

**Politechnika Śląska  
Wydział Mechaniczny Technologiczny  
Katedra Podstaw Konstrukcji Maszyn**

**Marek Fidali**

**Metody  
łącznej analizy sygnałów  
w wielokanałowych układach  
diagnozujących  
maszyn wirnikowych**

**Gliwice 2003**

*Recenzenci*

Prof. dr hab. inż. Wojciech Batko, Akademia Górniczo Hutnicza w Krakowie

Prof. dr hab. Wojciech Moczulski, Politechnika Śląska w Gliwicach

*Redaktor Zeszytów*

Wojciech Cholewa

*Redaktor językowy*

Ewa Opoka

*Redaktor techniczny*

Marek Wyleźoł

*Projekt okładki*

Wojciech Cholewa, Marek Wyleźoł

**ISBN 83–916957–1–9**

*Wydawca*

Katedra Podstaw Konstrukcji Maszyn

Wydział Mechaniczny Technologiczny

Politechnika Śląska

ul. Konarskiego 18a, 44-100 Gliwice

tel. (32) 237-14-67, fax (32) 237-13-60

<http://kpk.m.polsl.pl>

---

Druk i oprawa (z dostarczonych materiałów)

Drukarnia cyfrowa D&D sp. z o.o. ul. Moniuszki 6, 44-100 Gliwice

## Od autora

Zeszyt został opracowany na podstawie mojej pracy doktorskiej, wykonanej pod kierunkiem prof. dr. hab. inż. Wojciecha Cholewy. Publiczna obrona rozprawy odbyła się 15 kwietnia 2003 roku przed Komisją powołaną przez Radę Wydziału Mechanicznego Technologicznego. W opracowaniu zostały uwzględnione uwagi recenzentów rozprawy doktorskiej: prof. dr. hab. inż. Wojciecha Batki i prof. dr. hab. Wojciecha Moczulskiego.

Składam serdeczne podziękowania Józefowi Krzewińskiemu za pomoc przy przygotowaniu stanowiska badawczego, żonie Agnieszce i mojej rodzinie za wsparcie i wyrozumiałość, a także Koleżankom i Kolegom z Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej za okazaną mi pomoc i życzliwość w czasie wykonywania pracy. Szczególnie zaś dziękuję promotorowi prof. dr. hab. inż. Wojciechowi Cholewie za możliwość podjęcia i realizacji samodzielnych badań oraz cenne uwagi krytyczne.

*Gliwice, czerwiec 2003*

*Marek Fidali*

Część przeprowadzonych i opisanych w pracy badań realizowana była w ramach projektu promocyjnego KBN 7 T07B 00919 pod tytułem "Metody łącznej analizy sygnałów w wielokanałowych układach diagnozujących dla maszyn wirnikowych" oraz projektu KBN 8 T07B 02321 pod tytułem "Metody modelowania obiektów dla potrzeb diagnostyki technicznej", finansowanych przez Komitet Badań Naukowych.



# Spis treści

<b>Od autora</b> . . . . .	3
<b>Wykaz ważniejszych oznaczeń</b> . . . . .	9
<b>Rozdział 1. Wstęp</b> . . . . .	11
<b>Rozdział 2. Geneza pracy</b> . . . . .	13
2.1. Diagnostowanie stanu maszyn . . . . .	13
2.2. Łączna analiza sygnałów . . . . .	16
2.2.1. Łączna analiza dwóch sygnałów . . . . .	17
2.2.2. Możliwości łącznej analizy wielu sygnałów . . . . .	21
2.3. Opis problemu badawczego . . . . .	26
2.4. Cel pracy . . . . .	27
2.5. Tezy pracy . . . . .	28
2.6. Zakres pracy . . . . .	28
<b>Rozdział 3. Przedmiot badań</b> . . . . .	31
3.1. Powstawanie zjawisk wibroakustycznych w maszynie . . . . .	31
3.2. Czas w badaniach diagnostycznych . . . . .	32
3.3. Sygnały diagnostyczne . . . . .	33
3.3.1. Sygnały wibroakustyczne . . . . .	34
3.3.2. Sygnały towarzyszące . . . . .	35
3.4. Cechy sygnałów diagnostycznych . . . . .	35
3.4.1. Przekształcanie cech sygnałów . . . . .	36
3.4.2. Przestrzenie obrazów cech . . . . .	37
3.5. Model diagnostyczny maszyny . . . . .	37
3.5.1. Modele strukturalne . . . . .	38
3.5.2. Modele oparte na relacjach diagnostycznych . . . . .	39
3.6. Koncepcje procesu diagnostowania . . . . .	42
3.7. Środki wspomagające podejmowanie decyzji diagnostycznej . . . . .	45
3.7.1. Systemy doradcze . . . . .	45
3.7.2. Sztuczne sieci neuronowe . . . . .	46
3.7.3. Rozpoznawanie wzorców . . . . .	46
<b>Rozdział 4. Koncepcja łącznej analizy sygnałów</b> . . . . .	49

4.1.	Uogólnione okno danych . . . . .	49
4.1.1.	Wysokość okna danych . . . . .	51
4.1.2.	Szerokość okna danych . . . . .	51
4.1.3.	Głębokość okna danych . . . . .	52
4.2.	Analiza sygnałów . . . . .	53
4.2.1.	Zbiór rozpatrywanych sygnałów . . . . .	55
4.2.2.	Zbiór rozpatrywanych cech sygnałów . . . . .	58
4.2.3.	Optymalizacja przestrzeni wartości cech . . . . .	61
4.2.4.	Klasyfikacja stanu obiektu . . . . .	64
<b>Rozdział 5. Przykład zastosowania proponowanej koncepcji . . . . .</b>		<b>67</b>
5.1.	Opis zadania badawczego . . . . .	68
5.2.	Plan badań . . . . .	68
5.3.	Pozyskiwanie sygnałów diagnostycznych . . . . .	69
5.3.1.	Stanowisko badawcze . . . . .	69
5.3.2.	Zakres czynnego eksperymentu badawczego . . . . .	71
5.3.3.	Plan eksperymentu czynnego . . . . .	72
5.4.	Przykład zastosowania metody . . . . .	75
5.4.1.	Zbiór rozpatrywanych sygnałów . . . . .	75
5.4.2.	Zbiór rozpatrywanych cech sygnałów . . . . .	77
5.4.3.	Przestrzeń wartości cech sygnałów . . . . .	78
5.4.4.	Przestrzeń wartości cech głównych . . . . .	81
5.4.5.	Klasyfikacja stanu maszyny . . . . .	83
5.4.6.	Narzędzia wykorzystane do obliczeń . . . . .	84
5.5.	Ogólna charakterystyka przeprowadzonych badań . . . . .	84
5.6.	Wyniki analizy pojedynczych sygnałów . . . . .	86
5.7.	Wyniki łącznej analizy sygnałów . . . . .	92
5.7.1.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X}$ . . . . .	93
5.7.2.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{R}$ . . . . .	99
5.7.3.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{U}$ . . . . .	107
5.7.4.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{RU}\phi$ . . . . .	111
5.7.5.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X} \cup \mathbf{R}$ . . . . .	117
5.7.6.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X} \cup \mathbf{RU}\phi$ . . . . .	119
5.7.7.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{U} \cup \mathbf{RU}\phi$ . . . . .	121
5.7.8.	Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$ . . . . .	125

---

5.7.9. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X} \cup \mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$ . . . . .	127
5.8. Porównanie wyników klasyfikacji . . . . .	129
5.9. Trajektorie wartości cech głównych . . . . .	133
5.9.1. Uwagi ogólne . . . . .	142
<b>Rozdział 6. Uwagi końcowe i wnioski</b> . . . . .	<b>143</b>
6.1. Podsumowanie . . . . .	143
6.2. Wnioski wynikające z pracy . . . . .	143
6.2.1. Wnioski ogólne . . . . .	144
6.2.2. Wnioski szczegółowe . . . . .	145
6.3. Kierunki dalszych badań . . . . .	145
<b>Spis literatury</b> . . . . .	<b>146</b>
<b>Bibliografia</b> . . . . .	<b>147</b>
<b>Streszczenie</b> . . . . .	<b>158</b>





## Wykaz ważniejszych oznaczeń

$a_i$	$i$ -ty element wektora głównego
$\mathbf{a}$	macierz jednowierszowa lub jednokolumnowa
$\mathbf{A}$	macierz wielowymiarowa
$c$	klasyfikator
$\mathbf{d}$	wektor własny miary Fishera
$\varphi$	droga kąтова wału
$F$	miara Fishera
$g$	cecha główna
$G^m$	wielowymiarowa przestrzeń wartości cech głównych
$\mathbf{G}$	zbiór cech głównych
$j$	identyfikator chwili czasu "makro"
$k$	identyfikator numeru kanału pomiarowego
$K$	wysokość okna danych
$L$	głębokość okna danych
$m$	wymiar przestrzeni cech
$n$	wymiar ograniczonej przestrzeni cech głównych
$\mathbf{O}$	zbiór obiektów wytworzonych według wspólnej dla nich konstrukcji
$r(t)$	sygnał promienia trajektorii
$S_i$	$i$ -ty stan obiektu
$\mathbf{S}$	zbiór cech stan technicznego
$\xi$	czas rzeczywisty
$t$	czas "mikro"
$\theta$	czas "makro"
$\tau$	opóźnienie czasowe
$v$	cecha sygnału diagnostycznego
$V^m$	wielowymiarowa przestrzeń wartości cech
$\mathbf{V}$	zbiór cech sygnałów
$W$	wysokość okna danych
$x_k(t)$	sygnał rzeczywisty obserwowany w $k$ -tym kanale pomiarowym
$X(t, \theta)$	wielokanałowy sygnał diagnostyczny
$\mathbf{X}$	zbiór obserwowanych sygnałów diagnostycznych
$\mathbf{Y}$	zbiór dodatkowych sygnałów pomocniczych
$z(t)$	zespolony sygnał diagnostyczny, trajektoria drgań



## Rozdział 1

# Wstęp

Ciągły rozwój przemysłu, w tym takich kluczowych gałęzi gospodarki jak przemysł energetyczny czy petrochemiczny, wymusza potrzebę minimalizacji kosztów oraz zapewnienia ciągłości procesu produkcji energii elektrycznej, cieplnej oraz paliw. Jednym ze sposobów zaspokojenia powyższych potrzeb jest obniżanie kosztów eksploatacji, utrzymanie optymalnej sprawności i dyspozycyjności obiektów technicznych oraz wydłużenie czasu ich eksploatacji. Realizacja powyższych zadań możliwa jest m. in. dzięki stosowaniu metod diagnostyki technicznej, obejmujących zarówno zagadnienia diagnostyki maszyn jak i diagnostyki procesów przemysłowych [102, 40, 148]. Podstawowym celem stosowania metod diagnostycznych jest rozpoznawanie stanu obiektu technicznego (maszyny, urządzenia, procesu) na podstawie dostępnych informacji o tym obiekcie, co można rozpatrywać przez pryzmat działań mających na celu [180, 37, 38, 40, 132]:

- określanie bieżącego stanu technicznego obiektu (diagnozowanie),
- określanie przyczyn zaistnienia obecnego stanu obiektu (genezowanie),
- określanie horyzontu czasowego przyszłej zmiany stanu technicznego obiektu (prognozowanie).

Zadania diagnostyki technicznej mogą dotyczyć różnych klas obiektów. Znaczną grupę obiektów, biorących udział w procesie realizacji istotnych procesów wytwórczych, stanowią maszyny wirnikowe [141, 132, 37, 112], dlatego rozważania ograniczono do klasy obiektów będących maszynami wirnikowymi i w dalszej części pracy obiekt badań będzie nazywany maszyną. Dostępnym źródłem informacji o stanie maszyny są sygnały diagnostyczne. Spośród dużej liczby różnych sygnałów diagnostycznych na szczególną uwagę zasługują sygnały związane z występowaniem procesów resztkowych, towarzyszących w sposób nieodłączny i niezamierzony działaniu maszyny. Są to procesy termiczne, tarciove, elektryczne, a przede wszystkim wibroakustyczne, przejawiające się w postaci drgań, hałasu i pulsacji medium roboczego w maszynie. Procesy te można traktować w wielu przypadkach jako objaw lub determinantę zużycia maszyny, dlatego są one powszechnie wykorzystywane do pośredniej (bezdemontażowej) oceny stanu maszyn [38, 40, 131, 148, 102]. Badanie stanu maszyn (diagnozowanie) polega na detekcji, lokalizacji i identyfikacji uszkodzeń maszyny w wyniku zbierania, przetwarzania analizy oraz oceny sygnałów diagnostycznych. Diagnozowanie można realizować na różnym poziomie szczegółowości, uzyskując tym samym dokładną informację o uszkodzeniu lub określając jedynie ogólną klasę stanu maszyny. Obecnie proces diagnozowania maszyn realizowany jest na podstawie danych pochodzących z pomiarów dokonywanych okresowo przez operatorów maszyny lub w sposób ciągły przez rozmaite sys-

temy, pozwalające na monitorowanie, nadzór i zabezpieczanie procesu eksploatacji maszyny [2, 48, 5, 139, 140, 153, 26, 165]. Cechą wspólną wszystkich systemów jest to, że umożliwiają one rejestrację, przetwarzanie i analizę sygnałów jednocześnie w wielu kanałach pomiarowych. W stosowanych układach diagnozujących proces wnioskowania diagnostycznego dokonywany jest na podstawie relacji między cechami sygnałów diagnostycznych i cechami stanu maszyny [46, 37, 165]. W celu wyznaczenia cech sygnałów stosowane są różne metody analizy sygnałów [23, 21, 169, 161, 50, 42, 85, 30, 3, 29, 95, 110, 123, 60, 102, 20, 149]. Metody te pozwalają pozyskać cechy własne sygnałów w wyniku analizy pojedynczych sygnałów lub cechy wzajemne, w wyniku łącznej analizy dwóch sygnałów. Dostępne autorowi, dalej opisane, wyniki badań literaturowych wskazują, że wyznaczanie cech łącznych dwóch sygnałów pozwala na pozyskanie takich relacji diagnostycznych, których nie można byłoby pozyskać w wyniku analizy każdego sygnału z osobna. Stosowanie wzajemnych cech dwóch sygnałów diagnostycznych we wnioskowaniu diagnostycznym ma wiele zalet. Nasuwa się jednocześnie pytanie, w jakim stopniu cechy wzajemne większej liczby sygnałów (co najmniej trzech) mogą przyczynić się do poprawy procesu diagnozowania, a tym samym poprawy działania układów diagnozujących. W pracy opisano wyniki badań autora, zapoczątkowanych pod kierunkiem profesora Wojciecha Cholewy, mających na celu określenie metod łącznej analizy kilku (co najmniej trzech) sygnałów.

