkodzeniu dla szerszego zakresu wielkości UAV.

Pokazane dotychczas etapy analizy spektrogramów pokazały, że istnieje pewien stały w czasie obserwacji przedział częstotliwości, w którym zawiera się częstotliwość charakterystyczna dla uszkodzenia. Ostatnią próbą było zbadanie jego szerokości ze względu na dynamiczne zmiany prędkości wirowania w trakcie wykonywania manewrów w locie. W tym celu zarejestro-



Rys. 3.7: Widma wibracji uzyskane dla różnego położenia akcelerometru

wano sekwencję danych z eksperymentu, w którym wprowadzono maszynę w szereg gwałtownych manewrów w ruchu postępowym. Na ilustracji 3.8 przedstawiono zestawienie surowych danych z akcelerometru oraz synchronizowanego czasowo spektrogramu wibracji. Lot wykonywany był z jednym uszkodzonym wirnikiem.



Rys. 3.8: Zmiana częstotliwości charakterystycznej uszkodzenia w trakcie wykonywania przez *BSP* gwałtownych manewrów

Na podstawie powyższej oraz szeregu analogicznych prób można sformułować tezę, że zakres zmienności częstotliwości charakterystycznej uszkodzenia jest niewielki i zamyka się w przedziale od kilku do kilkunastu procent. Szerokość tego pasma jest mocno zależna od dynamiki statku powietrznego i osiąganych przez wirniki zakresów obrotów. Poboczną obserwacją jest niewystarczająca rozdzielczość spektrogramu rejestrowanego w trakcie gwałtownych przyspieszeń, zarówno w dziedzinie czasu, jak i częstotliwości. Wskazuje to na potencjalne techniczne ograniczenie wykorzystania analizy wibracyjnej ze względu na pasmo akwizycji czujnika IMU.

Podsumowując przeprowadzone eksperymenty, należy wskazać cztery kluczowe cechy badanych sygnałów, które powinny być wzięte pod uwagę przy tworzeniu rozwiązań diagnostycznych:

- W widmach wibracji rejestrowanych w trakcie lotów w zdecydowanej większości przypadków widoczna jest składowa częstotliwościowa związana z pracą niewyważonych wirników nośnych. Jej zawartość zdecydowanie rośnie w przypadku wystąpienia uszkodzenia wirnika, ze względu na dalsze zaburzenie rozkładu jego masy i pojawienie się wypadkowej siły odśrodkowej. Amplituda wibracji w zdefiniowanym paśmie nie może być wykorzystana jako jedyny i rozstrzygający wskaźnik informacji o uszkodzeniu ze względu na zakres jej zmienności. Czynniki takie jak jakość wykonania płatów wirnika i idący za nią nominalny poziom generowanych wibracji, odległość sensora od napędu czy wreszcie tłumienie wprowadzone przez masę i geometrię statku powietrznego mogą w znacznym stopniu wpłynąć na amplitudę rejestrowanego sygnału wibracyjnego.
- Z uwagi na fakt, że generowana częstotliwość charakterystyczna uszkodzenia jest zależna od prędkości kątowej wirników nośnych, podlega jednocześnie analogicznym wymuszeniom. Jej średnia wartość obserwowana w dłuższym przedziale czasu jest funkcją masy platformy oraz stopnia naładowania akumulatora i co za tym idzie — ciągu zadanego pośrednio przez pokładowy kontroler lotu.
- W krótkim horyzoncie czasowym prędkość kątowa wirników zmienia się zauważalnie w zależności od wykonywanej przez statek powietrzny trajektorii lotu, a zwłaszcza w trakcie gwałtownej zmiany orientacji.

Dla wykorzystywanej w eksperymentach maszyny różnica wynosi do kilkunastu procent wartości średniej podczas lotu w zawisie.

- W rejestrowanych widmach widoczne jest wiele innych składowych, których wartość nasila się wraz z wystąpieniem uszkodzenia. Przypuszczalnie należą do nich kolejne harmoniczne częstotliwości charakterystycznej czy też szumy w znacznej części rejestrowanego pasma.
- Pomimo sporej niejednoznaczności symptomów uszkodzeń w widmie sygnałów wibracyjnych, regularnie zauważalne są pewne wzorce widmowe, odmienne dla obu podstawowych przypadków diagnostycznych.

Implementacja i prace techniczne dotyczące rozwiązań diagnostycznych

Poniższy rozdział opisuje szereg opracowanych przez autora rozwiązań technicznych, stanowisk badawczych i systemów pomiarowych. Ich projektowanie i konstrukcja miała na celu:

- Przygotowanie bezpiecznego środowiska do badań nad UAV z uszkodzonymi wirnikami nośnymi. Większość prac skupiała się na tworzeniu stanowisk laboratoryjnych, które na pierwszym etapie prac wykorzystywane były do obserwacji i rejestracji charakterystyk wybranych parametrów systemu w warunkach wystąpienia uszkodzeń wirników.
- Dostosowanie wykorzystywanego w szeregu innych prac zespołu badawczego wielowirnikowego drona *Falcon V5* do eksperymentów zakładających loty z uszkodzonymi wirnikami. Prace dotyczyły dostosowania mechanizmów akwizycji zaimplementowanych w awionice maszyny do rejestracji danych kluczowych pod kątem wykorzystania w diagnostyce uszkodzeń.
- Zaprojektowanie i wykonanie autorskich układów pomiarowych. Jedną kategorię stanowią rozwiązania powstałe na podstawie rozwiązań dostępnych na rynku i odpowiednio dobranych, skonfigurowanych i oprogramowanych przez autora podzespołów. Z drugiej strony, większość prac poświęcona była na opracowanie własnoręcznie projektowanych i wykonanych obwodów drukowanych i systemów wbudowanych.

4.1 Aspekty techniczne diagnozowanych systemów

Prace nad rozwiązaniami technicznymi poprzedzone zostały analizą cech specyficznych obiektu diagnostyki opisywaną szerzej w rozdziale 3. Następnie, właściwe prace techniczne rozpoczęto od zdefiniowania potencjalnych braków w wyposażeniu badawczym będącym w dyspozycji autora. W początkowym etapie badań zakładano wykorzystanie dotychczasowej konfiguracji platformy latającej *Falcon V5* z minimalnymi zmianami w oprogramowaniu awioniki pokładowej. Celem pierwszych eksperymentów było zebranie danych z czujników przyspieszeń pokładowego modułu IMU w celu analizy sygnatury sygnału wibracyjnego. Nadrzędną ideą towarzyszącą całemu tokowi badawczemu była możliwość praktycznej implementacji rozwiązań diagnostycznych w systemach pokładowych UAV. Z tego względu poddano analizie takie cechy wykorzystywanego statku powietrznego jak zdolności obliczeniowe sterownika pokładowego czy możliwości akwizycji dłuższego bufora danych pomiarowych.

4.1.1 Stan wiedzy

Systemy awioniki pokładowej bezzałogowych obiektów latających nieustannie podlegają ciągłemu rozwojowi i zwiększaniu ich możliwości. Pierwsze kontrolery lotu dla bezzałogowych dronów realizowane były najczęściej z wykorzystaniem systemu wbudowanego, którego zasadniczą część stanowił pojedynczy mikrokontroler [77]. Taka jednostka obliczeniowa odpowiedzialna była zarówno za obsługę komunikacji z czujnikiem inercyjnym (IMU), estymację stanu maszyny czy wreszcie realizację algorytmu stabilizacji lotu i podążania za zadaną trajektorią. Dodatkowy narzut obliczeniowy wprowadzany był przez zadania niekrytyczne dla samego utrzymania się w powietrzu — komunikację z operatorem, rejestrację stanu maszyny i inne. Wraz z rozwojem sektora BSP sterowniki pokładowe ewoluowały w kierunku systemów o większym stopniu skomplikowania, składających się nierzadko z całego szeregu podjednostek tworzących układ rozproszony. Typowym przykładem konfiguracji awioniki jest podział zadań na układ odpowiedzialny za rejestrację pomiarów i estymację stanu (moduł AHRS), podstawowy kontroler lotu odpowiedzialny za sterowanie orientacją i stabilizację platformy w locie oraz poboczne moduły komunikacyjne, kontrolujące system zasilania itp [78].

Wraz z rozwojem wielowirnikowych dronów w stronę platform pół- lub całkowicie autonomicznych, zadanie sterowania lotem przestało polegać na bezpośrednim kontrolowaniu przez pilota orientacji i wysokości lotu maszyny. Pilotaż oparto na bardziej wyrafinowanych metodach, takich jak zadawanie prędkości postępowej, sterowanie pozycją z wykorzystaniem zewnętrznych systemów odniesienia, czy wreszcie realizowanie w autonomiczny sposób złożonych trajektorii w samodzielnie tworzonej mapie otoczenia [79]. Zadania te, wymagające większej mocy obliczeniowej i wykorzystania sensorów dostarczających wysoko ilościowych danych (kamery, skanery laserowe), doprowadziło do pojawienia się na pokładzie UAV kolejnego elementu systemu. Konstrukcje dronów zaczęły być wyposażane w zaawansowane komputery pokładowe o znacznej mocy obliczeniowej, dedykowane do takich rozwiązań jak systemy wizyjne, algorytmy *SLAM* (ang. *Simultaneous Localization and Mapping* czy złożone metody planowania ruchu.

Głównym ograniczeniem pozostaje w dalszym ciągu udźwig, dostępne miejsce i zapas energii na pokładzie drona. Stanowi to sedno tzw. filozofii *SWAP* (ang. *Size, Weight and Power*) w projektowaniu BSP, czyli ograniczaniu rozmiaru, wagi i poboru energii przez systemy awioniki pokładowej. Niemniej, powszechne jest już wykorzystanie układów o 64-bitowej architekturze klasy *x86* jako komputerów odpowiedzialnych za realizację lotu autonomicznego. Jednostki te są jednocześnie nadrzędne względem innych podsystemów opartych o mikrokontrolery bądź układy *FPGA* (ang. *Field-Programmable Gate Array*) [78]. Alternatywnym sposobem na ominięcie ograniczeń związanych z dostępną na pokładzie UAV mocą obliczeniową jest przeniesienie części zadań do zewnętrznych jednostek obliczeniowych. W takim układzie system awioniki pokładowej drona odpowiada jedynie za niskopoziomowe zadania, takie jak bezpośrednia komunikacja ze sprzętem (napędami, czujnikami), estymacja stanu czy wreszcie sterowanie orientacją i stabilizacją platformy w locie. Bardziej złożone elementy misji związane np. z autonomią lotu są planowane, zadawane i nadzorowane z poziomu naziemnej stacji kontrolnej - *GCS* (ang. *Ground Control Station*). Niezbędne w takim wypadku jest zapewnienie w systemie stabilnego, dwukierunkowego łącza bezprzewodowego o wysokiej niezawodności i niskim opóźnieniu [80].

4.1.2 Wnioski w kontekście implementacji rozwiązań diagnostycznych

Powyższe rozważania prowadzą do szeregu konkluzji dotyczących możliwości uruchamiania proponowanych rozwiązań diagnostycznych w aplikacjach rzeczywistych. Uwzględnić należy znaczną różnorodność stosowanych obecnie dronów wielowirnikowych pod kątem zainstalowanych jednostek obliczeniowych będących na wyposażeniu systemu. Niskopoziomowy kontroler lotu oparty o pojedynczy mikrokontroler jest standardowym rozwiązaniem dostępnym praktycznie w każdym rodzaju wielowirnikowego UAV. Za jeden z najpopularniejszych systemów tej klasy uważany jest Pixhawk¹. Projekt ten ewoluował od otwartego kontrolera lotu stworzonego na uczelni ETH w Zurychu do szerokiego standardu i ekosystemu modułów sprzętowych oraz oprogramowania dla różnego rodzaju dronów i robotów. Niemniej, rozwiązanie niezmiennie oparte jest na pojedynczym mikrokontrolerze głównego sterownika i standaryzowanym zestawie zewnętrznych modułów i czujników. Znaczna liczba projektów badawczych i wdrożeniowych w tematyce autonomicznych dronów opiera się na wykorzystaniu kontrolerów lotu stworzonych zgodnie ze stosem Pixhawk i autorskich rozwiązań wprowadzanych dopiero na etapie nadrzędnego komputera misji [81]. Dlatego przyjęto strategię projektowania w pierwszym rzędzie takich rozwiązań, które będą możliwie niewymagające obliczeniowo. Dzięki temu proponowane rozwiązania diagnostyczne będą możliwe do uruchomienia na jak najszerszej kategorii BSP. Dopiero w sytuacji, gdy dostępne układy i moc obliczeniowa okazywały się niewystarczające do zapewnienia skutecznej detekcji uszkodzeń wirników, zdecydowano się na stosowanie zewnętrznych systemów o większych możliwościach.

4.1.3 Porównanie dostępnych platform sprzętowych

Analizując możliwości aplikacyjne opracowanych przez autora rozwiązań diagnostycznych, zasadnym jest wykonać przegląd parametrów dostępnych na rynku układów sprzętowych. Za kluczowe dla zestawienia parametry przyjęto:

¹<https://pixhawk.org/standards/#autopilot>

- Wydajność podstawowej jednostki obliczeniowej, określana w zależności od dostępności danych za pomocą dwóch benchmarków:
 1. *DMIPS* (ang. „Dhrystone” Million Instructions Per Second) - syntetyczna miara wydajności oparta o liczbę operacji całkowitoliczbowych na sekundę w odniesieniu do pewnej maszyny referencyjnej.
 2. *CoreMark* - popularny benchmark opracowany przez organizację EEMBC² dostarczający miary wydajności, która lepiej odpowiada rzeczywistym zadaniom. Oparty został na standaryzowanym teście obejmującym szereg typowych działań obliczeniowych.
- Pojemność wbudowanej pamięci nieulotnej *FLASH* jako potencjalnego bufora danych pomiarowych.
- Szybkość próbkowania pokładowego czujnika IMU (**ODR**, ang. *Output Data Rate*) oraz częstotliwość podstawowej pętli sterowania i estymacji stanu (f_S / f_E). Informacja o tym, jak często wykonywane są wspomniane cykle jest bardzo istotna. Wiele implementacji oprogramowania sterującego ogranicza szybkość rejestracji danych z akcelerometrów do częstotliwości wywoływania funkcji estymujących stan maszyny i jednocześnie uaktualniających w danym momencie pomiary.

W tabeli 4.1 zawarto zestawienie kilku szeroko stosowanych niskopoziomowych kontrolerów lotu oraz parametrów układu awioniki pokładowej drona *Falcon V5*. Oprócz oznaczenia układu zamieszczono sygnaturę zastosowanego mikrokontrolera oraz rok opracowania systemu.

Na podstawie zestawienia w dalszym procesie projektowym przyjęto następujące wnioski i założenia:

- Bezzałogowy pojazd latający *Falcon V5* pod kątem zasobów obliczeniowych i możliwości akwizycji danych nie odbiega od współczesnych konstrukcji komercyjnych i może stanowić platformę eksperymentalną, uzasadniając jednocześnie hipotezę stwierdzającą, że projektowane rozwiązania diagnostyczne są możliwe do zaimplementowania w powszechnie stosowanych kontrolerach lotu.

²Embedded Microprocessor Benchmark Consortium - <https://www.eembc.org/coremark/>

Układ sprzętowy	DMIPS/CoreMark	FLASH	IMU @ ODR	f_S / f_E
Pixhawk 5X (FMUv5X) STM32F765 (2021)	462 / 1002	2048 kB	ICM20649 @ 4.5kHz	1800/400 [Hz]
Pixhawk 3 Pro (FMUv4) STM32F469 (2018)	225 / 613	2048 kB	ICM20602 @ 4kHz	~250 Hz
Pixhawk (ETH/3DR) STM32F427 (2013)	225 / 608	1024 kB	MPU6000 @ 1kHz	100-200 Hz
Paparazzi UAV Chimera STM32F767 (2017)	462 / 1082	2048 kB	MPU9250 @ 4kHz	Zmienna
OpenPilot Revo STM32F405 (2017)	210 / 566	1024 kB	MPU6000 @ 1kHz	4 kHz
Falcon V5 MB / AHRS STM32F407 (2014)	210 / 566	1024 kB	ADIS16488 @ 400Hz	400 Hz

Tab. 4.1: Porównanie wybranych parametrów niskopoziomowych kontrolerów lotu

- Częstotliwość akwizycji danych inercyjnych we wszystkich przypadkach jest wystarczająca do ich wykorzystania w algorytmach diagnostycznych opisywanych w rozdziale 5.
- Moc obliczeniowa dostępnych systemów awioniki pozwala na implementację rozwiązań diagnostycznych w ograniczonym zakresie, dla bardziej rozbudowanych modeli i klasyfikatorów zasadne będzie wykorzystanie dodatkowej jednostki obliczeniowej.


4.2 Platforma eksperymentalna - UAV *Falcon*

Wielowirnikowy BSP *Falcon* jest projektem konstrukcyjno-rozwojowym realizowanym w ramach prac Instytutu Robotyki i Inteligencji Maszynowej Politechniki Poznańskiej. Na przestrzeni lat powstało kilka iteracji zarówno platformy latającej [82, 83, 84], jak i awioniki pokładowej [85]. Od momentu powstania maszyna przewidziana była jako dron badawczy służący prowadzeniu eksperymentów oraz rozwijaniu rozwiązań technicznych, zarówno w obszarze konstrukcji, wykorzystywanych materiałów i dobieranych jednostek napędowych, jak i oprogramowania sterującego. Warto nadmienić, że wypracowywane w ramach projektu *Falcon* rozwiązania posłużyły jako punkt wyjścia dla kilku projektów badawczo-rozwojowych i wdrożeniowych [17, 18].

Autor rozprawy uczestniczył w pracach nad dronem oraz wykorzystał rzeczony UAV w ostatniej, piątej wersji jako platformę eksperymentalną na potrzeby opracowywania i ewaluacji omawianych rozwiązań diagnostycznych.

4.2.1 Cechy szczególne urządzenia


Wielowirnikowy BSP *Falcon V5*, którego widok ogólny przedstawiony został na ilustracji 4.1, jest konstrukcją opartą o klasyczny układ kinematyczny *quadrotora* opisany na planie czteroramiennego krzyża. Każde z ramion zakończone jest podwójną, przeciwbieżną jednostką napędową (1). Moduły ESC (3) stanowiące regulatory napędów opartych o silniki BLDC (2) oraz wiązki przewodów ulokowane są wzdłuż ramion. W centralnym punkcie krzyża ulokowany jest szereg płaskich płyt (4), które spajają całą konstrukcję i służą za miejsce montażu najważniejszych podsystemów elektronicznych. Dolną część konstrukcji tworzą szyny do montażu wymiennych modułów akumulatorów zasilających (5) oraz elastyczne podwozie wykonane w technologii druku 3D (6).



Rys. 4.1: Wielowirnikowy UAV *Falcon V5*

Do wspomnianego systemu elektroniki pokładowej należą głównie moduły awioniki, a w szczególności kontroler lotu (układ **MB** - *MainBoard* (7)),

podsystem nawigacji inercyjnej z czujnikiem IMU (układ **AHRS** (8)) oraz systemem dystrybucji i kontroli zasilania dla napędów i poszczególnych modułów (układ **PDB** (9)). Te trzy moduły, zilustrowane na rysunku 4.2, w połączeniu z odbiornikiem systemu modelarskiej aparatury radiowej (10) tworzą minimalną konfigurację potrzebną do lotu sterowanego przez operatora.



Rys. 4.2: Lokalizacja podstawowych elementów awioniki drona *Falcon*

Modułowa konstrukcja [85] i spory zapas miejsca oraz udźwigu pozwalają na montaż dodatkowego oprzyrządowania. W trakcie prac z dronem wielokrotnie wykorzystywano szereg modułów dodatkowych, takich jak czujniki ultradźwiękowe, LIDAR-y, kamery systemów wizyjnych, układy komunikacyjne i telemetryczne czy wreszcie nadrzędne komputery lotu do realizacji lotów autonomicznych.

System napędowy UAV *Falcon V5* oparty jest o osiem napędów śmigłowych zgrupowanych parami na końcach ramion. W obrębie każdej z czterech jednostek wirniki pracują przeciwbieżnie. Pojedynczy napęd śmigłowy składa się z silnika BLDC *T-Motor MN3110* o maksymalnej mocy 150 W i połączonego z nim na sztywno śmigła o średnicy 10 i skoku 3.3 cala. Ten sposób konfiguracji układu napędowego posiada szereg zalet. Przy niewielkich gabarytach maszyny, wynoszących 610×610 mm w obrysie i 450 mm pomiędzy osiami

przeciwległych wirników, udało się uzyskać wysoki współczynnik ciągu do masy. Na podstawie testów statycznych na hamowni szacuje się, że układ napędowy *Falcona* pozwala na wygenerowanie około 65 N ciągu, natomiast masa platformy w podstawowej konfiguracji do lotu wynosi zaledwie 1600 gramów bez uwzględnienia akumulatorów zasilających. W zależności od zastosowanej ich liczby (powstały wersje z gniazdami na jeden lub dwa pakiety) czas lotu wynosi od 8 do 12 minut. Pakiety złożone z 4-ogniw charakteryzują się napięciem znamionowym o wartości 14.8 V i pojemności 5000 mAh. Taka konfiguracja układu napędowego pozwoliła na stworzenie uniwersalnej platformy eksperymentalnej o dużych możliwościach przenoszenia niezbędnego w pracach badawczych wyposażenia.



Rys. 4.3: Przeciwbieżna jednostka napędowa drona *Falcon*

Zastosowanie zdwojonych, przeciwbieżnych jednostek napędowych niesie za sobą szereg dodatkowych korzyści. Naturalną konsekwencją takiej konfiguracji jest sytuacja, w której dolny wirnik pracuje w śladzie aerodynamicznym wirnika górnego. Z jednej strony, ze względu na niższą prędkość strumienia powietrza opływającego profil lotniczy, maksymalny ciąg generowany przez dolny wirnik jest niższy. Z drugiej jednak pracuje on w zakresie charakterystyki o wyższej sprawności, co przekłada się na lepsze osiągi napędu w zakresie zużycia energii. Szczegóły koncepcji wykorzystania napędów przeciwbieżnych i proces analizy osiągnięć przedstawiony został w jednej z prac autora rozprawy [12]. Kolejną kluczową zaletą omawianego układu napędowego jest jego wysoka redundancja, rozumiana w tym przypadku jako zdolność do kontynuowania lotu w sytuacji kompletnej utraty jednego

lub większej liczby wirników [86]. Podczas prac badawczych wykonywane były eksperymenty symulujące całkowitą utratę jednego z wirników poprzez nagłe odcięcie sterowania danej jednostki. Dron pozwala na kontynuowanie lotu w przypadku wystąpienia takiej sytuacji, kosztem zwiększonej trudności pilotażu.

System nawigacji bezwładnościowej opisywanego BSP oparty jest o wysokiej klasy czujnik IMU *ADIS16488*. Jest to zaawansowany układ integrujący w sobie zestaw trójosiowych akcelerometrów, żyroskopów i magnetometrów oraz dodatkowo czujnik ciśnienia atmosferycznego. Podsystem charakteryzuje się dostępnością wielu wewnętrznych mechanizmów poprawiających dokładność pomiarów, takich jak dynamiczna kompensacja czułości, poprawa liniowości pomiarów czy redukcja błędów systematycznych ³.



Rys. 4.4: Czujnik bezwładnościowy *ADIS16488* połączony z układem *AHRS*

Mając na uwadze rodzaj danych wykorzystywanych w opisywanych systemach diagnostycznych, kluczowe są zapisy pochodzące z dwóch akcelerometrów o osiach pomiarowych leżących w płaszczyźnie pracy wirników. Tym samym dla poprawnej klasyfikacji sygnatury sygnału wibracyjnego istotnymi parametrami są zakres pomiarowy, czułość, powtarzalność pomiarów i poziom szumów wprowadzanych przez sam czujnik. Deklarowane przez producenta wartości wymienionych parametrów zebrano w tabeli 4.2.

³<https://www.analog.com/media/en/technical-documentation/data-sheets/ADIS16488.pdf>

Parametr	Wartość	Jednostka
Zakres	± 18	[g] ($9.81 \frac{m}{s^2}$)
Czułość	$1.22 * 10^{-8}$	[g/LSB]
Powtarzalność	± 0.5	[%]
Widmowa gęstość szumu	0.067	$[\frac{mg}{\sqrt{Hz}}]$
Szybkość próbkowania	2.4	[kSps]

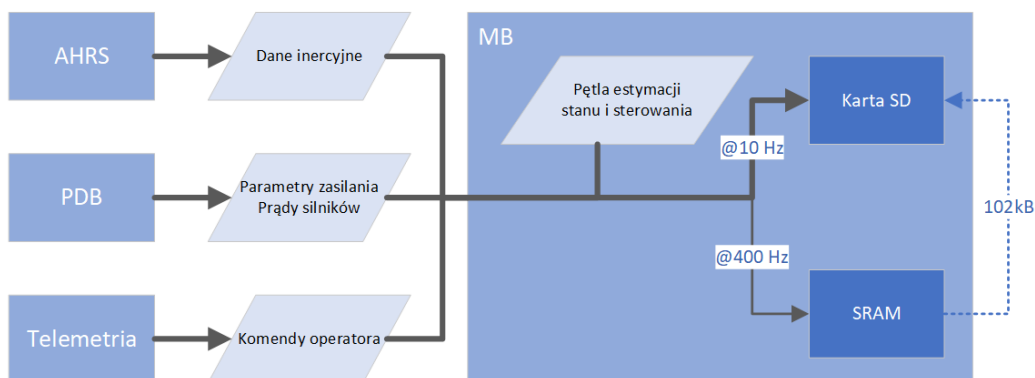
Tab. 4.2: Wybrane parametry czujnika bezwładnościowego ADIS16488

4.2.2 Wybrane funkcje oprogramowania pokładowego

Dane pomiarowe i telemetryczne pozyskiwane w systemie awioniki pokładowej drona *Falcon* mogą być rejestrowane na kilka różnych sposobów. W ogólności wyróżnić można dwie podstawowe drogi akwizycji. Pierwsza z nich to zdalna transmisja danych telemetrycznych do terminala naziemnego. W toku prac rozwojowych nad platformą powstał wysiłkiem autora rozprawy szereg rozwiązań tej klasy. Do przykładów można zaliczyć m.in. system naziemnej stacji kontrolnej z anteną śledzącą czy też układ *OSD* (ang. *On-Screen Display*), czyli rozwiązanie nakładające dane telemetryczne na strumień sygnału wideo transmitowanego do operatora. Niemniej, istotniejszą pod kątem systemów diagnostycznych jest druga kategoria możliwości akwizycji danych sensorycznych, czyli pokładowe mechanizmy zapisywania danych w pamięci systemu awioniki. Zaimplementowane na omawianej platformie latającej rozwiązanie oparte jest o kartę pamięci w standardzie *Secure Digital* (SD). Jest to obecnie jeden z najpopularniejszych i szeroko dostępnych rodzajów przenośnej pamięci nieulotnej. W kontrolerze lotu *MB* umieszczony jest slot dla kart w formacie *micro* wraz z połączeniami sygnałowymi z głównym mikrokontrolerem za pomocą szybkiego interfejsu *full-duplex* w standardzie *SPI* (ang. *Serial Peripheral Interface*).

Przepływ danych telemetrycznych w BSP zwizualizowano na grafice 4.5. Linia przerywaną zaznaczono zapis danych z pamięci ulotnej do karty SD po zakończeniu lotu.

W warstwie oprogramowania rejestracja danych telemetrycznych odbywa się z wykorzystaniem dwóch podstawowych mechanizmów:



Rys. 4.5: Schematyczny opis procesu akwizycji danych w awionice drona Falcon

- Podstawową metodą jest system tzw. „czarnej skrzynki”, czyli stały zapis szerokiego zestawu danych informujących o bieżącym stanie maszyny. Do rejestrowanych informacji należą m.in. podstawowy wektor stanu określający orientację i prędkości kątowe statku powietrznego, dane z systemu zasilania (napięcie pakietu ogniw, prądy zestawów napędowych), wartości poszczególnych sygnałów sterujących i wyjść regulatorów oraz wiele innych. Wymienione dane zapisywane są z częstotliwością 10 Hz przez cały czas pracy maszyny, od momentu uruchomienia awioniki do jej wyłączenia po zakończonym locie. Zapis odbywa się bezpośrednio do karty SD.
- Drugą metodą, przygotowaną specjalnie na potrzeby prowadzenia eksperymentów naukowych jest tzw. „szybki zapis”. Mechanizm opiera się na rejestracji wybranych zmiennych z pełną dostępną częstotliwością odświeżania danych z sensorów wynoszącą 400Hz. Zapis odbywa się w zdefiniowanym oknie czasowym i wyzwalany jest przez operatora UAV z poziomu aparatury sterującej. Ograniczeniem metody jest szybkość interfejsu do obsługi karty SD. Zarówno interfejsy sprzętowe, jak i *firmware* stosowanych mikrokontrolerów z rodziny STM32 nie pozwalają na przetwarzanie tak intensywnego strumienia danych w czasie rzeczywistym w dłuższym horyzoncie akwizycji. Kolejną przeszkodą jest znaczny narzut obliczeniowy tego procesu, co skutkowałoby opóźnieniami w obsłudze zadań sterowania lotem platformy lub utratą synchronizacji danych telemetrycznych. Z tego względu, w trybie „szybkiego zapisu” dane tymczasowo przechowywane są w pamięci ulotnej mikrokontrolera, a po zakończeniu lotu kopiowane są do nieulotnej karty pamięci. Dzięki zastosowaniu układu wyposażonego w kontroler DMA (*ang. Direct Memory Access*) procedura nie obciąża głównej pętli sterowania.

Ograniczeniem jest rozmiar pamięci *SRAM*, co w praktyce oznacza rejestrację maksimum 25600 4-bajtowych słów. W trakcie wykonywania eksperymentów z rejestrowaniem sygnałów wibracyjnych ograniczało to czas zapisu danych z dwóch osi akcelerometrów do około 30 sekund. Szersze rozważania na temat rozwiązań pomiarowych stosowanych w projekcie *Falcon* oraz możliwości ich ulepszenia opublikowano w artykule [87].

Prace wykonane przez autora rozprawy polegały na ulepszaniu i dostosowaniu mechanizmów akwizycji do zadania rejestracji danych wibracyjnych wymaganych w omawianych zagadnieniach diagnostycznych.

4.3 Sieć sensorowa oparta o akcelerometry MEMS

4.3.1 Założenia techniczne

Rozszerzeniem możliwości systemu diagnostycznego opartego o pojedynczy czujnik IMU jest sieć składająca się z szeregu czujników wibracji. Podstawowym celem, jaki towarzyszył pracom, było zebranie danych eksperymentalnych do opracowania i weryfikacji metody diagnostycznej opisywanej szerzej w rozdziale 5.3. Kolejnym istotnym zadaniem było usunięcie ograniczeń w rozmiarze rejestrowanych danych sensorycznych. Istniejące limity znacząco utrudniały prowadzenie eksperymentów na platformie *Falcon V5* ze względu na możliwość zapisu jednorazowo jedynie dwóch 30-sekundowych wektorów. Z tego względu przyjęto szereg technicznych założeń projektowych:

- Prototyp stanowić ma rozwiązanie zaprojektowane w skali i z zastosowaniem kategorii układów pozwalających na jego potencjalną integrację z platformą latającą. Z tego względu zdecydowano na oparcie systemu o mikokontroler z tej samej rodziny i o podobnych możliwościach jak pozostałe układy stosowane w systemie awioniki pokładowej. Moduły czujników wibracji projektowano starając się maksymalnie zredukować ich wymiary fizyczne w taki sposób, aby nie stanowiły dodatkowego obciążenia i nie zajmowały znacznej przestrzeni, co w założeniu ma

pozwaląc na bezpośrednie porównanie danych uzyskanych na obu wersjach wyposażenia UAV.

- Dla wygodny prowadzenia badań, zaprojektowano oprzyrządowanie jako urządzenie niezależne od systemu awioniki pokładowej drona *Falcon V5*. Rozumiane jest to jako posiadanie własnego źródła zasilania, kanału sterowania i komunikacji z operatorem oraz możliwości prowadzenia akwizycji danych sensorycznych niezależnie od fazy działania samej platformy latającej.
- Po zakończonych względny sukcesem próbach opracowania metody diagnostycznej opartej o centralny AHRS, zdecydowano się na zastosowanie w pierwszym prototypie czujników łatwo dostępnych i charakteryzujących się niskim kosztem. Uzyskane wyniki oraz obserwacja jakości danych wykorzystywanych do klasyfikacji uszkodzeń pozwalały sądzić, że ulokowanie sensorów bliżej jednostek napędowych pozwoli na zastosowanie mniej zaawansowanych układów przy zachowaniu skuteczności detekcji. Będący na wyposażeniu drona *Falcon* czujnik IMU *ADIS16488* jest urządzeniem wysokiej klasy o cenie rynkowej przewyższającej niejedyn kompletny system BSP podobnej kategorii. Z tego względu, w pierwszej iteracji projektu sieci sensorowej wykorzystano popularne akcelerometry wykorzystywane np. w elektronice konsumenckiej. Pozwoliło to na zredukowanie kosztu całego systemu do ułamka wartości elementów awioniki pokładowej. Z uwagi na bardzo dobre wyniki ewaluacji metod diagnostycznych opartych o system rozproszony, zrezygnowano z wymiany czujników na bardziej zaawansowane układy uznając ich możliwości za wystarczające (zob. 7.3).
- Aby zwiększyć czas akwizycji i uniknąć ograniczeń dotyczących dostępnej pamięci w niskopoziomowych mikrokontroler, zdecydowano się na dodanie układu nadrzędnego. W tym celu przewidziano trójpoziomą, hierarchiczną strukturę sieci sensorowej z miniaturowym komputerem jako układem do zapisywania i przechowywania rejestrowanych danych sensorycznych.


4.3.2 Realizacja sprzętowa

Zgodnie z założeniami zaprojektowano trzy kategorie układów połączonych w sieć pomiarową. Do pierwszej z nich należą cztery miniaturowe czujniki wibracji oparte o 12-bitowy, trójosiowy akcelerometr MEMS *MMA8452*⁴. Jest to układ scalony w niewielkiej obudowie typu *QFN* o wymiarach 3x3mm, przeznaczony do wykorzystania w taniej elektronice konsumenckiej. Niektóre z jego parametrów zebrano w tabeli 4.3.