## Rozdział 2

# Geneza pracy

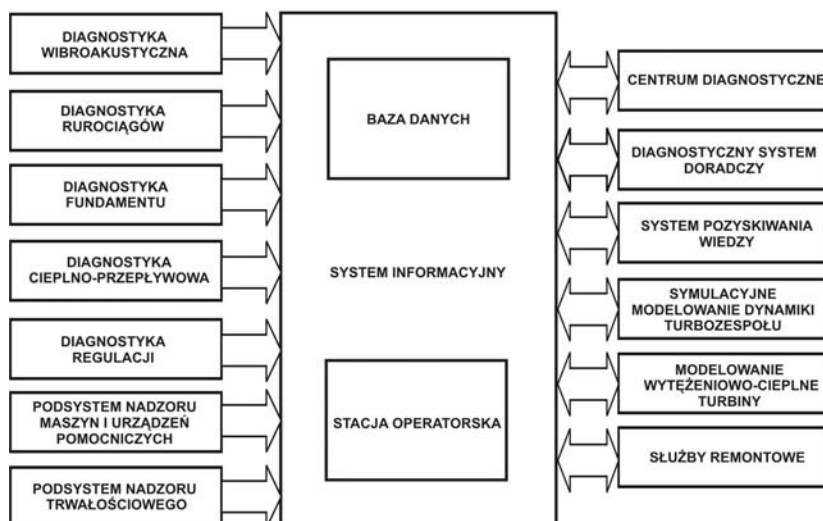
W rozdziale przedstawiono stan aktualnej wiedzy dotyczącej wybranych zagadnień diagnozowania maszyn wirnikowych oraz metod analizy sygnałów w stosowanych układach diagnostycznych. Wskazano zalety łącznej analizy dwóch sygnałów. Przeanalizowano możliwości łącznej analizy większej liczby sygnałów. Rozważania te stały się podstawą do sformułowania problemu badawczego, ustalenia celu, przedstawienia tez i zakresu pracy.

### 2.1. Diagnozowanie stanu maszyn

Od pewnego czasu można zaobserwować wzrost liczby zastosowań metod diagnostyki technicznej dla potrzeb przemysłowych pod postacią szeroko rozumianych systemów diagnostycznych. Na dynamikę wdrożeń systemów diagnostycznych mają wpływ liczne korzyści [165, 102] płynące m. in.:

- z obniżenia kosztów eksploatacji maszyn poprzez obniżenie ich kosztów remontów, nieprzewidzianych przestojów awaryjnych itp.,
- z podniesienia niezawodności i żywotności obiektu,
- ze zmniejszenia prawdopodobieństwa oddziaływania negatywnych skutków ewentualnych awarii na człowieka, środowisko naturalne, instalacje przemysłowe itp.

Aktualne rozwiązania systemów diagnostycznych często nazywane są systemami monitorowania, gdyż pozwalają na diagnozowanie obiektów w czasie rzeczywistym wraz z sygnalizacją i ewentualną graficzną wizualizacją stanu lub zmian stanu obiektu (maszyny, procesu). Ze względu na zastosowanie rozróżnia się systemy diagnostyczne dla procesów przemysłowych oraz systemy diagnostyczne (monitorowania) stanu maszyn. Bardzo często systemy te współdziałają. Przykładem mogą być rozwiązania systemów diagnostycznych procesu produkcji energii elektrycznej [2, 48]. Na tej podstawie można przedstawić (rys. 2.1) złożoność działań, jakie muszą być podejmowane w celu zabezpieczenia ciągłości produkcji energii elektrycznej. Bardzo ważną rolę (z punktu widzenia autora), z uwagi na funkcję pełnioną w przemyśle, odgrywają systemy monitorowania stanu maszyn (systemy diagnostyczne czasu rzeczywistego). Systemy te stanowią zespół elementów (sprzęt pomiarowy, oprogramowanie, komputery) niezbędnych do realizacji diagnostyki eksploatacyjnej maszyn i zbiór relacji (porównania i implikacji) między tymi elementami [180]. Charakterystykę współczesnych systemów monitorowania maszyn przedstawiono m. in. w [165, 102]. Wynika z niej, że w systemach tych największe znaczenie diagnostyczne ma analiza sygnałów, występujących jako drgania i hałas, emitowanych przez maszynę podczas jej działania. Na podstawie dostępnej autorowi

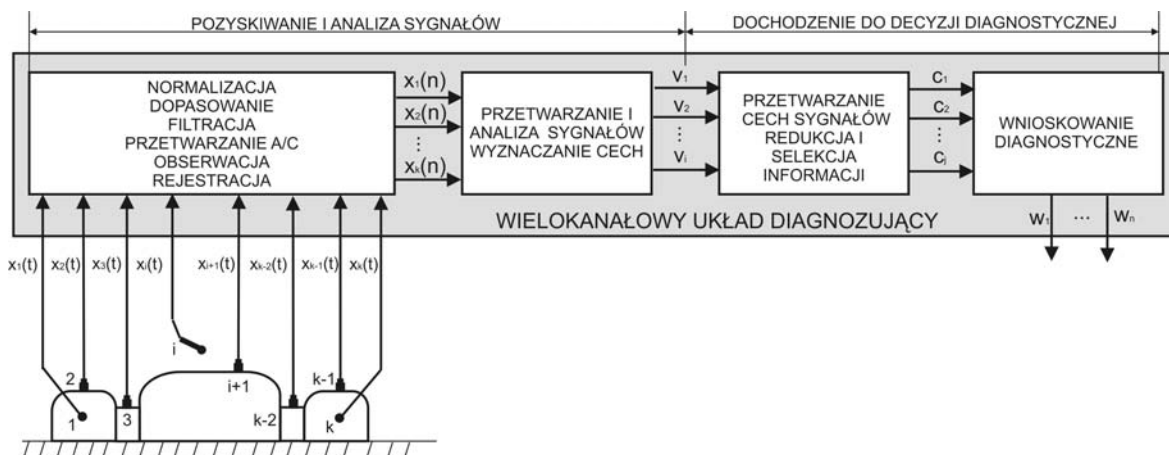


Rys. 2.1. Przykładowa struktura systemu diagnostycznego turbozespołu

dokumentacji różnych systemów monitorowania stanu maszyn [2, 48, 5, 139, 140, 153, 26, 31] ogólną strukturę takiego systemu można przedstawić w następujący sposób:

- układ czujników,
- układ kondycjonowania sygnałów,
- układ diagnozujący,
- układ komunikacyjny.

Z punktu widzenia diagnostyki najważniejsze znaczenie ma układ diagnozujący, który poprzez realizację szeregu działań pozwala na określenie stanu technicznego obiektu, tym samym zaspokajając potrzeby, np. bezawaryjnego działania obiektu wynikającą z obniżenia kosztów eksploatacji itp. (rys. 2.2).



Rys. 2.2. Zadania realizowane w układzie diagnozującym

Dla układu diagnozującego źródłem informacji o procesach zachodzących w maszynie wirnikowej podczas jej działania są sygnały wibroakustyczne odbierane przez przetworniki pomiarowe. Liczba, miejsce położenia i rodzaj przetwornika pomiarowego zależy od zidentyfikowanych własności i właściwości maszyny, planu eksperymentu, stosowanych urządzeń i technik pomiarowych itp. Jako przetworniki pomiarowe mogą być stosowane m. in. mikrofony umieszczane w pobliżu maszyny, czujniki drgań bezwzględnych montowane w wybranych punktach na korpusie maszyny, czujniki drgań względnych umieszczane w łożyskach ślizgowych maszyny i obserwujące bezpośrednio drgania wału [37], [39], [50], [112] oraz czujniki sygnałów pomocniczych, np. tachometryczne, będące źródłem informacji o prędkości obrotowej wału [7, 112, 50]. Podstawowym zadaniem układu diagnozującego jest detekcja, lokalizacja i identyfikacja uszkodzeń w wyniku równoległej obserwacji, rejestracji, przetwarzania i analizy odpowiednio przygotowanych sygnałów odbieranych przez  $k$  czujników rozmieszczonych w wybranych punktach pomiarowych danej maszyny. Powyższe zadania realizowane są w wielu kanałach pomiarowych jednocześnie, dlatego układ diagnozujący może być nazywany wielokanałowym układem diagnozującym.

W wielokanałowym układzie diagnozującym można wyróżnić dwie istotne grupy działań:

- działania mające na celu pozyskanie i analizę sygnałów,
- działania mające na celu wypracowanie decyzji diagnostycznej.

Pierwsza grupa działań polega na realizacji rozmaitych czynności wykonywanych na sygnałach pochodzących z czujników. Czynnościami tymi są: dopasowanie, normalizacja, konwersja analogowo-cyfrowa sygnałów. Następnie sygnały mogą zostać poddane obserwacji i/lub rejestracji, po czym — przetwarzaniu i analizie. Zadanie przetwarzania sygnałów obejmuje wybór i separację sygnałów użytecznych, filtrowanie, uśrednianie itp. Analiza sygnałów ma na celu wyznaczenie wartości ich cech w wyniku stosowania różnego rodzaju estymat. We współczesnych wielokanałowych układach diagnozujących analizie poddawane są pojedyncze sygnały oraz pary określonych sygnałów.

Czynności objęte drugą grupą działań, mających na celu wypracowanie decyzji diagnostycznej, polegają głównie na wydobyciu z cech sygnałów takiej informacji diagnostycznej, na podstawie której można w skuteczny sposób prowadzić wnioskowanie diagnostyczne [130]. Proces wnioskowania diagnostycznego może być prowadzony:

- z wykorzystaniem symptomów diagnostycznych, na podstawie których można zbudować zbiór relacji symptom – stan.
- z wykorzystaniem modeli, w tym przypadku możliwa jest budowa zbioru relacji stan – parametry modelu.

W procesie wnioskowania diagnostycznego rozpatruje się niezależnie cechy własne pojedynczych sygnałów lub wzajemne – dwóch sygnałów. Decyzja diagnostyczna może zostać podjęta w sposób półautomatyczny przez specjalistę, bądź zostać wypracowana w sposób automatyczny przez układy wnioskujące, wykorzystujące środki wspomagające, takie jak metody sztucznej inteligencji, metody predykcji i analizy ciągów czasowych, metody adaptacyjne, systemy doradcze itp. [130, 126, 44, 142, 103, 91, 28, 102]. Problem budowy i zastosowania modeli diagnostycznych obiektów ma szerokie odzwierciedlenie w dostępnej literaturze [47, 98, 49, 57, 62, 90, 145, 102, 130]. Dla większości znanych ocen sygnałów stosowanych w

praktycznych rozwiązaniach układów diagnozujących modele takie zostały wyznaczone i na tej podstawie określono klasy stanu obiektu [48, 97, 47, 98, 49]. Wyznaczanie i zastosowanie modeli jest bardzo istotne wówczas, gdy sygnały poddawane są analizie z zastosowaniem nowych metod analizy sygnałów, gdzie nie są znane relacje symptom–stan oraz klasy stanu.

## 2.2. Łączna analiza sygnałów

W wielokanałowym układzie diagnozującym podstawą niezbędną do określenia stanu maszyny jest zbiór cech sygnałów pozyskanych w wyniku analizy sygnałów diagnostycznych. U podstaw każdej ze stosowanych metod analizy sygnałów jest założenie modelu analizowanego sygnału. Przy wyborze metody analizy sygnałów można przyjmować [102] następujące modele sygnałów:

- modele uniwersalne – niezależne od badanego obiektu i obserwowanego sygnału. Metody ich identyfikacji (analizy) nazywane są metodami nieparametrycznymi.
- modele parametryczne (AR, MA, ARMA) – pozyskiwane z analizowanych danych bez potrzeby uwzględnienia informacji o badanym obiekcie. Metody ich identyfikacji nazywane są metodami parametrycznymi.
- modele uwzględniające własności obiektu. Identyfikacja takich modeli może być dokonywana z zastosowaniem zarówno metod nieparametrycznych jak i parametrycznych.
- modele uwzględniające działanie obiektu; są identyfikowane na podstawie np. analizy synchronicznej.