Parametr	Wartość	Jednostka
Zakres	± 8	[g] ($9.81 \frac{m}{s^2}$)
Czułość	$9.76 * 10^{-4}$	[g/LSB]
Powtarzalność	± 2.64	[%]
Widmowa gęstość szumu	0.126	[$\frac{mg}{\sqrt{Hz}}$]
Szybkość próbkowania	800	[Sps]

Tab. 4.3: Wybrane parametry trójosiowego akcelerometru *MMA8452*


Dla akcelerometru zaprojektowano i wykonano płytkę drukowaną, na której umieszczony jest sam układ, kilka pasywnych komponentów dla konfiguracji adresu czujnika i filtracji zasilania oraz złącze do komunikacji z pozostałymi elementami systemu. Cały moduł czujnika ma wymiary zewnętrzne około 10×10 mm i został przedstawiony na ilustracji 4.6.



Rys. 4.6: Czujnik wibracji oparty o akcelerometr *MMA8452*

⁴<https://www.nxp.com/docs/en/data-sheet/MMA8452Q.pdf>

Nadrzędnym dla zestawu czterech akcelerometrów układem jest moduł akwizycji danych, tzw. DAQ (*ang. Data Acquisition*). Zrealizowany został jako system wbudowany oparty o mikrokontroler z rodziny *STM32F415*⁵ na własnoręcznie zaprojektowanej i wykonanej płytce drukowanej. Poza jednostką obliczeniową, na płycie znajduje się własny blok zasilania, elementy pomocnicze dla mikrokontrolera i złącza do modułów czujników. Połączenia zrealizowane są z wykorzystaniem adresowanej, synchronicznej magistrali I²C (*ang. Inter-IC Bus*) pracującej w trybie *Fast-mode* z częstotliwością zegara wynoszącą 400kHz. W projekcie wykorzystano kilka niezależnych magistral, co pozwala na synchroniczną akwizycję danych z wszystkich akcelerometrów równocześnie. Oprócz połączeń z czujnikami układ wyposażony jest w interfejs UART (*ang. Universal Asynchronous Receiver-Transmitter*) do komunikacji z komputerem nadrzędnym.




Rys. 4.7: Elementy systemu sieci sensorowej - DAQ oraz cztery czujniki wibracji

Elementem sieci sensorowej o najwyższym poziomie w hierarchii jest platforma komputerowa *Raspberry Pi Zero W*. Jest to układ zrealizowany w postaci pojedynczego obwodu drukowanego — tzw. SBC (*ang. Single Board Computer*). Wymiary zewnętrzne modułu to zaledwie 65 × 30 mm, a waga wynosi jedynie 9 gramów.

Komputer oparty jest o procesor *ARM1176* taktowany z częstotliwością 1 GHz, 521 MB pamięci SDRAM i stanowi pełnoprawny system architektury *x86* pozwalający na uruchomienie systemów operacyjnych opartych na jądrze *Linux*. Wybór układu podyktowany był wymiarami fizycznymi

⁵<https://www.st.com/resource/en/datasheet/stm32f415rg.pdf>



Rys. 4.8: Komputer typu SBC Raspberry Pi Zero W

oraz niewielkim średnim poborem energii wynoszącym około 0,75 W. Układ pełni rolę magazynu danych, który zarządza procesem akwizycji oraz odbiera dane przesyłane przez DAQ, zapisuje je do plików i przechowuje w pamięci nieulotnej.

4.3.3 Oprogramowanie

Oprogramowanie systemu sieci sensorowej zostało zrealizowane na dwa sposoby:

- W formie programu uruchamianego na module DAQ. Głównym zadaniem jest przetworzenie strumieni danych z modułów akcelerometrów. Proces obejmuje w pierwszej kolejności obsługę komunikacji opartej o magistralę I²C z wykorzystaniem kontrolera DMA będącego składową rdzenia mikrokontrolera. Następnie, surowe i zsynchronizowane wartości są skalowane i przeliczane do jednostek fizycznych i formowane w pakiety zawierające dane z czterech czujników po dwie osie pomiaru w każdym oraz sumy kontrolnej. Ostatnim zadaniem jest przesłanie pakietowanych danych do układu nadrzędnego. Oprogramowanie zostało stworzone w języku ANSI C z wykorzystaniem bibliotek do obsługi peryferiów sprzętowych oraz innych narzędzi deweloperskich dostarczanych przez producenta układu.

- Jako zestaw skryptów języka *Python* wykonywanych na komputerze *Raspberry Pi* i towarzyszących im programów pomocniczych. Na wspomnianej jednostce nadrzędnej odbywa się obsługa strumienia danych przesyłanych z DAQ z wykorzystaniem interfejsu UART. Głównym zadaniem realizowanym przez skrypty jest dekodowanie ramek danych i zapisywanie pomiarów do plików wraz z podziałem strumienia na okna czasowe o zadanej długości. Za poprawność przesyłanych danych odpowiada mechanizm cyklicznych kodów nadmiarowych, natomiast kodowanie ramek transmitowanych w asynchronicznej magistrali odbywa się z wykorzystaniem algorytmu COBS (*ang. Consistent Overhead Byte Stuffing*) [88]. Zarządzanie procesem akwizycji zapewnia dostęp do systemu operacyjnego komputera nadrzędnego z wykorzystaniem sieci *WiFi* i protokołu *SSH* (*ang. Secure Shell*). Użytkownik prowadzący eksperyment może w sposób niezależny od sterowania lotem samej platformy zdalnie uruchomić rejestrację sygnałów wibracyjnych ze wszystkich czujników sieci na zadany czas.

Stworzony system sieci sensorowej znacznie ułatwił prowadzenie eksperymentów związanych z lotami dronów w warunkach uszkodzeń wirników. Rozwiązanie zapewnia czas rejestracji przekraczający maksymalny czas lotu maszyny, pozwala na uruchomienie i zakończenie zapisu w dowolnym momencie i jest całkowicie niezależne od awioniki pokładowej. Przebieg eksperymentów wykonywanych z wykorzystaniem systemu, a także opis zarejestrowanych danych został przedstawiony w rozdziale 6.


4.4 Podsystem macierzy mikrofonowej

Kolejnym z systemów stworzonych w celu opracowania i walidacji jednej z kategorii omawianych w rozprawie rozwiązań diagnostycznych był moduł macierzy mikrofonowej. W przypadku tego rozwiązania celem była rejestracja sygnałów o odmiennym charakterze — pogłosu emitowanego przez pracujące wirniki. Część założeń przyjęto na podstawie doświadczeń z systemem rozproszonym opartym o zestaw akcelerometrów. Przykładowo, zaplanowano wykorzystanie nie jednego, a czterech mikrofonów umieszczonych w sposób, który potencjalnie pozwala na zlokalizowanie miejsca uszkodzenia. Również od strony realizacji sprzętowej przewidziano architekturę omawianego systemu jako samodzielne, niezależne od awioniki pokładowej drona *Falcon V5* rozwiązanie. Podstawową zmianą w założeniach było porzucenie

koncepcji budowania systemu od podstaw, a zamiast tego wykorzystanie dostępnych na rynku podsystemów o wyższym stopniu złożoności. Było to możliwe przede wszystkim dzięki faktycznej dostępności elementów tego typu. Dla kontrastu, w przypadku systemu sieci akcelerometrów, rozwiązania o wymaganych parametrach w zakresie rozmiaru, wagi i autonomii pracy nie są oferowane w sprzedaży.

4.4.1 Architektura sprzętowa

Architekturę systemu oparto na dwóch podstawowych komponentach. Najistotniejszym z punktu widzenia celu projektu elementem jest moduł macierzy mikrofonowej *ReSpeaker*⁶. Należy do rodziny układów elektronicznych kategorii IoT (ang. *Internet of Things*) opracowanych przez firmę *Seed Studio*. Moduły mają postać płytek drukowanych w formie nakładek na komputery SBC. Wyposażone są w jeden lub więcej miniaturowych mikrofonów wykonanych w technologii MEMS. Ich domyślne zastosowanie to rozbudowa możliwości urządzenia internetu rzeczy o funkcję sterowania i rozpoznawania głosu. Spośród szeregu różnych wersji niektóre moduły *ReSpeaker* z macierzą 4 lub 6 mikrofonów pozwalają również na określenie lokalizacji źródła sygnału akustycznej techniką DoA (ang. *Direction of Arrival*).



Rys. 4.9: Moduł macierzy mikrofonowej *ReSpeaker*

⁶<https://respeaker.io>

Na potrzeby projektowanego systemu rejestracji sygnałów akustycznych wybrano wersję modułu *ReSpeaker* z czterema mikrofonami rozmieszczonymi na planie kwadratu. Układ wyposażony jest między innymi w:

- Wspomniane wyżej cztery mikrofony MEMS - układy *MSM321A3729H9BP*⁷. W trakcie procesu doboru komponentów systemu zwracano uwagę m.in. na jak najwyższy tzw. akustyczny punkt przeciążenia - AOP (*ang. Acoustic Overload Point*). Jest to parametr, który typowo opisuje się jako poziom ciśnienia akustycznego, w którym współczynnik odkształcenia harmonicznego w rejestrowanym dźwięku, THD (*ang. Total Harmonic Distortion*), przekracza 10%. Stanowi to o tyle istotne zagadnienie, że pracujące wirniki wytwarzają dźwięk o wysokim natężeniu. Zbyt niski zakres pomiaru mikrofonu mógłby uniemożliwić rejestrację sygnału o wystarczającej zawartości informacji pozwalających na skuteczną diagnostykę. Z tego względu, kolejnym ważnym parametrem jest stosunek sygnału do szumu i średni THD w paśmie rejestracji mikrofonu. Wartości wybranych parametrów mikrofonów *MSM321A3729H9BP* zebrano w tabeli 4.4.
- Układ przetwornika analogowo-cyfrowego *AC108*⁸, dedykowanego do konwersji sygnałów audio do postaci cyfrowej. Podzespół posiada cztery niezależne kanały akwizycji i cyfrowy interfejs *I²S* (odmianę klasycznej magistrali *I²C*) jako wyjście. Pozwala na próbkowanie sygnałów z szybkością do 48 kSps i posiada programowalny wzmacniacz z zakresu 0 ÷ 30 dB.
- Pierścień złożony z 12 diod LED do wykorzystania przez użytkownika.

Parametr	Wartość	Jednostka
Pasma przenoszenia	100 ÷ 10k	[Hz] w zakresie ±3dB
THD	0.1	[%]
AOP	123	[dB SPL]
SNR	65	[dB]
Czułość	-32dB	[dB] dla 1kHz względem 1V/Pa


Tab. 4.4: Wybrane parametry układu mikrofonu *MEMS MSM321A3729H9BP*

Moduł jest kompatybilny poprzez uniwersalne złącze szpilkowe z szeregiem SBC z rodziny *RaspberryPi*. Do projektu wybrano model *3B+* ze

⁷<http://www.memsensing.com/webupfile/1531103042534785279.0-ENG.pdf>

⁸www.x-powers.com/en.php/Info/down/id/101

względu na wyposażenie go w moduł *WiFi* co pozwala na zdalne zarządzanie systemem. Uzupełnieniem systemu są własne źródło zasilania (akumulator o napięciu 5 V) oraz stelaż wykonany w technologii druku 3D pozwalający na montaż zestawu nad awioniką pokładową drona *Falcon*. Sposób montażu zaplanowano orientując 4 mikrofony macierzy zgodnie z ramionami platformy latającej oraz umieszczając system tak, aby ograniczyć osłonięcie sensorów przez inne elementy konstrukcji UAV.



Rys. 4.10: Kompletny podsystem macierzy mikrofonowej: moduł *Respeaker* (1), *SBC Raspberry Pi* (2), stelaż (3)

4.4.2 Oprogramowanie


Oprogramowanie systemu macierzy mikrofonowej ma postać prostych skryptów języka *Python* opartych na sterownikach przygotowanych przez producenta modułu *ReSpeaker* dla systemów z rodziny *Linux*. Podobnie jak w systemie sieci akcelerometrów, przygotowane skrypty pozwalają sterować pracą macierzy niezależnie od głównego systemu awioniki. Wykorzystywane są analogiczne narzędzia do zdalnego dostępu poprzez sieć *WiFi*. Użytkownik może w dowolnym momencie rozpocząć nagrywanie oraz zdefiniować czas rejestracji i szybkość próbkowania sygnałów z wszystkich czterech mikrofonów. Dodatkowo pierścień diod LED wykorzystywany jest jako wskaźnik informujący o trwającej rejestracji, co jest szczególnie pomocne dla drugiej osoby uczestniczącej w eksperymencie i pilotującej BSP.

4.5 Pomocnicze stanowiska badawcze

Przygotowania do badań nad detekcją uszkodzeń wirników obejmowały dwa zadania związane ze stacjonarnymi stanowiskami laboratoryjnymi.


4.5.1 Hamownia napędów śmigłowych

System hamowni napędów śmigłowych opracowany został w celu prowadzenia prób statycznych jednostek wykorzystywanych w szeregu bezzałogowych pojazdów latających. Udziałem autora w projekcie stanowiska była koncepcja systemu, dobór niektórych rozwiązań technicznych oraz nadzór nad jego wykonaniem. Wygląd ogólny urządzenia przedstawiono na ilustracji 4.11. Urządzenie składa się z kompozytowej belki (1) o wymiarach i przekroju odpowiadającym konstrukcji ramienia nośnej drona, z którego pochodzi zestaw napędowy. Na szczycie belki, w analogiczny sposób jak na UAV, zamocowany jest bezszczotkowy silnik prądu stałego (2), natomiast drugi jej koniec jest sztywno zamocowany do sześciosiowego czujnika siły i momentu (3). Ten z kolei związany jest z solidną, nieruchomą podstawą. Z konstrukcją współpracuje dedykowany układ kontrolno-pomiarowy, który oprócz zestawu sensorów (4) zawiera w sobie egzemplarz docelowego regulatora obrotów (ESC) (5).



Rys. 4.11: Widok ogólny hamowni napędów śmigłowych

Układ elektroniczny hamowni zrealizowany jest w formie obwodu drukowanego opartego o mikrokontroler. Na ilustracji 4.12 przedstawiono omawianą płytkę. Architektura systemu podzielona jest na dwie zasadnicze i odseparowane galwanicznie części. Pierwsza z nich odpowiada za zasilanie badanych jednostek napędowych i dostarcza mechanizmów zabezpieczeń pozwalających na odcięcie silników w sytuacji awaryjnej. System hamowni pozwala na badanie klasycznych oraz przeciwbieżnych (opartych o dwa współosiowe wirniki) zestawów śmigłowych osiągających ciągłą moc elektryczną do około 700-800 W na jednostkę. Druga część układu elektronicznego to system pomiarowy, który komunikuje się z terminalem komputerowym i zarządza sygnałami zadawanymi do regulatorów obrotów. Oprócz centralnego mikrokontrolera na płytce znajdują się sensory prądu i napięcia, dostępne niezależnie dla każdego z dwóch napędów. Pozostałe dwa typy sensorów są umieszczone poza płytka układu pomiarowego. Należą do nich układ do bezczujnikowego pomiaru prędkości obrotowej silnika BLDC oraz wspomniany wcześniej 6-osiowy czujnik siła-moment *ATI mini45*⁹.




Rys. 4.12: Obwód drukowany układu kontrolno-pomiarowego hamowni napędów śmigłowych

Do pracy ze stanowiskiem wykorzystywana jest dedykowana aplikacja komputerowa która pozwala na wizualizację danych, zapis przebiegów do pliku oraz sterowanie przebiegiem próby. Szczegółowy opis systemu został opublikowany w artykule [89].

⁹http://atiindustrialautomation.com/app_content/documents/9610-05-1018%20TWE.pdf

4.5.2 Urządzenie do lotu na uwięzi o 3 stopniach swobody

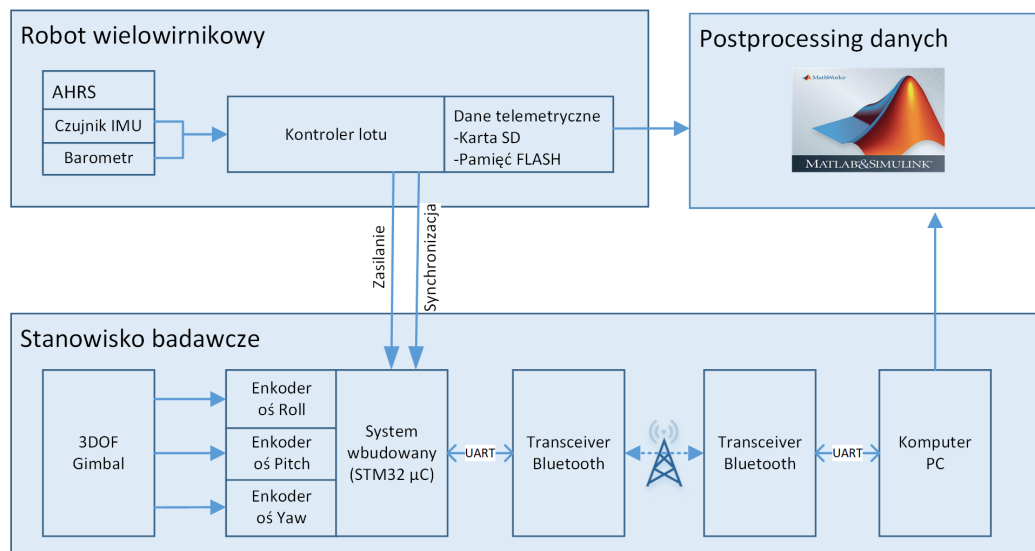
Ostatnim z opracowanych rozwiązań technicznych było stanowisko do lotu na uwięzi [90]. System został opracowany dla różnych zastosowań, w tym był wykorzystywany w początkowej fazie badań nad diagnostyką uszkodzeń wirników. Głównym założeniem tych eksperymentów było sprawdzenie zachowania platformy latającej, stabilności pętli sterowania i wytrzymałości wirników na długotrwałą pracę w warunkach ich uszkodzenia.



Rys. 4.13: Wygląd rzeczywisty i model CAD stanowiska do lotu na uwięzi

Wygląd urządzenia z zamontowanym dronem *Falcon V5* oraz model CAD mechanizmu przedstawiono na rysunku 4.13. Stanowisko oparte jest o konstrukcję przegubu krzyżakowego (2) łączącego parę identycznych zawiasów (1). Dolny z nich połączony jest z walcowym członem (4) obracającym się swobodnie względem podstawy stanowiska (6). Zestaw enkoderów absolutnych (3) pozwala na pomiar orientacji uwiązanej platformy w kątach *roll*, *pitch* i *yaw* (*RPY*). Zwieńczeniem systemu jest układ elektroniczny (5), który rejestruje impulsy enkoderów, konwertuje dane do ustalonego sposobu zapisu orientacji oraz zarządza komunikacją bezprzewodową z nadrzędnym komputerem PC.

Oprogramowanie stanowiska wykonywane jest na dwóch jednostkach obliczeniowych. Pierwszą z nich jest wspomniany system wbudowany, natomiast drugi zestaw skryptów uruchamiany jest na komputerze PC z poziomu środowiska *MATLAB*. System pomiarowy zasilany jest bezpośrednio z platformy latającej dla umożliwienia swobodnego obrotu wokół osi pionowej.



Rys. 4.14: Zasada działania i przepływ danych w stanowisku badawczym

Dane z obu źródeł — pokładowego AHRS drona oraz enkoderów stanowiska badawczego — synchronizowane są za pomocą dedykowanej linii sygnałowej. Ilustracja 4.14 pokazuje schematycznie algorytm działania systemu pomiarowego.

Metody diagnostyczne

W poniższym rozdziale zostały opisane proponowane metody i algorytmy diagnostyczne. Rozwiązania opisywane są w kolejności zgodnej z ewolucyjnym procesem rozwoju i ich ulepszania. Łączy się to w dużej mierze ze wzrostem stopnia skomplikowania i złożoności prezentowanych metod. W rozdziale zawarte zostały założenia oraz opisy poszczególnych etapów przetwarzania sygnałów i modeli wnioskujących o uszkodzeniach. Wyniki ewaluacji proponowanych algorytmów oraz wnioski dotyczące porównania ich skuteczności opisano odpowiednio w rozdziałach 7 oraz 8.

5.1 Analiza wibrometryczna

5.1.1 Wstęp

Pierwszą z proponowanych metod detekcji uszkodzeń wirników nośnych jest wnioskowanie na podstawie widmowej zawartości częstotliwości charakterystycznej dla uszkodzenia, nazywane dalej metodą wibrometryczną. Na podstawie wyników eksperymentów prezentowanych w podrozdziale 3.2.2 zaprojektowano algorytm, którego działanie polega na klasyfikowaniu wskaźników diagnostycznych opartych o amplitudę drgań w zdefiniowanym paśmie widma. Sednem rozwiązania jest założenie, że wykorzystanie pewnego wyuczonego modelu statystycznego pozwoli na prawidłowe rozpoznanie próbki sygnałów wibracyjnych i tym samym skuteczne wnioskowanie o wystąpieniu uszkodzenia.

Analiza spektrogramów sygnałów wibracyjnych jasno wykazała istnienie pewnej składowej charakterystycznej dla uszkodzenia, której częstotliwość wynika bezpośrednio z prędkości kątovej wirników. Jest to parametr zmienny, zależny w dalszej kolejności od takich właściwości UAV jak rodzaj zastosowanych napędów, obciążenie czy aktualna wartość sterowania. W pewnym krótkim horyzoncie czasowym mieści się jednak w pewnym węższym zakresie, którego analiza potencjalnie może wyodrębnić wibracje wprowadzane przez uszkodzenie od pozostałych składowych w widmie. Koncepcja za-

kłada możliwość zaprojektowania algorytmu, który na podstawie pomiaru lub estymaty prędkości kątowej wirników pozwoli na wycięcie z widma interesującego zakresu i proste wnioskowanie o wystąpieniu uszkodzenia na podstawie natężenia wibracji w zadanym paśmie. Warto nadmienić, że omawiana metoda została rozwinięta jedynie do etapu prototypu, ponieważ nie wykazała wysokiej skuteczności detekcji. Pomimo to, jej opis został zawarty w rozprawie, ze względu na cenne wnioski, które posłużyły do opracowania bardziej skutecznych rozwiązań diagnostycznych opisanych w dalszej części rozdziału. Kolejne akapity opisują sekwencję kroków algorytmu prowadzącą od surowego sygnału wibracyjnego do zgłoszenia wystąpienia uszkodzenia.

5.1.2 Wstępne przetwarzanie sygnałów

Opracowana metoda diagnostyczna wykorzystuje krótkie fragmenty rejestrowanych sygnałów wibracyjnych. Z tego względu pierwszym krokiem algorytmu jest wykorzystanie okna czasowego do pobrania wektora próbek sygnału. W zależności od zastosowania źródłem danych mogą być pliki logów pokładowych rejestrowanych w trakcie lotu, jak i cykliczny bufor zapisywany w czasie rzeczywistym w pamięci układu, na którym wykonywany jest program diagnostyczny. Rozwiązanie zostało opracowane i przetestowane z wykorzystaniem pierwszego z podejść, natomiast docelowa implementacja z założenia ma się opierać na danych buforowanych. Długość okna jest parametrem rozważanym dalej pod kątem skuteczności detekcji. W metodzie zastosowano funkcję okna typu *Flat-Top*, ze względu jego dobrą dynamikę i idącą za tym możliwość lepszego rozróżniania amplitud sygnałów składowych [91].

5.1.3 Określanie analizowanego zakresu widma


W następnym kroku, dla przetwarzanej próbki sygnału wyznaczane jest widmo amplitudowe z wykorzystaniem algorytmu szybkiej transformaty Fouriera - FFT (*ang. Fast Fourier Transform*). Ze spektrum wycinany jest fragment wyśrodkowany na częstotliwości wynikającej z aktualnej średniej prędkości kątowej wirników. Szerokość pasma jest w tym przypadku kolejnym parametrem wpływającym na dokładność wykrywania uszkodzenia.

Zasadniczym problemem technicznym przy projektowaniu omawianej metody diagnostycznej był brak informacji o prędkości kątowej wirników drona *Falcon*. System nie jest wyposażony w odpowiednie sensory, takie jak czujniki hallotronowe czy ESC z mechanizmem pomiaru bezczujnikowego. Według najlepszej wiedzy autora, takie wyposażenie jest stosunkowo rzadkie w przypadku wielowirnikowych UAV. Kolejnym istotnym aspektem była sama struktura BSP wykorzystująca wiele identycznych jednostek napędowych. Tym samym problematyczny staje się wybór konkretnego wirnika jako punktu odniesienia do wyznaczenia badanego zakresu pasma na podstawie jego prędkości wirowania.

Jako rozwiązanie tego problemu zaproponowano zastąpienie pomiaru modelem jednostki napędowej. W typowym układzie złożonym z silnika bezszczotkowego i regulatora ESC sterowanie odbywa się przy otwartej pętli regulacji. Sterownik pokładowy UAV generuje sygnały elektryczne typu PWM o zmiennym współczynniku wypełnienia osobno dla każdego zespołu napędowego. Następnie, sterownik reguluje napięcie zasilające kolejne bieguny silnika w sposób liniowo proporcjonalny do sygnału wejściowego. W większości przypadków na tym etapie wprowadzane jest niewielkie opóźnienie dla uniknięcia skoków prądu zasilania. Literatura oraz obserwacje własne wskazują, że prędkość wirnika przy stałej wartości sygnału sterującego jest funkcją takich zmiennych jak napięcie zasilania czy opór na wale stawiany przez pracujący wirnik. Przy założeniu pracy napędu w punkcie ustalonym, stałej gęstości powietrza i zastosowaniu wirników o identycznych parametrach można wyznaczyć przybliżoną estymatę prędkości kątowej jedynie na podstawie napięcia zasilania i wartości sterowania [92]. Obydwie wymienione zmienne są bezpośrednio mierzone i rejestrowane w awionice drona *Falcon* stosowanego do weryfikacji działania metod diagnostycznych (zob. podrozdział 4.2).

Powyższą hipotezę zweryfikowano poprzez stworzenie modelu jednostki napędowej stosowanej na wspomnianym dronie. W tym celu posłużono się stanowiskiem do badania jednostek napędowych (tzw. „hamownią”) opisanym w sekcji 4.5.1. Przeprowadzono szereg prób, w których mierzono prędkość kątową jednostki napędowej identycznej ze stosowaną na UAV przy możliwie szerokim pokryciu przestrzeni dwóch zdefiniowanych zmiennych wejściowych. Testy prowadzono przy wykorzystaniu skryptów automatyzujących przejścia pomiędzy poszczególnymi punktami pracy.

Na podstawie uzyskanych danych dokonano aproksymacji punktowej w celu wyznaczenia dwuargumentowej funkcji wielomianowej opisującej szukaną zależność. Zastosowano dopasowanie powierzchni z wykorzystaniem metody najmniejszych kwadratów. Do modelowania dobrano wielomian piątego rzędu. Dane wejściowe zostały dodatkowo znormalizowane dla zredukowania błędów numerycznych. Na ilustracji 5.1 przedstawiono graficznie opracowany model wielomianowy w postaci powierzchni dopasowanej do zaznaczonych punktów pomiarowych. Zakres napięć wejściowych odpowiada stosowanemu w dronie 4-ogniwowemu akumulatorowi litowo-polimerowemu. Zakres sygnału sterującego jest zgodny z realnie wykorzystywanym w trakcie lotu. Przy wypełnieniu powyżej 90% następuje nasycenie i zakres ten jest zablokowany programowo w kontrolerze lotu. Sterowanie poniżej 30% PWM w części pokrywa strefę martwą ESC (0-14%), a w pozostałym zakresie w praktyce nie jest nigdy wykorzystywane w trakcie lotu ze względu na niewystarczającą generowaną siłę nośną.




Rys. 5.1: Wielomianowy model jednostek napędowych - dopasowana powierzchnia

Zależność pozwalająca na wyznaczenie prędkości kątovej wirnika dana jest równaniem:

$$\omega = 703.7 + 135.1p + 24.36V_{SS} + 27.83p^2 + 8.616 * pV_{SS} + 8.655p^3 + 3.45p^2V_{SS} - 7.26p^4 - 2.1p^3V_{SS} - 2.08p^5 - 1.77p^4V_{SS}, \quad (5.1)$$

gdzie jako p oznaczono wartość sygnału sterującego wyrażoną w procentach współczynnika wypełnienia, V_{SS} to napięcie zasilania, natomiast ω oznacza poszukiwaną prędkość kątovej wirnika.

Następnie dokonano oceny dokładności przeprowadzonej aproksymacji. W tym celu wykreślono residua oraz oszacowano podstawowe metryki jakościowe. Dokładność dopasowania zaprezentowano graficznie na ilustracji 5.2.




Rys. 5.2: Wielomianowy model jednostek napędowych - dokładność dopasowania

Dla znacznej części charakterystyki różnica w dopasowaniu pomiędzy danymi pomiarowymi a modelem nie przekracza kilkudziesięciu obrotów na minutę, co w zgrubnym oszacowaniu pozwoliłoby na wskazanie częstotliwości charakterystycznej z dokładnością do pojedynczych herców. Całkowity błąd średniokwadratowy dla modelu wynosi $1.98 \frac{rad}{s}$. W praktyce na dokładność wyznaczanej tym sposobem estymaty wpływ ma dodatkowo dokładność

pomiarowa stosowanych urządzeń czy stany nieustalone przy zmianach sygnału sterującego.

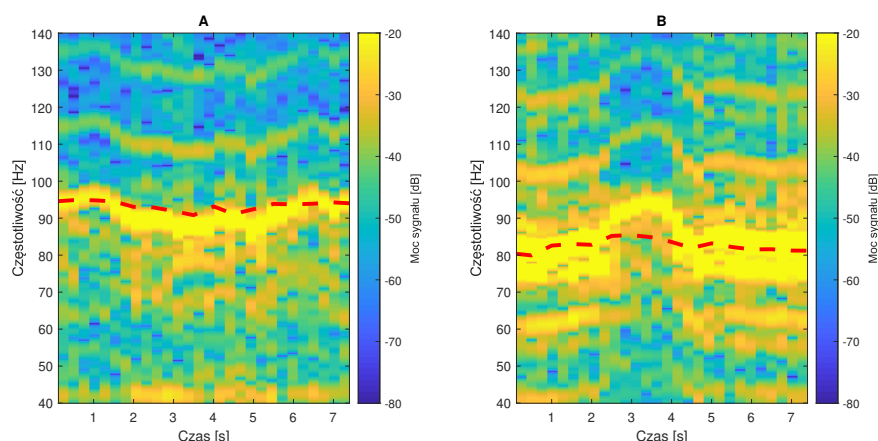
Pozornie nierozwiązanym problemem pozostaje kwestia wyboru punktu odniesienia dla algorytmu wyznaczania pasma w sytuacji, gdy w systemie jest 8 niezależnie sterowanych wirników. Z tego względu postanowiono użyć średniej wartości z wszystkich ośmiu sygnałów sterujących zadawanych przez sterownik w danej chwili. Przyjęto założenie, że w przypadku gdy do dyspozycji jest jedynie zgrubna estymata prędkości obrotowej napędów oraz przy uwzględnieniu wspomnianych niedokładności pomiarowych analizowany zakres widma można jedynie zgrubnie zawęzić do pewnego przedziału. W trakcie typowego lotu różnice między sygnałami sterującymi sięgają kilku punktów procentowych — większość generowanego ciągu ma na celu wytworzenie siły nośnej, mniejsza część generuje momenty wpływające na orientację platformy latającej. Na rysunku 5.3 przedstawiono przebieg sygnałów sterujących w trakcie lotu w zawisie.



Rys. 5.3: Przykładowy przebieg sygnałów sterujących modułami ESC w trakcie 5-sekundowego lotu w zawisie

Proponowany mechanizm zweryfikowano na danych z dwóch sekwencji zarejestrowanych w trakcie lotu z uszkodzeniami. W jednej z nich (sekwencja **A**) dron wisiał nieruchomo w powietrzu. W trakcie drugiej (sekwencja **B**) wykonano manewr zmiany orientacji w jednej z osi w taki sposób, aby uszkodzony wirnik aktywnie brał udział w wymuszeniu. Rezultaty przedstawiono

na rysunku 5.4 w formie spektrogramów z naniesionym wyjściem z modelu jednostek napędowych.



Rys. 5.4: Weryfikacja działania algorytmu wyznaczania pasma w trakcie lotu w zawisie (A) oraz podczas wykonywania manewru (B)

Na podstawie przedstawionych spektrogramów można wnioskować, że zaproponowana metoda śledzenia pasma częstotliwości charakterystycznej jest skuteczna w pierwszym rzędzie dla danych uzyskanych w locie w zawisie. Pozwala jednak zgrubnie oszacować częstotliwość środkową szukanego pasma.