Aktualnie w analizie sygnałów realizowanej w wielokanałowych układach diagnozujących powszechnie stosuje się modele nieparametryczne. Stopień stosowania pozostałych modeli sygnałów zależy od specyfiki układu diagnozującego, jego budowy i zastosowania. Cechą wspólną stosowanych metod analizy sygnałów jest to, że głównie stosowane są one do pojedynczych sygnałów, czasami analizie poddawane są łącznie dwa sygnały. Do wyznaczania cech pojedynczych sygnałów diagnostycznych stosowane są powszechnie znane i szeroko opisane metody analizy [23, 21, 169, 161, 50, 42, 85, 30, 29, 95, 76, 123, 60, 132, 141, 149, 102, 20, 110] pozwalające na wyznaczenie cech punktowych (liczbowych) sygnału jak wartość średnia, wartość skuteczna, wartość szczytowa itp. oraz cech funkcyjnych, jak funkcja autokorelacji, widmo amplitudowe, widmo fazowe, funkcja koherencji, funkcja gęstości widmowej, cepstrum itp. Dużą popularnością w analizie pojedynczych sygnałów cieszą się również estymaty oparte na statystykach wyższych rzędów (poliwidma) [137, 138, 121, 55, 66, 159, 59, 152, 65, 120, 117, 155, 148, 164, 177, 9, 11, 54] i ocenach czasowo–częstotliwościowych [163, 77, 123, 108, 18, 20], jak np. przekształcenie Wignera–Ville’a, przekształcenie falkowe itp. Stosowane są również metody statystyczne wyznaczające histogramy sygnałów oraz pozwalające określić składowe główne sygnału (PCA) [23, 85, 102, 148].

Ocena łączna dwóch wybranych sygnałów realizowana jest przez stosowanie miar wzajemnych. Wiele publikacji dotyczących diagnostyki maszyn opisuje zastosowania estymat wzajemnych dwóch sygnałów [37, 50, 132, 149, 173, 51, 141, 40]. Wskazano na duże zalety i przydatność takiego sposobu analizy sygnałów dla określania stanu maszyn. Istnieje wiele sformalizowanych i dobrze opisanych metod pozwalających na wyznaczanie cech łącznych



dwóch sygnałów [23, 21, 38, 173, 87, 34, 106]. Do bardziej znanych, najczęściej wyznaczanych, cech łącznych dwóch sygnałów można zaliczyć:

- funkcję wzajemnej gęstości prawdopodobieństwa,
- funkcję korelacji wzajemnej,
- funkcję wzajemnej gęstości widmowej,
- funkcję koherencji,
- trajektorię, np. środka czopa,
- różnicę w przesunięciach fazowych sygnałów.

Stosowanie cech łącznych dwóch sygnałów umożliwia pozyskanie takiej informacji diagnostycznej, która nie jest możliwa do zdobycia w wyniku oceny każdego z analizowanych sygnałów z osobna. Taka sytuacja ma miejsce w przypadku np. wyznaczania trajektorii środka czopa, gdzie na podstawie kształtu trajektorii identyfikacja takiej niesprawności, jak np. przeciążenie [67, 173], jest łatwiejsza niż gdyby wyznaczano i analizowano osobno cechy każdego z sygnałów tworzących tę trajektorię. Poniżej opisano zastosowanie i wskazano zalety wymienionych estymat łącznych.

### 2.2.1. Łączna analiza dwóch sygnałów

#### Łączna gęstość prawdopodobieństwa

Łączna (dwuwymiarowa) gęstość prawdopodobieństwa dwóch sygnałów losowych określa prawdopodobieństwo tego, że oba sygnały w dowolnej chwili będą jednocześnie przybierały wartości w dwóch określonych przedziałach [23, 85, 21, 161, 133]. Głównym celem pomiaru łącznej gęstości prawdopodobieństwa jest opisanie pewnych wspólnych lub łącznych charakterystyk statystycznych dla zjawisk, które opisuje się dwiema realizacjami sygnałów związanymi ze sobą w pewien określony sposób. W pewnych przypadkach okazuje się niezbędne wyznaczenie związku między prawdopodobieństwem zajścia dwóch zdarzeń a prawdopodobieństwem zajścia jednego z nich. Do rozwiązania tego zagadnienia — określenia prawdopodobieństw warunkowych — niezbędna jest również znajomość łącznej gęstości prawdopodobieństwa. Łączna gęstość prawdopodobieństwa znalazła zastosowanie np. bezpośrednio do prognozowania zderzeń dwóch konstrukcji sprężystych, które drgają w sposób losowy, przy czym drgania te częściowo zależą wzajemnie od siebie [23]. Łączna gęstość prawdopodobieństwa znajduje również zastosowanie przy prognozowaniu rozkładu wartości szczytowych i wartości ekstremalnych dwóch procesów [23]. Prawa rozkładu dają stosunkowo pełną charakterystykę procesu stochastycznego, ale dla zastosowań praktycznych są one najczęściej zbyt skomplikowane [34] ze względu na trudności w interpretacji uzyskanych wyników.

#### Korelacja wzajemna

Funkcja korelacji wzajemnej dwóch sygnałów charakteryzuje wzajemną zależność wartości jednego sygnału od wartości drugiego sygnału, przesuniętego w czasie [23]. Najczęściej stosowana jest jako miara podobieństwa sygnałów w dziedzinie czasu, pozwalająca na stwierdzenie, w jakim stopniu sygnał obserwowany w jednym punkcie obiektu jest podobny do sygnału obserwowanego w innym punkcie tego samego obiektu w tym samym czasie. Ta

cecha funkcji korelacji wzajemnej dwóch sygnałów jest powszechnie stosowana w większości zagadnień związanych z analizą sygnałów [23, 21, 169, 161, 50, 85, 29, 123, 60, 149].

Szerokim polem zastosowania funkcji korelacji wzajemnej jest określanie czasu opóźnienia między dwoma sygnałami [87, 34, 106, 149]. Operacja ta potwierdza przydatność łącznej analizy sygnału, gdyż wyznaczenie czasu opóźnienia między dwoma sygnałami nie byłoby możliwe w razie osobnego analizowania tych sygnałów. Czas opóźnienia wyznaczony dzięki zastosowaniu korelacji wzajemnej stosowany jest w zagadnieniach lokalizacji źródła sygnałów, w tym hałasu [115, 87, 34] i różnego rodzaju zakłóceń. Przykładem może być problem lokalizacji przecieków w rurociągach [37], [106], gdzie miejsce przecieku wyznaczane było na podstawie m. in. pomiaru czasów opóźnień pomiędzy sygnałami pochodzącymi z odpowiednich par czujników. Innym przykładem może być problem lokalizacji niesprawnej maszyny, działającej w otoczeniu innych obiektów tej samej klasy [34]. Maszyna niesprawna jest źródłem sygnałów wibroakustycznych, o specyficznych cechach dla istniejącej niesprawności. Zastosowanie odpowiedniej metody pomiarowej za pomocą dwóch lub większej liczby mikrofonów pozwala na lokalizację obiektu odbiegającego stanem technicznym od pozostałych. Problem lokalizacji źródeł za pomocą metod korelacyjnych opartych na korelacji wzajemnej znalazł szerokie zastosowanie w innych dziedzinach nauki i techniki, jak oceanografia, radiolokacja, echolokacja, medycyna, czego potwierdzeniem może być bogata literatura [151, 167, 99, 12, 13, 79, 134]. Funkcja korelacji wzajemnej pozwala na wyznaczanie własności toru transmisji sygnału dzięki m. in. znajomości czasu opóźnienia między sygnałem wejściowym i wyjściowym. Ta właściwość znalazła zastosowanie w projektowaniu i ocenie własności tłumiących przegród akustycznych, identyfikacji rodzaju i własności ośrodka propagacji sygnałów itp. [37, 149, 34, 23]. Innym zagadnieniem, gdzie niezależna analiza pojedynczych sygnałów nie pozwoliłaby na uzyskanie zadowalających wyników, a funkcja korelacji wzajemnej jest powszechnie i efektywnie stosowana, jest zagadnienie wykrywania i odtwarzania sygnałów (również nieokresowych) ukrytych w szumie oraz problem poszukiwania ukrytych okresowości [23, 167, 149]. Przykładem mogą być m. in. zastosowania korelacji wzajemnej w diagnostyce medycznej. W celu wyodrębnienia sygnału pracy serca płodu ludzkiego, zakłóconego przez szумы wywoływane przez mięśnie, układ trawienny, a przede wszystkim maskowanego przez sygnał pracy serca matki, zastosowano analizę kilku sygnałów z zastosowaniem samodopasowującego się (adaptacyjnie) filtru Wienera [151, 167], którego działanie w głównej mierze oparte jest na wyznaczaniu macierzy korelacji wzajemnych sygnałów. Metody adaptacyjne mają podobne zastosowania w takich dziedzinach jak oceanografia, echo- i radiolokacja [167, 134, 79]. Innym przykładem zastosowania korelacji wzajemnej może być łączna analiza sygnałów dwuwymiarowych (czterech sygnałów diagnostycznych) pochodzących z dwóch węzłów łożyskowych, przy założeniu, że pary tych sygnałów reprezentowane są w postaci zespolonej [173, 70]. Omówione przykłady nie wyczerpują pola możliwych zastosowań korelacji wzajemnej [34, 87, 85], jednak potwierdzają zaletę i celowość stosowania łącznej analizy sygnałów, wskazując również na ważność tego typu analizy nad analizą pojedynczych sygnałów, oczywiście w pewnych, określonych przypadkach.

## Widma wzajemne

Wzajemna gęstość widmowa jest funkcją określającą właściwości probabilistyczne dwóch sygnałów w dziedzinie częstotliwości [50, 23, 149]. Funkcja wzajemnej gęstości widmowej wynika bezpośrednio z określenia funkcji korelacji wzajemnej i jest transformatą Fouriera tej funkcji [23]. Funkcja ta często stanowi podstawę do wyznaczania innych funkcji, ale ogólnie można powiedzieć, że moduł tej funkcji daje miarę stopnia skorelowania dwóch sygnałów w dziedzinie częstotliwości, natomiast argument (kąąt fazowy) jest miarą przesunięcia fazowego między składowymi dwóch sygnałów w funkcji częstotliwości. Funkcja wzajemnej gęstości widmowej jest określona dla wszystkich wartości częstotliwości (dodatnich i ujemnych) [149]. Funkcja ta, podobnie jak w przypadku korelacji, umożliwia wyznaczanie czasu opóźnienia sygnałów w funkcji częstotliwości [23]. Przykładem zastosowania tej funkcji może być metoda detekcji wycieku w rurociągach z zastosowaniem analizy widmowej [166]. Widma wzajemne dzięki związkowi łączącemu tę ocenę z charakterystykami badanych układów fizycznych znalazły szerokie zastosowanie do pomiarów transmitancji układów fizycznych, struktur mechanicznych itp. [23, 149, 37, 85, 80]. Szerokim polem zastosowania widma wzajemnego jest analiza modalna i np. problem wyznaczania częstości drgań własnych przez stosowanie testu impulsowego lub harmonicznego [80]. Identyfikacja własności struktury nie byłaby możliwa tylko i wyłącznie przez analizę pojedynczych sygnałów, konieczne jest do tego analizowanie łącznie dwóch sygnałów. Ważnym polem zastosowań widma wzajemnego jest ocena natężenia dźwięku w sytuacji, gdy rozpatrywane są dwa sygnały pochodzące z mikrofonów rozmieszczonych blisko siebie [149].

Wyznaczanie łącznej oceny widmowej zastosowano do analizy zespolonego sygnału dwuwymiarowego [172, 72], co bezpośrednio wskazuje na możliwość stosowania powszechnie znanej metody widm wzajemnych do oceny pary dwuwymiarowych sygnałów zespolonych (trajektorii). Cała gama różnorodnych aplikacji została opisana w licznych pozycjach literaturowych, jak np. [21, 23, 149, 37, 132].

## Koherencja wzajemna

Funkcja koherencji [50] jest miarą stopnia zależności liniowej między dwoma sygnałami w funkcji częstotliwości [149]. Dla przypadku idealnego układu liniowego o stałych parametrach, z jednym ściśle określonym sygnałem wejściowym i wyjściowym, funkcja koherencji jest równa jedności. Jeśli sygnały są całkowicie niezależne, to funkcja koherencji jest równa zeru. Jeśli funkcja koherencji jest większa od zera, ale mniejsza od jedności, to występuje co najmniej jeden z trzech możliwych przypadków [23]:

- wyniki pomiarów są obarczone błędem wynikającym z obecności szumów zewnętrznych,
- układ wiążący ze sobą sygnały jest nieliniowy,
- na wejściu układu poza obserwowanym sygnałem wejściowym występują inne nieznanne sygnały.

Funkcja koherencji (dla wszystkich częstotliwości) może być interpretowana jako część wartości średniokwadratowej sygnału wyjściowego pochodząca od składnika widma sygnału wejściowego [23].

Funkcja koherencji wzajemnej ma dobre własności diagnostyczne. Pojawienie się sygnału nowego uszkodzenia narusza spójność poprzednich, co powoduje, że funkcja koherencji maleje. Przykładem zastosowania tej funkcji może być ocena kontrolna łożysk tocznych [37, 36], gdzie do oceny luzów zastosowano dwa sygnały: siły wymuszającej oraz drgań odbieranych na bieżni zewnętrznej. Innym przykładem może być identyfikacja składowych widmowych związanych z częstotliwością obrotową wału na podstawie sygnałów drgań i sygnału tachometrycznego [149]. Ponieważ funkcja koherencji jest unormowaną funkcją wzajemnej gęstości widmowej, dlatego jest stosowana w badaniach i ocenie własności struktur mechanicznych [80]. Funkcję koherencji stosuje się również do obliczania stosunku sygnału do szumu [149]. Stosowane są również funkcje koherencji cząstkowej i koherencji wielokrotnej. Funkcja koherencji wielokrotnej pozwala na ocenę zależności między wieloma sygnałami na wejściu układów liniowych a sygnałem obserwowanym na wyjściu takiego układu [23]. Jak wskazują przykłady [37, 36, 23, 149], analiza pojedynczych sygnałów nie dałaby rezultatów takich, które można uzyskać w wyniku stosowania łącznej oceny dwóch sygnałów przez obliczanie funkcji koherencji.