5.1.4 Wyznaczanie wskaźników diagnostycznych i wnioskowanie

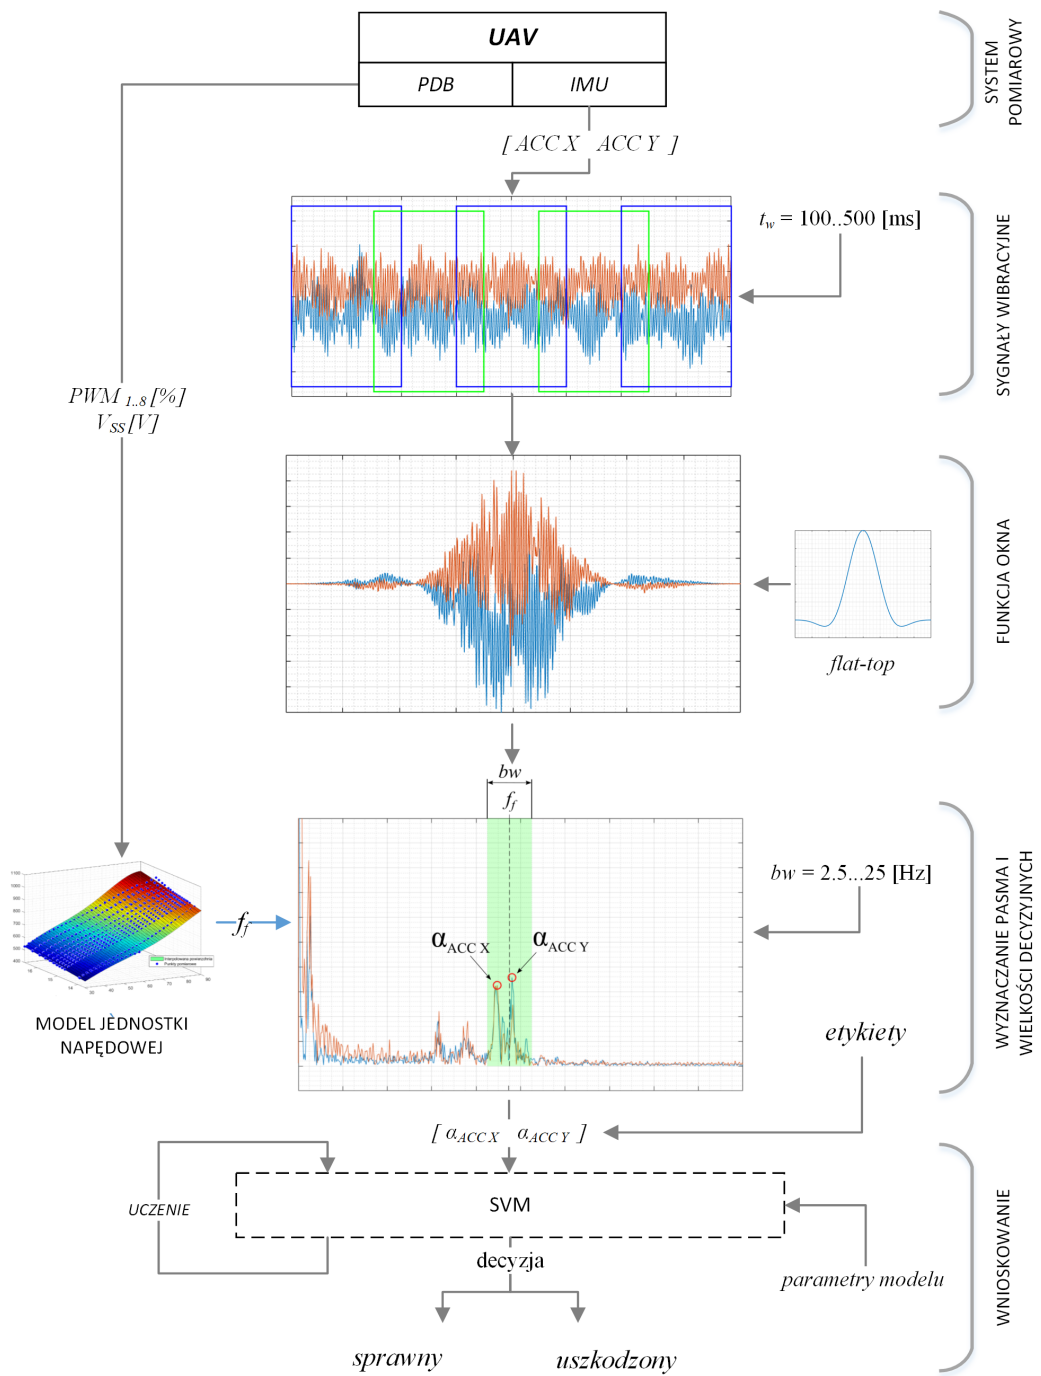
Stworzony model jednostek napędowych dostarcza estymaty częstotliwości charakterystycznej dla uszkodzenia f_f będącej parametrem wejściowym dla etapu wyznaczania wskaźników diagnostycznych. W analizie uwzględniany jest pewne szersze pasmo bw o konfigurowalnej szerokości. W kolejnym etapie algorytmu wyznaczane są wartości wskaźników diagnostycznych pod postacią amplitud widma w badanym zakresie. W metodzie wykorzystywane są dane z dwóch osi pomiarowych akcelerometru położonych w płaszczyźnie wirowania śmigieł. W teorii, drgania w obydwu powinny charakteryzować się przebiegami zbliżonymi, ale przesuniętym w fazie. Wykorzystanie obydwu dostępnych wskaźników ma w założeniu poprawić skuteczności detekcji poprzez zredukowanie wpływu wartości odstających. W rezultacie danymi wejściowymi dla klasyfikatora są dwie wartości skalarne oznaczane jako α_{accX} oraz α_{accY} .

W ostatnim kroku przeprowadzane jest wnioskowanie o wystąpieniu uszkodzenia. Jako klasyfikator wykorzystano algorytm maszyny wektorów nośnych - SVM (*ang. Support Vector Machine*). Jest to jedna z klasycznych metod nadzorowanego uczenia maszynowego, stosowana z sukcesem i od dłuższego czasu w zadaniach diagnostyki i monitorowania urządzeń technicznych [93]. Podstawową koncepcją algorytmu jest wyznaczenie hiperpłaszczyzny separującej z maksymalnym możliwym marginesem przykłady należące do dwóch klas. Jednym z kluczowych zagadnień przy stosowaniu metody jest dobór funkcji bazowej dla danego problemu z uwagi na fakt, że niektóre z nich pozwalają na klasyfikowanie próbek ze zbiorów nieseparowalnych liniowo [94]. Algorytm jest najczęściej stosowany w połączeniu z poprzedzającym klasyfikację etapem ekstrakcji cech, jako że nie zapewnia tego mechanizmu samoczynnie. Jest to zgodne z założeniami omawianej metody diagnostycznej. Klasyfikator SVM wybrano ze względu na znajomość algorytmu i szerokie zastosowanie w diagnostyce maszyn wirujących [95, 94]. Jest on także nieskomplikowany obliczeniowo, zwłaszcza dla tak niewielkiego wektora cech jak w omawianym przypadku. W opisywanej metodzie diagnostycznej zastosowano SVM z radialną funkcją jądra. Klasyfikator uczony był z wykorzystaniem algorytmu optymalizacji SMO (*ang. Sequential Minimal Optimization*).

Na ilustracji 5.5 przedstawiono graficznie podsumowanie kolejnych etapów omawianego algorytmu.

5.1.5 Podsumowanie

Opracowana metoda wibrometryczna jest najprostsza koncepcyjnie i najmniej złożona obliczeniowo spośród omawianych rozwiązań. Szeroka analiza wyników oraz wnioski z eksperymentów walidacyjnych przedstawione są w rozdziale 7. Do najważniejszych z nich należy ograniczona skuteczność dla lotów w zmiennych warunkach i parametrach BSP. Bezpośrednia analiza zawartości składowej częstotliwości charakterystycznej dla uszkodzenia w widmie jest jednak skuteczna przy następujących założeniach:



Rys. 5.5: Schemat blokowy metody diagnostycznej

- Dron znajduje się w zawisie, a napędy pracują ze zbliżoną prędkością.
- Klasyfikator został wytrenowany na danych uzyskanych przy zbliżonym rozkładzie masy i ciężarze własnym maszyny w locie, co wpływa istotnie na poziom wibracji wprowadzanych przez uszkodzenie.
- Klasyfikowane jest jedynie wystąpienie jednej kategorii uszkodzeń, bez możliwości lokalizacji uszkodzonego wirnika i wnioskowania o typie uszkodzenia płata.

5.2 Klasyfikacja wzorców widmowych

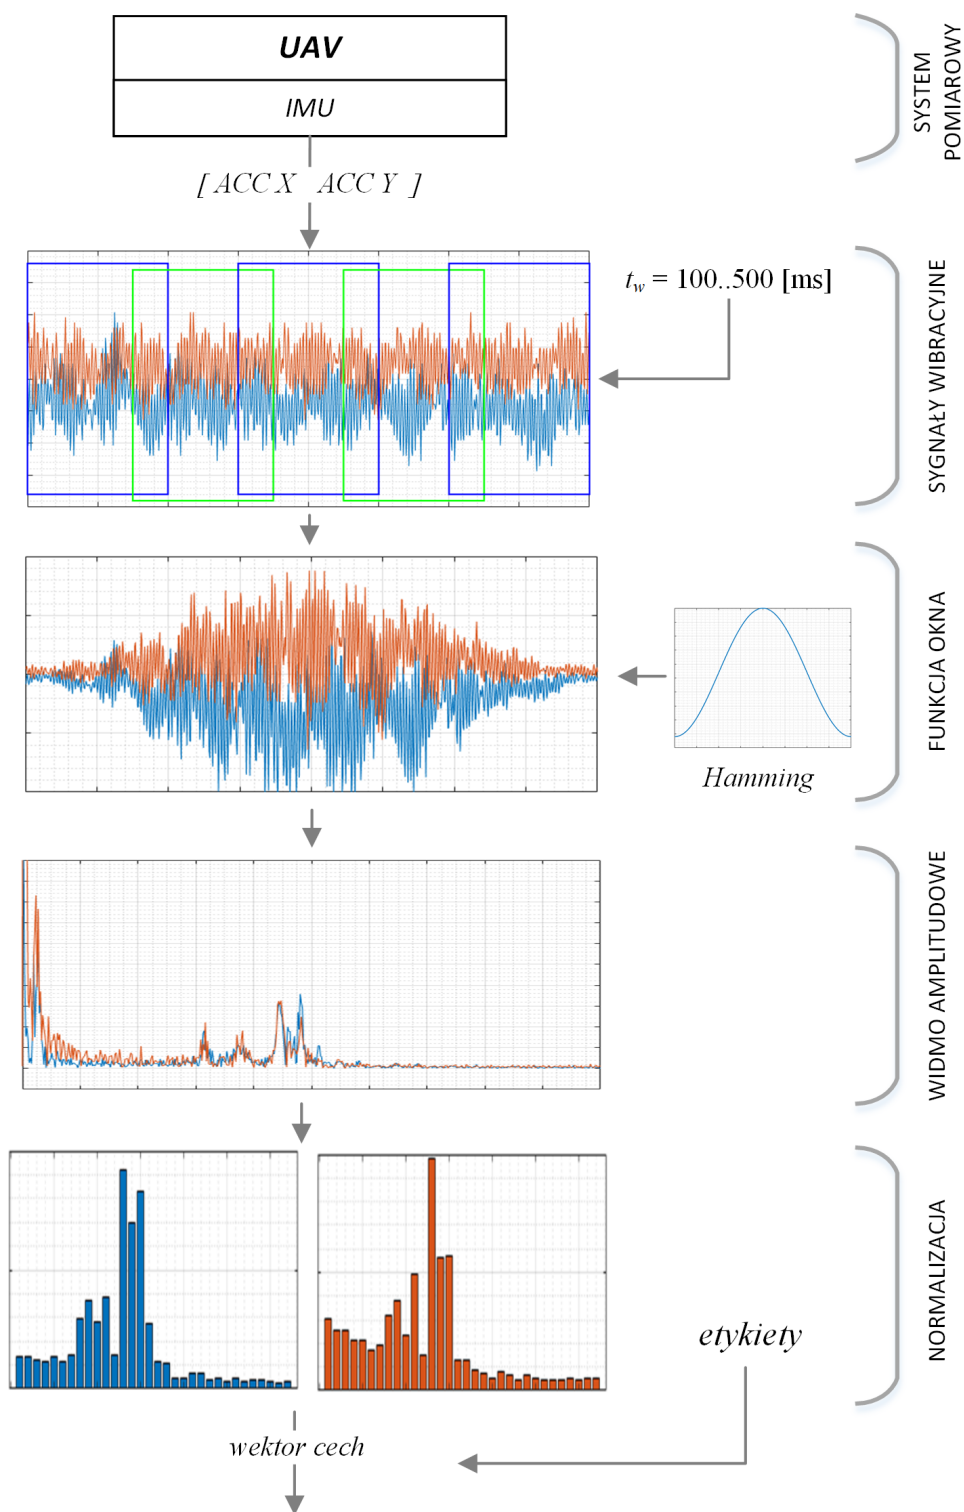
5.2.1 Wstęp

Kolejny z omawianych w rozprawie algorytmów diagnostycznych stanowi ewolucję metody wibrometrycznej. Rozpatrywane wcześniej podejście, oparte o analizę amplitudy drgań w pewnym zdefiniowanym paśmie, charakteryzuje się szeregiem wad. Do najważniejszych można zaliczyć niską skuteczność przy klasyfikowaniu uszkodzeń występujących w zmiennych warunkach lotu. Analiza spektrogramów sygnałów wibracyjnych przedstawiona w rozdziale 3.2.2 sugeruje istnienie pewnego wzorca w widmie amplitudowym, różnego dla pomiarów uzyskanych w eksperymentach ze sprawnym i uszkodzonym wirnikiem. Z tego względu koncepcję systemu diagnostycznego rozszerzono. Nowo opracowany klasyfikator uczony jest rozpoznawania szerokiego zakresu spektrum jako pewnego wzorca widmowego charakterystycznego dla rozpatrywanych stanów uszkodzeń.

5.2.2 Propozycja procedury diagnostycznej

Proponowany algorytm diagnostyczny składa się z szeregu etapów, w których przetwarzany jest sygnał wibracyjny rejestrowany przez akcelerometry pokładowego czujnika IMU. Kolejne etapy przetwarzania sygnałów wibracyjnych do postaci wektora cech przedstawiono na grafice 5.6. Omawiana metoda zachowuje ogólną koncepcję i realizację przepływu danych jak rozwiązanie bazowe. W procesie analizowane są ramki sygnałów pochodzących z dwóch osi pomiarowych położonych w płaszczyźnie pracy wirników. Surowe dane są pobierane z wykorzystaniem przesuwne okna *Hamminga*. Zostało ono dobrane jako kompromis pomiędzy możliwością rozróżnienia częstotliwości oraz ich amplitud w widmie [91]. Zastosowano próbkowanie oknem z przesunięciem wynoszącym 50% dla uzyskania maksimum informacji z zebranych danych eksperymentalnych [96].

W następnym kroku analogicznie do metody wibrometrycznej wyznaczone jest widmo amplitudowe obydwu sygnałów wibracyjnych. W tym celu ponownie wykorzystywany jest algorytm FFT. Następnie, wartości widma są normalizowane do zakresu $\langle 0; 1 \rangle$, a jego rozmiar zredukowany jest poprzez uśrednienie wartości w 32 przedziałach o szerokości 8 Hz i obejmujących



Rys. 5.6: Schemat procesu przetwarzania sygnałów wibracyjnych dla metody diagnostycznej opartej o wzorce widmowe

zakres częstotliwości od 8 do 200 Hz. Dolną granicę przedziału dobrano dla wyeliminowania składowej stałej oraz wolno zmiennych przyspieszeń powiązanych ze zmianami orientacji drona w locie. Z kolei górne ograniczenie zostało przyjęte zgodnie z prawem *Nyquista* dla uniknięcia zjawiska aliasingu. Podział widma na 32 „koszyki” wykonywany jest dla ujednoczenia rozmiaru wektora cech dla różnych szerokości okna i jednocześnie w celu ograniczenia wielkości modelu oraz czasu wykonywania obliczeń na etapie klasyfikacji wzorców.

Przedstawiona koncepcja wektora cech jest znacząco różna od podejścia stosowanego w omawianej wcześniej metody wibrometrycznej. Pierwotny algorytm oparty był na sile sygnału wibracyjnego w wybranym paśmie. W ulepszonej metodzie klasyfikacja oparta jest na pewnej charakterystycznej sygnaturze w dziedzinie częstotliwości. Normalizacja wartości widma powoduje, że omawiany dalej klasyfikator rozpoznaje wzorzec tj. proporcje zawartości poszczególnych składowych częstotliwościowych w sygnale. W zamyśle jest to odpowiedź na widoczną w spektrogramach rejestrowanych w trakcie eksperymentów (*zob.* rozdział 3.2.2) zmienną amplitudę składowej charakterystycznej dla uszkodzenia. Zjawisko było widoczne dla różnych egzemplarzy wirników w zależności od jakości ich wykonania oraz przy zmiennym obciążeniu platformy latającej. Wymienione czynniki wpływają na propagację i tłumienie wibracji w konstrukcji bezzałogowego statku powietrznego. Jednakże pewien wzorzec, rozumiany jako relacja składowej charakterystycznej do pozostałych składników widma, był jasno widoczny w zdecydowanej większości przypadków. Niewątpliwą zaletą oparcia metody o rozpoznawanie szerzej zdefiniowanej sygnatury uszkodzenia jest odejście od mało precyzyjnej metody wyznaczania pasma na podstawie estymaty prędkości kątowej wirników. W zamyśle nowe podejście ma zwiększyć skuteczność prawidłowego klasyfikowania sygnałów rejestrowanych w trakcie wykonywania manewrów i idących za nimi szybkich zmian prędkości wirowania poszczególnych napędów.

Na koniec etapu przetwarzania sygnałów próbki danych przeznaczone do uczenia modelu decyzyjnego zawierają 66 elementów każda. Do każdej z nich należą 32-elementowe wzorce widmowe z obydwu osi pomiarowych oraz dwuelementowa etykieta wskazująca na klasę uszkodzenia. Pierwszy element etykiety wskazuje na wystąpienie uszkodzenia. Przyjęto konwencję, w której zidentyfikowanie niesprawnego wirnika jest predykcją pozytywną.

Drugi element etykiety wskazuje na typ uszkodzenia, tj. utratę końcówki płata lub naruszenie krawędzi natarcia.

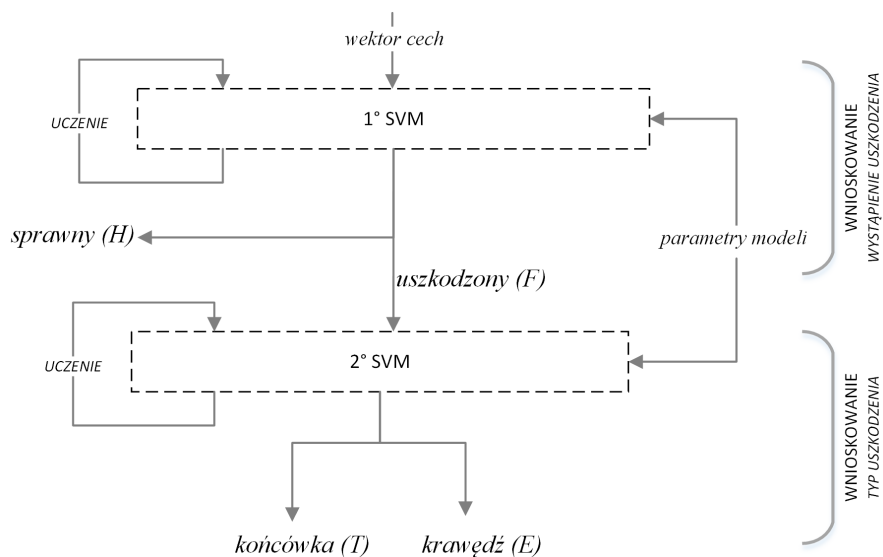
5.2.3 Klasyfikator uszkodzeń

Kolejnym etapem jest wnioskowanie wykonywane z wykorzystaniem dwuetapowego modelu opartego o maszynę wektorów nośnych (SVM). W rozszerzonej metodzie diagnostycznej użyto algorytmu klasyfikacji o podobnym typie do wersji opracowanej dla rozwiązania wibrometrycznego. Zastosowano SVM z radialną lub wielomianową funkcją bazową jądra, uczoną w procesie z wykorzystaniem optymalizatora SMO. Podstawową różnicą jest rozbudowa algorytmu klasyfikatora do postaci dwóch połączonych kaskadowo modeli trenowanych do rozpoznawania zarówno faktu wystąpienia uszkodzenia, jak i do określenia jego typu. Ewaluację metody przeprowadzono na danych zawierających sygnały rejestrowane w trakcie lotów z dwoma typami uszkodzeń — złamaną końcówkę płata wirnika oraz uszkodzoną krawędzią natarcia profilu lotniczego. Szczegółowy opis rozpatrywanych stanów systemu i zebranych danych zamieszczono w rozdziale 6.

W proponowanej metodzie pierwsza maszyna wektorów nośnych klasyfikuje próbkę, przypisując ją do jednej z dwóch podstawowych klas (*sprawny/uszkodzony*). Drugi etap wykorzystuje kolejną SVM i aktywowany jest jedynie, gdy próbce zostanie przypisana klasa wskazująca na wystąpienie uszkodzenia. Ogólną koncepcję klasyfikatora uszkodzeń i stosowane oznaczenia przedstawiono na grafice 5.7.

5.2.4 Podsumowanie

Opracowana metoda diagnostyczna rozszerza koncepcję wykorzystania sygnałów wibracyjnych poprzez klasyfikowanie wzorców uzyskanych z widma amplitudowego drgań. Jest to podejście korzystające z modeli o znacznie większej liczbie wejść. Proces przetwarzania sygnałów jest istotnie uproszczony i pomija krok estymacji prędkości kątowej wirników oraz analizy wartości widma w wąskim paśmie. Wyniki ewaluacji metody, opisywane szerzej w podrozdziale 7.2, wskazują na zauważalnie większą skuteczność przy klasyfikowaniu uszkodzeń na podstawie próbek uzyskanych w różnych



Rys. 5.7: Schemat blokowy klasyfikatora uszkodzeń opartego o wzorce widmowe

fazach i warunkach lotów UAV. Dodatkowo, informacje zawarte we wzorcach widmowych pozwalają na dość skuteczną predykcję typu uszkodzenia.

5.3 Metoda wykorzystująca sieć sensorową

5.3.1 Wstęp

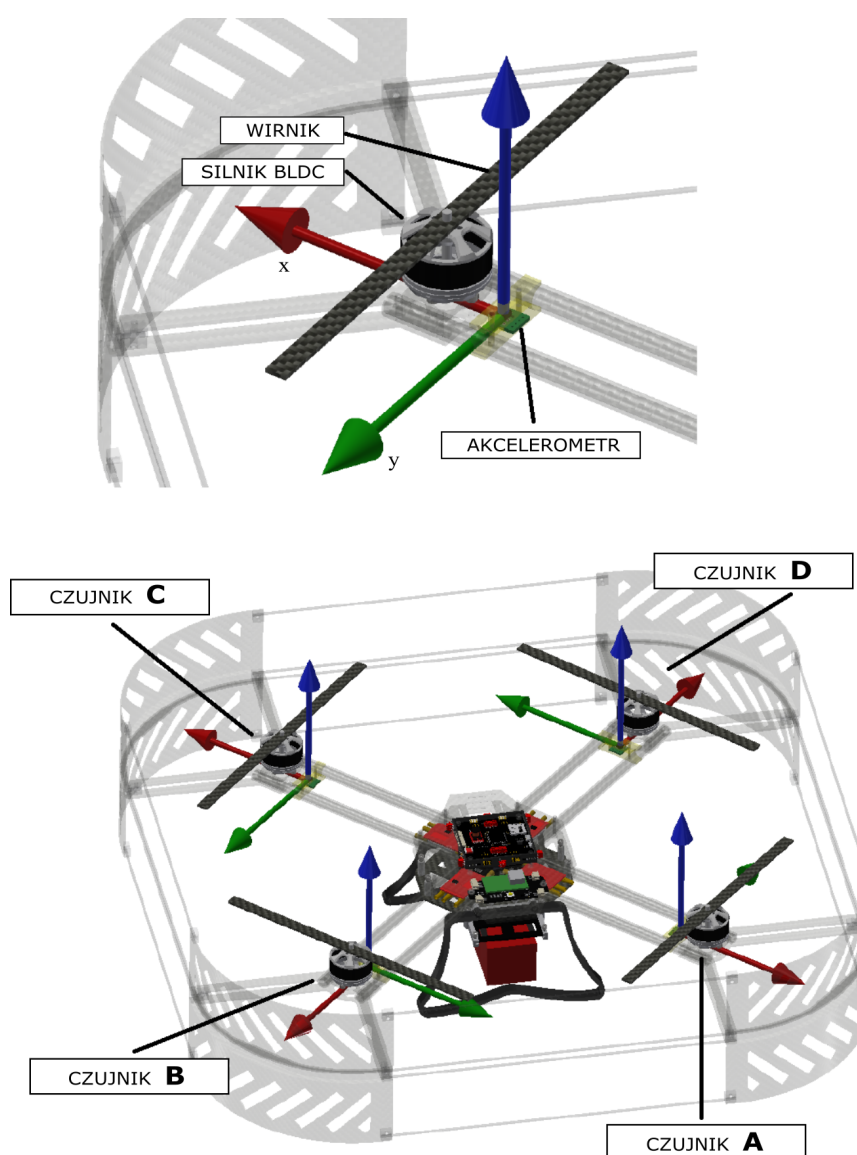
Przedstawione dotąd metody diagnostyczne charakteryzują się zasadniczą wadą, polegającą na braku zdolności lokalizowania miejsca wystąpienia uszkodzenia. Pewne początkowe próby prowadzono w trakcie ewaluacji metody opartej o wzorce widmowe, jako że wykorzystywany zbiór danych zawierał próbki rejestrowane przy różnym umiejscowieniu uszkodzonego wirnika. Próby nauczania klasyfikatora rozpoznawania danych opisywanych dodatkowymi etykietami zawierającymi informację o lokalizacji defektu przyniosły efekty w postaci modelu zwracającego całkowicie losowe wartości. Istotnym faktem jest sposób akwizycji sygnałów wibracyjnych wykorzystujący akcelerometr ulokowany na przecięciu ramion drona w centralnej części statku powietrznego. Mając na uwadze geometrię konstrukcji typowego wielowirnikowego UAV można przypuszczać, że wibracje generowane przez poszczególne jednostki napędowe nie zawierają cech pozwalających na ich rozróżnienie pod kątem umiejscowienia uszkodzenia. Budowa jest symetryczna względem lokalizacji czujnika, a ewentualne przesunięcia w fazie sygnałów wibracyjnych są czynnikami o nieznanej i trudnej do zmierzenia wartości.

Po zidentyfikowaniu omówionych ograniczeń zaproponowano stworzenie systemu sieci sensorowej złożonej z większej liczby rozproszonych akcelerometrów. Opis techniczny systemu zawarto w części 4.3 rozprawy. Układ pomiarowy składa się z czterech akcelerometrów, modułu centralnego do synchronizacji i akwizycji danych z sensorów oraz nadrzędnej jednostki obliczeniowej przeznaczonej do rejestracji pomiarów.

5.3.2 Założenia metody

Podstawowym celem projektu było zweryfikowanie hipotezy, wedle której propagacja wibracji w konstrukcji UAV jest nierównomierna w stopniu wystarczającym do zlokalizowania uszkodzenia na podstawie pomiarów wykonywanych równolegle w kilku punktach. Założono umieszczenie sensorów

bepośrednio przy każdej z czterech jednostek napędowych, w identycznej odległości i orientacji względem pracującego wirnika. System pomiarowym zaprojektowano w taki sposób, aby możliwa była jednoczesna akwizycja synchronizowanych sygnałów wibracyjnych mierzonych wzdłuż ramienia drona oraz w osi do niego prostopadłej. Tak zdefiniowane sygnały nazywane są dalej wibracjami osiowymi i promieniowymi. Odległość poszczególnych czujników do osi wirników wynosi 50 mm. Przyjęto oznaczenia kolejnych sensorów i skojarzonych z nimi jednostek napędowych z wykorzystaniem wielkich liter alfabetu. Koncepcję rozmieszczenia poszczególnych akcelero-metrów sieci sensorowej w odniesieniu do konstrukcji wielowirnikowego UAV przedstawiono na ilustracji 5.8.



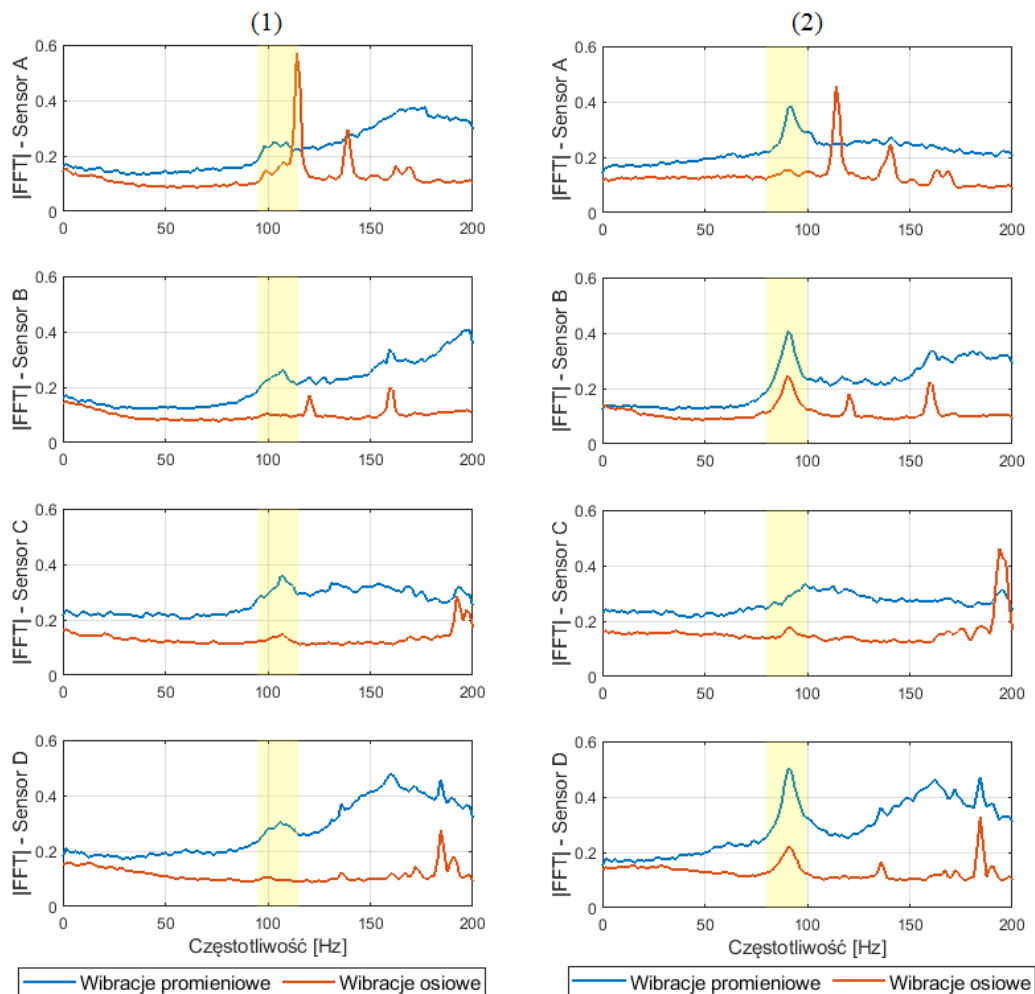
Rys. 5.8: Rozmieszczenie akcelero-metrów w systemie sieci sensorowej. *Opracowano na podstawie [97]*

W rezultacie system sieci sensorowej dostarcza ośmiu sygnałów wibracyjnych rejestrowanych z szybkością 800 próbek na sekundę. Jest to wartość dwukrotnie wyższa niż w przypadku pokładowego IMU drona *Falcon V5*. Zmiana została podyktowana możliwością wykorzystania nowocześniejszych i szybszych czujników. Dalszą część potoku przetwarzania sygnałów oparto o etapy sprawdzone w metodzie wykorzystującej wzorce widmowe. W zamyśle wykorzystanie wielu czujników miało umożliwić lokalizację uszkodzenia co do ramienia, na którym znajduje się niesprawny wirnik oraz zwiększyć dokładność detekcji dzięki umieszczeniu sensorów bliżej źródła wibracji.

5.3.3 Analiza widmowa

W celu wstępnego zweryfikowania postawionej hipotezy wykonano porównanie widm amplitudowych sygnałów wibracyjnych pochodzących z poszczególnych czujników sieci. Na podstawie danych zebranych w eksperymentach obejmujących szereg lotów ze sprawnymi oraz uszkodzonymi wirnikami wyznaczono widma dla kilkudziesięciu zarejestrowanych ramek. Każda z nich zawiera zestaw ośmiu sygnałów, czyli wibracji osiowych i promieniowych dla każdego z 4 sensorów. Czas akwizycji fragmentów sygnałów to 500 ms. Następnie, wartości widm uśredniono dla każdej z klas diagnostycznych w celu pokazania ogólnych trendów i potencjalnych wzorców częstotliwościowych. Na ilustracji 5.9 przedstawiono zbiór wykresów, na których porównano częstotliwości składowe wibracji w dwóch scenariuszach — lotu ze sprawnymi wirnikami oraz uszkodzenia płata wirnika w jednostce A. Na wykresach zaznaczono ponadto pasmo częstotliwości wyśrodkowany na estymowanej składowej charakterystycznej dla uszkodzenia.

Analizując wykreślone widma, można zaobserwować szereg różnic dla każdego ze stanów diagnostycznych. Przy wszystkich sprawnych wirnikach brak znaczących różnic w badanych pasmach widm wibracji osiowych z poszczególnych czujników. Z kolei w wibracjach promieniowych widoczna jest składowa związana z prędkością obrotową wirników — położona jest w okolicach środka pasma estymowanego wielomianowym modelem jednostek napędowych opisywanym w podrozdziale 5.1. Potwierdza to wcześniejsze obserwacje wskazujące, że nawet sprawne wirniki ze względu na brak idealnego wyważenia wprowadzają pewne drgania. Wzrost zawartości składowych charakterystycznych dla uszkodzenia jest widoczny dla sygnałów uzyskanych w eksperymencie z uszkodzonym wirnikiem. W pierwszej kolejności silniej-

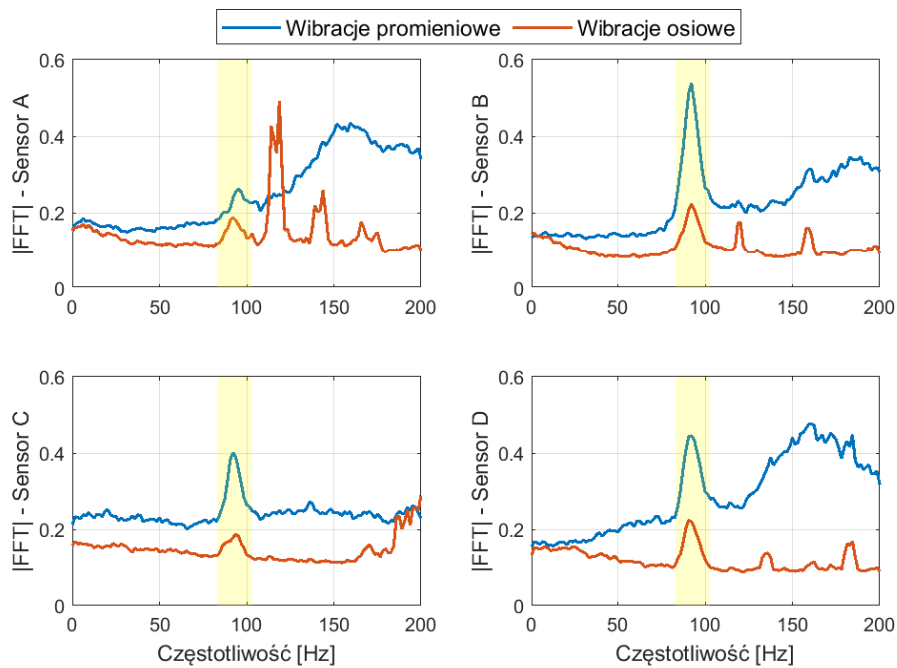


Rys. 5.9: Widma sygnałów wibracyjnych uzyskanych z sieci sensorowej przy braku uszkodzeń (1) oraz dla uszkodzonego wirnika w jednostce napędowej A (2). Opracowano na podstawie [97]

sze stają się wibracje promieniowe, chociaż składowa osiowa też wykazuje zauważalny przyrost. Najistotniejszą pod kątem weryfikacji postawionej hipotezy obserwacją są różnice w widmach dla poszczególnych sensorów. Charakterystyczne dla uszkodzenia wibracje promieniowe rejestrowane są z największą amplitudą przez czujniki **A** (najbliższy uszkodzeniu), **B** oraz **D**. Sygnały z sensora położonego naprzeciw uszkodzonego wirnika (**C**) nie wykazują zwiększonego udziału składowej charakterystycznej dla uszkodzenia, a nawet nieznacznie ją tłumią. W przypadku wibracji osiowych, akcelerometry położone w bezpośredniej bliskości oraz naprzeciw miejsca uszkodzenia nie wskazują zmian w widmie, natomiast zjawisko jest czytelnie obserwowalne w sygnałach z sensorów sąsiednich (**B** oraz **D**). Silna składowa o wartości około 120 Hz w sygnale osiowym z czujnika **A** została zidentyfikowana jako

artefakt spowodowany prawdopodobnie zbyt luźnym umocowaniem tego sensora. Została ona wyeliminowana w kolejnych eksperymentach.

Podobną analizę przeprowadzono dla uszkodzeń wirników na każdym z kolejnych sensorów. Sposób propagowania wibracji okazał się w dużej mierze analogiczny do opisanego przypadku z uszkodzeniem w jednostce A. Stały okazał się wzorzec, wedle którego lepszymi wskaźnikami uszkodzenia stają się wibracje promieniowe, a zmiana zawartości składowej charakterystycznej dla uszkodzenia obserwowana była przede wszystkim na czujnikach sąsiednich tj. zlokalizowanych w zakresie $\pm 90^\circ$ obwodu konstrukcji od miejsca uszkodzenia. Na ilustracji 5.10 przedstawiono przykład z widmami wibracji uzyskanymi przy uszkodzeniu wirnika C.

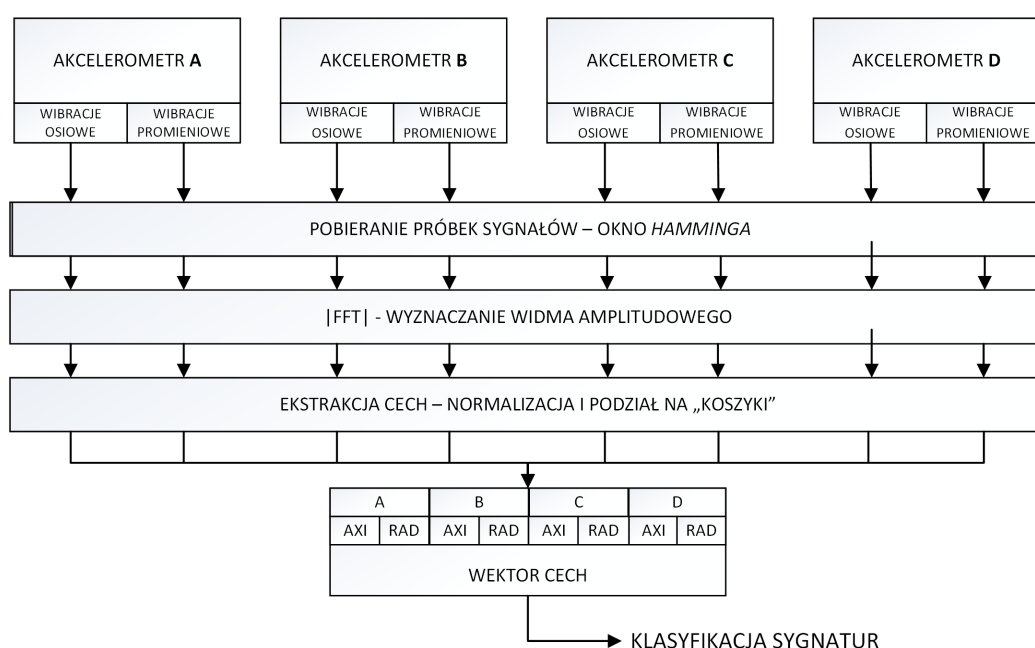


Rys. 5.10: Widma sygnałów wibracyjnych przy uszkodzeniu wirnika w jednostce C

Przeprowadzona wstępna analiza widm sygnałów wibracyjnych potwierdza hipotezę o nierównomiernej propagacji wibracji wprowadzanych przez uszkodzenie wirnika. Poczynione obserwacje uzasadniły kontynuowanie prac nad metodą polegających na opracowaniu nowego algorytmu diagnostycznego oraz wykonaniu dalszych eksperymentów w celu zebrania większej ilości danych z systemu sieci sensorowej.

5.3.4 Przetwarzanie sygnałów wibracyjnych


Metoda diagnostyczna wykorzystująca dane z sieci sensorowej powieliła schemat procesu przetwarzania sygnałów w wykorzystany w bazowym, opartym o centralny sensor algorytmie. Do kolejnych kroków należą pobranie próbek z sygnału z wykorzystaniem funkcji okna *Hamminga*, wyznaczenie widma amplitudowego z wykorzystaniem FFT oraz normalizacja i podział spektrum na stałą liczbę przedziałów tworzących wzorec widmowy. zasadniczą różnicą jest zwielokrotnienie przetwarzania z 2 do 8 równoległych kanałów. Na ilustracji 5.11 przedstawiono schemat podsumowujący proces przygotowywania danych do etapu klasyfikacji.



Rys. 5.11: Etapy przetwarzania sygnałów wibracyjnych. Opracowano na podstawie [97]

Istotną zmianą w nowym algorytmie diagnostycznym była modyfikacja parametrów etapu tworzenia sygnatury częstotliwościowej na podstawie widm sygnałów wibracyjnych. W trakcie ewaluacji metody, opisywanej szerzej w rozdziale 7.3, zdecydowano o zawężeniu analizowanego zakresu do przedziału od 60 do 140 Hz. Wartości graniczne odpowiadają częstotliwościom wibracji wprowadzanym przez wirniki przy minimalnej i maksymalnej użytecznej prędkości obrotowej. Takie podejście z jednej strony eliminuje z widma dalsze harmoniczne składowych charakterystycznej dla uszkodzenia, z drugiej usuwa liczne szумы i niezidentyfikowane oraz niecharakterystyczne w zadaniu diagnostycznym składowe w górnym zakresie widma. Przy węż-

szym zakresie analizowanych częstotliwości liczba przedziałów tworzących sygnaturę częstotliwościową została zredukowana do 16, co odpowiada „koszykom” o szerokości 5 Hz. Graficzny przykład wyznaczenia wektora cech z próbki sygnału wibracyjnego pojedynczego kanału akwizycji przedstawiono na ilustracji 5.12.



Rys. 5.12: Wizualizacja procesu wyznaczenia wzorca częstotliwościowego. Opracowano na podstawie [97]

Ostateczna forma wektora cech w omawianym zadaniu diagnostycznym to 128 elementów stanowiących ustawione kolejno 16-elementowe sygnatury wibracji osiowych i promieniowych dla 4 akcelerometrów sieci sensorowej.

5.3.5 Metoda klasyfikacji

Podczas projektowania rozszerzonej metody diagnostycznej zastosowano odmienny w stosunku do opisanych wcześniej rozwiązań algorytm uczenia maszynowego. Do wnioskowania o wystąpieniu i określenia lokalizacji uszkodzeń wirników zastosowano metodę tzw. lasu losowego, oznaczaną dalej RF (*ang. Random Forest*). Zmiana została wprowadzona po wstępnej ewaluacji metody i porównaniu czasu obliczeń i trafności klasyfikacji dla maszyny wektorów nośnych oraz algorytmu RF. Wykorzystanie modeli opartych o *Random Forest* skutkowało nieznacznie lepszymi wynikami w porównaniu do SVM przy wyraźnie krótszym czasie obliczeń. Co do zasady, maszyna

wektorów nośnych w swojej natywnej formie jest klasyfikatorem binarnym. Opisywana metoda diagnostyczna zakłada przypisywanie próbek do jednej z pięciu klas — braku uszkodzeń lub wykrycia degradacji w jednej z czterech możliwych lokalizacji. Stosując w takim zadaniu modele oparte o SVM konieczne jest wykorzystanie szeregu uczonych niezależnie klasyfikatorów wykonujących predykcję wg. strategii jeden przeciw wszystkim (ang. *one vs. all*) lub każdy przeciw każdemu (ang. *one vs. one*). W mniej wymagającym obliczeniowo pierwszym wariancie model składa się z tylu klasyfikatorów, ile rozpatrywanych jest klas, co znacząca zwiększa jego rozmiar i czas obliczeń [98].

Metoda RF jest lepiej dostosowana do klasyfikacji wieloklasowej ze względu na strukturę i sposób działania. Jest to algorytm oparty o mechanizm tzw. uczenia zespołowego (ang. *ensemble learning*), w którym finalny wynik stanowi połączenie predykcji z wielu składowych klasyfikatorów podrzędnych. W przypadku metody RF są to losowe drzewa decyzyjne, a łączenie predykcji odbywa się na zasadzie głosowania większościowego. Z uwagi na fakt, że klasyczne drzewa decyzyjne mają tendencję do nadmiernego dopasowania do zbioru treningowego, sednem algorytmu jest wykorzystanie dwóch specyficznych technik. Pierwszą z nich jest metoda *bootstrap aggregation*, czyli budowa indywidualnych drzew decyzyjnych na losowych podzbiorach tworzonych przez kombinację z powtórzeniami próbek całego zbioru uczącego. Drugim ulepszeniem względem konwencjonalnego zespołu drzew decyzyjnych jest wybieranie podziałów w drzewie jako najlepszych możliwych dla niewielkiego i losowo wyznaczonego fragmentu wektora cech [99]. Te techniki powodują, że modele oparte o RF charakteryzują się niższą wariancją i dobrą dokładnością przy dużej liczbie cech oraz są nieskomplikowane obliczeniowo i relatywnie łatwe do dostrojenia ze względu na niewielką liczbę wolnych parametrów [100, 101]. Metoda dość często znajduje zastosowanie w opartej o przetwarzanie sygnałów diagnostyce maszyn wirujących [102].

5.3.6 Podsumowanie

Rozszerzona metoda diagnostyczna oparta jest o klasyfikację wzorców widmowych z czterech wykonywanych równolegle pomiarów sygnałów wiibracyjnych. Poza rozbudową do większej liczby strumieni danych, pewne elementy podejścia bazowego zostały zmienione i ulepszone. Należą do nich

przede wszystkim pasmo częstotliwości wykorzystywanych przy budowie widmowej sygnatury uszkodzenia czy algorytm uczenia maszynowego stosowany na etapie wnioskowania. Ewaluację klasyfikatora uszkodzeń opartego o algorytm RF przedstawiono szczegółowo w części 7.3 rozprawy. Uzyskane wyniki wskazują, że ta metoda diagnostyczna dostarcza najbardziej dokładnej informacji o wystąpieniu uszkodzenia. Wyniki uzyskane dla eksperymentów obejmujących zbliżone scenariusze i warunki lotów oraz identyczne długości rejestrowanych sygnałów wibracyjnych są znacząco wyższe w porównaniu do obu opisanych wcześniej podejść. Dodatkowo, metoda pozwala na zlokalizowanie uszkodzonego wirnika bez straty w dokładności samej detekcji.

5.4 Metoda oparta o sygnały akustyczne

5.4.1 Wstęp

Ostatnia z proponowanych metod diagnostycznych charakteryzuje się zasadniczą różnicą w zakresie źródła informacji o uszkodzeniach. Podstawową zmianą jest oparcie procesu ich detekcji i lokalizacji o informacje zawarte w sygnale akustycznym. W trakcie przeprowadzania eksperymentów obejmujących loty UAV z uszkodzonymi wirnikami obserwowanym przez operatora zjawiskiem była różnica w natężeniu i charakterze dźwięku emitowanego przez pracujące napędy. Nierzadko słyszalny był specyficzny świst i pogłos, zauważalnie różny od nominalnego dźwięku drona w locie. Poczynione spostrzeżenia stały się inspiracją do rozwoju metody diagnostycznej opartej o sygnały rejestrowane z wykorzystaniem mikrofonów.

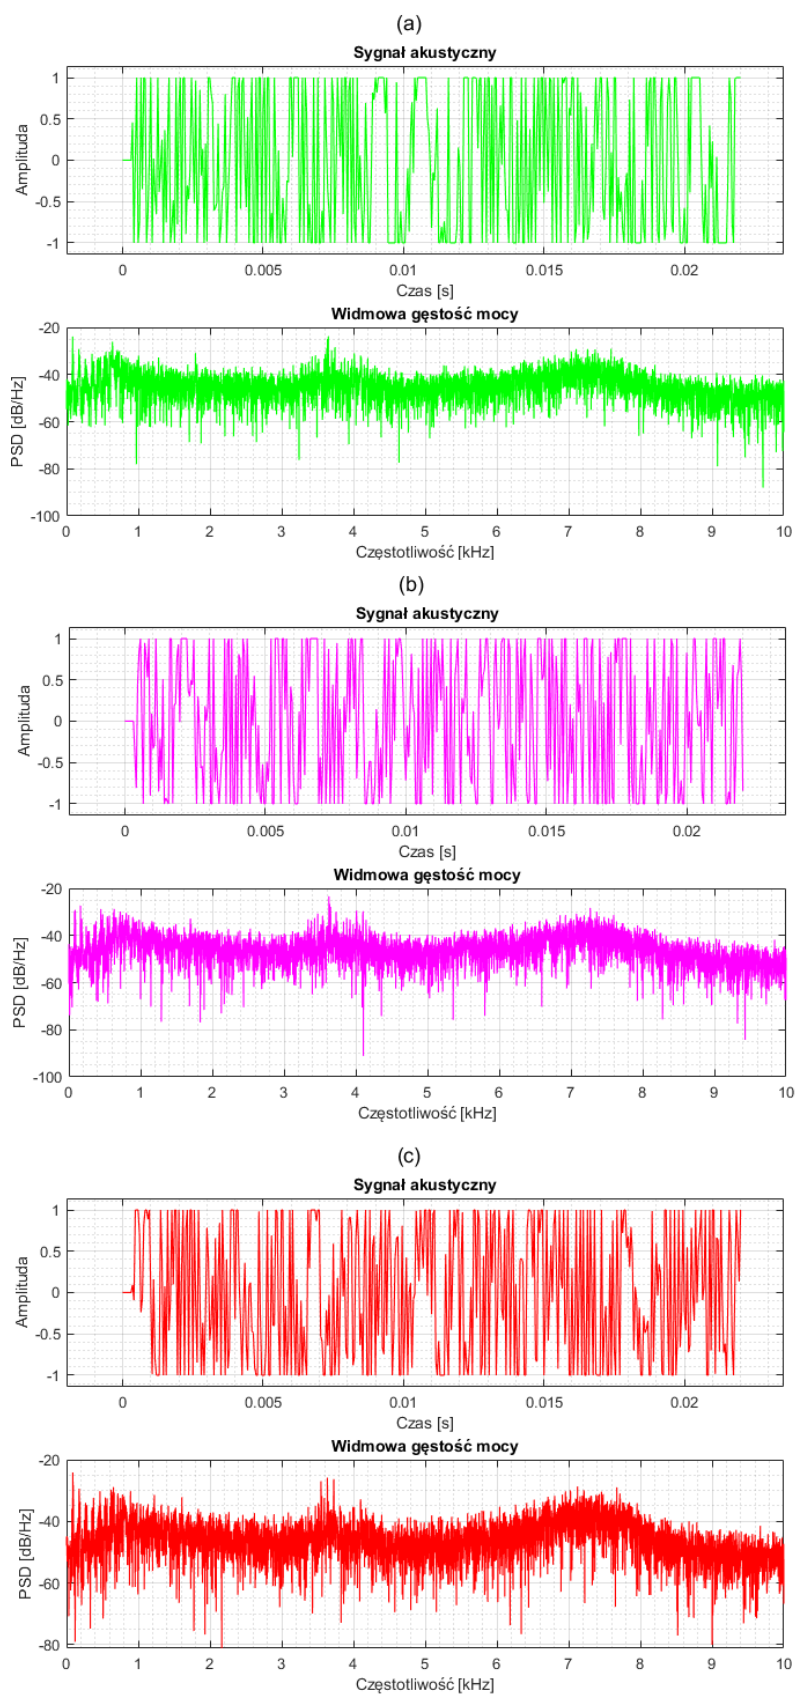
Szereg istniejących prac naukowych, dotyczących zarówno specyficznego problemu technicznego omawianego w rozprawie, jak i szerszych zastosowań diagnostycznych, wskazuje na potencjał informacji zawartej w falach dźwiękowych. W części 2.3.3 rozprawy przytoczono szereg przykładów, wskazując jednocześnie na pewne niedoskonałości i braki wspomnianych metod. Celem szczegółowym opracowania nowego algorytmu było uzyskanie wyników lepszych jakościowo oraz ewaluowanych na danych lepiej odzwierciedlających rzeczywisty lot UAV. Ponadto, według najlepszej wiedzy autora, nie zaprezentowano dotychczas rozwiązania opartego na sygnałach rejestrowanych bezpośrednio na pokładzie UAV i wykorzystującego macierz mikrofonów do zlokalizowania tej klasy uszkodzeń.

Prace nad metodą realizowane były w wieloosobowym zespole. Udziałem autora rozprawy jest pomysł wykorzystania sygnałów akustycznych do wykrywania uszkodzeń wirników, wykonanie oprzyrządowania oraz szczegółowa koncepcja metody. W tym pojęciu zawarte są: zaprojektowanie eksperymentów, wstępna analiza uzyskanych danych oraz dobór cech charakteryzujących występowanie uszkodzeń. Dalszy udział autora ograniczył się do nadzoru nad procesem ewaluacji wyników i przygotowania materiału do publikacji. Klasyfikator uszkodzeń oparty o techniki uczenia głębokiego (ang. *deep learning*) został zaproponowany i zaimplementowany przez Radosława Kulikowskiego oraz Marka Kołodziejczaka. Loty eksperymentalne połączone z rejestracją danych akustycznych zostały wykonane wspólnie.

5.4.2 Koncepcja metody

Na potrzeby opracowania i ewaluacji nowego algorytmu wykonano system pomiarowy wykorzystujący macierz czterech miniaturowych mikrofonów wykonanych w technologii MEMS. Wykorzystano dostępne na rynku komponenty przeznaczone pierwotnie do urządzeń typu IoT oraz popularną, miniaturową platformę komputerową typu SBC. Opracowane oprzyrządowanie pomiarowe omówiono szczegółowo w części 4.4 rozprawy. Podstawowym założeniem było skonstruowanie systemu o wielkości, masie i wymaganiach dotyczących poboru energii ograniczonych w takim stopniu, aby możliwa była jego autonomiczna praca na pokładzie robota *Falcon V5*. Struktura opracowanego oprzyrządowania jest oparta na podobnych założeniach co systemu sieci sensorowej. Oznacza to zastosowanie czterech mikrofonów rozlokowanych zgodnie z ramionami wielowirnikowego drona. W odróżnieniu od rozproszonego układu akcelerometrów wszystkie mikrofony ułożone są na płycie *ReSpeaker* znajdującej się w centralnej części UAV. Eliminuje to konieczność prowadzenia dodatkowego okablowania i ingerencji w konstrukcję ramion. Przyjęto założenie, wedle którego takie rozmieszczenie sensorów pozwoli na zlokalizowanie miejsca uszkodzenia na podstawie różnic w natężeniu i charakterze rejestrowanego dźwięku. Dla zweryfikowania tego założenia wykonano wstępny eksperyment, w którym zarejestrowano sygnały akustyczne dla dwóch bazowych scenariuszy — lotu ze sprawnymi oraz z jednym uszkodzonym wirnikiem. Na wykresach 5.13 przedstawiono wybrane próbki trzech kategorii sygnałów i ich widmowe gęstości mocy uśrednione dla kilkuset okien czasowych. Kategorie sygnałów obejmowały próbki rejestrowane odpowiednio przy braku uszkodzeń (a), przy wystąpieniu uszkodzenia i dla sygnału rejestrowanego przez najdalszy mikrofon macierzy (b) oraz dla próbki nagranej w tym samym okresie, ale z wykorzystaniem mikrofonu położonego najbliżej miejsca uszkodzenia (c).

Analiza wykonana bezpośrednio na sygnałach akustycznych nie pozwala na jednoznaczne wskazanie wzorców częstotliwościowych. Z drugiej strony, wyraźnie widoczna jest różnica w rozkładzie częstotliwości dla widma uzyskanego za pomocą mikrofonu najbliższego uszkodzeniu. Pozwala to przyjąć założenie, że nawet jeśli charakterystyczna sygnatura uszkodzenia nie jest widoczna tak jasno, jak dla sygnałów wibracyjnych, to odpowiednio dobrana metoda ekstrakcji cech i oparty na niej model wykorzystujący uczenie maszynowe mogą pozwolić na klasyfikację uszkodzeń na podstawie akustycznego źródła informacji.



Rys. 5.13: Próbkę sygnałów akustycznych i wyznaczone dla nich wykresy widmowej gęstości mocy [103]

5.4.3 Przetwarzanie sygnałów akustycznych

Potok przetwarzania sygnałów akustycznych oparto na zasadzie zbliżonej do prezentowanych w poprzednio omawianych schematach diagnostycznych. Algorytm diagnostyczny opiera się na krótkich wycinkach sygnałów pobieranych z czterokanałowych plików audio z wykorzystaniem funkcji okna *Kaisera*. Szerokość stosowanych ramek ponownie jest parametrem rozważanym dalej w kontekście skuteczności procesu diagnostycznego. Każdy z kanałów zawiera dane z jednego z mikrofonów i w dalszych etapach przetwarzany jest niezależnie. Surowe sygnały są wstępnie filtrowane i odszumiane z wykorzystaniem wbudowanych funkcji przetwornika ADC (*ang. Analog to Digital Converter*) macierzy mikrofonowej.

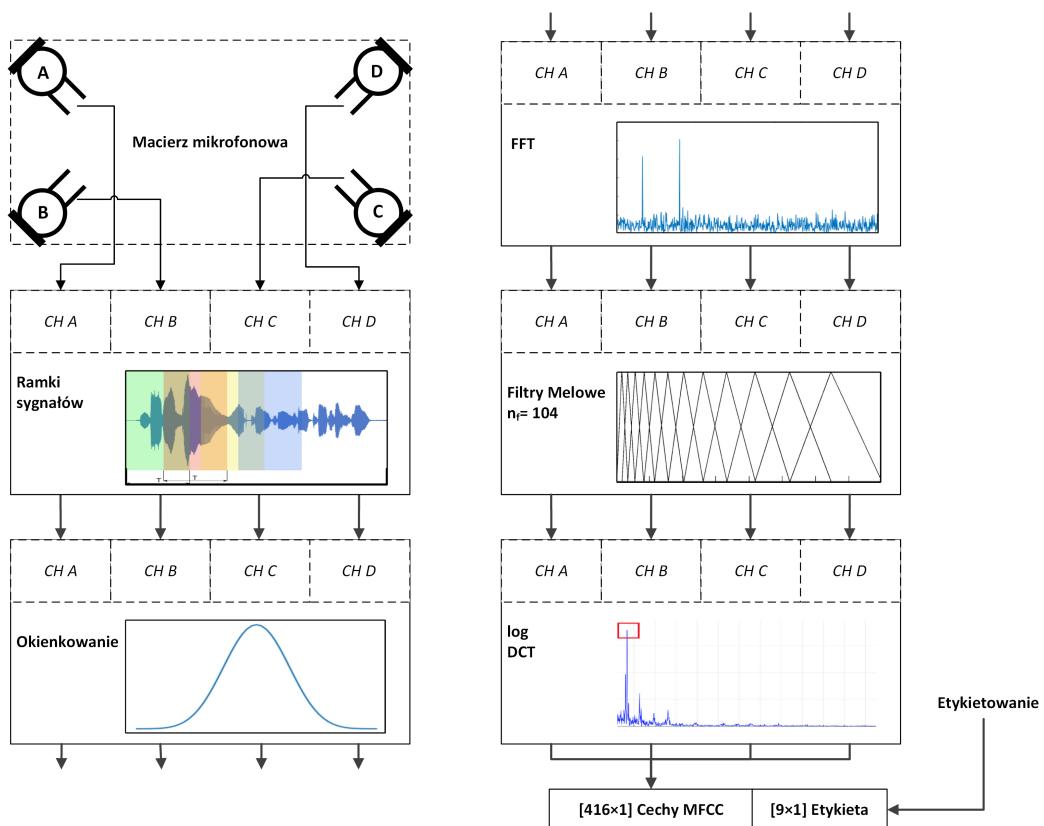
Charakterystyczna sygnatura akustyczna tworzona jest za pomocą metody MFCC (*ang. Mel Frequency Cepstrum Coefficients*). Podstawowym zastosowaniem tego narzędzia są algorytmy rozpoznawania mowy [104]. Metoda dostarcza współczynników cepstralnych opisujących sygnał akustyczny w dziedzinie częstotliwości z wykorzystaniem skali *melowej*, naturalnej dla ludzkiego zmysłu słuchu. Z racji, że wiele typów uszkodzeń maszyn wirujących dostarcza sygnatur dźwiękowych w słyszalnym zakresie, metoda MFCC w ostatnich latach znajduje szerokie zastosowanie w zadaniach diagnostycznych tej kategorii [105, 106]. Zastosowana implementacja algorytmu składa się z następujących kroków [107]:

1. W pierwszym etapie przetwarzania wykonywana jest preemfaza sygnału, czyli sztuczne wzmocnienie przebiegu wraz ze zwiększaniem się częstotliwości. Zabieg ten wykonywany jest dla wyrównania energii sygnału w całym analizowanym zakresie w celu poprawy stosunku sygnału do szumu i uniknięcia błędów numerycznych oraz istotnych różnic w wartościach widma.
2. Następnie, dla pojedynczej ramki sygnału pobranego z wykorzystaniem funkcji okna wyznaczane jest widmo amplitudowe z użyciem algorytmu FFT.
3. W kolejnym kroku widmo amplitudowe przekształcane jest do tzw. *spektrum Melowego*. Proces polega na filtrowaniu sygnału z wykorzystaniem zespołu pasmowo przepustowych trójkątnych filtrów rozmieszczonych w dziedzinie częstotliwości w równych odstępach według skali melowej.

Uzasadnieniem tego podejścia jest nieliniowy sposób postrzegania wysokości tonów przez ludzkie ucho. Stosowana skala jest w przybliżeniu liniowa dla częstotliwości do ok. 1 kHz i logarytmiczna dla wyższych. W bazowej wersji metody diagnostycznej stosowany jest bank 208 filtrów, natomiast do dalszej analizy wybierane są 104 najbardziej istotne cechy.

4. Dalszy etap algorytmu polega na wyznaczeniu dyskretnej transformaty cosinusowej z logarytmu filtrowanego widma. W rezultacie uzyskiwane jest cepstrum sygnału. Proces wykonuje się w celu dekorelowania współczynników opisujących sąsiadujące ze sobą pasma.

Do otrzymanych współczynników MFCC na podstawie scenariusza realizowanego w danym eksperymencie dodawane są etykiety opisujące wystąpienie, lokalizację i rodzaj uszkodzenia. W efekcie pełen opis parametryczny dźwięku rejestrowanego przez macierz mikrofonów składa się z 416 współczynników cepstralnych grupowanych kanałami oraz wspomnianej etykiety. Kolejne kroki algorytmu przetwarzania i wyznaczania wektora cech sygnałów akustycznych podsumowano na ilustracji 5.14.

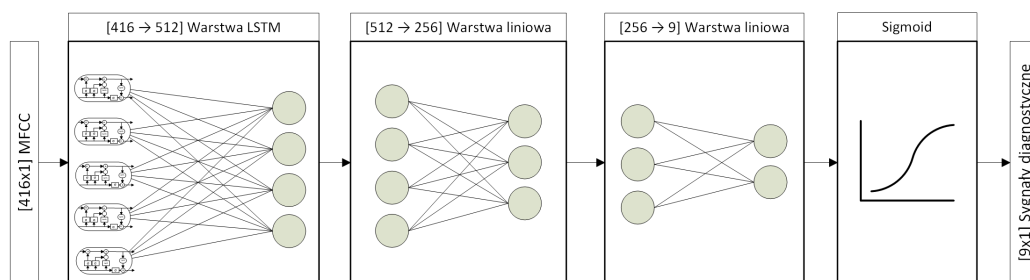


Rys. 5.14: Etapy przetwarzania sygnałów akustycznych [103]

5.4.4 Klasyfikator uszkodzeń

Ostatnim etapem algorytmu diagnostycznego jest klasyfikacja wedle strategii pozwalającej na wykrycie, zlokalizowanie i określenie typu uszkodzenia. W ramach pracy zespołowej zaproponowano do walidacji szereg modeli opartych o metody uczenia głębokiego. Najbardziej obiecujące wyniki uzyskano dla klasyfikatora opartego o rekurencyjną sztuczną sieć neuronową - RNN (*ang. Recurrent Neural Network*). Charakterystycznym elementem stworzonego modelu jest warstwa LSTM złożona z komórek typu *long-short term memory* (w wolnym tłumaczeniu: *długa pamięć krótkich wzorców*). Sieci o tej strukturze są szeroko stosowane do rozpoznawania wzorców w sekwencjach i modelowania zależności czasowych. Dodatkowo, użyteczną cechą sieci typu LSTM jest znaczne wyeliminowanie problemu zanikającego gradientu [108]. W ostatnich latach modele o tej architekturze znalazły zastosowanie w licznych problemach diagnostycznych, ze szczególnie dużą liczbą implementacji dotyczącej detekcji uszkodzeń maszyn wirujących [109, 110].

Architektura proponowanego klasyfikatora uszkodzeń ma postać sieci neuronowej o warstwie wejściowej typu LSTM, następujących po niej dwóch w pełni połączonych warstwach ukrytych oraz warstwy wyjściowej z sigmoidalną funkcją aktywacji. Wejściem sieci jest wspomniany wcześniej 416-elementowy wektor składający się z czterech grup po 104 współczynniki MFCC wyznaczone dla każdego kanału — mikrofonu macierzy. Strukturę omawianej RNN przedstawiono na ilustracji 5.15.



Rys. 5.15: Architektura klasyfikatora LSTM [103]

Model posiada 9 binarnych wyjść wskazujących na wynik predykcji. Jest to zasadnicza różnica w sposobie wskazywania rezultatu klasyfikacji do poprzednio omawianych metod, w których każdy z klasyfikatorów miał jedno wyjście określające przynależność do dwóch lub większej liczby klas. Pierwsze z wyjść modelu LSTM wskazuje na wystąpienie uszkodzenia. Sklasyfikowanie wszystkich wirników jako sprawnych traktowane jest jako predykcja

pozytywna i tym samym rzeczona flaga przyjmuje wartość „1”, blokując jednocześnie pozostałe wyjścia. W przeciwnym wypadku pozostałe osiem wyjść wskazuje na możliwe kombinacje lokalizacji uszkodzeń (w obrębie jednostek napędowych oznaczanych literami A-B-C-D) oraz typów uszkodzeń (etykiety T oraz E oznaczające odpowiednio złamanie końcówki płata lub uszkodzenie krawędzi natarcia). Warto zaznaczyć, że sieć uczona była na zbiorze danych zawierającym sygnały rejestrowane podczas lotów z dwoma uszkodzonymi wirnikami. Z tego względu, w obrębie prawidłowych klasyfikacji system diagnostyczny może zgłosić dwie pozytywne predykcje. Struktura warstwy wyjściowej modelu została dopasowana do zadania rozpoznawania uszkodzeń według przypadków zakładanych w zebranych danych. Jego szerszy opis zawarto w części 6.5 rozprawy.

5.4.5 Podsumowanie

Akustyczna metoda diagnostyki wirników nośnych jest najbardziej złożoną i wymagającą obliczeniowo spośród wszystkich proponowanych algorytmów. Ogólna konstrukcja potoku przetwarzania sygnałów w opartej o dane metodzie diagnostycznej pozostała niezmienna, natomiast zasadniczo zmodyfikowano rodzaj technik przetwarzania sygnałów i klasyfikacji ich sygnatur. Jako źródło informacji o uszkodzeniu wykorzystywane są 4 kanały sygnałów audio rejestrowanych z wykorzystaniem podsystemu macierzy mikrofonowej. Wskazany system pomiarowy został opracowany w miniaturowej formie i umieszczony bezpośrednio na pokładzie UAV. Do parametryzacji sygnałów akustycznych wybrano metodę MFCC, natomiast wnioskowanie o wystąpieniu, lokalizacji i typie uszkodzenia wykonywane jest z wykorzystaniem rekurencyjnej sieci neuronowej. Obydwa algorytmy są znacznie bardziej złożone obliczeniowo w porównaniu do nieskomplikowanych sygnatur widmowych i klasyfikatorów stosowanych z powodzeniem dla sygnałów wibracyjnych. Z wymienionych powodów metoda akustyczna jest rozwiązaniem innej klasy, przeznaczonym raczej do aplikacji w pokładowych komputerach lotu, niż w niskopoziomowych sterownikach opartych o mikrokontroler.