## Trajektorie

Trajektoria jest krzywą opisującą tor ruchu punktu materialnego w prostokątnym układzie współrzędnych. Obserwacja trajektorii znajduje zastosowanie wszędzie tam, gdzie konieczne jest określenie położenia punktu na płaszczyźnie na podstawie jego współrzędnych. Zadanie takie realizuje się np. do wyznaczania przemieszczeń czubka wieży Eiffla. W maszynach wirnikowych wyznaczone są trajektorie ruchu środka czopa w łożysku ślizgowym na podstawie jednoczesnej obserwacji sygnałów drgań czopa w dwu wzajemnie prostopadłych kierunkach [173]. Sposób wyznaczania trajektorii jest bardzo prosty, ponieważ wystarczy do tego dwukanałowy oscyloskop z wejściem wyzwajającym. W diagnostyce wibroakustycznej stosowanie obserwacji trajektorii środka czopa jest jednym z bardziej rozpowszechnionych sposobów oceny stanu technicznego [48, 173, 26, 24, 51, 17]. Najczęściej trajektorie wyznaczone są w wyniku obserwacji drgań względnych z zastosowaniem czujników "wiroprądowych". W zależności od sposobu obserwacji sygnałów i ich własności mogą być wyznaczone trajektorie centralne, względne i/lub bezwzględne. Trajektorie stanowią pełny opis przemieszczeń wału w płaszczyźnie promieniowej, niemożliwy do otrzymania przy zastosowaniu jednego czujnika, ponieważ ocena sygnałów drgań względnych w jednym kierunku najczęściej wymaga założenia, że kierunek pomiaru pokrywa się z kierunkiem maksymalnych amplitud drgań wału [50, 37, 6, 8]. Kierunek ten trudno przewidzieć przed zainstalowaniem czujnika i może on zmienić się w czasie działania maszyny, co może być przyczyną niedokładności w ocenie stanu maszyny [173]. Trajektoria jest funkcją dwóch zmiennych, zatem można ją traktować jako sygnał dwuwymiarowy i poddawać go analizie z zastosowaniem znanych estymat sygnałów. Szersze rozważania dotyczące możliwości oceny sygnałów dwuwymiarowych i wyznaczania cech trajektorii środka czopa maszyny wirnikowej przeprowadzono w [173], gdzie również opisano sposób jej reprezentacji dla potrzeb diagnostycznych baz danych. Stwierdzono, że cech opisujących trajektorię środka czopa, takich jak kształt, kierunek obrotu, okresowość, nie można otrzymać w wyniku analizy składowych sygnałów jednowymiarowych [173]. Obser-

wacja i ocena kształtu trajektorii pozwala na wyznaczenie symptomów diagnostycznych, które trudno uzyskać na podstawie niezależnej analizy sygnałów składowych [173, 51]. Katalog relacji diagnostycznych z zastosowaniem trajektorii środka czopa przedstawiono w [67, 173, 51]. Stosowanie trajektorii, np. środka czopa, potwierdza zalety i celowość łącznej analizy sygnałów wibroakustycznych.

### Różnica faz

W układach diagnozujących dla maszyn wirnikowych wyznaczane i obserwowane są wektory drgań poszczególnych składowych sygnałów [48, 139, 140]. Położenie wektora określone jest w układzie biegunowym na podstawie amplitudy i wartości kąta przemieszczenia fazowego wybranych składowych harmonicznych sygnału drganiowego. Dysponując informacjami o wartościach kąta przemieszczenia fazowego wektora drgań w dwóch sąsiadujących ze sobą węzłach łożyskowych dla tej samej składowej harmonicznej, określa się różnicę przemieszczeń fazowych wektorów drgań. Informacja o tym, jaka jest różnica między kątami fazowymi wektorów drgań dla określonych składowych w sąsiadujących ze sobą węzłach łożyskowych, pozwala na ocenę stanu niewyważenia wirnika, jak również detekcji takich niesprawności jak rozosierzenie, zgięcie czy pęknięcie wału [38]. Obserwacja różnicy między kątami fazowymi jest istotna wtedy, gdy nadzór drganiowy jest prowadzony w czasie ciągłym, gdyż zmiany kąta fazowego w odniesieniu do wartości różnic zarejestrowanych na początku pomiarów pozwalają na wskazanie przyczyny tych zmian. W ten sposób można obserwować zmiany korozyjne w łopatkach wirników, gdyż ulega zmianie charakter niewyważenia. Charakterystyczna różnica wartości kątów fazowych dla niewyrównoważenia dynamicznego, momentowego, zgięcia wału odpowiada wartości około  $180^\circ$  [111, 112, 38, 37]. Informacja diagnostyczna, jaką można uzyskać w wyniku obserwacji różnicy kątów fazowych wektorów drgań dwóch sygnałów, nie mogłaby być zdobyta w wyniku analizy każdego z tych sygnałów z osobna. Potwierdza to zalety łącznej analizy dwóch sygnałów.

#### 2.2.2. Możliwości łącznej analizy wielu sygnałów

Zaletą łącznej analizy dwóch sygnałów jest to, że pozwala ona na pozyskanie cech łącznych, na podstawie których możliwe jest uzyskanie takich informacji, które nie mogłyby być zdobyte na podstawie cech otrzymanych w wyniku analizy każdego z tych sygnałów z osobna.

Z badań literaturowych przeprowadzonych przez autora wynika, że istnieje możliwość analizowania, a tym samym pozyskiwania, cech łącznych większej liczby sygnałów niż dwa. Należy dodać, że uzyskanie cechy łącznej może wiązać się z analizą cech własnych pojedynczych sygnałów [46, 52]. W łącznej analizie większej liczby sygnałów można zastosować rozwiązania oparte na:

- metodach uśredniania i sumowania,
- dostępnych ocenach łącznych,
- wyznaczaniu statystyk wyższych rzędów,
- metodach adaptacyjnych,
- sieciach neuronalnych,
- metodach parametrycznych,

— metodach rozpoznawania wzorców.

### **Rozwiązania oparte na metodach uśredniania i sumowania**

Najbardziej rozpowszechnionymi sposobami analizy łącznej sygnałów może być stosowanie uśredniania i/lub sumowania synchronicznego. W [37] przedstawiono przykład selekcji przestrzennej sygnału uderzeń tłoka o cylinder przez sumowanie (odejmowanie) par czterech sygnałów diagnostycznych z odpowiednią fazą. Działanie takie doprowadziło do selekcji istotnego, w dalszych badaniach, sygnału diagnostycznego. Opisane działania wskazują, że w pewnych określonych sytuacjach sumowanie (odejmowanie) sygnałów lub wybranych par sygnałów może pozwolić na wyznaczenie cech łącznych kilku sygnałów stosowanych do późniejszej analizy stanu maszyny. Ogólne zasady sumowania i uśredniania sygnałów opisane w m. in. [37, 5, 21, 125] wskazują na możliwość zastosowania tej techniki do analizy kilku sygnałów przez sumowanie synchroniczne w dziedzinie czasu oraz przez sumowanie kwadratów ich widm w dziedzinie częstotliwości. Sumowanie sygnałów ma swoje ograniczenia szczególnie wtedy, gdy sumowaniu poddawane są sygnały w dziedzinie czasu. Ograniczenia te wynikają z tego, że sygnały mają różne charakterystyki fazowe, co w przypadku sumowania w dziedzinie czasu może doprowadzić do otrzymania wartości cech fałszujących rzeczywisty stan diagnozowanego obiektu. Ocena stanu maszyny z zastosowaniem techniki sumowania powinna być prowadzona umiejętnie ze znajomością przebiegów fazowych poszczególnych sygnałów.

### **Rozwiązania oparte na dostępnych ocenach łącznych**

Rozpowszechnione metody łącznej analizy dwóch sygnałów mogą być źródłem cech łącznych. O metodach łącznej analizy dwóch sygnałów wspomniano w rozdziale 2.3, jednak warto zwrócić uwagę na metodę łącznej oceny dwóch sygnałów zespolonych (czterech sygnałów rzeczywistych) za pomocą funkcji korelacji wzajemnej oraz funkcji widma wzajemnego zaproponowanej w [173, 172]. Dzięki łącznej analizie sygnałów zespolonych możliwe jest wyznaczenie łącznych cech funkcyjnych np. w postaci przebiegu modułu i argumentu funkcji korelacji wzajemnej sygnałów zespolonych. Sposób wyznaczania tych cech i badania wstępne omówiono w [71, 173]. Wprawdzie metoda pozwala na ocenę sygnałów w obrębie dwóch węzłów łożyskowych, jednak w przypadku maszyn o większej liczbie podpór łożyskowych cechy łączne wyznaczone dla każdej pary węzłów łożyskowych można poddać dalszej analizie.

### **Rozwiązania oparte na wyznaczaniu statystyk wyższych rzędów**

Szerokim działem analizy sygnałów nieparametrycznych, pozwalającym na pozyskanie cech łącznych sygnałów, jest statystyczna analiza wyższych rzędów. Przez statystyki wyższych rzędów można rozumieć momenty wyższego rzędu [85, 68] i pewne nieliniowe kombinacje momentów zwane kumulantami. Z momentami i kumulantami wyższych rzędów bezpośrednio związana jest widmowa analiza wyższych rzędów obejmująca m. in. wyznaczenie widma wzajemnego trzeciego, czwartego rzędu i koherencji wzajemnej wyższych rzędów. Szerszy opis dotyczący statystycznej analizy wyższych rzędów można znaleźć m. in. w [159, 137, 138, 152, 55]. Omówiono tam m. in. właściwości i możliwości wykorzystania statystyk wyższych rzędów do analizy sygnałów. Wskazano na możliwości zastosowania statystyk wyższych rzędów do pozyskiwania informacji o zmianach i odchyleniach sygnału od

rozkładu gaussowskiego, oceny fazy sygnałów niegaussowskich, detekcji i opisu nieliniowych właściwości mechanizmów przez badanie zależności fazowych między składowymi harmonicznymi sygnałów generowanych przez te mechanizmy. Statystyki wyższych rzędów, jak również widma wyższych rzędów, znalazły szerokie zastosowanie w komunikacji, medycynie, geofizyce, analizie sygnałów radarowych i sonarowych, analizie sygnałów mowy, analizie obrazów i innych [159]. Metody oparte na statystykach wyższych rzędów stosowano również w diagnostyce maszyn [65, 120, 117, 155, 148, 9, 11, 54, 68]. W [135] opisano aplikację ocen wyższych rzędów do celów klasyfikacji stanu maszyny wirnikowej. Wyznaczano momenty wzajemne wyższych rzędów oraz widma wzajemne wyższych rzędów. Klasyfikacje przeprowadzono z zastosowaniem sieci neuronalnej. Wynika z tego, że cechy pozyskane w wyniku zastosowania ocen wyższych rzędów mogą również zostać poddawane dalszemu przetwarzaniu łącznemu. Dzięki możliwości tłumienia szumów o charakterystyce gaussowskiej statystyki wyższych rzędów znalazły również zastosowanie w oceanografii przy rozwiązywaniu problemu lokalizacji i śledzenia źródeł i celów na podstawie sygnałów pochodzących z macierzy czujników [134, 160]. Problem lokalizacji źródła sygnału, określania kierunku jego przybycia oraz śledzenia źródła sygnału w środowisku wodnym poruszono m. in. w [4, 92, 158]. Podobne metody stosowano m. in. w medycynie np. przy ocenie położenia źródeł sygnałów nerwowych w ludzkim mózgu [154].

Statystyki wyższych rzędów od pewnego czasu wykorzystuje się w rozwiązywaniu problemów tzw. „ślepej” separacji sygnałów oraz „ślepych” rozplataniu [107, 22]. „Ślepa” separacja źródeł sygnałów polega na odzyskaniu sygnałów pochodzących z nieznanymi źródeł zakłóconych i zniekształconych w nieznanym środowisku propagacji z sygnałów obserwowanych przez macierze czujników. Ten sposób podejścia do sygnału wielokanałowego stosuje się w wielu dziedzinach nauki, również w diagnostyce maszyn wirnikowych [78]. Istnieje bogata literatura opisująca ten sposób analizy [174, 41, 10, 175, 22]. „Ślepe” rozplatanie polega na rozwiązaniu zadania odwrotnego splotu, tzn. sygnały, które mogły ulec splotowi w pewnym środowisku, można odzyskać poprzez operację modelowania odwrotnej operacji splotu w stosunku do operacji splotu, jaka była wykonana w pewnym nieznanym środowisku propagacji. Tematyka ta została dokładniej omówiona m. in. w [78, 107, 32].

### **Rozwiązania oparte na metodach adaptacyjnych**

Liczne metody adaptacyjne oparte na teorii filtru Wienera [168] stwarzają możliwości analizy wielu sygnałów. Metody te na przestrzeni wielu lat znalazły bardzo szerokie zastosowanie w różnych dziedzinach nauki, m. in. w diagnostyce technicznej. Filtry adaptacyjne działają na zasadzie dyskretnego samodopasowania parametrów transmitancji filtra do zakłóceń w celu ich eliminacji. Genezy powstania, opisu zasady działania i szerokiego przeglądu zastosowań filtracji adaptacyjnej dokonano m. in. w [167, 151]. Wskazano tam na możliwości wykorzystania tego typu analizy do sygnałów pochodzących z wielu czujników. Potwierdzenie możliwości stosowania filtracji adaptacyjnej do analizy wielu sygnałów można znaleźć np. w [79, 171, 83, 176], gdzie opisano jej zastosowanie w badaniach lokalizacji i śledzenia ruchomych, słabych i zakłóconych źródeł sygnału pod wodą. Liczne badania potwierdziły przydatność metod adaptacyjnych do celów tłumienia zakłóceń sygnałów sonarowych i de-

tekcji celów podwodnych. Adaptacyjna analiza wielu sygnałów znalazła również zastosowanie w medycynie [12] do redukcji zakłóceń przydźwięku sieci energetycznej, przy wykonywaniu badań EKG, przy identyfikacji i badaniach EKG płodu w łonie matki [167] czy diagnostyce górnych dróg oddechowych. Metody bazujące na założeniach filtracji adaptacyjnej, pozwalające analizować wiele sygnałów równocześnie, wykorzystywane są w tzw. aktywnej kontroli wibracji i hałasu [75] która, ogólnie mówiąc, polega na tłumieniu niepożądanych sygnałów w taki sposób, że w odpowiednich miejscach drgającej struktury wymuszane są przez wzbudniki lub głośniki przebiegi o takich samych cechach, lecz odwrotnej fazie. Postępowanie takie prowadzi w prostych przypadkach do znoszenia się dwóch takich samych fal, których faza jest odwrócona. Zadanie aktywnej redukcji wibracji i hałasu jest zagadnieniem bardzo złożonym, realizowane jest przez układy sterujące, w których stosowane są zarówno metody adaptacyjne, jak również różne metody analizy sygnałów, w tym metody statystyczne wyższych rzędów. Wykorzystują one sygnały pochodzące z wielu czujników, na podstawie których budowane są modele parametryczne generujące sygnał lub sygnały sterujące wzbudnikami. Ten sposób analizy znalazł zastosowanie do redukcji niepożądanego hałasu lub drgań oddziaływających na człowieka, np. w kabinach pojazdów [56] lub w marynarce wojennej do redukcji zakłóceń własnych czujnika akustycznego torpedy [150]. Na podstawie badań własnych [69] można potwierdzić zalety metody adaptacyjnej do analizy sygnałów diagnostycznych, jednak należy zwrócić uwagę na to, że badania dotyczące możliwości zastosowania filtracji adaptacyjnej wymagają określenia sposobu wyboru lub wydzielenia sygnału podstawowego (odniesienia). Sygnał podstawowy powinien odzwierciedlać w sobie wszystkie składowe charakterystyczne dla sygnałów pochodzących z obiektu. Wydzielenie takiego sygnału powinno być wynikiem operacji matematycznej. Ponadto konieczne jest określenie kryterium jakości, według którego oceniane będą wyniki badań.

### **Rozwiązania oparte na sieciach neuronalnych**

W wielu przypadkach do łącznej analizy sygnałów można zastosować sztuczne sieci neuronowe. W m. in. [144, 90, 114, 122, 145, 14, 102] użyto sieci neuronalnych w przemyśle do wykrywania nieprawidłowości w procesach technologicznych i detekcji uszkodzeń w maszynach realizujących określony proces produkcyjny. Obserwacja i detekcja zmian stanu procesu produkcyjnego dokonywana była na podstawie sygnałów pochodzących z czujników rozmieszczonych w różnych punktach linii technologicznej. Były to na przykład sygnały dwustanowe zaworów, sygnały drgań, sygnały temperatury itp. Sieć wcześniej została „nauczona”, w jaki sposób wygląda charakterystyka poprawnie przebiegającego procesu produkcyjnego. Jeśli w procesie technologicznym pojawiły się jakieś nieprawidłowości i znalazły one odbicie w którymś z sygnałów wejściowych, wtedy w sygnale wyjściowym sieci obserwowano zmiany. Gdy nie posiada się parametrów niezbędnych do nauczania sieci poprawnego przyporządkowania symptomu do stanu, można wykorzystać sieci samouczące się, które potrafią uogólnić wiedzę na podstawie dostępnego zbioru sygnałów podawanych na wejścia sieci. Innym przykładem zastosowania sieci neuronalnych do łącznej analizy sygnałów jest diagnostyka medyczna, gdzie przetwarzano 16 sygnałów wielokanałowego elektroencefalografu do celów wykrywania impulsów nerwowych [99], w diagnostyce technicznej do redukcji szumów, identyfikacji i klasyfikacji



stanu maszyn, modelowaniu własności nieznanego liniowego obiektu dynamicznego [147], w zagadnieniach predykcji parametrów obiektów, czy też metodach adaptacyjnych, gdzie zadaniem sieci neuronalnej było nauczenie się nieliniowej funkcji opisującej dany obiekt (np. filtr).

### **Rozwiązania oparte na metodach parametrycznych**


W większości przypadków w wielokanałowych układach diagnozujących cechy sygnałów są wyznaczane z zastosowaniem ocen nieparametrycznych. Liczne metody modelowania systemów liniowych pozwoliły na pozyskiwanie parametrycznych cech sygnałów, w tym łącznych cech sygnałów. W przypadku tych metod mamy do czynienia z problemem opartym na identyfikacji parametrów modeli z zastosowaniem sygnałów pochodzących z obiektów rzeczywistych. Sposoby analizy sygnałów, w których stosuje się zbiory parametrów opisujących cechy stanu obiektu, związane są z metodami stosowanymi w identyfikacji parametrycznych modeli systemów i identyfikacji parametrycznych modeli sygnałów [27, 28, 157, 80, 113, 116, 94, 136, 147, 145, 109, 57, 102, 58]. Można tutaj wskazać np. metody oparte na modelu przyczynowo-skutkowym klasy "czarna skrzynka", wspomagane przez techniki adaptacyjne, sieci neuronalne itp. Stosuje się je w diagnostyce, m. in. w redukcji zakłóceń i hałasu. Zarówno metody adaptacyjne jak i sieci neuronalne znalazły zastosowanie w doborze parametrów modeli (np. ARX, ARMAX) [157, 57, 58, 148, 102], przy wyznaczaniu cech łącznych (np. model MISO wiele wejść jedno wyjście). Warunkiem koniecznym dla budowy modelu parametrycznego wyznaczającego estymatę łączną jest przyjęcie pewnej struktury modelu oraz odpowiednich parametrów wejściowych, wyjściowych i zakłócających modelu.

### **Rozwiązania oparte na metodach analizy wzorców**

Obiecującym narzędziem pozwalającym na łączną analizę wielu sygnałów może być przetwarzanie i rozpoznawanie wzorców, znane również pod nazwą rozpoznawania i analizy obrazów. Liczne publikacje dotyczące tego zagadnienia potwierdzają szerokie zastosowanie tych metod w wielu dziedzinach nauki [63, 156, 170, 88, 146], również w diagnostyce technicznej [101, 102, 43, 162, 15]. Metody rozpoznawania wzorców sprowadzają się głównie do rozwiązywania zadań klasyfikacji, a główną tego zaletą jest możliwość budowy narzędzi diagnostycznych bazujących na sygnałach cyfrowych dostępnych w wielokanałowym układzie diagnozującym. Na podstawie wielu sygnałów możliwa jest budowa wielowymiarowej przestrzeni obrazów sygnałów. Analiza i rozpoznawanie wzorców jest przydatna w określaniu relacji diagnostycznych między symptomami a niesprawnościami na podstawie założenia, że obrazy sygnałów pochodzących z obiektu pewnej klasy, znajdującego się w określonym stanie technicznym, są bliższe sobie niż obrazy sygnałów z tego obiektu w innych stanach (mimo błędów pomiarowych, wpływu czynników losowych itp.) [102]. Możliwość rozpatrywania obrazów sygnałów jako wielowymiarowych przestrzeni pozwala na zastosowanie metod rozpoznawania wzorców dla potrzeb łącznej analizy wielu sygnałów.

### 2.3. Opis problemu badawczego

Jak wskazano w rozdziale 2.2, w praktycznych zastosowaniach, do wyznaczania i detekcji stanu technicznego maszyn wirnikowych, stosowane są metody analizy pojedynczych sygnałów drganiowych lub ich wybranych par (rys. 2.3).




Rys. 2.3. Aktualnie stosowany sposób analizy sygnałów w wielokanałowym układzie diagnostycznym

Odpowiednio przetworzone i przedstawione wartości cech otrzymane w wyniku analizy każdego sygnału z osobna lub par sygnałów są dla specjalisty lub układu wnioskującego źródłem informacji o stanie maszyny i jego zmianach. W wielokanałowych układach diagnostycznych dla maszyn wirnikowych jednocześnie obserwowanych, przetwarzanych i analizowanych jest bardzo dużo sygnałów diagnostycznych. Są to zarówno sygnały wolnozmiennne jak i szybkozmiennne, do których należą sygnały wibroakustyczne. Ich liczba, np. w systemie *DT200* [48], waha się w granicach 300. Ten sam system umożliwia pozyskiwanie około 1000 cech sygnałów. Przy tak dużej liczbie sygnałów i ich cech pojawia się wiele problemów związanych m. in. z wyborem i prezentacją cech wartościowych, określeniem stanów granicznych dla poszczególnych cech, czytelną i przejrzystą prezentacją ich wartości dla operatorów systemu, reprezentacją dla potrzeb automatycznych systemów wnioskujących oraz sposobem zapisu i organizacją w diagnostycznych bazach danych. Pomimo tego, że problemy te częściowo są rozwiązywane, mogą być źródłem błędnych wniosków, pomyłek, które w konsekwencji mogą doprowadzić do fałszywych alarmów, niepotrzebnych zatrzymań procesów technologicznych, zbędnych remontów itd.

Dużym uproszczeniem w procesie wyznaczania czy też detekcji zmian stanu technicznego maszyny mogłoby być zastosowanie takiej metody analizy sygnałów, która umożliwiłaby redukcję liczby wyznaczanych cech do jednej lub kilku cech łącznych. Pozwoliłoby to na jednoznaczne opisanie modelu relacji symptom – stan i poprawną klasyfikację stanu technicznego przy niewielkich jego zmianach (rys. 2.4). Metoda taka mogłaby wspomóc nadzór maszyny, gdyż specjalista lub układ wnioskujący, zamiast analizy kilkunastu cech sygnałów, mogłoby analizować tylko jedną lub kilka cech. Pozyskanie cech łącznych umożliwiłoby redukcję zbioru cech, co wpłynęłoby korzystnie na jakość (nowe reguły wnioskowania) i szybkość realizowanego procesu wnioskowania diagnostycznego. Ograniczenie liczby cech miałyby również swój

wymiar ilościowy, szczególnie w odniesieniu do pojemności diagnostycznych baz danych—pojemność ta mogłaby ulec zwiększeniu. Należy dodać, że zastosowanie metody łącznej analizy sygnałów w warunkach przemysłowych wymagałoby przeprowadzenia licznych badań wstępnych z uwagi na możliwe trudności interpretacyjne uzyskanych cech łącznych.



Rys. 2.4. Proponowany sposób łącznej analizy sygnałów w wielokanałowym układzie diagnostycznym

Wcześniej przeprowadzone rozważania (por. rozdz. 2.2) wskazują jednoznacznie, że analiza par sygnałów prowadzi do pozyskania nowej informacji diagnostycznej i może mieć wiele zalet przy określeniu stanu technicznego i jego zmian na podstawie ograniczonej liczby przesłanek. Postępowanie takie można porównać do działania takich zmysłów ludzkich jak słuch lub wzrok. Widzenie jednym okiem nie pozwala na pozyskanie informacji o przestrzeni, podobnie jak słyszenie jednym uchem nie umożliwia lokalizacji źródła dźwięku. Bazując na idei działania ludzkich zmysłów i zaletach łącznej analizy dwóch sygnałów, można przypuszczać, że łączna analiza wielu sygnałów pozwoli na wydobycie oryginalnej i nowej z punktu widzenia diagnostyki informacji przydatnej w procesie wnioskowania diagnostycznego. Problemem badawczym, z jakim autor w dalszej części pracy starał się uporać, było poszukiwanie i określenie metod pozwalających na łączne analizowanie wielu sygnałów oraz określenie, czy i do jakiego stopnia postępowanie takie może okazać się przydatne w procesie wnioskowania diagnostycznego.

## 2.4. Cel pracy

Celem badań było opracowanie metod łącznej analizy sygnałów wibroakustycznych i/lub ich cech obserwowanych podczas działania maszyny wirnikowej w wielu kanałach jednocześnie. Założono, że liczba sygnałów przyjętych do analizy nie powinna być mniejsza od trzech. Przyjęto, że opracowywane metody powinny znaleźć zastosowanie w wielokanałowym układzie diagnostycznym dla maszyn wirnikowych, umożliwiając poprawną klasyfikację stanu technicznego maszyny oraz detekcję zmian stanu technicznego, ze szczególnym uwzględnieniem zmian, które nie mogą być wykryte przez stosowanie konwencjonalnych metod analizy sygnałów.

## 2.5. Tezy pracy

1. Klasyfikatory diagnostyczne stosujące łączne cechy wielokanałowych sygnałów diagnostycznych mogą posiadać sprawność większą od klasyfikatorów uwzględniających wartości cech sygnałów wyznaczanych oddzielnie w każdym kanale lub parze kanałów.
2. Możliwe jest określenie metody postępowania, pozwalającej na systematyczne, nieuwarunkowane jedynie intuicją badacza, poszukiwanie definicji odpowiednich łącznych cech sygnałów wielokanałowych.