Eksperymenty walidacyjne

W poprzednich rozdziałach nakreślono kontekst problemu technicznego i przedstawiono propozycje metod jego rozwiązania wraz z opracowanymi rozwiązaniami technicznymi. Szósta część rozprawy zawiera zwięzły opis serii eksperymentów walidacyjnych, dzięki którym zbudowano zbiory sygnałów wibroakustycznych wykorzystywanych w zadaniu diagnostyki uszkodzeń wirników nośnych UAV (tzw. *ang. datasety*). W pierwszej kolejności prezentowane są założenia oraz przebieg procesu uczenia i ewaluacji klasyfikatorów uszkodzeń. W dalszej części pokazane są próbki i egzemplarze uszkodzonych wirników oraz analizowane stany systemu i zakresy zmienności parametrów statku powietrznego w trakcie lotu. W finalnych częściach rozdziału przedstawione jest ilościowe podsumowanie zarejestrowanych danych.

6.1 Metodyka prowadzenia eksperymentów

Przebieg przeprowadzonego procesu badawczego był zbliżony w przypadku wszystkich omawianych metod diagnostycznych i składał się z następujących kroków:

1. Opracowanie koncepcji algorytmu diagnostycznego rozumiane jako wykonanie pierwszych eksperymentów, analiza próbek sygnałów wibroakustycznych, obserwacja zjawisk i wstępny dobór odpowiednich metod w celu rozwiązania postawionego problemu.
2. Prace techniczne polegające na przygotowaniu eksperymentów poprzez stworzenie odpowiednich mechanizmów pomiarowych.
3. Pierwsza seria lotów eksperymentalnych prowadząca do zbudowania zbioru danych obejmującego najbardziej skrajne przypadki diagnostyczne.

4. Implementacja algorytmów przetwarzania sygnałów i uczenia maszynowego z wykorzystaniem zarejestrowanych danych. Wstępna analiza wyników, dobór, dostrajanie i optymalizacja stosowanych technik. Ewaluacja stworzonych rozwiązań technicznych.
5. Druga seria eksperymentów na UAV mająca na celu zebranie licznego zbioru danych rejestrowanych w możliwie szerokim zakresie warunków i scenariuszy lotów.
6. Właściwa walidacja metody diagnostycznej na podstawie szerokiego zestawu danych, dalsze ulepszanie klasyfikatorów uszkodzeń poprzez dostrajanie hiperparametrów.
7. Opracowanie finalnych wyników na podstawie klasyfikacji zbiorów testowych, podsumowanie i publikacja rezultatów.

Opisana metodyka dzieliła prowadzone badania na trzy zasadnicze etapy. W pierwszym szukano potwierdzenia wstępnych założeń i pomysłów dotyczących możliwości wykorzystania danych z sensorów pokładowych BSP w postawionym zadaniu diagnostycznym. Wykonywane były również prace techniczne. Kolejny etap dotyczył stworzenia prototypu (demonstratora) algorytmu diagnostycznego (ang. *proof of concept, PoC*), dla potwierdzenia postawionych hipotez i zdefiniowania problemów oraz ograniczeń w skuteczności projektowanego procesu FDI. Finalny etap miał na celu walidację i zweryfikowanie skuteczności metody dla szerokiego studium przypadków. Warto nadmienić, że omawiany proces niejednokrotnie przebiegał iteracyjnie ze względu na nowe obserwacje i wnioski uzyskiwane na różnych etapach badań.

6.2 Etapy przetwarzania danych eksperymentalnych

Zastosowany schemat rozwijania rozwiązań diagnostycznych jest typowy i charakterystyczny dla metod *data-driven*. Sednem mechanizmu detekcji i identyfikacji uszkodzeń jest zbudowanie modelu statystycznego na podstawie licznych danych eksperymentalnych i nauczanie klasyfikatora rozpoznawania charakterystycznych symptomów, które towarzyszą występowaniu

zdefiniowanych wariantów uszkodzeń wirników. Z tego względu schemat postępowania podzielić można na kilka zasadniczych kroków.

Pierwszym etapem jest seria eksperymentów przeprowadzanych tak, aby pokryć cały zakres analizowanych przypadków. Po zdefiniowaniu klas diagnostycznych wykonywane były loty wielowirnikowego UAV *Falcon* w odmiennych scenariuszach i warunkach lotów. Pod pojęciem scenariusza lotu rozumiane jest wykonywanie eksperymentu przy zakładanym stanie systemu, tj. z wirnikami sprawnymi lub pewną liczbą uszkodzonych, według kombinacji i typów obejmujących wszystkie klasy modelu. Istotnym aspektem była duża zmienność warunków, definiowanych z kolei jako czynniki mające wpływ na uzyskiwane z sygnałów wibroakustycznych wskaźniki diagnostyczne. Ewaluacja proponowanych metod detekcji uszkodzeń, opisywana szeroko w kolejnym rozdziale, wskazuje na duże znaczenie pewnych praktycznych parametrów pracy UAV w locie w skuteczności procesów diagnostycznych. Zostały one częściowo zdefiniowane podczas wstępnych obserwacji omawianych w części 3.2.2 rozprawy i usystematyzowane w kolejnych podrozdziałach. Nadrzędnym celem przeprowadzanych eksperymentów było jak najlepsze odwzorowanie rzeczywistych parametrów lotów BSP dla potwierdzenia skuteczności proponowanych rozwiązań diagnostycznych w warunkach możliwie zbliżonych do potencjalnej implementacji.

W kolejnym kroku zbiory surowych sygnałów dzielone są na dwie zasadnicze kategorie. Większa część przeznaczona jest do uczenia i walidacji klasyfikatorów uszkodzeń. W zależności od analizowanego algorytmu niektóre implementacje metod uczenia maszynowego samoczynnie dokonywały dalszego podziału na podzbiory uczący i walidacyjny. Przykładami są mechanizmy walidacji skróśnej wykorzystywane przy maszynach wektorów nośnych czy mechanizm *out-of-bag error* dla lasów losowych. Druga część danych przeznaczana była do wykonania finalnych testów skuteczności algorytmu detekcji jako tzw. zbiór testowy. Przydzielano do wszystkich trzech kategorii sygnałów wykonywano tak, aby dane z tego samego lotu nie były wykorzystywane jednocześnie w procesie uczenia i testowania modelu. Typowo stosowaną proporcją liczebności obu kategorii było 70 do 30%, z większym udziałem zbioru uczącego. Liczba próbek dla każdej z klas była zbliżona, a same dane obejmowały pełen zakres warunków pracy systemu.

W trzecim etapie wykonywane było przetwarzanie sygnałów według procedur opisywanych w rozdziale 5. Operacje wykonywane były indywidualnie

alnie dla każdej ramki sygnałów, rozumianej jako zestaw rejestrowanych w tym samym okresie sygnałów wibracyjnych lub akustycznych pobranych z pełnego zapisu z wykorzystaniem zdefiniowanej funkcji okna. Wynikiem tego kroku były wektory cech, czyli próbki przetworzonych danych opisujące stan maszyny w trakcie wykonywania danego lotu. Uzupełnione o etykiety określające przynależność do klasy diagnostycznej stanowią wejście dla modeli wnioskujących o uszkodzeniach wirników nośnych.

Opisana procedura znalazła zastosowanie przy projektowaniu, ulepszeniu i ocenie skuteczności klasyfikatorów uszkodzeń. Przedstawiony schemat jest stosunkowo łatwy w implementacji w warunkach rzeczywistych. Zasadniczą różnicą jest podział procesu na dwa podstawowe etapy:

1. Nauczenie klasyfikatora rozpoznawania wzorców uszkodzeń wykonane *offline* z wykorzystaniem danych opracowanych według opisanej procedury.
2. Implementacja potoku przetwarzania sygnałów oraz modelu *online* i klasyfikowanie zestawów sygnałów rejestrowanych w czasie rzeczywistym z wykorzystaniem buforów o zdefiniowanej długości.

Przykład praktycznej implementacji jednej z proponowanych metod diagnostycznych zamieszczono w [111].

6.3 Rozpatrywane typy uszkodzeń


Zarówno dostępna literatura [61, 112] jak i doświadczenia autora rozprawy [113, 97] wskazują na dwa podstawowe typy fizycznych uszkodzeń rotorów stosowanych w miniaturowych UAV. Pierwszy z nich polega na utracie końcowej części jednego z płatów wirnika. Do drugiej kategorii uszkodzeń dochodzi w sytuacji, gdy pracujący wirnik w wyniku kolizji z obcym obiektem ulegnie odkształceniu bez utraty części płata. Na ilustracji 6.1 przedstawiono przykładowe egzemplarze wirników uszkodzonych na dwa podstawowe sposoby.

Ostatni z wymienionych typów degradacji zaobserwowano dla wirników wykonanych z kompozytu CFRP (*ang.* *Carbon Fiber Reinforced Polymer*),



Rys. 6.1: Przykłady dwóch głównych typów uszkodzeń wirników — złamanie płata (po lewej) oraz deformacja krawędzi (po prawej)

czyli arkuszy włókna węglowego łączonych żywicą epoksydową. Właściwości materiału sprawiają, że w wyniku siły uderzenia często dochodzi do rozwarstwienia laminatu zamiast całkowitego pęknięcia. Na rodzaj uszkodzenia ma wpływ miejsce uderzenia — uszkodzenia w końcowej części płata skutkują przeważnie pełną utratą fragmentu wirnika, natomiast w przypadku uszkodzenia zachodzącego bliżej piasty w miejscu, gdzie szerokość profilu lotniczego jest większa, częściej dochodzi od odkształcenia krawędzi. Ten typ degradacji jest o tyle problematyczny, że rozwarstwienie fragmentu laminatu może postępować w wyniku sił działających na pracujący wirnik. Zjawisko to zostało zaobserwowane podczas jednego z eksperymentów, prowadząc do kompletnej utraty całego płata. Ilustracja 6.2 przedstawia w powiększeniu deformację krawędzi profilu wirnika wykonanego z CFRP.



Rys. 6.2: Deformacja krawędzi profilu lotniczego w 10-calowym wirniku wykonanym z CFRP

Pierwsze kilka egzemplarzy uszkodzonych wirników obu typów odzyskano bezpośrednio z incydentów które miały miejsce w trakcie lotów BSP. W ramach postępów prac, do walidowania proponowanych metod diagnostycznych na szerszym zbiorze danych dalsze wirniki uszkadzano celowo w kontrolowanych warunkach symulujących uderzenie o twardy obiekt.

Projektując klasyfikatory uszkodzeń, przyjęto szereg oznaczeń opisujących poszczególne klasy:

- System, w którym wszystkie wirniki są sprawne, oznaczany jest za pomocą litery **H** - klasa *sprawy*, ang. *Healthy*
- Dla uszkodzenia wirnika pierwszego typu, polegającego na utracie fragmentu płata stosowano oznaczenie **T**, ang. *Tip damage*
- Druga kategoria uszkodzeń obejmująca deformację krawędzi opisywana była literą **E**, ang. *Edge damage*
- Dla metod, które nie pozwalały na rozróżnienie typu, a jedynie wykrywały samo wystąpienie uszkodzenia, stosowana było zbiorcze oznaczenie **F**, ang. *Faulty*

Dla metody akustycznej pozwalającej jednocześnie na lokalizację i określenie typu uszkodzenia wirnika UAV stosowano dwuliterowe etykiety, stanowiące połączenie powyższego opisu z oznaczeniem jednostki napędowej według liter alfabetu (A-B-C-D).

6.4 Zbiory sygnałów wibracyjnych

Eksperymenty polegające na rejestracji sygnałów wibracyjnych w trakcie lotu BSP wykonywane były w kilkunastu seriach, zgodnie z etapami rozwijania kolejnych metod diagnostycznych. W przypadku danych rejestrowanych przez pokładowy czujnik IMU dodatkowe sekwencje rejestrowano również przy okazji eksperymentów z siecią sensorową i macierzą mikrofonów. Było to możliwe dzięki niezależnej pracy systemów pomiarowych. W rezultacie prezentowane w rozprawie wyniki ewaluacji dwóch pierwszych algorytmów diagnostycznych (zob. 7.1 oraz 7.2) korzystają z większej ilości danych i zakresu przypadków niż w momencie oryginalnej publikacji pierwszych wyników [113].

Planując loty eksperymentalne dokładano starań, aby zapewnić równą liczebność wszystkich analizowanych klas. Dla analizowanych przypadków loty wykonywano kilkakrotnie. W obrębie każdego modelowanego stanu

systemu zapewniano możliwie pełne pokrycie zakładanych parametrów lotu. Do zmiennych należały:

- Trajektoria lotu obejmująca lot w zawisie lub agresywne manewry drona. Poczynione obserwacje potwierdzają bezpośrednią zależność położenia składowej o częstotliwości charakterystycznej dla uszkodzenia w widmie sygnałów wibracyjnych od prędkości obrotowej wirników. Tym samym, przypadki w których dron wykonuje manewry i jednocześnie gwałtownie zmienia sterowanie jednostek napędowych są trudniejsze do klasyfikacji pod kątem wystąpienia uszkodzenia. Również sygnał akustyczny charakteryzuje się większym zakresem zmian częstotliwości i natężenia dla różnych trajektorii lotu. Przy pierwszych wersjach *datasetu* wibracyjnego loty obu rodzajów wykonywano oddzielnie. Po opracowaniu metod, których skuteczność była równie wysoka dla obu kategorii danych, łączono fazy lotu w obrębie jednego eksperymentu.
- Masa brutto UAV w locie. Analiza spektrogramów wibracji pokazała jasno wpływ tego parametru na tłumienie wibracji oraz zakres prędkości obrotowych osiąganych przez wirniki. Z tego względu część lotów wykonywano z dodatkowym obciążeniem wynoszącym typowo 20-35% nominalnej masy maszyny.
- Stosowanie poszczególnych egzemplarzy wirników. Do czterech pierwszych próbek odzyskanych z rzeczywistych incydentów dodano kolejne 5 uszkodzonych sztucznie w podobnym stopniu i charakterze. Wirniki pochodzące od trzech różnych producentów wymieniało pomiędzy eksperymentami. Również wśród sprawnych egzemplarzy stosowano dwa różne ośmioelementowe zestawy.

Dane z sieci sensorowej pozyskiwano z zastosowaniem innego mechanizmu pozwalającego na rejestrację dużo dłuższych sygnałów. W przypadku tych eksperymentów nie rozróżniano typu uszkodzenia, a zamiast tego zmieniano jego lokalizację. Oprócz tego zachowano zmienność czterech wspomnianych warunków lotu.

W tabeli 6.1 zawarto podsumowanie ilościowe zbudowanego zbioru sygnałów wibracyjnych. Rozmiar *datasetu* opisano w sekundach czasu rejestracji z uwagi na zmienną długość ramek sygnałów stosowanych w algorytmach diagnostycznych. Typowe wielkości fragmentów to kilkaset milisekund, co w

	Loty	Wirniki	Dł. sygnałów [s]
Wszystkie eksperymenty	91	17	2471
w tym: bez uszkodzeń	22	8	506
z uszkodzeniami	69	9	1965
w tym: typu T	45	6	1557
typu E	24	3	408

Tab. 6.1: Podsumowanie ilościowe zbioru sygnałów wibracyjnych

połączeniu z pobieraniem próbek z wykorzystaniem przesuwnego o ułamek długości okna pozwoliło na generowanie zbiorów uczących zawierających od kilkuset do kilku tysięcy elementów dla każdej z klas.

6.5 Zbiory sygnałów akustycznych

Tworzenie zbioru danych akustycznych miało odmienny charakter. *Dataset* rozszerzano w miarę rozwoju i zwiększania funkcjonalności klasyfikatora uszkodzeń. Przeprowadzone eksperymenty musiały pokryć w równym stopniu wszystkie kombinacje rozważanych przypadków, tj. klasy opisujące jednocześnie lokalizację, typ oraz samo wystąpienie uszkodzenia, w tym w postaci pary niesprawnych. Podwójne defekty rozpatrywano dla dwóch możliwości: uszkodzeń w dwóch sąsiadujących wirnikach oraz w parze przeciwległych jednostek napędowych. Opracowany system pomiarowy oparty o komputer SBC nie posiadał ograniczeń niskopoziomowych mechanizmów rejestrowania wibracji i pozwalał na nagrywanie sekwencji o praktycznie dowolnej długości. Ostatecznie wykonano 34 loty rejestrując w każdym od 200 do 240 sekund czterokanałowych sygnałów akustycznych. W przypadku występowania uszkodzenia, czas rejestracji był nieznacznie skrócony ze względu na zwiększony pobór energii przez napędy. W procesie zachowano założenia i zakres warunków lotów zakładany dla *datasetu* sygnałów wibracyjnych. W tabelicy 6.2 zawarto podsumowanie ilości zebranych danych pod kątem występujących w systemie uszkodzeń oraz liczebności danych dla każdej z dziewięciu rozpatrywanych klas.

Opisywany zbiór danych został przy okazji publikacji wyników badań udostępniony publicznie w ramach mechanizmu otwartego dostępu ¹.

¹<https://chmura.put.poznan.pl/s/u5rHJbmpRj90Eou>

Stan systemu	Loty	Dł. sygnałów [s]	
Brak uszkodzeń	10	2400	
Pojedynczy uszkodzony wirnik	12	2400	
Uszkodzenie podwójne	Kolejne wirniki	6	1200
	Przeciwnie wirniki	6	1200

Klasa	Lokalizacja uszkodzenia				Typ	Loty	Dł. sygnałów [s]
	A	B	C	D			
H	-	-	-	-	-	10	2400
AT	+	-	-	-	„T”	5	1000
BT	-	+	-	-		5	1000
CT	-	-	+	-		5	1000
DT	-	-	-	+		5	800
AE	+	-	-	-	„E”	5	800
BE	-	+	-	-		5	1000
CE	-	-	+	-		5	800
DE	-	-	-	+		5	1200

Tab. 6.2: Podsumowanie eksperymentów z rejestracją sygnałów akustycznych oraz liczebność danych dla każdej z klas [103]

6.6 Techniki stosowane do oceny modeli

Jednym z najistotniejszych etapów opracowywania metod diagnostycznych była walidacja i ewaluacja skuteczności proponowanych klasyfikatorów. Zarówno same modele, jak i poprzedzające je procesy przetwarzania sygnałów wibroakustycznych, charakteryzują się szeregiem wolnych parametrów wpływających na poprawność diagnostyki uszkodzeń. Do tych zmiennych, nazywanych powszechnie hiperparametrami, należą takie wartości jak długość rejestrowanych sygnałów, parametry algorytmu ekstrakcji cech i ich liczba czy wreszcie wewnętrzne parametry wybranych metod uczenia maszynowego. Zasadniczym etapem procesu tworzenia modeli diagnostycznych była wykonywana wielokrotnie walidacja mająca na celu dobór hiperparametrów prowadzących do uzyskania najlepszych wartości szeregu wybranych metryk. W finalnym etapie modele ewaluowano z wykorzystaniem zbiorów testowych.

6.6.1 Metody walidacji

Metody i techniki walidacji dobierano w zależności od charakteru analizowanego algorytmu uczenia maszynowego. W metodach diagnostycznych opartych o sygnały wibracyjne i klasyfikator SVM stosowano technikę n -krotnej stratyfikowanej walidacji krzyżowej [114]. Oznacza to proces, w którym zbiór treningowy dzielony jest na n podzbiorów, z czego $n - 1$ części wykorzystywane jest do ponownego uczenia klasyfikatora. Następnie przeprowadzany jest test predykcji z wykorzystaniem pozostałych danych. Procedurę powtarza się w taki sposób, aby każdy z fragmentów kolejno służył do testowania, a uzyskane wartości metryk uśrednia się po wszystkich iteracjach. Stratyfikacja oznacza technikę takiego dobierania danych w każdym z podzbiorów, aby zachować równą reprezentację każdej z klas. Dla dwóch wspomnianych modeli wykonywano dziesięciokrotną walidację krzyżową.

Metoda *lasu losowego*, wykorzystywana w algorytmie diagnostycznym opartym o dane z sieci sensorowej, dostarcza mechanizmu estymacji błędu *out-of-bag* o zbliżonym do walidacji krzyżowej zastosowaniu oraz dostarczającym zbieżnych wyników [115]. W algorytmie RF na etapie *baggingu* tworzone są poprzez kombinacje z powtórzeniami podzbiory danych treningowych, które następnie służą do uczenia poszczególnych „słabych” klasyfikatorów (drzew) w zespole. W naturalny sposób prowadzi to do niewykorzystania wszystkich próbek w procesie treningu. Pozostałe dane, określano jako próbki *out-of-bag*, mogą zostać wykorzystane do testowania tych drzew, które nie były na nich uczone [116]. Błąd klasyfikacji danych OOB dostarcza pierwszej informacji o dokładności modelu. Omawianą technikę stosowano wielokrotnie na etapie poszukiwania najlepszych hiperparametrów dla metody diagnostycznej wykorzystującej sieć sensorową.

W procesie doboru hiperparametrów sieci neuronowych klasyfikujących sygnatury sygnałów akustycznych wykorzystano klasyczny mechanizm walidacji na wydzielonym podzbiórze danych. Proces przeprowadzany był po każdej epoce uczenia sieci.

6.6.2 Podstawowe metryki

Zarówno na etapie walidacji, jak i w finalnej ewaluacji klasyfikatorów uszkodzeń podstawową metryką była dokładność (ang. *accuracy*), czyli od-

setek prawidłowych predykcji na zbiorze danych. W przypadku niektórych metod wieloklasowych charakter danych uzyskanych w trakcie eksperymentów nie pozwalał na uczenie modeli z wykorzystaniem *datasetów* o podobnej liczbie próbek dla każdego rozpatrywanego stanu systemu. W takich wypadkach do oceny stosowano metrykę dokładności zbilansowanej względem liczebności poszczególnych klas [117].

W zadaniach diagnostycznych niebanalny staje się problem kompromisu pomiędzy precyzją (ang. *precision*) a czułością (ang. *recall*) klasyfikatora. Stosowane metody uczenia maszynowego posiadają ciągłe wyjścia, a przypisanie predykcji do konkretnej klasy odbywa się na podstawie pewnej progowej wartości odcięcia. Prowadzi to do sytuacji, w której zwiększanie czułości modelu nieuchronnie skutkuje zmniejszeniem jego precyzji [118]. Z uwagi na przyjętą konwencję, w której wystąpienie uszkodzenia jest predykcją pozytywną, podczas procesu walidacji faworyzowano w niewielkim stopniu czułość, ponieważ wysoka jej wartość gwarantuje większą skuteczność wykrycia uszkodzenia kosztem liczniejszych „fałszywych alarmów”. Dla całościowej oceny modeli wykorzystano tzw. *metrykę F1*, czyli średnią harmoniczną z czułości i precyzji [119]. Dzięki temu możliwe było bezpośrednie porównanie klasyfikatorów na kolejnych etapach walidacji.

W problemach klasyfikacji binarnej do oceny poszczególnych modeli stosowano również krzywe ROC (ang. *Receiver Operating Curve*). Jest to sposób wizualizacji i optymalizacji wartości progowej dla wspomnianego kompromisu pomiędzy czułością modelu, a jego precyzją. Zwiększanie czułości, nazywanej inaczej TPR (ang. *True Positive Rate*), oznacza rosnącą liczbę predykcji fałszywie pozytywnych, a co za tym idzie — również malejącą swoistość modelu. Krzywa ROC prezentuje zależność pomiędzy czułością a metryką FPR (ang. *False Positive Rate*), czyli stosunkiem klasyfikacji fałszywie pozytywnych do całego zbioru próbek klasy negatywnej [120]. Wykreślanie charakterystyki ROC modelu w praktyce pozwala na jasne przedstawienie odsetka fałszywych alarmów (FPR) przy rosnącej czułości. Wybór odpowiedniego punktu na krzywej pozwala na odpowiednie „skonfigurowanie” algorytmu diagnostycznego.

Omawiana technika pozwala na wyznaczenie jeszcze jednej użytecznej wartości, jaką jest AUC (ang. *Area Under the Curve*). Jest to metryka redukująca rozmiar opisu za pomocą ROC do skalarnej wartości obliczanej jako pole powierzchni pod wspomnianą krzywą. Jest to sposób na bezpośrednie

porównywanie modeli, który został wielokrotnie wykorzystany w pracach przedstawianych w rozprawie.

Analiza uzyskanych rezultatów

W poniższym rozdziale przedstawiono rezultaty walidacji proponowanych metod diagnostycznych na podstawie danych eksperymentalnych opisanych w części 6 rozprawy. Wyniki działania algorytmów opisywane są w kolejności zgodnej z ich wprowadzeniem w rozdziale 5. Każda z części rozpoczyna się od wstępu, w którym przedstawiane są założenia dotyczące uwzględnianych w analizie stanów systemu, klas diagnostycznych, typów uszkodzeń i szczegółów wykorzystania zebranych sygnałów wibroakustycznych. W dalszej części opisów przedstawione są wyniki eksperymentów walidacyjnych modeli klasyfikatorów w zależności od stosowanej strategii przyjętej w zadaniu FDI oraz dla różnych wartości kluczowych hiperparametrów. Każda sekcja zakończona jest podsumowaniem wskazującym na mocne i słabe strony omawianych metod.

7.1 Ewaluacja metody wibrometrycznej

7.1.1 Wstęp

Ewaluacja metody opisanej w części 5.1 rozprawy została przeprowadzona na podstawie wybranych podzbiorów danych wibracyjnych. Sygnały rejestrowane były w awionice drona *Falcon V5* z wykorzystaniem pokładowego czujnika inercyjnego. Opis wykonanych eksperymentów i rozpatrywanych scenariuszy stanów uszkodzeń w pełnym zbiorze danych przedstawiono w podrozdziale 6.4.

Do analizy zastosowanie znalazły dwa zbiory danych podzielone w proporcji 70:30 na część przeznaczoną do treningu klasyfikatorów oraz do wykonania finalnej ewaluacji. Do części uczącej i testowej włączono pomiary z odrębnych lotów, realizowane niekiedy w dużym odstępie czasowym i podczas różnych eksperymentów. W analizie do poszukiwania najlepszych wartości hiperparametrów wykorzystano technikę walidacji krzyżowej.

W ewaluacji metody zastosowano dwa podzbiory danych:

- Zbiór A - „szeroki” zestaw danych obejmujący loty w dwóch podstawowych scenariuszach: brak uszkodzonych wirników (klasa „H”) oraz wystąpienie wirnika z jednym z dwóch rozważanych typów uszkodzeń (klasa „F”). Dla obu wymienionych przypadków zebrane dane obejmowały sekwencje rejestrowane podczas lotów w zawisie lub w trakcie wykonywania gwałtownych manewrów. Dodatkowo, dla połowy sekwencji zwiększono masę drona. Łącznie w zbiorze „A” zawarte jest 8 kombinacji możliwych scenariuszy lotów dla dwóch podstawowych stanów systemu.
- Zbiór B - jest to część omówionego powyżej zbioru ograniczona do danych rejestrowanych jedynie podczas lotu w zawisie i przy stałej masie platformy latającej.

Fragmenty sygnałów przetwarzane przez algorytm mają różną długość w zależności od zastosowanej szerokości funkcji okna. Pobierane były z przesunięciem o ułamek całkowitej długości. Stopień nakładania się na siebie kolejnych fragmentów (tzw. ang. *overlap*) dobierano w zakresie 0-50%, co pozwoliło na zapewnienie minimum 50 próbek dla każdej z klas w zbiorze testowym.

7.1.2 Model bazowy


Pierwszy z omawianych modeli stanowi punkt wyjścia do dalszej walidacji. Dla tego klasyfikatora uzyskano najlepsze wartości podstawowych metryk. Klasyfikator oparto o maszynę wektorów nośnych z jądrem wykorzystującym radialną funkcję bazową. W tabeli 7.1 przedstawiono hiperparametry omawianego klasyfikatora wraz z podstawowymi metrykami jakości predykcji. Uczenie, walidację oraz testy przeprowadzono na zbiorze A uwzględniającym wszystkie rozpatrywane scenariusze.

W dalszej kolejności dla opracowanego modelu wykreślono macierze błędów przedstawione na ilustracji 7.1. Zaprezentowane zostały w dwóch wersjach — jako procentowy udział danej kategorii predykcji w ogólnej liczbie próbek oraz bezpośrednio jako ilość klasyfikacji poszczególnych typów.

Parametr	Wartość
Długość pary sygnałów	500 ms
Szerokość analizowanego pasma	9.5 Hz
Liczebność - zbiór uczący	549
Liczebność - zbiór testowy	208
Funkcja jądra SVM	radialna
Optymalizator	SMO
Liczba n walidacji krzyżowej	10
Błąd walidacji	5.85%
Dokładność (<i>accuracy</i>)	0.923
Precyzja (<i>precision</i>)	1
Czułość (<i>recall</i>)	0.847
Metryka F1	0.918


Tab. 7.1: Hiperparametry oraz podstawowe metryki bazowego klasyfikatora SVM

W przyjętej konwencji wystąpienie uszkodzenia traktowane jest jako klasa pozytywna.



Rys. 7.1: Macierze błędów klasyfikatora bazowego dla testu na zbiorze A

Pierwszym spostrzeżeniem z analizy macierzy błędów jest brak wartości fałszywie dodatnich. W ani jednym wypadku próbka sygnału z lotu przy wszystkich sprawnych wirnikach nie została sklasyfikowana jako stan wystąpienia uszkodzenia. Wszystkie błędy predykcji oznaczają pominięcie rzeczywiście zaistniałego uszkodzenia. Niska czułość jest zdecydowanie niepożądaną cechą klasyfikatora w zastosowaniach diagnostycznych. Dla dalszego zobrazowania zagadnienia wykreślono rozkład wielkości decyzyjnych dla zbioru uczącego (rys. 7.2 wraz z podziałem na klasy). Wielkości decyzyjne opisano kolejno jako α_{ACCX} oraz α_{ACCY} , oznaczają amplitudy widma w przeszukiwanym paśmie dla dwóch kolejnych osi pomiarowych pokładowej jednostki IMU (zob. Rys. 5.5).



Rys. 7.2: Rozkład wielkości decyzyjnych w części treningowej zbioru A

Na podstawie graficznej reprezentacji można wnioskować, że problem wynika z trudnej separacji obu klas dla obszaru w środkowej części zakresów. Oznacza to, że wskaźniki dla obu klas przyjmują zbliżone wartości, natomiast klasyfikator ucząc się nierównomiernie, redukuje liczbę predykcji fałszywie pozytywnych lub fałszywie negatywnych. W efekcie model jest niedostatecznie czuły na występowanie uszkodzeń. Manipulując wartością progową dla wyjścia klasyfikatora, możliwe jest uzyskanie korzystniejszego stosunku czułości do precyzji. W rozpatrywanym modelu odbywało się to jednak kosztem znacznie zmniejszonej dokładności predykcji.

Wyniki ewaluacji metody na pełnym zbiorze danych potwierdzają wstępne przypuszczenia wysuwane na podstawie obserwacji spektrogramów. Algorytm wyznaczania pasma detekcji częstotliwości charakterystycznej uszkodzenia obarczony jest błędem, co może tłumaczyć nieprawidłowe klasyfikacje próbek rejestrowanych podczas gwałtowniejszych manewrów. Z drugiej strony, już na podstawie wstępnej analizy omawianej w rozdziale 3 można było spostrzec, że przy zwiększonym obciążeniu UAV sygnatyry uzyskane w trakcie lotów z uszkodzeniami był słabo rozróżnialne od tych rejestrowanych w trakcie lotu sprawnego systemu o nominalnej masie. Zauważalny był fakt, że każdy, nawet nieuszkodzony wirnik, nie jest idealnie wyważony i generuje

składową charakterystyczną. Ponadto propagacja i tłumienie drgań było zależne od masy platformy latającej.


7.1.3 Walidacja na zredukowanym zbiorze danych

Na podstawie wniosków opisanych w poprzednim podrozdziale przeprowadzono dodatkową analizę dla scenariuszy, w których algorytm śledzenia częstotliwości charakterystycznej ma potencjalnie największą skuteczność. Do uczenia klasyfikatora i jego ewaluacji wybrano próbki rejestrowane jedynie w trakcie lotów w zawisie oraz przy stałym obciążeniu platformy latającej (podzbiór **B**). W tabeli 7.2 przedstawiono hiperparametry i podstawowe metryki wytrenowanego klasyfikatora. Z kolei rysunek 7.3 przedstawia macierze błędów dla ewaluacji omawianym modelem na zbiorze testowym.


Parametr	Wartość
Długość pary sygnałów	500 ms
Szerokość analizowanego pasma	9.5 Hz
Liczebność - zbiór uczący	305
Liczebność - zbiór testowy	104
Funkcja jądra SVM	<i>radialna</i>
Optymalizator	<i>SMO</i>
Liczba n walidacji krzyżowej	10
Błąd walidacji	1.91%
Dokładność (<i>accuracy</i>)	0.942
Precyzja (<i>precision</i>)	1
Czułość (<i>recall</i>)	0.887
Metryka F1	0.94

Tab. 7.2: Hiperparametry oraz podstawowe metryki jakościowe klasyfikatora SVM wytrenowanego dla podzbioru **B**

Przedstawione wyniki wskazują na większą skuteczność detekcji uszkodzeń dla szczególnego podzbioru danych eksperymentalnych. W predykcjach ponownie nie wystąpiły wartości fałszywie dodatnie, a odsetek fałszywie ujemnych zauważalnie zmalał. Najśłabszą metryką ponownie jest czułość, co stanowi istotną wadę w zastosowaniu modelu do diagnostyki systemu. Analogicznie do poprzedniego kroku ewaluacji wykreślono rozkład wskaźników α . Wykres zamieszczono na rysunku 7.4.



Rys. 7.3: Macierze błędów klasyfikatora opracowanego na bazie podzbioru B




Rys. 7.4: Rozkład wielkości decyzyjnych dla podzbioru treningowego B

Analiza rozkładu wartości cech w zbiorze treningowym nie wykazuje poprawy dla zakresu problemowego w zbiorze A. Z drugiej strony, znacząco mniej jest próbek opisujących uszkodzenia i pokrywających się z klasą opisującą sprawny stan systemu w dolnym zakresie wartości. Potwierdza to hipotezę, że wyeliminowanie z analizy sekwencji pochodzących z lotów przy zmiennych warunkach zmniejsza liczbę przypadków z uszkodzeniami klasyfikowanych jako sprawny system. Dla takich przypadków proponowana metoda analizy widma nie wskazuje prawidłowo wystąpienia symptomów towarzyszących defektowi.