## 2.6. Zakres pracy

Praca obejmuje opis koncepcji łącznej analizy sygnałów oraz przykład zastosowania metody łącznej analizy sygnałów opracowanej na podstawie zaproponowanej koncepcji. Treść pracy zawarto w sześciu rozdziałach. Rozdział pierwszy zawiera wstęp do pracy, w którym ogólnie przedstawiono zagadnienia diagnostyki technicznej maszyn.

W rozdziale drugim zawarto opis aktualnie stosowanych rozwiązań w zakresie diagnozowania i nadzoru maszyn wirnikowych o szczególnym znaczeniu dla utrzymania istotnych gospodarczo procesów przemysłowych. Opisano budowę i zasadę działania wielokanałowych układów diagnozujących dla maszyn wirnikowych oraz metody analizy sygnałów stosowane w tych układach. Przy omawianiu metod analizy sygnałów szczególny nacisk położono na metody łącznej analizy sygnałów, tym samym dokonując przeglądu powszechnie znanych rozwiązań pozwalających na analizę dwóch sygnałów. Omówiono stan aktualnie istniejącej wiedzy dotyczącej łącznej analizy większej liczby sygnałów niż dwa. Na podstawie przeglądu stanu aktualnej wiedzy sformułowano problem badawczy oraz tezy pracy.

Rozdział trzeci zawiera opis pojęć i zagadnień składających się na przedmiot badań. Omówiono pojęcia dotyczące zjawisk powstających podczas działania maszyn wirnikowych. Zdefiniowano pojęcia czasu, sygnału, cechy oraz modelu maszyny. Przedstawiono aktualnie stosowane koncepcje diagnozowania stanu maszyn oraz narzędzia wspomagające proces podejmowania decyzji diagnostycznej.

Rozdział czwarty zawiera opis proponowanej koncepcji łącznej analizy sygnałów. Zdefiniowano i opisano w nim zaproponowane przez autora pojęcie uogólnionego okna danych, które stanowi podstawę do dalszych działań w zakresie łącznej analizy sygnałów. W celu wyznaczenia przestrzeni wartości cech, zawierającej informacje o wzajemnych zależnościach między sygnałami obserwowanymi podczas działania maszyny wirnikowej zdefiniowano pojęcie dodatkowego sygnału pomocniczego. Sygnały te będą stosowane w procesie diagnozowania stanu technicznego. Przedstawiono całą metodykę postępowania prowadzącą do określenia stanu technicznego na podstawie łącznej analizy sygnałów. Wskazano ogólne zasady postępowania przy określaniu zbioru rozpatrywanych sygnałów, zbioru rozpatrywanych cech, sposobu przekształcania przestrzeni wartości cech do ograniczonej przestrzeni wartości cech głównych oraz metody klasyfikacji stanu obiektu.

W rozdziale piątym omówiono szczegółowo metodę postępowania, którą przyjął autor w celu określania stanu technicznego obiektu na podstawie łącznej analizy sygnałów. Sfor-

mułowano zadanie badawcze, opisano plan proponowanego eksperymentu czynnego. Opisano sposób przeprowadzenia czynnego eksperymentu oraz scharakteryzowano zbiór danych uczących pozyskany w wyniku przeprowadzenia eksperymentu. Przedstawiono i opisano przykładowe wyniki badań. W ramach analizy wyników badań dokonano porównania rezultatów uzyskanych w wyniku łącznej analizy sygnałów oraz w wyniku niezależnej analizy każdego z obserwowanych sygnałów. Rezultaty badań zobrazowano licznymi wykresami i tabelami.

Rozdział szósty zawiera podsumowanie i wnioski płynące z przeprowadzonych badań i dotyczące przedstawionych tez pracy.



## Rozdział 3

# Przedmiot badań

### 3.1. Powstawanie zjawisk wibroakustycznych w maszynie

Wiedza o własnościach i właściwościach obiektu badań stanowi podstawę do określenia i zastosowania odpowiednich metod przetwarzania i analizy sygnałów wibroakustycznych. W celu zidentyfikowania relacji diagnostycznych między cechami sygnałów diagnostycznych i cechami stanu maszyny konieczne jest poznanie działania, struktury i otoczenia obiektu oraz mechanizmu generacji i propagacji zjawisk wibroakustycznych.

Przyjęto, że rozpatrywanym obiektem badań będzie  $j$ -ta maszyna wirnikowa  $o_j$  będąca elementem zbioru  $\mathbf{O}$  maszyn wirnikowych wytworzonych według wspólnej dla nich konstrukcji.

Powstawanie zjawisk dynamicznych, a w szczególności drgań w maszynie wirnikowej podczas jej działania w warunkach ustalonych, opisuje m. in. zaproponowany w [38] tribologiczny model generacji i propagacji zjawisk wibroakustycznych w maszynie. W modelu tym przyjęto, że podczas działania maszyny generowany jest pewien sygnał charakterystyczny  $\chi_i(t, \theta)$  związany z wystąpieniem zdarzenia elementarnego, np. obrotu wału maszyny. Sygnał ten jest sygnałem zdeterminowanym – poliharmonicznym, zakłóconym przez szum losowy  $n_i(\cdot)$ . Podczas działania maszyny sygnał charakterystyczny przekształcany jest przez tzw. transformację kinematyczną na sygnał ciągły  $f(t, \theta)$ , który wzbudza drgania otaczających systemów mechanoakustycznych tak, że sygnały drgań  $x_k(t, \theta)$  mierzone przez czujniki są w najprostszym przypadku odpowiedziami układów dynamicznych o charakterystyce impulsowej  $h(t, \theta)$ . Procesy drganiowe mają wpływ na intensywność procesu zużycia i, co za tym idzie, na stan techniczny maszyny przez istnienie sprzężenia zwrotnego. Niekorzystne oddziaływanie zwrotne ujawnia się powolną zmianą amplitudy i kształtu procesu pierwotnego  $\chi_i(t, \theta)$ .

Przedstawiony model w ogólnym przypadku jest prawdziwy, lecz nie zawsze jest tak prosty. W maszynach wirnikowych istnieje wiele źródeł sygnałów charakterystycznych, do których należą m. in.: siły odśrodkowe niewyważonych mas wirnika; momenty giroskopowe skośnie osadzonych tarcz łopatkowych; tarcie wewnętrzne (materiałowe i/lub konstrukcyjne); anizotropowe własności sprężyste wału (zwłaszcza generatora); siły hydrodynamiczne, powstające w warstwie oleju (w łożysku ślizgowym) lub w innej cieczy wypełniającej uszczelnienia; siły aerodynamiczne (cyrkulacyjne) wynikające z przepływu czynnika roboczego przez nierównomierną szczelinę promieniową między zukosowaną tarczą łopatkową i osłoną; anizotropowe własności sprężyste łożysk i podpór; niejednorodne pole elektromagnetyczne w gene-

ratorze powstające wskutek wirowania niewspółosiowo osadzonego wirnika względem statora. Przy czym trzy pierwsze wymienione przyczyny wzbudzają drgania synchroniczne z obrotami wirnika, siły hydro- i aerodynamiczne są odpowiedzialne za drgania samowzбудne, natomiast anizotropia zewnętrzna, podobnie jak wewnętrzna, powoduje drgania parametryczne [37, 84, 143].

Każde ze zdarzeń eksploatacyjnych zachodzących podczas działania maszyny ma wpływ na trwałe lub okresowe zmiany dynamiki części lub całej maszyny. Jeśli są one wykrywane w procesie diagnozowania i powodują bezpośrednio lub pośrednio zagrożenie pogorszenia jakości działania maszyny, uznaje się je za niesprawności. Większość niesprawności pojawiających się w maszynach wirnikowych dotyczy układu wirnik – łożyska – podpory łożyskowe – fundament [37] oraz układu przepływu mediów [1, 37] i mogą być nazwane cechami wewnętrznych oddziaływań w obiekcie. Opierając się na modelu generacji zjawisk wibroakustycznych w maszynie wirnikowej i na dostępnej literaturze [1, 112, 67, 38, 124, 19], za typowe niesprawności maszyn wirnikowych uznaje się:

- nadmierne niewyrównoważenie,
- nadmierne przeciążenie,
- przycieranie części zespołu wirnika o części korpusu,
- pęknięcia elementów wirujących,
- niestabilności działania łożysk hydrodynamicznych,

Poza wyżej wymienionymi niesprawnościami istnieje wiele innych, np. luzy w posadowieniu obiektu na fundamencie, wygięcia wału, spowodowane błędami w montażu oraz eksploatacji obiektu [112]. Wymienione niesprawności mogą się "kumulować", tzn. występować razem w tym samym czasie, np. niewyważenie i przycieranie itp, tym samym powodując występowanie złożonych stanów obiektu. Pojawienie się niesprawności wywołuje zmianę stanu maszyny. Stan maszyny można rozumieć jako zbiór własności  $\mathbf{W}$  przysługujących jej w danej chwili, koniecznych i wystarczających do zidentyfikowania jej w tej chwili [43]. Własności maszyny rozpatrywane są jako procesy stochastyczne  $w(t, \theta)$ , zatem stan maszyny  $S(t, \theta)$  i jego zmiany opisywane są w dziedzinie czasu.

### 3.2. Czas w badaniach diagnostycznych

Zwykle pod pojęciem czasu rozumiemy czas zegarowy (tzw. czas "rzeczywisty"  $\xi$ ), który może być reprezentowany przez zbiór liniowo uporządkowanych chwil. Dla potrzeb badań diagnostycznych wprowadzono [46] rozróżnienie dziedzin czasu na:

- czas "makro"  $\theta$  - nazywany czasem "życia" obiektu opisujący historię zmian stanu technicznego obiektu w postaci wartości związanych z liczbą godzin, dni, miesięcy lub lat;
- czas "mikro"  $t$  - określony przez chwilę czasu, w której rozpatrywany proces (np. mierzony sygnał drgań) uznawany jest za stacjonarny [46], [50]. Czas "mikro" nazywany jest czasem dynamicznym [37] i określany przez wartości podawane np. w milisekundach.

W diagnostyce maszyn wirnikowych wykorzystywane są dwa zbiory czasu "mikro": czas zegarowy  $t$  oraz zbiór, którego elementami są chwilowe wartości drogi kątowej wału  $\varphi$  określone w radianach i mierzone od pewnego wyróżnionego położenia wału [173]. Podczas działania



maszyny wirnikowej droga kątowna czopa jest monotonicznie rosnącą funkcją czasu zegarowego. Oznacza to, że dla wirującego wału czas zegarowy może być zapisany jako monotonicznie rosnąca funkcja drogi kątownej czopa  $t(\varphi)$ . Droga kątowna może być również zapisana jako monotonicznie rosnąca funkcja czasu zegarowego  $\varphi(t)$ . Ze względu na chwilowe zmiany prędkości wirowania wału odwzorowania  $t(\varphi)$  i  $\varphi(t)$  nie są odwzorowaniami liniowymi.

W praktyce diagnostycznej nie jest możliwa ciągła obserwacja badanych wielkości, dlatego zbiór czasu "makro" definiowany jest jako ciąg chwil czasu. Za [43] można przyjąć, że chwile czasu "mikro" i "makro" mogą być elementami różnych zbiorów.

Zakłada się, że rozpatrywany będzie zbiór wartości sygnałów drgań rejestrowanych w dziedzinie chwil czasu "mikro" i w dziedzinie chwil czasu "makro".

### 3.3. Sygnały diagnostyczne

Źródłem informacji przydatnych w diagnozowaniu stanu maszyny podczas jej działania są procesy w niej zachodzące. Dzięki obserwacji diagnozowanego obiektu informacje związane z określonymi procesami docierają do obserwatora różnymi drogami, które można nazwać również kanałami informacyjnymi. Nośnikiem tych informacji jest sygnał diagnostyczny<sup>1</sup> rozumiany jako dowolny materialny nośnik, najczęściej przebieg pewnej wielkości fizycznej, umożliwiający przenoszenie wiadomości o stanie obserwowanego obiektu lub procesu w czasie [37, 102]. Jeśli informacje o zachodzących w maszynie procesach docierają do obserwatora różnymi kanałami, można mówić, że mamy do czynienia z sygnałem wielokanałowym. Aby możliwe było zastosowanie do diagnozowania informacji zawartej w sygnale, konieczne jest przyjęcie pewnej jego reprezentacji. Sygnał może być reprezentowany przez wartości cech będące wynikiem jego analizy. Wartości cech w pewnych określonych przypadkach mogą być nazywane symptomami diagnostycznymi, jeśli świadczą one o wystąpieniu określonego typu uszkodzenia. Ponieważ własności maszyn są procesami stochastycznym, zatem sygnał  $f$  obserwowany podczas działania maszyny można opisać za pomocą jednowymiarowego procesu losowego,

$$f : (t, \theta) \rightarrow x \in \mathbf{R} \quad (3.1)$$

lub przez wielowymiarowy proces stochastyczny.

$$f^k(t, \theta) \rightarrow X \in \mathbf{R}^k \quad (3.2)$$

gdzie:

$t$  – czas "mikro",

<sup>1</sup> W diagnostyce procesów przemysłowych sygnał diagnostyczny często jest rozumiany jako sygnał wyznaczany na podstawie pewnych zmiennych procesowych będących bezpośrednio mierzonymi wartościami cech sygnałów, wartościami wyliczonymi na podstawie innych wartości będących wynikiem pomiaru itp. Ponieważ zmienne procesowe obejmują informację o warunkach działania obiektu, wszystkie sygnały dotyczące oddziaływania obiektu z otoczeniem mogą być traktowane jako sygnały diagnostyczne. Aby przyjąć pewien zakres uogólnienia, w pracy skupiono się tylko na pewnym rodzaju sygnałów diagnostycznych, którymi są sygnały wibroakustyczne.