7.1.4 Znaczenie szerokości analizowanego pasma

Jednym z kluczowych parametrów metody diagnostycznej jest szerokość pasma wyznaczanego przez algorytm śledzenia częstotliwości charakterystycznej uszkodzenia, oznaczana dalej jako bw . Do obliczania wartości cech wykorzystywana jest amplituda wycinka widma w granicach $\pm \frac{bw}{2}$ od estymowanej częstotliwości charakterystycznej. Z tego względu, zbyt wąskie pasmo może zmniejszać skuteczność metody poprzez wskazanie fragmentu widma, w którym nie występuje poszukiwana składowa. Z drugiej strony, zbyt duża wartość bw może powodować uwzględnienie w analizowanym paśmie innych składowych, niezwiązanych ze wskaźnikiem diagnostycznym. Jednym z początkowych etapów opracowywania modeli było porównanie klasyfikatorów wyuczonych i testowanych z wykorzystaniem danych generowanych dla różnych wartości parametru bw . Wynik analizy przedstawiono na ilustracji 7.5.




Rys. 7.5: Wpływ szerokości pasma na skuteczność klasyfikacji uszkodzeń

Do oceny skuteczności detekcji wykorzystano metrykę F1 jako kompromis pomiędzy czułością a precyzją. Na podstawie wykresu można wnioskować, że istnieje pewne maksimum skuteczności metody przy szerokości pasma wynoszącej około 10 Hz. Ta wartość została wykorzystana w pozostałych etapach walidacji.

7.1.5 Wpływ czasu rejestracji sygnału

W kolejnym kroku poddano analizie wpływ czasu rejestracji sygnałów na skuteczność modelu diagnostycznego. Z uwagi na fakt, że dłuższe okna czasowe zapewniają większą rozdzielczość częstotliwościową widma, zasadnym wydaje się hipoteza zakładająca spadek wartości metryk przy skracaniu czasu akwizycji. Z drugiej strony, sygnał wibracyjny ze składową wprowadzaną przez uszkodzony wirnik jest niestacjonarny, co w teorii ogranicza skuteczność algorytmu powyżej pewnej długości analizowanej pary sygnałów. Celem tego etapu walidacji było sprawdzenie, jak dalece można skrócić czas detekcji uszkodzenia przy zachowaniu minimalnej dokładności metody.

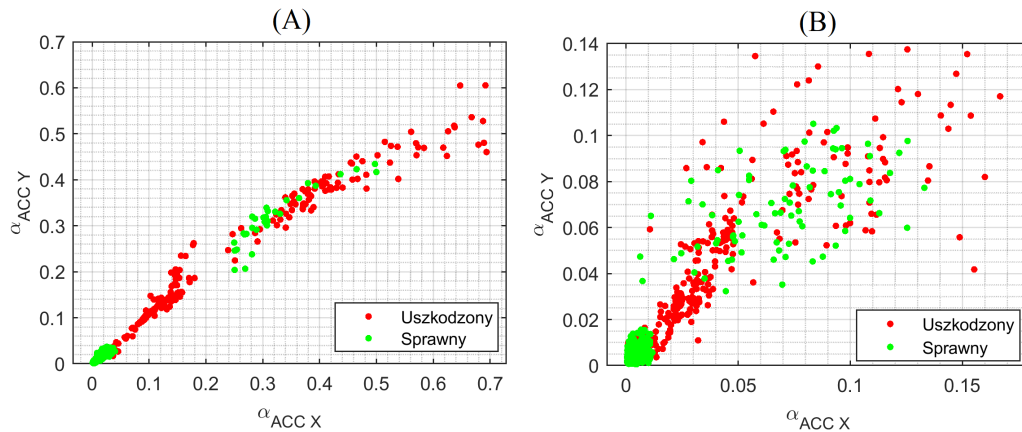
Na wykresie 7.6 przedstawiono dokładność klasyfikacji zbioru testowego w funkcji długości T_W okna akwizycji sygnału. Na rysunku wykreślono również wartości błędu walidacji.



Rys. 7.6: Skuteczność klasyfikacji uszkodzeń w funkcji czasu akwizycji sygnałów

Skracanie długości próbki sygnału początkowo skutkuje nieznacznym spadkiem skuteczności detekcji uszkodzeń. Efektywność algorytmu spada wyraźniej dla ramek krótszych od 350 ms. Co istotne, dla krótkich sygnałów znacząco zwiększa się różnica pomiędzy trafnością modeli walidowanych na zbiorze treningowym, a wynikami testów na danych z oddzielnych eksperymentów. Wskazuje to na zbyt duże skomplikowanie modelu względem liczby parametrów wejściowych i przeuczenie oraz utratę zdolności do poprawnego klasyfikowania nieznanymi wcześniej danych. Przepuszczalność jest związane ze sposobem obliczania wielkości decyzyjnych. Dla potwierdzenia na ilustra-

cji 7.7 porównano ich rozkład w zbiorach treningowych dla najdłuższego i najkrótszego z analizowanych okien czasowych.



Rys. 7.7: Porównanie rozkładu wielkości decyzyjnych dla okien o szerokości 500 ms (A) oraz 100 ms (B)

Porównanie pozwala wnioskować, że przy krótszym czasie analizy sygnału wibracyjnego wskaźniki diagnostyczne zaczynają przyjmować coraz bardziej losowe wartości, co przekłada się na przeuczenie i nieskuteczność modelu. Algorytm maszyny wektorów nośnych wyznaczając granice decyzyjne, dopasowuje się nadmiernie do słabo skupionych punktów danych i traci zdolność do skutecznej generalizacji nieznanymi wcześniej wartościami wskaźników.

7.1.6 Wnioski

Przedstawione wyniki ewaluacji metody wibrometrycznej prowadzą do następujących wniosków:

- Metoda jest nieskomplikowana obliczeniowo i oparta jest jedynie na parze prostych wskaźników diagnostycznych. Projektowana była do wykrywania uszkodzenia jednej klasy w pojedynczym wirniku UAV, bez informacji o lokalizacji.
- Metoda osiąga dokładność na poziomie około 92% przy klasyfikacji próbek uzyskanych dla szerszego zestawu scenariuszy lotów.
- W przypadku zawężenia rozpatrywanych przypadków, skuteczność detekcji wzrasta do poziomu przekraczającego 94%. Analizowane

scenariusze obejmują w tym przypadku jedynie loty w zawisie oraz przy stałym obciążeniu platformy latającej. Analiza modeli wykazała słabą zdolność do generalizacji, zwłaszcza przy krótkim czasie rejestracji sygnału.

- Wspomniana efektywność została osiągnięta dla próbek sygnału wibracyjnego wyodrębnianego funkcją okna o szerokości 500 ms. Oznacza to dość długi czas zadziałania metody od momentu wystąpienia uszkodzenia do jego zgłoszenia przez algorytm.
- Zakres kluczowego parametru metody, jakim jest szerokość pasma do poszukiwania wystąpienia częstotliwości charakterystycznej uszkodzenia, posiada pewne lokalne maksimum zapewniające najlepsze wartości metryk klasyfikatora uszkodzeń.

7.2 Klasyfikacja wzorców widmowych

7.2.1 Wstęp

W poniższym podrozdziale zamieszczono wyniki ewaluacji metody opisywanej w części 5.2 rozprawy. Algorytm oparty o rozpoznawanie wzorców widmowych sygnałów wibracyjnych wykorzystuje dane z większości eksperymentów opisywanych w rozdziale 6. Dzięki temu, zarówno proces uczenia modeli, jak i ich późniejszą walidację oraz testowanie przeprowadzono na próbkach rejestrowanych przy licznych wariantach warunków i parametrów lotu UAV. Eksperymenty były wykonywane w trakcie lotu w zawisie, wznoszeniu, zniżaniu oraz podczas wykonywania przez UAV szerokiej gamy manewrów. W rezultacie w zebranych sygnałach wibracyjnych składowe częstotliwościowe wskazujące na wystąpienie uszkodzenia charakteryzują się dużą zmiennością. Eksperymenty przeprowadzono z wykorzystaniem wielu egzemplarzy uszkodzonych wirników wykonanych przez kilku producentów z różną jakością i co za tym idzie — różnym wstępnym wyważeniem. Ponadto, w znacznej części lotów eksperymentalnych drona *Falcon V5* dodatkowo obciążono.

Rozpatrywane scenariusze uszkodzeń obejmowały dwie podstawowe kategorie: loty ze sprawnymi napędami oraz takie, w których podmieniono jeden z wirników na uszkodzony egzemplarz. Liczebność obu podzbiorów jest zbliżona i liczy około 900 próbek każdy. Przekłada się to na zbiór stosowany do uczenia i walidacji modelu zawierający 1265 próbek oraz około 540 przykładów przeznaczonych do finalnej ewaluacji metody. Zgodnie ze stosowaną konwencją oznaczeń, klasa obejmująca sprawne wirniki oznaczana jest literą „H”, natomiast w przypadku degradacji przyjęto etykietę „F”. Uszkodzone wirniki umieszczane były na różnych jednostkach napędowych i co do zasady podzielone były na dwa podtypy w zależności od rodzaju deformacji. W analizie rozpatrywane są uszkodzenia polegające na utracie końcówki płata (etykieta „T”) oraz odkształceniu krawędzi natarcia profilu lotniczego (klasa oznaczana jako „E”). Uzasadnienie wyboru, przykłady stosowanych wirników oraz szerszy opis rozpatrywanych typów uszkodzeń zawarto w rozdziale 6.

7.2.2 Wykrywanie uszkodzeń


W pierwszym etapie działania algorytmu decyzyjnego przeprowadzane jest wnioskowanie o wystąpieniu uszkodzenia. Na podstawie założeń metody opisanych w podrozdziale 5.2 stworzono szereg modeli klasyfikujących wzorce widmowe otrzymywane na podstawie sygnałów wibracyjnych. Część zbioru treningowego wykorzystano do walidacji metody, poszukując modelu charakteryzującego się jak najwyższymi wartościami podstawowych metryk — dokładności, czułości i precyzji. Na tym etapie dobrano podstawowe parametry zarówno klasyfikatora, jak i algorytmu przetwarzania sygnałów. W pierwszym przypadku rozważania dotyczyły głównie funkcji jądra metody SVM i jej parametrów. Dla etapów przetwarzania sygnałów wibracyjnych dobierano liczbę przedziałów, na jakie dzielone jest widmo sygnału (tzw. „koszyków”). Najlepsze wyniki klasyfikacji uzyskano dla 32 i więcej cech obliczanych dla każdej z osi pomiarowych akcelerometru. W metodzie zastosowano tę minimalną wartość w celu ograniczenia nakładu obliczeniowego. Dla ułatwienia porównania z metodą wibrometryczną początkową długość okna ustalono na 500 milisekund.

Najlepszy z opracowanych modeli oparto o nieliniową SVM z radialną funkcją jądra. Jego hiperparametry zawarto w tabeli 7.3, dodatkowo zamieszczając wartości podstawowych metryk uzyskanych przy klasyfikacji próbek ze zbioru testowego.

Parametr	Wartość
Długość pary sygnałów	500 ms
Liczba wektorów nośnych	548
Liczebność - zbiór uczący	1265
Liczebność - zbiór testowy	543
Funkcja jądra SVM	<i>radialna</i>
Optymalizator	<i>SMO</i>
Liczba n walidacji krzyżowej	10
Błąd walidacji	3.16%
Dokładność (<i>accuracy</i>)	0.951
Precyzja (<i>precision</i>)	0.976
Czułość (<i>recall</i>)	0.935
Metryka F1	0.956


Tab. 7.3: Hiperparametry oraz podstawowe metryki skuteczności klasyfikatora uszkodzeń opartego o wzorce widmowe

Wyniki wspomnianego testu przedstawiono szerzej z wykorzystaniem macierzy błędów zamieszczonych na ilustracji 7.8.



Rys. 7.8: Macierze błędów dla etapu wykrywania uszkodzeń

Rezultaty jasno wskazują na dużo większą skuteczność proponowanej metody detekcji uszkodzeń w porównaniu do algorytmu wibrometrycznego. Dla zbioru zawierającego próbki ze wszystkich rozpatrywanych scenariuszy uszkodzeń i warunków lotów średnia dokładność klasyfikacji przekracza 95%. Liczba predykcji fałszywie pozytywnych i fałszywie negatywnych jest zbliżona, co ma odzwierciedlenie w porównywalnych wartościach precyzji i czułości. Dla dalszej oceny modelu na podstawie zbioru testowego wykreślono krzywe ROC oraz obliczono parametr AUC. Na krzywej zaznaczono również punkt o współrzędnych odzwierciedlających parametry obliczone dla omawianego modelu bazowego. Wyniki przedstawiono na ilustracji 7.9.



Rys. 7.9: Krzywa ROC wykreślona dla etapu detekcji uszkodzeń

Analiza z wykorzystaniem ROC potwierdza wysoką skuteczność detekcji uszkodzeń z wykorzystaniem omawianego modelu. Pole powierzchni ma wartość 0,966, a krzywa jest silnie wklęsła. Zaobserwować można asymetrię ROC względem diagonalii wykresu. Wskazuje to na pewną właściwość modelu, jaką jest szybko wzrastające prawdopodobieństwo fałszywych alarmów (*FPR*) przy czułości metody przekraczającej około 92%. Oznacza to, że istnieje możliwość zwiększenia czułości algorytmu diagnostycznego kosztem niższej ogólnej skuteczności klasyfikacji sygnałów wibracyjnych.


7.2.3 Klasyfikacja typu uszkodzenia

W kolejnym kroku przeprowadzono ewaluację modelu opracowanego dla drugiego etapu wnioskowania — rozpoznawania typu uszkodzenia. Przyjęto konwencję, wedle której klasą pozytywną było wykrycie uszkodzenia końcówki płyta wirnika. Zasadniczą różnicą w parametrach maszyny wektorów nośnych zastosowanej na tym etapie jest zmiana funkcji jądra na wielomian czwartego rzędu. Parametry globalne i podstawowe metryki klasyfikacji zbioru testowego przedstawiono w tabeli 7.4.

Parametr	Wartość
Długość pary sygnałów	500 ms
Liczba wektorów nośnych	357
Liczebność - zbiór uczący	716
Liczebność - zbiór testowy	288
Funkcja bazowa	wielomianowa 4 rz.
Optymalizator	<i>SMO</i>
Liczba n walidacji krzyżowej	10
Błąd walidacji	5.95%
Dokładność (<i>accuracy</i>)	0.902
Precyzja (<i>precision</i>)	0.8381
Czułość (<i>recall</i>)	0.871
Metryka F1	0.854

Tab. 7.4: Parametry modelu użytego w drugim etapie wnioskowania - identyfikacji typu uszkodzenia

Analogicznie do poprzedniego etapu analizy wyniki klasyfikacji zbioru testowego przedstawiono na ilustracji 7.10 za pomocą macierzy błędów. Ewaluację przeprowadzono na zbiorze 288 elementów sklasyfikowanych jako uszkodzone przez model z pierwszego etapu wnioskowania. Oprócz tego wykreślono krzywą ROC, którą zamieszczono na rysunku 7.11.



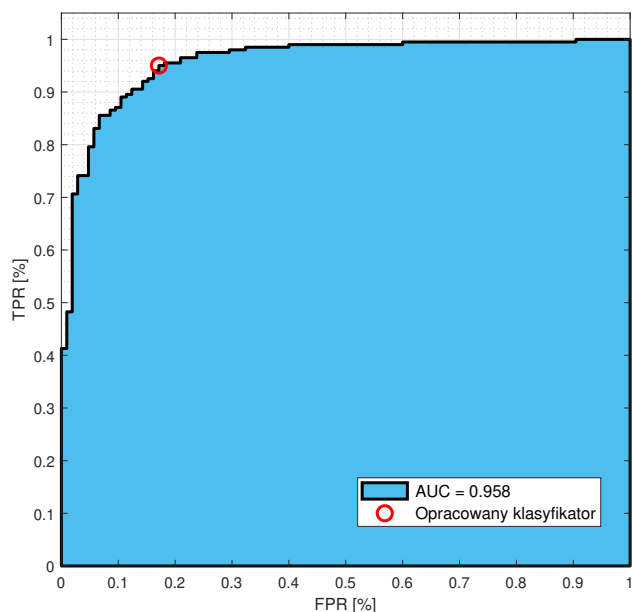
Rys. 7.10: Macierze błędów dla klasyfikatora określającego typ uszkodzenia

Przedstawione wyniki pokazują, że wzorce widmowe zawierają informacje pozwalające z dość dużą skutecznością na zidentyfikowanie nie tylko wystąpienia uszkodzenia, ale także jego określenie jego typu. Jak wspomniano w rozdziale 6, jest to informacja o tyle istotna, że uszkodzenia krawędzi płytów wirników wykonanych z laminatów mają większy potencjał dalszej degradacji. Dokładność metody jest niższa niż etapu wykrywania uszkodzenia, ale wciąż relatywnie wysoka z około 90% próbek prawidłowo sklasyfikowanych. Proporcja predykcji fałszywie pozytywnych i fałszywie negatywnych jest zbliżona, co oznacza, że model nie faworyzuje żadnego z przypadków.

7.2.4 Wpływ szerokości okna sygnałów wibracyjnych


Ostatnim krokiem ewaluacji omawianej metody diagnostycznej jest zbadanie wpływu długości przetwarzanych sygnałów na skuteczność detekcji i identyfikacji uszkodzeń. Przy stałej częstotliwości próbkowania jest ona podstawowym parametrem mającym wpływ na rozdzielczość częstotliwościową widma analizowanego sygnału. Z tego względu, sygnał próbkowany szerszym oknem, może zawierać bardziej szczegółowy wzorec widmowy i w rezultacie pozwolić na bardziej skuteczną predykcję uszkodzeń.

Dla oceny wpływu czasu akwizycji sygnałów wykonano wielokrotnie proces uczenia obydwu modeli diagnostycznych (dla detekcji i identyfikacji typu uszkodzenia) oraz testów na osobnym zbiorze. Przy każdej iteracji korzystano ze zbioru danych wygenerowanych dla wzrastającej długości




Rys. 7.11: Krzywa ROC wykreślona dla etapu identyfikacji typu uszkodzenia

okna czasowego (T_W), przy zachowaniu zbliżonej liczebności podzbiorów treningowego i testowego. Wyniki przedstawione są na dwa sposoby — jako wykres słupkowy czterech podstawowych metryk stosowanych w ocenie modeli (dokładności, czułości, precyzji i metryki F1) oraz jako porównanie krzywych ROC uzyskanych dla modeli analizowanych przy zmiennej długości sygnału. Na ilustracji 7.12 zamieszczono wykres uzyskany dla modelu wnioskującego w etapie detekcji uszkodzeń.



Rys. 7.12: Ocena jakości detekcji uszkodzeń dla różnych długości sygnałów wibracyjnych

Uzyskane wartości wskazują, że skuteczność klasyfikacji rośnie znacząco do momentu użycia w analizie próbek o długości przekraczającej 500 ms. Dla dłuższych okien czasowych zysk jest niewielki, a w przypadku próbek sygnałów o długości przekraczającej jedną sekundę wartości metryk nieznacznie spadają. Jest to prawdopodobnie spowodowane niestacjonarnością sygnałów wibracyjnych i co za tym idzie objęciem w analizowanym okresie fragmentu lotu, w którym wzorec poprzez przesunięcie częstotliwości charakterystycznej uszkodzenia zdążył ulec znaczącej zmianie i przez to stał się mniej charakterystyczny. Na uwagę zasługuje wysoka czułość metody już dla najkrótszych okien czasowych. Oznacza to, że większa rozdzielczość częstotliwościowa jest potrzebna, aby uniknąć klasyfikowania sprawnego systemu jako uszkodzonego, jako że występowanie zdegradowanego wirnika określono jako klasę pozytywną. Wynik analizy potwierdzono poprzez wykreślenie krzywych ROC przedstawionych na ilustracji 7.13.




Rys. 7.13: Krzywe ROC wykreślone dla modeli opracowanych dla zmiennych długości próbek sygnałów (etap detekcji uszkodzeń)


Analiza przy wykorzystaniu ROC pokazuje, że próbki o długości powyżej 700 ms charakteryzują się krzywymi o wartości AUC zbliżonym do jedności. Określa to górną granicę, do której warto zwiększać czas akwizycji.

W następnym kroku przeprowadzono podobną analizę dla drugiego etapu wnioskowania, czyli wykorzystania kolejnej SVM do określenia typu uszkodzenia. Wartości metryk skuteczności klasyfikacji w funkcji długości

sygnałów przedstawiono na wykresie 7.14, natomiast odpowiadające im krzywe ROC na ilustracji 7.15.



Rys. 7.14: Ocena skuteczności identyfikacji typu uszkodzenia dla różnych długości sygnałów wibracyjnych



Rys. 7.15: Krzywe ROC wykreślone dla modeli opracowanych dla zmiennych długości sygnałów (etap identyfikacji typu uszkodzenia)

Analiza obu sposobów opisu modelu sugeruje istnienie pewnego maksimum trafności predykcji typu uszkodzenia dla próbek sygnałów o długości około 500 milisekund. Jest to jednocześnie minimalna długość sygnałów dla których dokładność etapu identyfikacji przekracza 90%.

7.2.5 Podsumowanie

Zaproponowany algorytm detekcji i identyfikacji typu uszkodzeń wirników, wykorzystujący wzorce uzyskane z szerokiego zakresu widma sygnałów wibracyjnych, charakteryzuje się zwiększoną skutecznością klasyfikacji. Przy identycznych długościach próbek sygnałów dokładność predykcji wzrasta do ponad 95%, a wykorzystanie szerszych okien czasowych zwiększa tą wartość do blisko 98%. Co istotne, są to wyniki uzyskane dla zbioru danych rejestrowanych w szerokim zakresie warunków lotu. Dodatkowo wzorce widmowe jako źródło informacji o uszkodzeniu pozwalają na określenie typu deformacji wirnika z dokładnością przekraczającą 90% poprawnych predykcji na analizowanym zbiorze danych. Podobnie do metody wibrometrycznej, podczas walidacji modeli zauważono konieczność kompromisu pomiędzy czułością a dokładnością metody diagnostycznej. Możliwy jest taki dobór hiperparametrów, który pozwala na zwiększenie czułości diagnostycznej kosztem znacznie szybciej rosnącego odsetka fałszywych alarmów.

7.3 Metoda wykorzystująca sieć sensorową

7.3.1 Wstęp

W poniższym podrozdziale opisano proces walidacji oraz analizę uzyskanych wyników dla metody diagnostycznej opartej o sygnały wibracyjne z czterech akcelerometrów sieci sensorowej. Wykorzystany został zbiór danych opisanych w części 6.4 rozprawy, w części stanowiącej powtórzenie eksperymentów wykonanych na potrzeby dwóch poprzednich metod. Istotną zmianą techniczną jest przebieg procesu rejestracji sygnałów oraz wykorzystane oprzyrządowanie. Dzięki zastosowaniu dedykowanego podsystemu sieci sensorowej możliwa była dużo dłuższa akwizycja danych, co znacznie zredukowało liczbę lotów potrzebną do pokrycia wszystkich rozpatrywanych przypadków. Niezmienna pozostała duża różnorodność uwzględnionych parametrów i warunków lotu, obejmująca m.in. zmienne trajektorie ruchu UAV, masę platformy czy konkretne modele stosowanych wirników. Ważnym etapem było szczegółowe etykietowanie danych ze względu na umiejscowienie uszkodzonego wirnika, jako że jednym z głównych celów nowej metody diagnostycznej jest uzyskanie informacji o lokalizacji uszkodzeń.

Skuteczność zaproponowanego rozwiązania rozpatrywano dla dwóch podzbiorów danych wibracyjnych: podstawowego i rozszerzonego. Wedle pierwszej z wymienionych koncepcji klasyfikator korzysta z jednej wieloklasowej etykiety, do której przypisywane są następujące klasy diagnostyczne:

- Rozpoznanie sprawnego systemu, oznaczone w sposób analogiczny do omawianych wcześniej podejść klasą **H**.
- Wykrycie dowolnego uszkodzenia pojedynczego wirnika (klasa „**F**”) z podziałem na lokalizację względem jednostek napędowych. W nazewnictwie klas przyjęto koncepcję zgodną z oznaczeniami kolejnych sensorów i skojarzonych z nimi ramion drona. Tym samym w przypadku wykrycia degradacji wirnika etykieta przyjmuje wartości **A**, **B**, **C** lub **D**.

Rozszerzony zbiór danych zawiera w sobie dwie dodatkowe klasy reprezentujące uszkodzenia podwójne, rozumiane jako występowanie w systemie pary zdegradowanych wirników. Wprowadzono klasę **BD** identyfikującą uszkodzenia dwóch rotorów umiejscowionych po przeciwnych stronach płyty centralnej oraz klasę **CD** oznaczającą uszkodzenie dwóch sąsiednich wirników.


Obydwa podzbiory danych z sygnałów wibracyjnych zostały wzorem poprzednich ewaluacji podzielone na część treningową (uczącą) i testową. Przy poszukiwaniu najlepszych parametrów modeli opartych o metodę RF, część zbioru treningowego jest w naturalny sposób wykorzystywana do walidacji dzięki mechanizmowi wyliczania błędu *out-of-bag* (zob. 6.6). Finalną ewaluację modeli przeprowadzano na danych z odrębnych eksperymentów.

7.3.2 Dobór parametrów modelu

Podstawowym mechanizmem wykorzystanym w walidacji klasyfikatorów opartych o *random forest* jest błąd OOB. Przy dostatecznie długim procesie uczenia i wielu drzewach decyzyjnych w zespole ta metoda daje wyniki zbieżne do stosowanej dotychczas walidacji krzyżowej [120]. Bardziej szczegółowy opis metryk i technik stosowanych do oceny modeli zamieszczono w części 6.6 rozprawy.


Pomocną właściwością metody RF jest niewielka liczba wolnych parametrów modelu [121]. Jednym z podstawowych jest wielkość podwektora cech wykorzystywana do uczenia pojedynczego drzewa, którą w początkowych etapach walidacji dobrano na podstawie dokładności klasyfikacji jako pierwiastek kwadratowy liczby zmiennych. Dalszą analizę przeprowadzono dla pozostałych dwóch parametrów zidentyfikowanych jako kluczowe dla skuteczności metody diagnostycznej — liczby drzew w klasyfikatorze i długości sygnałów wibracyjnych. Na wykresie 7.16 przedstawiono wartości błędu *out-of-bag* przy walidacji przeprowadzonej na zbiorze zawierającym 5 klas diagnostycznych.

Przedstawione wyniki ponownie wskazują, że długość sygnałów ponownie jest kluczowym czynnikiem wpływającym na skuteczność działania metody. Wartości błędów szybko osiągają wartości poniżej 10% już dla kilkudziesięciu drzew decyzyjnych i sygnałów o czasie trwania przekraczającym



Rys. 7.16: Wykres błędu OOB w zależności od długości sygnałów i liczby drzew - zbiór o 5 klasach, pełen zakres

200 ms. Na kolejnej grafice 7.17 przedstawiono dolny wycinek powierzchni błędu, odcięty na poziomie około 6%. Zaznaczono dodatkowo trzy charakterystyczne pary hiperparametrów.



Rys. 7.17: Wykres błędu OOB w zależności od długości sygnałów i liczby drzew - zbiór o 5 klasach, najlepsze z uzyskanych rezultatów

W punkcie (1) zaznaczono model o dokładności równej w przybliżeniu odsetkowi błędnych klasyfikacji w omawianej poprzednio metodzie opartej o wzorce widmowe uzyskane z jednego, centralnie ulokowanego czujnika. Pokazuje to, że rozwiązanie z siecią sensorów ulokowanych bliżej miejsca uszkodzenia pozwala na skrócenie czasu detekcji. W omawianym punkcie długość analizowanych sygnałów to 250 ms, co stanowi dwukrotne skrócenie czasu akwizycji.

W analizowanym zakresie parametrów globalne minimum osiągnięto dla punktu oznaczonego (2), czyli próbek o czasie trwania 1000 ms klasyfikowanych zespołem 228 losowych drzew decyzyjnych. Wartość błędu OOB wynosi w tym przypadku 1.13%. Warto jednak zaznaczyć, że dla próbek dłuższych od około 500 ms i liczby drzew przekraczającej 200 powierzchnia staje się w dużej mierze płaska, z lokalnymi minimami dla pewnych czasów akwizycji. Zależność od liczby drzew jest w ogólności malejąca. Dlatego do finalnych testów dobrano parę parametrów, w której próbki sygnałów wibracyjnych rejestrowane były przez 500 ms, a liczba drzew w zbiorze wynosi 386 (punkt (3)). W tym miejscu zidentyfikowano lokalne minimum wykresu błędu wynoszące 1.48% i wybrano ten zestaw parametrów dla porównania z omawianymi wcześniej metodami przy zachowaniu zbliżonego czasu detekcji.

7.3.3 Finalny klasyfikator

Dla wyselekcjonowanego na etapie walidacji modelu przeprowadzono szczegółową analizę. Parametry klasyfikatora typu *random forest* zebrano w tabeli 7.5.

Parametr	Wartość
Długość sygnałów	500 ms
Liczba cech	128
Liczebność - zbiór uczący	1386
Liczebność - zbiór testowy	594
Liczba klas	5
Liczba drzew decyzyjnych	386
Błąd OOB	1.48%
Dokładność bilansowana	0.988

Tab. 7.5: Parametry klasyfikatora uszkodzeń jednokrotnych opartego o algorytm *RF*

Na podstawie wyników uzyskanych dla klasyfikacji próbek zbioru testowego wykreślono macierz błędów prezentowaną na ilustracji 7.18. W teście wykorzystano 594 wektorów cech pochodzących z odrębnych lotów i niebiorących udziału w trenowaniu drzew decyzyjnych. W dodatkowych kolumnach po prawej stronie macierzy zamieszczono dla każdej z klas czułość oraz odsetek predykcji fałszywie negatywnych. Podsumowanie znajdujące się pod macierzą zawiera odpowiednio wartość precyzji oraz odsetek predykcji fałszywie pozytywnych obliczone w analogicznym porządku.


Rzeczywista klasa	H	123		1			99.2%	0.8%
	A		110				100.0%	
	B	3		104			97.2%	2.8%
	C	1	2		133		97.8%	2.2%
	D					117	100.0%	
		96.9%	98.2%	99.0%	100.0%	100.0%		
		3.1%	1.8%	1.0%				
		H	A	B	C	D	Predykowana klasa	

Rys. 7.18: Macierz błędów dla zbioru testowego - uszkodzenia jednokrotne

Analiza błędów predykcji pokazuje w pierwszej kolejności bardzo wysoką dokładność klasyfikacji wynoszącą po zbilansowaniu względem liczebności klas 98.8%. Dla dwóch klas żadna z należących do nich próbek nie została błędnie zaklasyfikowana, a czułość klasyfikatora jest zbliżona dla wszystkich wartości etykiety. Zaobserwować można, że klasy o lepszej czułości charakteryzują się jednocześnie gorszą precyzją, co jest powszechnym kompromisem w problemach klasyfikacji [45].

Ostatnim etapem analizy wybranego klasyfikatora było oszacowanie ważności poszczególnych cech, rozumianej jako wkład poszczególnych zmienionych wejściowych modelu do finalnego wyniku. W tym celu wykorzystano jedno z zastosowań błędu OOB, jakim jest możliwość estymowania znaczenia każdej z cech [122]. Procedura polega na modyfikacji zbioru treningowego poprzez permutowanie wartości wybranej cechy w obrębie dostępnych obserwacji. Następnie obliczany jest spadek błędu OOB dla tak zmodyfikowanych wejść modelu. Operacja wykonywana jest kolejno dla wszystkich drzew, a wynik zostaje znormalizowany w obrębie całego klasyfikatora [123]. Po powtórzeniu procedury kolejno dla poszczególnych elementów wektora uzyskuje się miarę wpływu każdej zmiennej na finalny wynik. Analizę według tej metody przeprowadzono dla omawianego modelu. Wyniki zaprezentowano w formie graficznej na ilustracji 7.19. Na wykresie słupkowym zaznaczono

kolorami kolejne kanały akwizycji sygnałów wibracyjnych wedle prezentowanego na ilustracji 5.11 podziału na osie pomiaru i kolejne sensory sieci.




Rys. 7.19: Oszacowanie ważności cech dla klasyfikatora uszkodzeń

Otrzymane wyniki wskazują, że największy udział we wnioskowaniu mają cechy określające zawartość w widmie częstotliwości o wartościach ulokowanych w środku analizowanego przedziału. Odpowiada to w praktyce najczęściej występującym w systemie prędkościom obrotowym wirników pracujących typowo w zakresie około $5000-6000 \frac{obr}{min}$. Cechy związane ze składowymi bliżej granic analizowanych pasm mają mniejszą wagę, ale wciąż znacząco wpływają na predykcję klasy uszkodzeń. Przedstawiona analiza została wykonana kilkakrotnie na różnych etapach rozwoju modelu i stanowiła podstawę do wyznaczenia finalnego zakresu częstotliwości uwzględnianych na etapie przetwarzania sygnałów wibracyjnych.

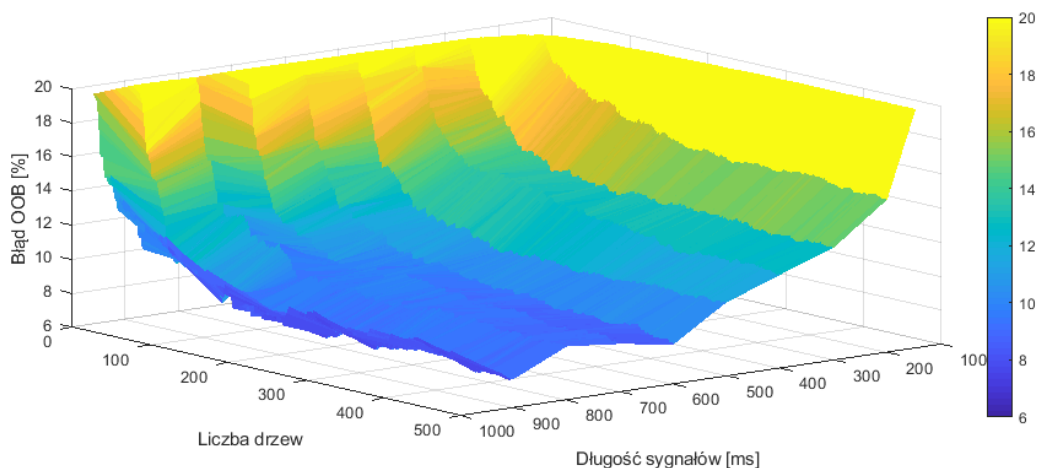
7.3.4 Identyfikacja uszkodzeń wielokrotnych

Skuteczność omawianej metody diagnostycznej przetestowano na rozszerzonym zbiorze danych z dwoma dodatkowymi klasami opisującymi występowanie w układzie pary uszkodzonych wirników. Wykorzystując powiększony zbiór treningowy wykonano ponownie zasadniczy krok walidacji, czyli wykreślenie wartości błędu *out-of-bag* w funkcji liczby drzew decyzyjnych oraz długości 8-kanałowego sygnału wibracyjnego. Zachowując dotychczasową konwencję na grafice 7.20 zamieszczono w całości otrzymaną powierzch-

nię, natomiast na ilustracji 7.21 przedstawiono wycinek dla najniższych uzyskanych wartości błędów.



Rys. 7.20: Wykres błędu OOB dla detekcji uszkodzeń wielokrotnych - pełen zakres



Rys. 7.21: Wykres błędu OOB dla detekcji uszkodzeń wielokrotnych - najlepsze uzyskane modele

Na podstawie przedstawionych danych można wnioskować, że zadanie identyfikacji uszkodzeń wielokrotnych jest znacznie bardziej skomplikowane. Najlepsze modele osiągnęły wartość błędu OOB na poziomie około 8%. W porównaniu do procesu walidacji modeli rozpoznających 5 klas można zauważyć brak wypłaszczenia powierzchni wraz ze wzrostem wartości rozpatrywanych parametrów. Jednakże, dla sygnałów o długości ponad 700 ms i liczby drzew decyzyjnych przekraczającej 300 różnice między wartościami błędów OOB stają się niewielkie, a w charakterystyce widoczne są lokalne minima. Do szczegółowej ewaluacji wyselekcjonowano model o parametrach opisanych w tabeli 7.6.

Parametr	Wartość
Długość sygnałów	700 ms
Liczba cech	128
Liczebność - zbiór uczący	1857
Liczebność - zbiór testowy	797
Liczba klas	7
Liczba drzew decyzyjnych	493
Błąd OOB	10.5%
Dokładność bilansowana	0.885

Tab. 7.6: Parametry i podstawowe metryki wyselekcjonowanego klasyfikatora uszkodzeń wielokrotnych

Wyniki klasyfikacji zbioru testowego rozszerzonego o scenariusze uszkodzeń wielokrotnych przedstawiono na ilustracji 7.22. Wykorzystano macierz błędów z podsumowaniem czułości (na prawo) oraz precyzji (poniżej) predykcji poszczególnych klas diagnostycznych.

Rzeczywista klasa	H	122						100.0%		
	A		120	1			4	96.0%	4.0%	
	B			122		1	4	96.1%	3.9%	
	C				119			100.0%		
	D					113		100.0%		
	BD	1	1	8		3	83	14	75.5%	24.5%
	CD			4		1	34	42	51.9%	48.1%
		99.2%	99.2%	90.4%	100.0%	95.8%	66.4%	75.0%		
		0.8%	0.8%	9.6%		4.2%	33.6%	25.0%		
		H	A	B	C	D	BD	CD		
		Predykowana klasa								

Rys. 7.22: Macierz błędów dla klasyfikacji zbioru danych zawierających uszkodzenia wielokrotne

Analiza wyników pokazuje, że najtrudniejsze do rozpoznania są scenariusze z dwoma uszkodzonymi wirnikami. Skuteczność klasyfikacji pozostałych klas pozostała zasadniczo na niezmiennym poziomie, natomiast dla etykiet

BD i CD jest wyraźnie niższa. Co jednak istotne, błędne predykcje mieszczą się przeważnie w obrębie dwóch problemowych kategorii. Uszkodzenia wielokrotne zostały sklasyfikowane jako brak uszkodzeń tylko w jednym przypadku. Oznacza to, że samo wykrycie uszkodzenia oraz zidentyfikowanie go jako uszkodzenie podwójne jest dość precyzyjne. Problematyczne dla stworzonego modelu jest rozróżnienie lokalizacji pary niesprawnych wirników w obrębie dwóch ewaluowanych klas.

7.3.5 Alternatywna implementacja


Opisując skuteczność omawianej metody diagnostycznej, warto przytoczyć jej alternatywną implementację. W pracy [111] przedstawiono wariację algorytmu opartego o sieć sensorową. Głównym twórcą rozwiązania jest Radosław Puchalski, natomiast rolą autora rozprawy było dostarczenie danych eksperymentalnych oraz konsultowanie prac. Metoda wykorzystuje ten sam zbiór danych, natomiast zasadniczą różnicą jest zmiana klasyfikatora uszkodzeń na jednokierunkową (ang. *feedforward*) sztuczną sieć neuronową typu MLP. Ponadto klasyfikator wykorzystuje wycinek widma w zakresie 60-140 Hz w sposób bezpośredni, z pominięciem procesu uśredniania i podziału na „koszyki”, co skutkuje zmienną długością wektora cech w zależności od długości próbki sygnału. Do walidacji modelu wykorzystano wszystkie 7 rozpatrywanych scenariuszy uszkodzeń. Parametry sieci przedstawiono w tabeli 7.7.

Porównując przytaczana wersję metody diagnostycznej do oryginalnego rozwiązania, należy zauważyć, że uzyskała lepszą dokładność klasyfikacji dla poszerzonego zestawu klas diagnostycznych. Pokazuje to, że możliwe jest zastosowanie innych modeli predykcyjnych o zbliżonym stopniu złożoności dla poprawienia skuteczności detekcji i lokalizacji uszkodzeń wirników. Szczegółowe wyniki uzyskane na zbiorze testowym przedstawiono na ilustracji 7.23.

Analiza macierzy błędów wskazuje, że wykorzystanie sieci neuronowej pozwala na poprawę najsłabszego aspektu klasyfikatora opartego o RF, czyli rozpoznawania wystąpienia par uszkodzeń wirników. Obydwa się to kosztem nieznacznego pogorszenia czułości dla klas opisujących uszkodzenia pojedyncze. W ostatecznym rozrachunku uśredniona względem liczebności klas dokładność ma jednak zauważalnie wyższą wartość.

Parametr	Wartość
Typ warstw	<i>dense</i> (gęste)
Liczba neuronów w warstwie wejściowej	264
Liczba neuronów w warstwie ukrytej	160
Liczba neuronów w warstwie wyjściowej	7
Funkcja aktywacji warstwy wejściowej	<i>ReLU</i>
Funkcja kosztu	entropia krzyżowa
Funkcja aktywacji warstwy wyjściowej	<i>softmax</i>
Optymalizator	<i>RMSprop</i>
Liczba epok	8483
Dokładność na zbiorze treningowym	1.00
Dokładność na zbiorze walidacyjnym	0.98
Rozmiar modelu - pamięć FLASH	170.03 KiB
Rozmiar modelu - RAM	1.71 KiB
Dokładność na zbiorze testowym	98.08%

Tab. 7.7: Model oparty o sztuczną sieć neuronową - hiperparametry



Rys. 7.23: Macierz błędów dla najlepszego z modeli opartych o sztuczną sieć neuronową [111]

Istotnym elementem omawianej realizacji było zaimplementowanie i uruchomienie całego procesu diagnostycznego na niskoenergetycznym systemie wbudowanym. W tym celu wykorzystano platformę ewaluacyjną opartą o mikrokontroler *STM32F746ZG* wyposażony 320kB RAM oraz rdzeń *Cortex-M7* taktowany z częstotliwością 216 MHz. Oprogramowanie wbudowane, napisane w języku *ANSI C*, realizowało cały algorytm od pobrania fragmentu sygnału z wykorzystaniem funkcji okna, poprzez ekstrakcję cech, aż do etapu wnioskowania o uszkodzeniu. W tabeli 7.8 przedstawiono zmierzone średnie czasy przetwarzania dla sygnałów o różnej długości oraz związaną z tym liczbą próbek w widmach.

Czas akwizycji	Liczba próbek w widmie	Czas przetwarzania [ms]
160	136	5
320	264	8
640	520	16
1280	1032	31

Tab. 7.8: Czas przetwarzania algorytmu diagnostycznego w systemie wbudowanym

Rezultaty testów czasu obliczeń wskazują, że opisywana metoda diagnostyczna jest możliwa do implementacji na jednostkach obliczeniowych o ograniczeniach dotyczących rozmiaru, typu i poboru energii występujących w systemach awioniki miniaturowych UAV. Zastosowany mikrokontroler należy do tej samej rodziny, co układy stosowane w popularnych systemach kontrolerów lotu (zob. 4.1.3). Warto zauważyć, że czasy wykonywania obliczeń, sięgające maksymalnie kilkudziesięciu milisekund, stanowią zaledwie ułamek okresu akwizycji sygnałów wibracyjnych. Tym samym w końcowym czasie zadziałania metody liczonym od wystąpienia uszkodzenia do wypracowania diagnozy największy udział ma samo zarejestrowanie wibracji o charakterze identyfikującym zjawisko, a nie przetwarzanie zawartej w nich informacji.

7.3.6 Podsumowanie

Metoda detekcji uszkodzeń oparta o sygnały z sieci sensorowej charakteryzuje się najlepszą skutecznością spośród wszystkich omawianych rozwiązań opartych o analizę wibracji. Zasadnicze ulepszenie, jakim było użycie wielu sensorów umieszczonych bliżej miejsca uszkodzenia, pozwoliło na osiągnięcie dokładności detekcji na poziomie przekraczającym 98% analizowanych przypadków w zbiorze. Omawiana wartość metryki została osiągnięta przy

porównywalnym do wcześniej omawianych metod czasie akwizycji. Możliwe jest dalsze skrócenie długości próbek przy zachowaniu wysokiej trafności klasyfikacji. Proces diagnostyczny obejmuje również wskazanie lokalizacji uszkodzenia z dokładnością do jednostki napędowej. Wariacja algorytmu wykorzystująca do wnioskowania sieć neuronową została uruchomiona w systemie wbudowanym tej samej klasy co awionika pokładowa drona *Falcon*. Uzyskane rezultaty pokazują, że poziom złożoności procesu przetwarzania sygnałów i klasyfikowania stanów diagnostycznych umożliwia implementację algorytmu w czasie rzeczywistym. Metoda charakteryzuje się nieco gorszą skutecznością w przypadku wprowadzenia do modelu klas opisujących występowanie pary uszkodzeń. Wadą zaprezentowanej metody jest konieczność instalacji dodatkowego oprzyrządowania na pokładzie UAV, z elementami znajdującymi się poza centralną płytą mieszającą awionikę statku powietrznego. Wymaga to dość znacznej ingerencji w konstrukcję BSP, m.in. poprzez prowadzenie dodatkowych wiązek kablowych i modyfikację konstrukcji ramion w celu montażu zestawu akcelerometrów.

7.4 Wyniki uzyskane z wykorzystaniem metody akustycznej

7.4.1 Wstęp

W ostatniej części rozdziału prezentowane są wyniki eksperymentów dotyczących działania metody detekcji i identyfikacji uszkodzeń opartej o sygnały akustyczne. Do ewaluacji i testowania opracowanych klasyfikatorów wykorzystano zbiór danych zebranych w ramach eksperymentów opisywanych szerzej w części 6.5 rozprawy. We wspomnianym podrozdziale zawarto również opis rozpoznawanych klas diagnostycznych. Rozpatrywane są wszystkie przytoczone dotychczas scenariusze występowania uszkodzeń. Należą do nich sytuacje, w której na platformie latającej zamontowane były zarówno jeden, jak i dwa wirniki uszkodzone na oba zdefiniowane sposoby — poprzez złamanie końcówki oraz deformację krawędzi płata. Klasyfikator wskazuje również na lokalizację wystąpienia uszkodzenia z dokładnością do przeciwbieżnej jednostki napędowej. Zachowana została również różnorodność danych w zakresie rejestrowanych faz lotu i typów wykonywanych przez UAV trajektorii.

W sposób analogiczny do ewaluacji trzech omawianych wcześniej metod dostępne dane podzielono na trzy podzbiory. Pierwszy z nich wykorzystany został do treningu sieci neuronowej. Drugi podzbiór znalazł zastosowanie do walidacji polegającej na dostrajaniu hiperparametrów modeli. Finalne metryki opisujące trafność detekcji i identyfikacji uszkodzeń uzyskano z wykorzystaniem trzeciego podzbioru.

7.4.2 Dobór rozmiaru warstw sieci

Zasadniczy etap rozwoju modelu klasyfikującego uszkodzenia polegał na testowaniu struktury oraz rozmiaru sztucznej sieci neuronowej. Dobór typu oraz układu poszczególnych warstw neuronów został wykonany na etapie wstępnego projektowania klasyfikatora w momencie uzyskania pierwszych satysfakcjonujących wyników. Omawiana w rozdziale 5.4 architektura rekurencyjnej sieci neuronowej została następnie dopracowana w procesie walidacji. Głównym czynnikiem wpływającym na trafność klasyfikacji sy-

gnatur akustycznych był rozmiar warstwy zawierającej komórki typu LSTM oznaczany jako n_{LSTM} i związana z nim wielkość kolejnej warstwy w pełni połączonej n_{lin} . Analizę rozpoczęto od sieci zawierającej 64 jednostki LSTM, a następnie rozmiar warstwy podwajano do momentu braku zauważalnej poprawy podstawowych metryk. Wyniki testu zaprezentowano w tabeli 7.9.

Lp	n_{LSTM}	n_{lin}	F1	Precyzja	Czułość	Dokładność
1	64	32	0.910	0.858	0.969	0.967
2	128	64	0.936	0.900	0.975	0.977
3	256	128	0.982	0.987	0.978	0.994
4	512	256	0.985	0.989	0.980	0.995

Tab. 7.9: Wpływ rozmiaru warstwy LSTM na trafność detekcji uszkodzeń [103]

Zwiększanie liczby komórek LSTM w pierwszej warstwie sieci poprawia trafność klasyfikacji. Warto zauważyć, że nawet najmniejsze modele charakteryzują się dokładnością zbliżoną do uzyskanej w metodach opartych o sygnały wibracyjne. Zauważalną cechą proponowanej sieci neuronowej jest wysoka czułość diagnostyczna przy zauważalnie gorszej precyzji. Dopiero dla największych analizowanych rozmiarów modelu wartości obu metryk zbliżają się do siebie. Oznacza to, że sieci o mniejszych rozmiarach mają tendencję do zgłaszania „fałszywych alarmów”, tj. rozpoznawania sygnałów opisujących lot ze sprawnymi wirnikami jako wystąpienie uszkodzenia. Model wyróżniony w tabeli 7.9 kolorem został wybrany do dalszej analizy. Jego hiperparametry oraz podstawowe metryki uzyskane w procesie uczenia i walidacji zawarto w tabeli 7.10.

Parametr	Wartość
Liczba komórek LSTM	512
Liczba neuronów warstwy ukrytej	256
Liczba neuronów warstwy wyjściowej	9
Rozmiar wsadu	640
Funkcja straty	Entropia skrośna
Funkcja aktywacji w w. wyjściowej	Sigmoid
Optymalizator	Adam
Liczba epok	866
Dokładność - zbiór walidacyjny	0.998
Dokładność - zbiór testowy	0.994

Tab. 7.10: Parametry wybranego klasyfikatora opartego o sieć LSTM

Finalne testy wykonano na podzbiorze liczącym 7900 próbek sygnałów akustycznych. Na ilustracji 7.24 przedstawiono cząstkowe macierze błędów dla każdej z 9 klas diagnostycznych. Omawiane wyniki uzyskano dla zbioru danych, w którym obecne były próbki reprezentujący występowanie uszkodzeń jednocześnie na dwóch jednostkach napędowych. Z tego względu sieć może poprawnie wskazać więcej niż jedną dodatnią wartość etykiety.

AF	Klasa predykowana	
Kl. rzecz.	0	1
0	6727	0
1	39	1134

AE	Klasa predykowana	
Kl. rzecz.	0	1
0	6270	66
1	52	1512

BF	Klasa predykowana	
Kl. rzecz.	0	1
0	6335	1
1	10	1554

BE	Klasa predykowana	
Kl. rzecz.	0	1
0	6317	19
1	29	1535

CF	Klasa predykowana	
Kl. rzecz.	0	1
0	6321	15
1	95	1469

CE	Klasa predykowana	
Kl. rzecz.	0	1
0	6726	1
1	2	1171

DF	Klasa predykowana	
Kl. rzecz.	0	1
0	6336	0
1	0	1564

DE	Klasa predykowana	
Kl. rzecz.	0	1
0	6331	5
1	11	1553

H	Klasa predykowana	
Kl. rzecz.	0	1
0	7404	25
1	1	470

Rys. 7.24: Macierze błędów dla modelu LSTM [103]

Dla zbioru testowego uzyskano dokładność klasyfikacji wynoszącą 99,4%, co wskazuje na bardzo wysoką skuteczność metody wykorzystującej sygnały akustyczne w porównaniu do algorytmów opartych o analizę wibracji. Obserwując rozkład błędnych predykcji pomiędzy poszczególnymi klasami, nie jest możliwe jednoznaczne wskazanie typu lub lokalizacji uszkodzenia, które byłyby obarczone większym błędem klasyfikacji.

7.4.3 Wpływ długości analizowanych sygnałów

Skuteczność proponowanego algorytmu diagnostycznego zbadano również ze względu na długość analizowanych sygnałów akustycznych. Jest to czynnik, który wpływa znacząco na trafność detekcji uszkodzeń we wszystkich omawianych w rozprawie metodach diagnostycznych. Analiza polegała na wygenerowaniu nowych zbiorów danych, opartych o krótsze ramki sygnałów akustycznych, a następnie przeprowadzenie ponownie procesu uczenia i walidacji RNN. Wyniki zebrano w tabeli 7.11.

Analogicznie do procesów walidacji pozostałych metod diagnostycznych wskazać można pewien zakres długości ramek sygnałów, dla których metoda uzyskuje najwyższe wartości dokładności, czułości i precyzji. Krótsze okna czasowe nie zapewniają wystarczająco szczegółowej informacji ze względu

Lp	Długość sygnału [ms]	F1	Precyzja	Czułość	Dokładność
1	600	0.980	0.986	0.975	0.993
2	500	0.985	0.989	0.980	0.995
3	400	0.975	0.980	0.969	0.991
4	300	0.964	0.972	0.955	0.988
5	200	0.947	0.956	0.938	0.982

Tab. 7.11: Trafność klasyfikacji uszkodzeń dla różnych długości sygnałów akustycznych

na mniejszą rozdzielczość częstotliwościową, która jest istotnym parametrem również w przypadku cech MFCC. Z drugiej strony, przy rejestracji sygnału w odpowiednio długim horyzoncie, staje się on w większej mierze niestacjonarny, co powoduje utratę szczegółowości sygnatury uszkodzenia. Warto też zauważyć, że już dla sygnałów o długości około 200 ms algorytm akustyczny uzyskuje wyniki zbliżone do najlepszych rezultatów osiągniętych z wykorzystaniem metod opartych o sygnały wibracyjne o długości 500-600 ms. Oznacza to, że wykorzystanie nowego źródła danych do diagnostyki uszkodzeń wirników pozwala na znaczne skrócenie fazy akwizycji danych sensorycznych.

7.4.4 Czas przetwarzania

Rozważając zdolność metody diagnostycznej do szybkiego określenia stanu systemu, istotnym jest oszacowanie czasu przetwarzania ramki sygnałów akustycznych. Przeprowadzono eksperyment, w którym podzielono algorytm na dwa zasadnicze etapy: ekstrakcję cech opartych MFCC oraz samą klasyfikację z wykorzystaniem omówionego modelu RNN. Testy prowadzono na dwóch platformach. Pierwsza z nich to wysokiej klasy komputer PC wykorzystywany do uczenia i walidacji sieci neuronowych. Wyposażony był w procesor z serii *AMD Ryzen 9*, 128 GB RAM oraz kluczową w obliczeniach kartę graficzną z układem *Nvidia RTX 2070*. Druga jednostka to wykorzystany w procesie akwizycji danych akustycznych SBC *Raspberry Pi 3B+*. Są to jednostki o zupełnie skrajnym przeznaczeniu i dostępnej mocy obliczeniowej. W eksperymencie obliczono średnią oraz odchylenie standardowe dla kilkudziesięciu próbek czterokanałowego sygnału audio. Wyniki zawarto w tabeli 7.12.

Uzyskane wyniki wskazują, że opisywana metoda diagnostyczna jest zdecydowanie najbardziej wymagająca obliczeniowo ze wszystkich omawia-

		PC	Rpi
Ekstrakcja MFCC	Średnia dla ramki [ms]	2.860	1599
	σ [ms]	0.032	25
Klasyfikacja	Średnia dla ramki [ms]	0.037	1022
	σ [ms]	0.003	26

Tab. 7.12: Czas przetwarzania algorytmu diagnostycznego

nych. Czasy przetwarzania w niskoenergetycznym systemie wbudowanym są o trzy rzędy wielkości większe od osiągniętych dla przykładowej implementacji algorytmu opartego o sygnały wibracyjne (zob. 7.3). Do przyczyn zaliczyć można dużo bardziej intensywny strumień danych — sygnały akustyczne próbkowane są ze znacznie większą częstotliwością, co przekłada się na rozmiar sygnału o podobnej długości. Również proces obliczania MFCC, jak i stopień skomplikowania klasyfikatora mają znaczący wpływ na czas wypracowania odpowiedzi diagnostycznej.

Na rynku dostępne są platformy obliczeniowe spełniające wymagania *swap* dla BSP i charakteryzujące się znacznie większą mocą obliczeniową w zadaniach uczenia maszynowego ¹. Możliwe jest zatem skrócenie czasu działania systemu diagnostycznego opartego o proponowaną metodę. Niemniej, jest to algorytm o znacznie większych wymaganiach dotyczących mocy obliczeniowej i w warunkach aplikacji konieczne staje się wyposażenie typowego UAV w nadrzędny system komputerowy.

7.4.5 Podsumowanie

Omawiana metoda diagnostyczna ma najbardziej uniwersalny charakter — dostarcza informacji zarówno o wystąpieniu, lokalizacji, jak i charakterze uszkodzenia jednego lub pary wirników nośnych. Dokładność klasyfikacji na najliczniejszym i najbardziej zróżnicowanym ze stosowanych zbiorze danych jest bardzo wysoka i osiąga wartości bliskie 100%. Tak wysoka skuteczność pozwala na skonfigurowanie algorytmu do pracy na krótszych sygnałach akustycznych przy zachowaniu wysokiej trafności predykcji stanu systemu. Charakter źródła informacji o uszkodzeniu, złożony etap przetwarzania sygnałów oraz rozbudowany klasyfikator uszkodzeń znacząco zwiększają wymagania

¹Przykładami są układy serii *Nvidia Jetson*, *Google Coral* lub *Intel Compute Stick*

algorytmu dotyczące mocy obliczeniowej. Ogranicza to zalety opracowanego rozwiązania w kontekście praktycznej implementacji.

Podsumowanie

W rozprawie zaproponowano szereg rozwiązań sformułowanego w rozdziale pierwszym problemu technicznego. Zagadnienie dotyczy wczesnej i wykonywanej automatycznie diagnostyki stanu elementów wykonawczych wielowirnikowego BSP. Rozpatrywaną kategorią degradacji systemu są fizyczne uszkodzenia płatów wirników nośnych, rozpoznane względem dwóch podstawowych podtypów — zniszczenia (utruty) końcówki rotora oraz deformacji krawędzi natarcia profilu lotniczego. Opracowane metody należą do kategorii rozwiązań opartych o dane i wykorzystują sygnały wibroakustyczne oraz modele oparte na uczeniu maszynowym do klasyfikowania symptomów uszkodzeń. Przeprowadzono szereg eksperymentów dostarczających obserwacji właściwości sygnałów wibracyjnych towarzyszących wystąpieniu uszkodzenia. Na ich podstawie opracowano założenia i koncepcje wykorzystania informacji sensorycznej w postawionym zadaniu diagnostycznym oraz zaproponowano prototyp metody detekcji uszkodzeń. Realizowany w dalszej kolejności program badań dostarcza trzech wysoce skutecznych algorytmów diagnostycznych, dla których przeprowadzono ewaluację eksperymentalną na szerokich zbiorach danych uzyskanych w trakcie kilkudziesięciu lotów rzeczywistego UAV. Podczas przeprowadzania eksperymentów różnicowano w znacznym stopniu warunki wykonywanych lotów i parametry systemu dla możliwie wiernego odwzorowania realnych zadań wykonywanych przez wielowirnikowe bezzałogowe systemy latające.

8.1 Wnioski

Skuteczność proponowanych algorytmów diagnostycznych rozpatrywać można względem szeregu kryteriów, obejmujących zarówno ilościowe metryki skuteczności klasyfikacji stanów systemu, jak i zagadnienia techniczne oraz aplikacyjne. Porównanie trzech w pełni rozwiniętych metod, tj. klasyfikacji wzorców widmowych, jej rozszerzenia z wykorzystaniem danych z sieci sensorowej oraz analizy emisji akustycznej, prowadzi do szeregu spostrzeżeń:

1. Najwyższą dokładność oceny stanu systemu pod kątem detekcji uszkodzeń uzyskano dla metod wielosensorowych, tj. algorytmu opartego o sieć czujników oraz analizę akustyczną. Uzyskane metryki dokładności klasyfikacji próbek zebranych w eksperymentach sięgają blisko 99% dla pierwszego i niemal 100% dla drugiego podejścia. Bazowa metoda, czyli rozwiązanie oparte o sygnały wibracyjne pochodzące z pojedynczej, pokładowej IMU charakteryzuje się niewiele gorszą, bliską 97% maksymalną dokładnością. Istotną właściwością zaobserwowaną dla metod opartych o sygnały wibracyjne jest trudność w uzyskaniu wysokiej czułości algorytmów. Charakter stosowanych wzorców widmowych prowadzi przy zmniejszającej się dokładności metody do faworyzowania predykcji fałszywie negatywnych. Dopiero wykorzystanie danych z czteroelementowej sieci czujników eliminuje w znacznym stopniu opisany problem.
2. Wykorzystanie metod opartych o wiele sensorów stanowi rozwiązanie problemu lokalizacji miejsca uszkodzenia z dokładnością do ramienia symetrycznej konstrukcji UAV. Klasyfikacja występowania pojedynczych uszkodzonych aktuatorów wykonywana jest z identyczną dokładnością jak dla zadania detekcji. W przypadku systemu opartego o sieć sensorową, eksperymenty wykonywane na danych zawierających przypadki występowania dwóch niesprawnych wirników dostarczały zauważalnie gorszych rezultatów, ale jedynie w obrębie rozróżnienia klas opisujących uszkodzenia wielokrotne. Niezmiennie wysoka pozostała czułość systemu na samo wystąpienie dowolnego rodzaju uszkodzenia. Najskuteczniejsza metoda akustyczna nie posiada tych ograniczeń i pozwala na określenie miejsca występowania zarówno jednego, jak i dwóch uszkodzonych wirników bez strat w ogólnej skuteczności. Rezultaty wskazują, że pomiary wykonywane z wykorzystaniem wielu odpowiednio umieszczonych sensorów pozwalają na skuteczną lokalizację uszkodzeń. Kluczowymi aspektami jest sposób propagacji wibracji wprowadzanych przez uszkodzony wirnik w konstrukcji maszyny oraz pomiar zjawiska w kilku właściwie dobranych punktach. Innym rozwiązaniem problemu jest zastosowanie macierzy odpowiednio umiejscowionych i zorientowanych mikrofonów do rejestrowania sygnałów akustycznych.
3. Skuteczność proponowanych algorytmów diagnostycznych w zadaniu rozróżnienia podtypu rozważanych uszkodzeń zweryfikowano dla jednoczujnikowej metody wibracyjnej oraz algorytmu akustycznego. O

ile analiza wibracji pozwoliła na wskazanie jednego z dwóch rodzajów uszkodzeń z dokładnością około 90%, to wykorzystanie analizy sygnałów audio pozwoliło na określanie typu uszkodzenia z bliską 100% dokładnością równą osiąganą w zadaniach detekcji i lokalizacji.

4. Czynnikiem znacznie różnicującym postrzeganie przytoczonych rezultatów jest długość analizowanych sygnałów. Jak wykazano w omówieniu wyników ewaluacji poszczególnych metod, rozmiary ramek wielokanałowych sygnałów wibroakustycznych ma zasadniczą rolę w skuteczności wszystkich rozważanych algorytmów. Zakłócenie wprowadzane przez uszkodzenie wirnika ma niestacjonarny charakter, zależny w szerszym horyzoncie od typu BSP, jego masy i rodzaju stosowanych jednostek napędowych. W krótkim okresie częstotliwość charakterystyczna dla uszkodzenia zależy od aktualnych wartości sterowania systemem napędowym. Z tego względu zwiększanie długości analizowanych fragmentów sygnałów powyżej pewnej wartości nie poprawia, a nawet nieznacznie pogarsza jakość detekcji. Z drugiej strony, zbyt krótkie ramki nie zawierają wystarczającej ilości informacji do stworzenia sygnatury jasno identyfikującej stan systemu. Odnosząc zagadnienie do osiągnięć proponowanych metod diagnostycznych na zbliżonych zbiorach danych (pkt 1), wspomniane wyniki osiągnięto dla sygnałów o długości powyżej 900 ms (dla metody z centralnym sensorem), 800-1000 ms (dla algorytmu opartego o sieć sensorową) i 400-500 ms w przypadku analizy sygnałów akustycznych. Przyjmując jako punkt odniesienia dokładność klasyfikacji na poziomie 95%, wymagana długość sygnałów spada odpowiednio do około 500, 250 i 100 milisekund. Wskazuje to na dużo szybszą diagnostykę w przypadku wykorzystania informacji z wielu sensorów oraz przewagę sygnału akustycznego nad wibracyjnym jako źródła informacji o uszkodzeniu.
5. Rozważając w kontekście aplikacyjnym przewagę jednego typu sygnału nad drugim, istotnym jest odniesienie się do złożoności obliczeniowej proponowanych algorytmów. Przewaga metody akustycznej skutecznie niwelowana jest przez ograniczenia mocy obliczeniowej dostępnej na pokładzie typowego UAV. W pracy przytoczono przykłady implementacji proponowanych potoków przetwarzania w systemach wbudowanych. Czas diagnostyki alternatywnej wersji algorytmu opartego o dane z sieci sensorowej, rozumiany jako okres od zarejestrowania zestawu sygnałów wibracyjnych do momentu zwrócenia wyniku klasyfikacji, oszacowano

na kilka do maksymalnie kilkudziesięciu milisekund. Przetwarzanie w złożonej metodzie akustycznej, opartej o cechy MFCC i rekurencyjną sztuczną sieć neuronową, pochłania czas dłuższy o trzy rzędy wielkości i to przy zastosowaniu wydajniejszej platformy obliczeniowej. Prowadzi to do wniosku, że w kontekście praktycznej implementacji dobór konkretnej metody diagnostycznej jest silnie zależny od dostępnej platformy sprzętowej.

6. Omówione w poprzednim punkcie zagadnienie jest połączone z szerszym kontekstem wprowadzania dodatkowego oprzyrządowania na potrzeby systemu diagnostycznego. Wszystkie rozwiązania oraz ich fizyczne elementy projektowano w taki sposób, aby ingerencja w konstrukcję statku powietrznego była minimalna i nie zmieniała jego parametrów oraz osiąarów. Niemniej, najbardziej skuteczne metody diagnostyczne wymagają dodatkowego wyposażenia w postaci sieci akcelerometrów lub miniaturowej macierzy mikrofonów. Tylko metoda oparta o pokładową IMU korzysta jedynie z domyślnej konfiguracji systemu awioniki. Wymóg stosowania dodatkowych komponentów występuje również dla zapewnienia funkcjonalności lokalizacji miejsca uszkodzenia.

8.1.1 Ocena stopnia realizacji przyjętych celów

Wysunięte wnioski można odnieść do postawionych hipotez oraz celów zdefiniowanych w części 1.2 rozprawy:

- Podsumowanie skuteczności w zadaniu detekcji oraz lokalizacji uszkodzeń wirników nośnych (pkt. 1 oraz 2) wskazuje, że zaproponowane metody stanowią przykład skutecznej diagnostyki rozważnej klasy defektów na podstawie informacji z sensorów wielowirnikowego robota latającego. Rozważania dotyczące implementacji i opracowanych rozwiązań technicznych (pkt. 6) pokazują, że postawione zadanie diagnostyczne jest możliwe do zrealizowania z wykorzystaniem sensorów i zasobów obliczeniowych dostępnych lub możliwych do zastosowania na pokładzie UAV ze względu na ich wymiary, masę i pobór energii. Analiza czasu przetwarzania algorytmów (pkt. 5) oraz długości analizowanych sygnałów wibroakustycznych (pkt 4.) dowodzą, że rozwiązania zapewniają wczesne wykrycie uszkodzenia i mogą być wykonywane w

czasie rzeczywistym. Dodatkowym potwierdzeniem są dwa przykłady uruchomienia potoków przetwarzania metod diagnostycznych w systemach wbudowanych. Powyższe fakty udowadniają pierwszą z hipotez o brzmieniu „*Analiza online sygnałów sensorów pokładowych umożliwia wczesne wykrycie i lokalizację uszkodzenia wirnika nośnego robota latającego (platformy wielowirnikowej)*”. Wspomniane wnioski potwierdzają również spełnienie celów pracy w zakresie zdefiniowanych dla systemu diagnostycznego wymagań technicznych.

- Przeprowadzone na kilku etapach prac analizy widm sygnałów wibroakustycznych oraz skuteczność omawianych metod (pkt. 1, 2 i 3) w postawionym zadaniu potwierdzają prawdziwość drugiej z postawionej hipotez: „*Sygnał wibroakustyczny pochodzący z pracującego wirnika jest wystarczającym źródłem informacji pozwalającym na stwierdzenie uszkodzenia oraz jego identyfikację*”. Opracowane algorytmy opierają się na analizie i klasyfikacji sygnatur uzyskanych z wielokanałowych sygnałów wibracyjnych oraz akustycznych jako jedyne źródła pozwalającego na stwierdzenie wystąpienia, lokalizację oraz określenie charakteru uszkodzenia wirników nośnych.
- Analiza widmowa sygnałów wibracyjnych uzyskanych z wykorzystaniem sieci akcelerometrów przedstawiona w części 5.3 rozprawy, wyniki ewaluacji powiązanej metody diagnostycznej oraz wnioski dotyczące jej skuteczności w lokalizacji miejsca uszkodzenia (pkt. 2) potwierdzają ostatnią z postawionych hipotez o brzmieniu „*Charakter propagowania się w konstrukcji UAV wibracji generowanych przez uszkodzony wirnik pozwala na zlokalizowanie miejsca wystąpienia uszkodzenia z dokładnością do ramienia konstrukcji*”.