$\theta$  – czas "makro",

$k$  – liczba kanałów pomiarowych  $k = 1, 2, \dots, K$ ,

$\mathbf{R}$  – zbiór liczb rzeczywistych.

Jak wspomniano wcześniej (por. rozdz. 2.2), w wielokanałowych układach diagnozujących dla maszyn wirnikowych jednocześnie obserwowanych i/lub rejestrowanych jest wiele sygnałów diagnostycznych we wspólnym czasie "mikro"  $t$  i czasie "makro"  $\theta$  w różnych kanałach pomiarowych. Sygnały te można potraktować jako elementy pewnego zbioru  $\mathbf{X}$  sygnałów obserwowanych, których wartości wyznaczono w tych samych chwilach czasu i nazwać wielokanałowym sygnałem diagnostycznym. Dla celów dalszych rozważań wygodnie jest przyjąć macierzową reprezentację wielokanałowego sygnału diagnostycznego opisującą zbiór sygnałów obserwowanych  $\mathbf{X}$  podczas działania określonej maszyny wirnikowej:

$$X(t, \theta) = [x_1(t, \theta), x_2(t, \theta), \dots, x_K(t, \theta)]^T \quad (3.3)$$

Obecnie analiza sygnałów prowadzona jest najczęściej z zastosowaniem technik cyfrowych. Dla potrzeb tych technik można przyjmować, że praktycznie całą informację źródłową zawartą w ciągłym sygnale można przekazać za pomocą ciągu wartości chwilowych [161]. Zakładamy, że sygnał diagnostyczny poddawany analizie jest sygnałem cyfrowym określonym w dyskretnych chwilach czasu i przyjmującym wartości z pewnego określonego zbioru. Sygnał wielokanałowy może uwzględniać różnego rodzaju sygnały diagnostyczne, m.in. sygnały wibroakustyczne, które były podstawą do dalszych rozważań.

### 3.3.1. Sygnały wibroakustyczne

Sygnały wibroakustyczne pochodzą z  $k : k = 1, 2, \dots, K$  czujników umieszczonych w określonych punktach maszyny lub w jej otoczeniu. Można rozpatrywać m.in. sygnały hałasowe obserwowane przez mikrofony, sygnały drgań obserwowane przez przetworniki pomiarowe do pomiaru przemieszczeń, prędkości i przyspieszeń drgań [50, 112, 37, 31]. Najczęściej stosowanymi przetwornikami drgań są akcelerometry i czujniki przemieszczeń drgań względnych [48, 5, 139, 140, 153, 26, 31]. Stosowanie układów różniczkujących lub całkujących w procesie wstępnego przetwarzania sygnałów umożliwia w łatwy sposób konwersję pomiędzy mierzonymi wielkościami.

Bardzo często w maszynach wirnikowych obserwuje się trajektorie drgań środka czopa [26, 48, 173, 24], przez układy czujników przemieszczeń względnych montowanych w łożyskach w jednej płaszczyźnie promieniowej, w dwóch wzajemnie prostopadłych kierunkach. (rys.3.1a)

Taki sposób obserwacji pozwala na rozpatrywanie trajektorii środka czopa jako sygnału zespolonego  $z(t, \theta)$  [173] np.:


$$z_l(t, \theta) = x_{lx}(t, \theta) + jx_{ly}(t, \theta) \quad (3.4)$$

gdzie:

$z_l(t, \theta)$  – sygnał zespolony obserwowany w  $l$ -tej podporze łożyskowej,

$x_{lx}(t, \theta)$  – sygnał obserwowany w  $l$ -tej podporze łożyskowej w kierunku promieniowym  $x$ ,

$x_{ly}(t, \theta)$  – sygnał obserwowany w  $l$ -tej podporze łożyskowej w kierunku promieniowym  $y$ .



Rys. 3.1. Sposób obserwacji środka czopa (a) i reprezentacja trajektorii w postaci sygnału zespolonego (b)

Podójście takie oparte jest na wzajemnie jednoznacznym podobieństwie między uporządkowanymi parami współrzędnych kartezjańskich punktów, którymi opisywana jest trajektoria, a liczbami zespolonymi (rys. 3.1b), opisywanymi na płaszczyźnie zespolonej.

Własności sygnałów zespolonych opisane zostały m. in. w [161, 173, 81].

### 3.3.2. Sygnały towarzyszące

W badaniach maszyn wirnikowych i w procesie analizy sygnałów wibroakustycznych istotną rolę spełniają sygnały, na podstawie których można dokonać identyfikacji:

- wyróżnionego położenia kąтового wału wirnika;
- wyróżnionych  $N \gg 1$  położen kątowych wału;
- chwilowej prędkości obrotowej wirnika.

Sygnały takie, w zależności od zastosowania, nazywa się sygnałami tachometrycznymi, synchronizującymi, wyzwalającymi lub strobuującymi.

W większości układów diagnozujących dla maszyn wirnikowych sygnały takie są obserwowane i otrzymuje się je w wyniku stosowania specjalnych układów pomiarowych, np. czujnika optycznego lub magnetycznego, współdziałającego ze specjalnym znacznikiem (lub znacznikami), umieszczonym na powierzchni wirującego wału, enkoderów optycznych połączonych z wirującym wałem lub prądnic tachometrycznych. W zależności od stosowanego rozwiązania układy takie w literaturze nazywane są znacznikami fazy ("keyphasor") [24] lub układami tachometrycznymi [50, 124]. Sposoby pozyskiwania i generacji tego typu sygnałów są opisane w literaturze [7, 24, 25].

## 3.4. Cechy sygnałów diagnostycznych

Sygnał diagnostyczny opisywany jest za pomocą cech, przy czym na ogół tylko niektóre z nich niosą istotne informacje diagnostyczne. Są to tzw. czynne cechy sygnału [50] i tworzą one pewien skończony zbiór cech  $\mathbf{V}$ , który może być wyznaczony na podstawie zbioru sygnałów  $\mathbf{X}$

obserwowanych podczas działania maszyny. Cecha sygnału diagnostycznego jest jego oceną (estymatą) i może być opisana w postaci uporządkowanej trójki:

$$v = \langle obj, nam(v), val(v) \rangle \quad (3.5)$$

gdzie:

*obj* – nazwa rozpatrywanego obiektu,

*nam* – nazwa cechy,

*val* – wartość cechy.

Informacja o obiekcie często jest pomijana w zapisie cechy i do opisu sygnałów diagnostycznych wykorzystywane są głównie nazwa cechy i jej wartość. Można przyjąć, że cecha  $v$  sygnału diagnostycznego  $x(t, \theta)$  jest funkcją wyłącznie czasu "makro"  $v(\theta)$  i nie zależy od czasu "mikro"  $t$  [43]. Cechy pojedynczych sygnałów diagnostycznych nazywane są cechami własnymi, natomiast cechy sygnału wielokanałowego —  $X(t, \theta)$  cechami wzajemnymi. Zagadnienia odnoszące się do rodzajów wyznaczanych cech i metody ich wyznaczania omówiono w rozdziale 2.2.

Cechy sygnałów można klasyfikować następująco [46, 52]:

- cechy ilościowe i cechy jakościowe,
- cechy punktowe i cechy funkcyjne,
- cechy jednowymiarowe i cechy wielowymiarowe.

Bez ograniczania ogólności rozważań można przyjąć, że ze względu na stosowanie numerycznych metod przetwarzania sygnałów wartości cech funkcyjnych mogą być reprezentowane jako zbiory wartości odpowiednio określonych cech punktowych (np. wartość widma zapisywana jest jako zbiór wartości prążków widma dyskretnego). Uproszczenie to pozwala na przyjęcie założenia, że rozpatrywane będą zbiory cech punktowych sygnałów diagnostycznych. Pojęcie "zbiór cech sygnałów obserwowanych" powinno być odróżniane od pojęcia "zbiór wartości cech" [43]. Zbiór cech sygnałów obserwowanych  $\mathbf{V}$  jest zbiorem funkcji typu  $v(\theta)$ , natomiast zbiór wartości cech sygnałów obserwowanych w chwili  $\theta_j$  jest zbiorem wartości funkcji  $v(\theta_j) \in V$ , które są zapisywane w postaci macierzy. Jeśli przyjąć pewne uporządkowanie elementów zbioru cech  $\mathbf{V}$ , wyznaczające uporządkowanie ich wartości, wtedy możliwe będzie zapisanie zbioru wartości cech sygnału w chwili  $\theta_j$  w postaci macierzy  $V^m(\theta_j)$  interpretowanej jako zbiór współrzędnych punktu w  $m$  – wymiarowej przestrzeni wartości cech. W badaniach diagnostycznych zbiór wyznaczanych cech  $\mathbf{V}$  jest zbiorem skończonym i moc tego zbioru może być przedmiotem optymalizacji [43].

### 3.4.1. Przekształcanie cech sygnałów

Podczas prowadzenia badań diagnostycznych, zbiór wartości cech niosący informacje o stanie maszyny może być zbiorem bardzo licznym. Problemem często trudnym do rozwiązania jest zadanie wyboru cech istotnych do dalszych badań. Wybór uwzględnianych cech zwykle dokonywany jest arbitralnie przez badacza na podstawie posiadanej przez niego wiedzy i doświadczenia. W przypadku istnienia początkowo dużej liczby cech zadanie optymalnego wyboru cech jest trudne, a nawet niewykonalne [43]. Istnieją metody pozwalające na ograniczenie liczby uwzględnianych cech. Prostą metodą jest m. in. przekształcenie zbioru wartości

cech  $\mathbf{V}$  określonych w wielowymiarowej przestrzeni wartości cech  $V^m$  w zbiór wartości cech głównych  $\mathbf{G}$  określony w przestrzeni wartości cech głównych  $G^m$  na podstawie wartości i wektorów własnych macierzy kowariancji. Wyznaczona przestrzeń cech głównych jest następnie poddawana ograniczeniu na podstawie wybranego podzbioru wektorów własnych. Szersze omówienie tej oraz innych metod ograniczania przestrzeni cech opisano m. in. w [133, 89, 46, 43, 52, 156].

### 3.4.2. Przestrzeń obrazów cech

W wyniku prowadzenia badań diagnostycznych można uzyskać przestrzeń wartości cech, w której możliwe jest rozróżnianie grup wartości cech reprezentujących stan maszyny przynależny do pewnych wyróżnionych klas stanów. Podobieństwa rozpatrywanych wartości cech w przestrzeni wartości cech do wyróżnionych klas stanów interpretowane są jako współrzędne elementu w nowej przestrzeni nazywanej przestrzenią obrazów cech [46]. Opierając się na przestrzeniach obrazów wartości cech, możliwe jest przeprowadzenie optymalizacji wymiarów przestrzeni cech nie w wyniku bezpośredniego określania położenia dowolnej wartości cechy w przestrzeni wartości cech, lecz za pomocą podobieństw tego elementu do wyróżnionych klas elementów w tej przestrzeni. Sformalizowany sposób wyznaczania przestrzeni obrazów opisano m. in. w [43, 46, 102].

## 3.5. Model diagnostyczny maszyny

Bezpośrednie przewidywanie relacji diagnostycznych między cechami sygnałów i cechami stanu jest trudne z uwagi na dużą złożoność maszyn i ich własności losowe wynikające ze sposobu wytwarzania, kontroli i eksploatacji. Relacje te wyznaczane są na podstawie pewnych założeń upraszczających po przyjęciu pewnego modelu <sup>2</sup> maszyny.

Przy określaniu modelu maszyny można rozpatrywać dwa rodzaje takich modeli [126, 46]:

- modele indywidualne – opisujące właściwości pojedynczej maszyny (określonego jej egzemplarza),
- modele grupowe – opisujące łącznie właściwości określonej klasy maszyn.

W większości rozważań diagnostycznych stosowane są modele grupowe, dlatego też w dalszym ciągu ten typ modeli będzie nazywany modelem.

Istnieje wiele klas i rodzajów modeli mogących opisywać maszynę wirnikową, jej działanie i procesy w niej zachodzące. [126, 180, 40, 47, 98, 49, 57, 130].

Dla potrzeb opisu maszyny wirnikowej oraz procesów w niej zachodzących stosowane są m. in. modele strukturalne odwzorowujące strukturę dynamiczną i wzajemne oddziaływania elementów maszyny [84, 37] oraz modele diagnostyczne obiektów [126, 46] opisujące relacje

---

<sup>2</sup> Aby ograniczyć objętość niniejszej pracy, w głównej mierze skupiono się na modelu diagnostycznym maszyny, który stanowił podstawę do rozważań prowadzonych w pracy. Zrezygnowano ze szczegółowego opisu różnych modeli maszyn, uzupełniając ogólnie przedstawione informacje o odpowiednio odniesienia do pozycji literaturowych omawiających tę tematykę w szerszym stopniu.

między cechami stanu i cechami sygnałów diagnostycznych wyznaczane (identyfikowane) na podstawie eksperymentów.