8.1.2 Oryginalność prac

Prezentowane w rozprawie metody diagnostyczne wypełniają szereg luk w obecnych w literaturze rozwiązaniach rozpatrywanego problemu. Do najistotniejszych z nich zaliczyć można bardzo słabe odwzorowanie warunków i stanów systemu w porównaniu do rzeczywistych lotów. Publikowane prace dotyczą często diagnostyki uszkodzeń sztucznie symulowanych poprzez uproszczenie problemu do znaczącego spadku wartości ciągu generowanego przez uszkodzony napęd. W rezultacie diagnozowany jest jedynie objaw

uszkodzenia, podczas gdy utrata nawet istotnej części płyta wirnika niekoniecznie prowadzi do tak znacznego spadku efektywności (zob. 1.3). Z kolei eksperymenty walidacyjne przeprowadzane dla metod diagnozujących realne uszkodzenia nierzadko wykonywane są jedynie podczas lotu w zawisie, co prowadzi do nieuwzględnienia znacznego stopnia zmienności sygnałów wibracyjnych. Ponadto pomiary wykonywane są często z wykorzystaniem wysokiej klasy zewnętrznych systemów akwizycji, niemożliwych do zastosowania w warunkach aplikacji na pokładzie BSP. Nieliczne są też rozwiązania podejmujące tematykę lokalizacji tej kategorii uszkodzeń, będącej kluczową informacją dla potencjalnych algorytmów sterowania tolerującego uszkodzenia.

Opracowana przez autora metoda klasyfikacji wzorców widmowych sygnałów wibracyjnych z pokładowej IMU na chwilę publikacji [113] dorównywała skutecznością innym dostępnym w literaturze rozwiązaniom, demonstrując dodatkowo możliwość rozróżnienia typu uszkodzenia na podstawie zastosowanego źródła informacji. Została również przetestowana dla dużo szerszego studium warunków lotu. Rozszerzenie koncepcji o system sieci sensorowej i wprowadzenie funkcjonalności lokalizacji miejsca uszkodzenia na podstawie sygnałów wibracyjnych [97] jest rozwiązaniem oryginalnym. Przy współudziale autora powstała również alternatywna wersja algorytmu o zwiększonej skuteczności diagnostyki w przypadku występowania w systemie pary uszkodzonych wirników [111]. Metoda akustyczna [103] wyróżnia się spośród kilku podobnych rozwiązań wprowadzeniem funkcjonalności lokalizacji i identyfikacji typu uszkodzenia. Jednocześnie jest unikatowym rozwiązaniem wykorzystującym macierz mikrofonów rejestrujących sygnały bezpośrednio na pokładzie platformy wielowirnikowej.

8.2 Dalsze kierunki badań

Kierunki dalszych badań autora koncentrują się w kilku najważniejszych obszarach:

- Doprowadzenie omawianych metod diagnostycznych do etapu pełnej implementacji na pokładzie bezzałogowego pojazdu latającego i wykonanie eksperymentów polegających na fizycznym wywołaniu uszkodzenia w locie oraz ocenie skuteczności systemów diagnostycznych pracujących w czasie rzeczywistym.

- Dalsze ulepszenia polegające na optymalizacji algorytmów pod kątem czasu przetwarzania i przenośności dla różnych BSP.
- Wykorzystanie szerszego potencjału sygnałów wibroakustycznych do detekcji i identyfikacji innych kategorii uszkodzeń elementów wykonawczych UAV. Przykładowym celem jest opracowanie metod dla inspirowanych naturą dronów utrzymujących się w powietrzu dzięki ruchom skrzydeł (tzw. *flapper drones*), czy też analiza innego typu defektów układów napędowych klasycznej platformy wielowirnikowej.
- Rozwój opracowanych równolegle prototypów nowych metod diagnostycznych dla rozważanego w rozprawie problemu. Plany obejmują wykorzystanie alternatywnych źródeł informacji o uszkodzeniu, na przykład sygnaury prądów uzwojeń silników (metoda MCSA, ang. *Motor Current Signature Analysis*).

Bibliografia

- [1]É. Beke, A. Bódi, T. G. Katalin i in. „The Role of Drones in Linking Industry 4.0 and ITS Ecosystems“. W: *2018 IEEE 18th International Symposium on Computational Intelligence and Informatics (CINTI)*. 2018, s. 000191–000198 (cyt. na s. 1).
- [2]D. C. Tsouros, S. Bibi i P. G. Sarigiannidis. „A Review on UAV-Based Applications for Precision Agriculture“. W: *Information* 10.11 (2019) (cyt. na s. 1).
- [3]F. Mohammed, A. Idries, N. Mohamed, J. Al-Jaroodi i I. Jawhar. „UAVs for smart cities: Opportunities and challenges“. W: *2014 International Conference on Unmanned Aircraft Systems (ICUAS)*. 2014, s. 267–273 (cyt. na s. 1).
- [4]H. Shakhathreh, A. H. Sawalmeh, A. Al-Fuqaha i in. „Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges“. W: *IEEE Access* 7 (2019), s. 48572–48634 (cyt. na s. 1).
- [5]B. de Miguel Molina i M. S. Oña. „The drone sector in Europe“. W: *Ethics and civil drones*. Springer, Cham, 2018, s. 7–33 (cyt. na s. 1).
- [6]C. Stöcker, R. Bennett, F. Nex, M. Gerke i J. Zevenbergen. „Review of the Current State of UAV Regulations“. W: *Remote Sensing* 9.5 (2017) (cyt. na s. 1).
- [8]G. Wild, J. Murray i G. Baxter. „Exploring Civil Drone Accidents and Incidents to Help Prevent Potential Air Disasters“. W: *Aerospace* 3.3 (2016) (cyt. na s. 2).
- [9]A. Susini. „A Technocritical Review of Drones Crash Risk Probabilistic Consequences and its Societal Acceptance“. W: *RIMMA 2014 Berlin, Risk information management, risk models and applications Conference*. List. 2015 (cyt. na s. 2).
- [10]Q. Zhai i Z.-S. Ye. „How reliable should military UAVs be?“ W: *IISE Transactions* 52.11 (2020), s. 1234–1245 (cyt. na s. 2).
- [11]„Rozporządzenie wykonawcze Komisji (UE) 2019/947 z dnia 24 maja 2019 r. w sprawie przepisów i procedur dotyczących eksploatacji bezzałogowych statków powietrznych“. W: *Dziennik Urzędowy Unii Europejskiej*, L 152, 11 czerwca 2019. 2019 (cyt. na s. 2).

- [12]A. Bondyra, S. Gardecki, P. Gąsior i W. Giernacki. „Performance of coaxial propulsion in design of multi-rotor UAVs“. W: *International Conference on Automation*. 2016, s. 523–531 (cyt. na s. 3, 24, 47).
- [13]M. Mizui, I. Yamamoto i R. Ohsawa. „Effects of Propeller-balance on Sensors in Small-scale Unmanned Aerial Vehicle“. W: *IOSR Journal of Engineering* Vol.2 (sierp. 2012), pp.23–27 (cyt. na s. 3).
- [14]M. A. Al-Mashhadani. „Optimal control and state estimation for unmanned aerial vehicle under random vibration and uncertainty“. W: *Measurement and Control* 52.9-10 (2019), s. 1264–1271 (cyt. na s. 3).
- [15]M. Ramesh, R. Vijayanandh, G. R. Kumar i in. „Comparative Structural Analysis of Various Composite Materials based Unmanned Aerial Vehicle’s Propeller by using Advanced Methodologies“. W: *IOP Conference Series: Materials Science and Engineering* 1017 (sty. 2021), s. 012032 (cyt. na s. 4).
- [16]K. P. Valavanis. „Unmanned aircraft systems challenges in design for autonomy“. W: *2017 11th International Workshop on Robot Motion and Control (RoMoCo)*. IEEE. 2017, s. 73–86 (cyt. na s. 4).
- [17]T. Lutz, C. Gu, S. Gardecki i in. „StarTiger Dropter project: Development and flight experiment of a Skycrane-like terrestrial lander demonstrator“. W: *The 9th International ESA Conference on Guidance, Navigation and Control Systems*. 2014 (cyt. na s. 5, 6, 44).
- [18]T. Hormigo, C. Gu, T. Lutz i in. „StarTiger Dropter Project: Integrated, closed-loop vision-aided navigation with hazard detection and avoidance“. W: *GNC 2014: 9th International ESA conference on Guidance, Navigation & Control Systems* (cyt. na s. 5, 44).
- [19]L. DJI Technology Co. *Three-Propeller Emergency Landing of the Matrice 300 RTK White Paper*. 2020 (cyt. na s. 13).
- [20]N. Meskin i K. Khorasani. *Fault detection and isolation: Multi-vehicle unmanned systems*. Springer Science & Business Media, 2011 (cyt. na s. 13).
- [21]M. Wiczak i M. Pazera. „Fault tolerant-control: Solutions and challenges“. W: *Pomiary Automatyka Robotyka* 20.1 (2016), s. 5–16 (cyt. na s. 13).
- [22]S. Simani, C. Fantuzzi i R. J. Patton. „Model-based fault diagnosis techniques“. W: *Model-based Fault Diagnosis in Dynamic Systems Using Identification Techniques*. Springer, 2003, s. 19–60 (cyt. na s. 13).
- [23]A. Fekih. „Fault diagnosis and Fault Tolerant Control design for aerospace systems: A bibliographical review“. W: *2014 American Control Conference*. 2014, s. 1286–1291 (cyt. na s. 14, 17).
- [24]J. Korbicz. „Trendy i problemy w diagnostyce procesów“. W: *Diagnostyka* Vol. 30, T. 1 (2004), s. 275–286 (cyt. na s. 14).

- [25]M. Mansouri, M.-F. Harkat, H. Nounou i M. N. Nounou. *Data-driven and model-based methods for fault detection and diagnosis*. Elsevier, 2020 (cyt. na s. 14, 15).
- [26]R. J. Patton, P. M. Frank i R. N. Clark. *Issues of fault diagnosis for dynamic systems*. Springer Science & Business Media, 2013 (cyt. na s. 14).
- [27]J. Korbicz, J. M. Koscielny, Z. Kowalczyk i W. Cholewa. *Fault diagnosis: models, artificial intelligence, applications*. Springer Science & Business Media, 2012 (cyt. na s. 15).
- [28]K. Patan. *Artificial neural networks for the modelling and fault diagnosis of technical processes*. Springer, 2008 (cyt. na s. 15).
- [29]O. Janssens, V. Slavkovikj, B. Vervisch i in. „Convolutional neural network based fault detection for rotating machinery“. W: *Journal of Sound and Vibration* 377 (2016), s. 331–345 (cyt. na s. 15).
- [30]S. Rajakarunakaran, P. Venkumar, D. Devaraj i K. S. P. Rao. „Artificial neural network approach for fault detection in rotary system“. W: *Applied Soft Computing* 8.1 (2008), s. 740–748 (cyt. na s. 15).
- [31]P. Frank i T. Marcu. „Fuzzy techniques in fault detection, isolation and diagnosis“. W: *Fuzzy Logic Control: Advances in Applications* (1999), s. 135–159 (cyt. na s. 15).
- [32]S. Adhikari, N. Sinha i T. Dorendrajit. „Fuzzy logic based on-line fault detection and classification in transmission line“. W: *SpringerPlus* 5.1 (2016), s. 1–14 (cyt. na s. 15).
- [33]Y. L. Murphey, M. A. Masrur, Z. Chen i B. Zhang. „Model-based fault diagnosis in electric drives using machine learning“. W: *IEEE/ASME Transactions On Mechatronics* 11.3 (2006), s. 290–303 (cyt. na s. 15).
- [34]Y. Lei, B. Yang, X. Jiang i in. „Applications of machine learning to machine fault diagnosis: A review and roadmap“. W: *Mechanical Systems and Signal Processing* 138 (2020), s. 106587 (cyt. na s. 15).
- [35]K. Guo, L. Liu, S. Shi, D. Liu i X. Peng. „UAV Sensor Fault Detection Using a Classifier without Negative Samples: A Local Density Regulated Optimization Algorithm“. W: *Sensors* 19.4 (2019) (cyt. na s. 16).
- [36]D. Wang i Q. Miao. „Smoothness index-guided Bayesian inference for determining joint posterior probability distributions of anti-symmetric real Laplace wavelet parameters for identification of different bearing faults“. W: *Journal of Sound and Vibration* 345 (2015), s. 250–266 (cyt. na s. 16).
- [37]Q. Jiang i X. Yan. „Nonlinear plant-wide process monitoring using MI-spectral clustering and Bayesian inference-based multiblock KPCA“. W: *Journal of Process Control* 32 (2015), s. 38–50 (cyt. na s. 16).

- [38]R. Patton. „Fault detection and diagnosis in aerospace systems using analytical redundancy“. W: *IEE Colloquium on Condition Monitoring and Fault Tolerance*. 1990, s. 1/1–120 (cyt. na s. 16).
- [39]R. Isermann i P. Ballé. „Trends in the application of model-based fault detection and diagnosis of technical processes“. W: *Control Engineering Practice* 5.5 (1997), s. 709–719 (cyt. na s. 16).
- [40]G. K. Fourlas i G. C. Karras. „A Survey on Fault Diagnosis and Fault-Tolerant Control Methods for Unmanned Aerial Vehicles“. W: *Machines* 9.9 (2021) (cyt. na s. 17).
- [41]X. Qi, D. Theilliol, J. Qi i in. „Fault diagnosis and fault tolerant control methods for manned and unmanned helicopters: a literature review“. W: *2013 Conference on Control and Fault-Tolerant Systems (SysTol)*. IEEE. 2013, s. 132–139 (cyt. na s. 17).
- [42]J. Huang, M. Li, Y. Zhang i in. „Fault Detection and Classification for Sensor Faults of UAV by Deep Learning and Time-Frequency Analysis“. W: *2021 40th Chinese Control Conference (CCC)*. 2021, s. 4420–4424 (cyt. na s. 17).
- [43]A. Y. Ouadine, M. Mjahed, H. Ayad i A. El Kari. „UAV quadrotor fault detection and isolation using artificial neural network and Hammerstein-Wiener model“. W: *Stud Inform Control* 29.3 (2020), s. 317–328 (cyt. na s. 17).
- [44]G. Heredia, F. Caballero, I. Maza i in. „Multi-Unmanned Aerial Vehicle (UAV) Cooperative Fault Detection Employing Differential Global Positioning (DGPS), Inertial and Vision Sensors“. W: *Sensors* 9.9 (2009), s. 7566–7579 (cyt. na s. 17).
- [45]P. Freeman, R. Pandita, N. Srivastava i G. J. Balas. „Model-based and data-driven fault detection performance for a small UAV“. W: *IEEE/ASME Transactions on mechatronics* 18.4 (2013), s. 1300–1309 (cyt. na s. 17, 132).
- [46]E. Baskaya, M. Bronz i D. Delahaye. „Fault detection amp; diagnosis for small UAVs via machine learning“. W: *2017 IEEE/AIAA 36th Digital Avionics Systems Conference (DASC)*. 2017, s. 1–6 (cyt. na s. 17).
- [47]A. Abbaspour, P. Aboutalebi, K. K. Yen i A. Sargolzaei. „Neural adaptive observer-based sensor and actuator fault detection in nonlinear systems: Application in UAV“. W: *ISA Transactions* 67 (2017), s. 317–329 (cyt. na s. 17).
- [48]A. Suti, G. Di Rito i R. Galatolo. „Fault-Tolerant Control of a Three-Phase Permanent Magnet Synchronous Motor for Lightweight UAV Propellers via Central Point Drive“. W: *Actuators* 10.10 (2021) (cyt. na s. 17).
- [49]A. L. Christensen, R. O’Grady, M. Birattari i M. Dorigo. „Fault detection in autonomous robots based on fault injection and learning“. W: *Autonomous Robots* 24.1 (2008), s. 49–67 (cyt. na s. 18).

- [50]A. Abbaspour, S. Mokhtari, A. Sargolzaei i K. K. Yen. „A Survey on Active Fault-Tolerant Control Systems“. W: *Electronics* 9.9 (2020) (cyt. na s. 18).
- [51]F. Sharifi, M. Mirzaei, B. W. Gordon i Y. Zhang. „Fault tolerant control of a quadrotor UAV using sliding mode control“. W: *2010 Conference on Control and Fault-Tolerant Systems (SysTol)*. 2010, s. 239–244 (cyt. na s. 18).
- [52]M. Moghadam i F. Caliskan. „Actuator and sensor fault detection and diagnosis of quadrotor based on Two-Stage Kalman Filter“. W: *2015 5th Australian Control Conference (AUCC)*. 2015, s. 182–187 (cyt. na s. 18).
- [53]Z. Cen, H. Noura i Y. A. Younes. „Robust Fault Estimation on a real quadrotor UAV using optimized Adaptive Thau Observer“. W: *2013 International Conference on Unmanned Aircraft Systems (ICUAS)*. 2013, s. 550–556 (cyt. na s. 18).
- [54]Z. Cen i H. Noura. „An Adaptive Thau Observer for estimating the time-varying LOE fault of quadrotor actuators“. W: *2013 Conference on Control and Fault-Tolerant Systems (SysTol)*. 2013, s. 468–473 (cyt. na s. 18).
- [55]Z. Cen, H. Noura, T. B. Susilo i Y. A. Younes. „Engineering implementation on fault diagnosis for quadrotors based on nonlinear observer“. W: *2013 25th Chinese Control and Decision Conference (CCDC)*. 2013, s. 2971–2975 (cyt. na s. 18).
- [56]M. Saied, B. Lussier, I. Fantoni i in. „Fault diagnosis and fault-tolerant control strategy for rotor failure in an octorotor“. W: *2015 IEEE International Conference on Robotics and Automation (ICRA)*. 2015, s. 5266–5271 (cyt. na s. 19).
- [57]A. Freddi, S. Longhi i A. Monteriù. „Actuator fault detection system for a mini-quadrotor“. W: *2010 IEEE International Symposium on Industrial Electronics*. 2010, s. 2055–2060 (cyt. na s. 19).
- [58]A. S. Cândido, R. K. Harrop Galvão i T. Yoneyama. „Actuator fault diagnosis and control of a quadrotor“. W: *2014 12th IEEE International Conference on Industrial Informatics (INDIN)*. 2014, s. 310–315 (cyt. na s. 19).
- [59]Y. A. Younes, H. Noura, A. Rabhi i A. E. Hajjaji. „Actuator Fault-Diagnosis and Fault-Tolerant-Control using intelligent-Output-Estimator Applied on Quadrotor UAV“. W: *2019 International Conference on Unmanned Aircraft Systems (ICUAS)*. 2019, s. 413–420 (cyt. na s. 19).
- [60]J. Fu, C. Sun, Z. Yu i L. Liu. „A hybrid CNN-LSTM model based actuator fault diagnosis for six-rotor UAVs“. W: *2019 Chinese Control And Decision Conference (CCDC)*. IEEE. 2019, s. 410–414 (cyt. na s. 19, 22).
- [61]F. Pourpanah, B. Zhang, R. Ma i Q. Hao. „Anomaly Detection and Condition Monitoring of UAV Motors and Propellers“. W: *2018 IEEE SENSORS*. 2018, s. 1–4 (cyt. na s. 20, 22, 100).

- [62]B. Ghalamchi, Z. Jia i M. W. Mueller. „Real-Time Vibration-Based Propeller Fault Diagnosis for Multicopters“. W: *IEEE/ASME Transactions on Mechatronics* 25.1 (2020), s. 395–405 (cyt. na s. 20, 22).
- [63]G. Iannace, G. Ciaburro i A. Trematerra. „Fault Diagnosis for UAV Blades Using Artificial Neural Network“. W: *Robotics* 8.3 (2019) (cyt. na s. 21, 22).
- [64]W. Liu, Z. Chen i M. Zheng. „An Audio-Based Fault Diagnosis Method for Quadrotors Using Convolutional Neural Network and Transfer Learning“. W: *2020 American Control Conference (ACC)*. 2020, s. 1367–1372 (cyt. na s. 21).
- [65]A. Altinors, F. Yol i O. Yaman. „A sound based method for fault detection with statistical feature extraction in UAV motors“. W: *Applied Acoustics* 183 (2021), s. 108325 (cyt. na s. 21, 22).
- [66]R. Mahony, V. Kumar i P. Corke. „Multirotor aerial vehicles: Modeling, estimation, and control of quadrotor“. W: *IEEE Robotics and Automation Magazine* 19.3 (2012), s. 20–32 (cyt. na s. 23, 27).
- [67]S. Rajappa, M. Ryll, H. H. Bühlhoff i A. Franchi. „Modeling, control and design optimization for a fully-actuated hexarotor aerial vehicle with tilted propellers“. W: *2015 IEEE International Conference on Robotics and Automation (ICRA)*. 2015, s. 4006–4013 (cyt. na s. 23, 24).
- [68]N. Osmić, M. Kurić i I. Petrović. „Detailed octotorotor modeling and PD control“. W: *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2016, s. 002182–002189 (cyt. na s. 24).
- [69]T. P. Nascimento i M. Saska. „Position and attitude control of multi-rotor aerial vehicles: A survey“. W: *Annual Reviews in Control* 48 (2019), s. 129–146 (cyt. na s. 24).
- [70]G. B. Raharja, K. G. Beom i Y. Kwangjoon. „Design and implementation of coaxial quadrotor for an autonomous outdoor flight“. W: *2011 8th International Conference on Ubiquitous Robots and Ambient Intelligence (URAI)*. 2011, s. 61–63 (cyt. na s. 24).
- [71]J. Gośliński, A. Kasiński, W. Giernacki, P. Owczarek i S. Gardecki. „A study on coaxial quadrotor model parameter estimation: an application of the improved square root unscented Kalman filter“. W: *Journal of Intelligent & Robotic Systems* 95.2 (2019), s. 491–510 (cyt. na s. 24).
- [72]C. Peng, Y. Bai, X. Gong i in. „Modeling and robust backstepping sliding mode control with Adaptive RBFNN for a novel coaxial eight-rotor UAV“. W: *IEEE/CAA Journal of Automatica Sinica* 2.1 (2015), s. 56–64 (cyt. na s. 24).
- [73]P. Pounds, R. Mahony i P. Corke. „Modelling and control of a quad-rotor robot“. W: *Proceedings of the 2006 Australasian Conference on Robotics and Automation*. The Australian Robotics i Automation Association Inc. 2006, s. 1–10 (cyt. na s. 27).

- [74]G. Padfield i J. Karnkowski. *Dynamika lotu śmigłowców: teoria i wykorzystanie właściwości lotnych i modeli symulacyjnych*. Wydawnictwo Komunikacji i Łączności, 1998 (cyt. na s. 29).
- [75]L. Ou, D. Li i J. Li. „Shaft center orbit diagnoses technology of broken-blade propeller induced shaft vibration fault“. W: *2013 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE)*. 2013, s. 1777–1780 (cyt. na s. 29).
- [76]J. Fries. *The effect of helicopter main rotor blade damage on the rotor disk (whole rotor) motion*. Spraw. tech. ARMY RESEARCH LAB ABERDEEN PROVING GROUND MD, 2000 (cyt. na s. 30).
- [77]E. Ebeid, M. Skriver, K. H. Terkildsen, K. Jensen i U. P. Schultz. „A survey of Open-Source UAV flight controllers and flight simulators“. W: *Microprocessors and Microsystems* 61 (2018), s. 11–20 (cyt. na s. 40).
- [78]T. Khamvilai, J. Dunham, E. Feron i E. N. Johnson. „Avionics of Aerial Robots“. W: *Current Robotics Reports* 2.2 (2021), s. 113–124 (cyt. na s. 40, 41).
- [79]J. Jeon, S. Jung, E. Lee, D. Choi i H. Myung. „Run Your Visual-Inertial Odometry on NVIDIA Jetson: Benchmark Tests on a Micro Aerial Vehicle“. W: *IEEE Robotics and Automation Letters* 6.3 (2021), s. 5332–5339 (cyt. na s. 41).
- [80]A. Vega, C.-C. Lin, K. Swaminathan i in. „Resilient, UAV-embedded real-time computing“. W: *2015 33rd IEEE International Conference on Computer Design (ICCD)*. 2015, s. 736–739 (cyt. na s. 41).
- [81]S. Chen, D. F. Laefer i E. Mangina. „State of technology review of civilian UAVs“. W: *Recent Patents on Engineering* 10.3 (2016), s. 160–174 (cyt. na s. 42).
- [82]S. Gardecki i A. Kasiński. „Wielowirnikowy robot latający Hornet“. W: *Prace Naukowe Politechniki Warszawskiej. Elektronika* 175, t. 2 (2010), s. 655–664 (cyt. na s. 44).
- [83]S. Gardecki i A. Kasiński. „Badanie i dobór elektrycznych jednostek napędowych wielowirnikowego robota latającego“. W: *Pomiary Automatyka Kontrola* 58 (2012), s. 80–83 (cyt. na s. 44).
- [84]A. Bondyra, S. Gardecki, P. Gašior i A. Kasiński. „Falcon: A compact multirotor flying platform with high load capability“. W: *Progress in Automation, Robotics and Measuring Techniques*. Springer, 2015, s. 35–44 (cyt. na s. 44).
- [85]A. Bondyra, S. Gardecki i P. Gašior. „A distributed control system for multirotor aerial platforms“. W: *Measurement Automation Monitoring* 61 (2015) (cyt. na s. 44, 46).
- [86]M. Achtelik, K.-M. Doth, D. Gurdan i J. Stumpf. „Design of a multi rotor MAV with regard to efficiency, dynamics and redundancy“. W: *AIAA Guidance, Navigation, and Control Conference*. 2012, s. 4779 (cyt. na s. 48).

- [87]P. Gašior, A. Bondyra i S. Gardecki. „Comparison of different methods of flight data logging used in multirotor UAVs“. W: *Measurement Automation Monitoring* 63 (2017) (cyt. na s. 51).
- [88]S. Cheshire i M. Baker. „Consistent overhead byte stuffing“. W: *IEEE/ACM Transactions on Networking* 7.2 (1999), s. 159–172 (cyt. na s. 56).
- [89]P. Aszkowski, K. Błoszyk, A. Bondyra, P. Gašior i W. Giernacki. „UAV propulsion analysis system with reconfigurable controller feature“. W: *Measurement Automation Monitoring* 63 (2017) (cyt. na s. 61).
- [90]A. Bondyra, P. Gašior i S. Gardecki. „Experimental test bench for multirotor UAVs“. W: *International Conference Automation*. Springer. 2017, s. 330–338 (cyt. na s. 62).
- [91]M. Pawlak. „Zastosowanie funkcji okien czasowych w diagnostyce wirników silników indukcyjnych“. W: *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały* 62.28 (2008), s. 520–527 (cyt. na s. 66, 75).
- [92]C. Xiang, X. Wang, Y. Ma i B. Xu. „Practical modeling and comprehensive system identification of a BLDC motor“. W: *Mathematical Problems in Engineering* 2015 (2015) (cyt. na s. 67).
- [93]Z. Yin i J. Hou. „Recent advances on SVM based fault diagnosis and process monitoring in complicated industrial processes“. W: *Neurocomputing* 174 (2016), s. 643–650 (cyt. na s. 72).
- [94]R. Liu, B. Yang, E. Zio i X. Chen. „Artificial intelligence for fault diagnosis of rotating machinery: A review“. W: *Mechanical Systems and Signal Processing* 108 (2018), s. 33–47 (cyt. na s. 72).
- [95]X. Li, F. Duan, D. Mba i I. Bennett. „Multidimensional prognostics for rotating machinery: A review“. W: *Advances in Mechanical Engineering* 9.2 (2017), s. 1687814016685004 (cyt. na s. 72).
- [96]G. Heinzel, A. Rüdiger i R. Schilling. „Spectrum and spectral density estimation by the Discrete Fourier transform (DFT), including a comprehensive list of window functions and some new at-top windows“. W: (2002) (cyt. na s. 75).
- [97]A. Bondyra, P. Gasior, S. Gardecki i A. J. Kasinski. „Development of the Sensory Network for the Vibration-based Fault Detection and Isolation in the Multirotor UAV Propulsion System“. W: *International Conference on Informatics in Control, Automation and Robotics (ICINCO)*. 2018, s. 112–119 (cyt. na s. 81, 83, 85, 86, 100, 152).
- [98]C.-W. Hsu i C.-J. Lin. „A comparison of methods for multiclass support vector machines“. W: *IEEE Transactions on Neural Networks* 13.2 (2002), s. 415–425 (cyt. na s. 87).

- [99]K. Fawagreh, M. M. Gaber i E. Elyan. „Random forests: from early developments to recent advancements“. W: *Systems Science & Control Engineering* 2.1 (2014), s. 602–609 (cyt. na s. 87).
- [100]L. Breiman. „Random forests“. W: *Machine learning* 45.1 (2001), s. 5–32 (cyt. na s. 87).
- [101]S. C. Peter, J. K. Dhanjal, V. Malik i in. „Encyclopedia of bioinformatics and computational biology“. W: *Ranganathan, S., Gribskov, M., Nakai, K., and Schönbach, C., editors* (2019), s. 661–676 (cyt. na s. 87).
- [102]S. Manikandan i K. Duraivelu. „Fault diagnosis of various rotating equipment using machine learning approaches – A review“. W: *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering* 235.2 (2021), s. 629–642 (cyt. na s. 87).
- [103]A. Bondyra, M. Kołodziejczak, R. Kulikowski i W. Giernacki. „An Acoustic Fault Detection and Isolation System for Multirotor UAV“. W: *Energies* 15.11 (2022) (cyt. na s. 91, 93, 94, 105, 141, 142, 152).
- [104]D. Gupta, P. Bansal i K. Choudhary. „The state of the art of feature extraction techniques in speech recognition“. W: *Speech and language processing for human-machine communications* (2018), s. 195–207 (cyt. na s. 92).
- [105]T. Marwala. „Data processing techniques for condition monitoring“. W: *Condition Monitoring Using Computational Intelligence Methods* (2012), s. 27–51 (cyt. na s. 92).
- [106]K. B. T. Shaikh, N. P. Jawarkar i V. Ahmed. „Machine diagnosis using acoustic analysis: a review“. W: *2021 IEEE Conference on Norbert Wiener in the 21st Century (21CW)*. 2021, s. 1–6 (cyt. na s. 92).
- [107]K. S. Rao i A. K. Vuppala. *Speech processing in mobile environments*. Springer, 2014 (cyt. na s. 92).
- [108]K. Smagulova i A. P. James. „A survey on LSTM memristive neural network architectures and applications“. W: *The European Physical Journal Special Topics* 228.10 (2019), s. 2313–2324 (cyt. na s. 94).
- [109]B. Lindemann, B. Maschler, N. Sahlab i M. Weyrich. „A survey on anomaly detection for technical systems using LSTM networks“. W: *Computers in Industry* 131 (2021), s. 103498 (cyt. na s. 94).
- [110]M. Jalayer, C. Orsenigo i C. Vercellis. „Fault detection and diagnosis for rotating machinery: A model based on convolutional LSTM, Fast Fourier and continuous wavelet transforms“. W: *Computers in Industry* 125 (2021), s. 103378 (cyt. na s. 94).

- [111]R. Puchalski, A. Bondyra, W. Giernacki i Y. Zhang. „Actuator fault detection and isolation system for multirotor unmanned aerial vehicles“. W: *2022 26th International Conference on Methods and Models in Automation and Robotics (MMAR) (artykuł przyjęty do publikacji)*. 2022 (cyt. na s. 100, 136, 137, 152).
- [112]Y. Jiang, Z. Zhiyao, L. Haoxiang i Q. Quan. „Fault detection and identification for quadrotor based on airframe vibration signals: A data-driven method“. W: *2015 34th Chinese Control Conference (CCC)*. 2015, s. 6356–6361 (cyt. na s. 100).
- [113]A. Bondyra, P. Gasior, S. Gardecki i A. Kasiński. „Fault diagnosis and condition monitoring of UAV rotor using signal processing“. W: *2017 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*. 2017, s. 233–238 (cyt. na s. 100, 102, 152).
- [114]P. Refaeilzadeh, L. Tang i H. Liu. „Cross-Validation“. W: *Encyclopedia of Database Systems*. Boston, MA: Springer US, 2009, s. 532–538 (cyt. na s. 106).
- [115]S. Janitza i R. Hornung. „On the overestimation of random forest’s out-of-bag error“. W: *PloS one* 13.8 (2018), e0201904 (cyt. na s. 106).
- [116]L. Breiman. „Out-of-bag estimation“. W: (1996) (cyt. na s. 106).
- [117]M. Grandini, E. Bagli i G. Visani. „Metrics for multi-class classification: an overview“. W: *arXiv preprint arXiv:2008.05756* (2020) (cyt. na s. 107).
- [118]B. Hanczar i M. Nadif. „Controlling and Visualizing the Precision-Recall Trade-off for External Performance Indices“. W: *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. Springer. 2018, s. 687–702 (cyt. na s. 107).
- [119]D. M. Powers. „Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation“. W: *arXiv preprint arXiv:2010.16061* (2020) (cyt. na s. 107).
- [120]T. Hastie, R. Tibshirani, J. H. Friedman i J. H. Friedman. *The elements of statistical learning: data mining, inference, and prediction*. T. 2. Springer, 2009 (cyt. na s. 107, 129).
- [121]G. James, D. Witten, T. Hastie i R. Tibshirani. *An introduction to statistical learning*. T. 112. Springer, 2013 (cyt. na s. 129).
- [122]N. Ellis, S. J. Smith i C. R. Pitcher. „Gradient forests: calculating importance gradients on physical predictors“. W: *Ecology* 93.1 (2012), s. 156–168 (cyt. na s. 132).
- [123]C. Strobl, A.-L. Boulesteix, T. Kneib, T. Augustin i A. Zeileis. „Conditional variable importance for random forests“. W: *BMC bioinformatics* 9.1 (2008), s. 1–11 (cyt. na s. 132).

Strony WWW

[7]EASA, European Union Aviation Safety Agency. *Easy Access Rules for Unmanned Aircraft Systems*. 2021. URL: <https://www.easa.europa.eu/downloads/110913/en> (term. wiz. 9 czer. 2022) (cyt. na s. 1).