### 3.5.1. Modele strukturalne

Modele strukturalne są często stosowanymi modelami maszyn w badaniach diagnostycznych. Umożliwiają one wnioskowanie o rodzaju wielkości fizycznych, których zmiany powinny być obserwowane podczas badań jako sygnały diagnostyczne (tzn. sygnały zależne od stanu obiektu), o rodzaju cech tych sygnałów, które prawdopodobnie są wrażliwe na zmiany stanu obiektu, o zalecanej lokalizacji czujników pomiarowych oraz o wymaganych warunkach działania obiektu podczas badań [43].

Modele strukturalne wykorzystuje się do analizy dynamiki wirnika i/lub układu wirnik – podpory – fundament. W oparciu o wyznaczone równania ruchu i przyjęte warunki brzegowe [84] buduje się modele matematyczne (numeryczne).

Do budowy każdego z modeli matematycznych, niezależnie od wzajemnego zróżnicowania, w równaniach ruchu uwzględnia się wpływ [84]:

- elementów bezwładnych (inercyjnych); są nimi z reguły tarcze i sprzęgła, natomiast bezwładność wału i podpór bywa pomijana,
- elementów sprężystych; są nimi z reguły wały, często pomija się natomiast podatność podpór,
- czynników warunkujących ruch precesyjny (wirowanie); powodowane są one z reguły przez niewyważenie wirnika, efekt giroskopowy tarcz, anizotropię sprężystą oraz tarcie wewnętrzne wału, siły hydrodynamiczne (podłoże hydrauliczne) i siły aerodynamiczne (cyrkulacyjne).

Do typowych modeli matematycznych maszyn wirnikowych jedno- i wielopodporowych można zaliczyć [84, 143, 82]:

- model jednotarczowy, symetryczny (Foppla-Jefcotta),
- model z bezwładnym wirnikiem sztywnym osadzonym na podporach podatnych, tłumiących drgania.
- model z wirnikiem wielotarczowym, wykorzystywany w modelowaniu typowych wirników turbiny parowej, sprężarki odśrodkowej lub pompy wirowej wielostopniowej przy czym bezwładność wału może być uwzględniana lub pomijana,
- model wirnika wielopodporowego turbogeneratorskiego dużej mocy; wirnik składa się z kilku wzajemnie sprzęgniętych odcinków, rzeczywista łączna długość takiego wirnika może osiągać ok. 70 m, a całość podparta jest w kilku lub kilkunastu łożyskach.

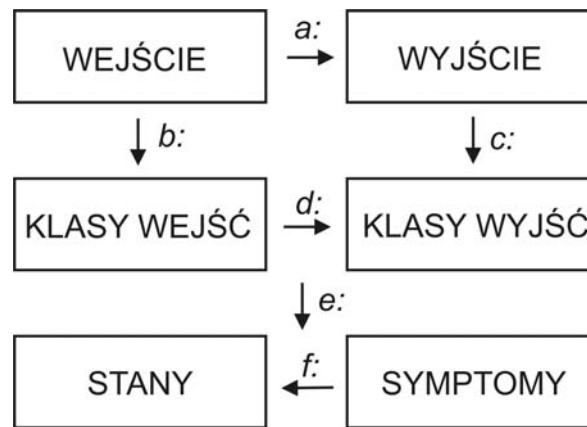
Modele matematyczne (numeryczne) znalazły szerokie zastosowanie w badaniach diagnostycznych maszyn wirnikowych [97, 105, 47, 98, 130] i bardzo często wyniki obliczeń na nich prowadzone stanowią podstawę do:

- identyfikacji relacji między cechami stanu i cechami sygnałów diagnostycznych,
- budowy zbioru możliwych stanów obiektu,
- pozyskania sygnałów z dowolnych punktów pomiarowych.

Należy zaznaczyć, że przy identyfikacji modeli strukturalnych przyjmowane są pewne uproszczenia, które mogą skutkować często brakiem zgodności szczegółowych wniosków dotyczących relacji między cechami sygnałów diagnostycznych i cechami stanu obiektu, wyznaczonych na podstawie modeli, z wnioskami co do relacji wyznaczanych na podstawie eksperymentów [43].

### 3.5.2. Modele oparte na relacjach diagnostycznych

Modele oparte na relacjach diagnostycznych bazują na ogólnej teorii systemów, co pozwala na jednolite rozpatrywanie obiektów opisanych za pomocą wejść, wyjść i stanów. Ważną cechą podejścia systemowego jest to, że aby zidentyfikować model, nie wystarcza specyfikacja elementów składowych, konieczne jest również zidentyfikowanie relacji zachodzących między tymi elementami (włącznie z otoczeniem). W badaniach diagnostycznych wspomaganym modelem obiektu można identyfikować następujące klasy relacji diagnostycznych (rys. 3.2) [47].




Rys. 3.2. Relacje diagnostyczne [47]

- a:* relacja *wejście – wyjście* (model obiektu),
- b:* klasyfikator wejściowych cech modelu (nauczyciel) pozwalający na przekształcenie cech ilościowych w cechy jakościowe,
- c:* klasyfikator wyjściowych cech modelu, pozwalający na przekształcenie cech ilościowych w cechy jakościowe,
- d:* zmodyfikowany (przybliżony) model obiektu,
- e:* operacja odwracania modelu,
- f:* poszukiwany model odwrotny pozwalający na wnioskowanie o klasie stanu technicznego na podstawie symptomów.

Na podstawie przedstawionych wyżej relacji buduje się następujące klasy modeli [102]:

- modele do detekcji uszkodzeń – opisujące związki między sygnałami wejściowymi i sygnałami wyjściowymi w maszynie,
- modele do lokalizacji uszkodzeń lub klasyfikacji stanów maszyny – określają związek między cechami sygnałów diagnostycznych a uszkodzeniami (cechami stanu).

Opierając się na ujęciu systemowym [61, 46], maszyna może zostać wyodrębniona z otoczenia przy odpowiednio przyjętych i wyraźnych granicach i potraktowana jako system rzeczywisty reprezentowany w postaci tzw. "czarnej skrzynki", co pozwala na pominięcie rozważań dotyczących struktury wewnętrznej obiektu. Oddziaływania otoczenia na obiekt odbywają się za pomocą wejść obiektu, a oddziaływania obiektu na otoczenie za pośrednictwem wyjść, przy czym zbiory wejść i zbiory wyjść są rozłączne (rys. 3.3).



Rys. 3.3. Model obiektu w ujęciu systemowym (na podstawie [46])

Wejście i wyjście maszyny może być obserwowane za pośrednictwem sygnałów. Wyznaczone cechy sygnałów mogą być interpretowane jako cechy wejścia i wyjścia.

W procesie identyfikacji własności i właściwości obiektu badań stosowane są również modele tzw. "szarej skrzynki" lub skrzynki względnie przezroczystej, w której poza znajomością wejść i wyjść, znana jest również częściowo struktura wewnętrzna obiektu, tzn. istotne właściwości wpływające na wzajemne relacje wejść i wyjść [61].


Rozdzielenie oddziaływań na rozłączne zbiory wejść i wyjść może być trudne lub niemożliwe ze względu na ich charakter przyczynowo-skutkowy, podobnie jak zdefiniowanie systemu obiektu rzeczywistego jako relacji określonej na iloczynie kartezjańskim wejść i wyjść jest praktycznie niemożliwe ze względu na nieskończoną liczbę wejść i wyjść oraz na brak możliwości ich bezpośredniego wyznaczenia.

Budowane są systemy oparte na modelu o ograniczonej liczbie wejść i wyjść, przy czym wejścia i wyjścia opisywane są za pomocą zbiorów sygnałów i/lub ich cech pozyskanych w wyniku obserwacji oddziaływań zewnętrznych z zastosowaniem odpowiednich technik pomiarowych, metod analizy i przetwarzania sygnałów [21, 23, 112, 40]. Należy pamiętać, że istnienie systemu modelu ze skończoną liczbą wejść może doprowadzić do braku przyczyn



objaśniających zmiany wyjść [46, 43]. Sytuacja taka związana jest z niekompletnym zbiorem wejść.

Ze względu na to, że zmiany w działaniu maszyny wirnikowej zachodzą w czasie, większość modeli opartych na ujęciu systemowym należy do grupy modeli (systemów) dynamicznych [46]. W systemach dynamicznych wartości sygnałów wyjściowych w określonej chwili czasu zależą nie tylko od wartości sygnałów wejściowych w tej samej chwili czasu, lecz również od wartości sygnałów wejściowych w chwilach poprzedzających. Oznacza to, że cechy wewnętrzne systemu mogą być opisywane przez zmienne stanu (rys. 3.4) [46].



Rys. 3.4. Model obiektu.  $x(t)$  – sygnał wejściowy,  $y(t)$  – sygnał wyjściowy,  $s(t)$  – zmienna stanu [46]

Na podstawie znajomości przestrzeni cech zmiennych stanu oraz przestrzeni cech wejść możliwe jest określenie przestrzeni cech wyjść, co stanowi podstawę budowy modelu obiektu, który dla określonego obiektu i ustalonego czasu można zapisać w postaci:

$$Y = X \times S \quad (3.6)$$

Bezpośrednie zastosowanie zmiennych stanu w badaniach diagnostycznych jest ograniczone, co jest wynikiem ich niejednoznaczności oraz nieumiejętności bezpośredniej interpretacji znaczenia wartości zmiennych stanu oraz zmian tych wartości. Nie zawsze możliwe jest również wyznaczenie wszystkich istotnych sygnałów wejściowych opisujących oddziaływania otoczenia na obiekt. Uwzględniając fakt, że dla celów badań diagnostycznych istotna jest detekcja zmian stanu obiektu na podstawie wszystkich oddziaływań zewnętrznych reprezentowanych zarówno przez zbiór sygnałów wejściowych jak i zbiór sygnałów wyjściowych, model 3.6 można zapisać w postaci następującej relacji [46]:

$$\mathbf{M} \subset X \times Y \times S \quad (3.7)$$

gdzie:

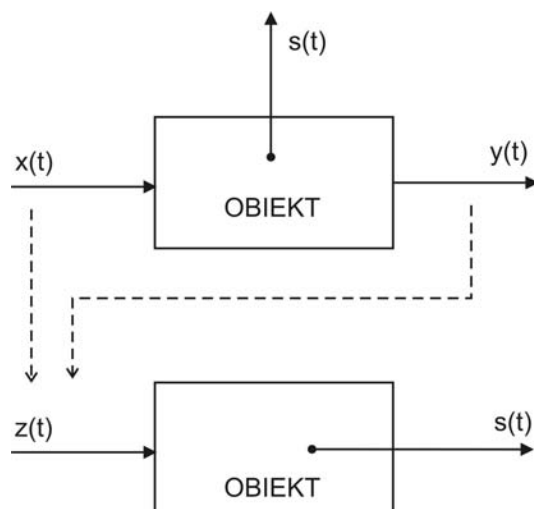
$\mathbf{M}$  – model dla wybranej maszyny,

$X$  – przestrzeń cech wejść,

$Y$  – przestrzeń cech wyjść,

$S$  – przestrzeń cech stanów,

co pozwala na połączenie zbioru sygnałów i/lub cech wejściowych ze zbiorem sygnałów i/lub cech wyjściowych w celu otrzymania zbioru sygnałów oddziaływań (rys. 3.5) [46].



Rys. 3.5. Przekształcenie modeli [46]

Ten sposób postępowania, zgodnie z [46], umożliwia zapisanie modelu diagnostycznego maszyny w postaci:

$$\mathbf{D} \subset Z \times S \quad (3.8)$$

gdzie

$$Z = X \times Y \quad (3.9)$$

gdzie:

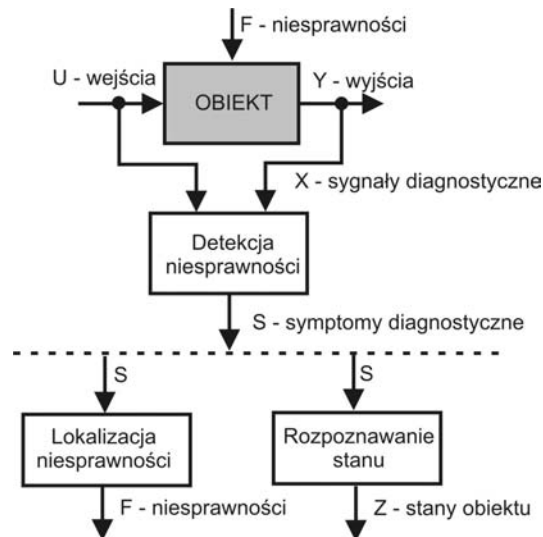
$\mathbf{D}$  – przestrzeń cech stanów,

$Z$  – przestrzeń cech oddziaływań zewnętrznych.

Opierając się na modelach 3.7 i 3.8, można określać stan obiektu na podstawie sygnałów i/lub ich cech, reprezentujących oddziaływania zewnętrzne oraz zmiany stanów obiektu na podstawie zmian wartości tych sygnałów i/lub ich cech w czasie [46].

### 3.6. Koncepcje procesu diagnozowania

Proces diagnozowania można rozpatrywać w trzech fazach: detekcji, lokalizacji i identyfikacji niesprawności, przy czym najczęściej realizowane są dwie pierwsze fazy, czyli detekcja i lokalizacja [102]. W fazie detekcji na podstawie analizy sygnałów diagnostycznych wykrywane są symptomy niesprawności. W fazie lokalizacji na podstawie wykrytych symptomów wskazywane są występujące niesprawności. Istnieją przypadki, gdy faza lokalizacji niesprawności może być zastępowana lub uzupełniana przez działania mające na celu rozpoznawanie stanu lub klasy stanów obiektu. Ogólny schemat diagnozowania za [102] przedstawiono na rysunku 3.6.

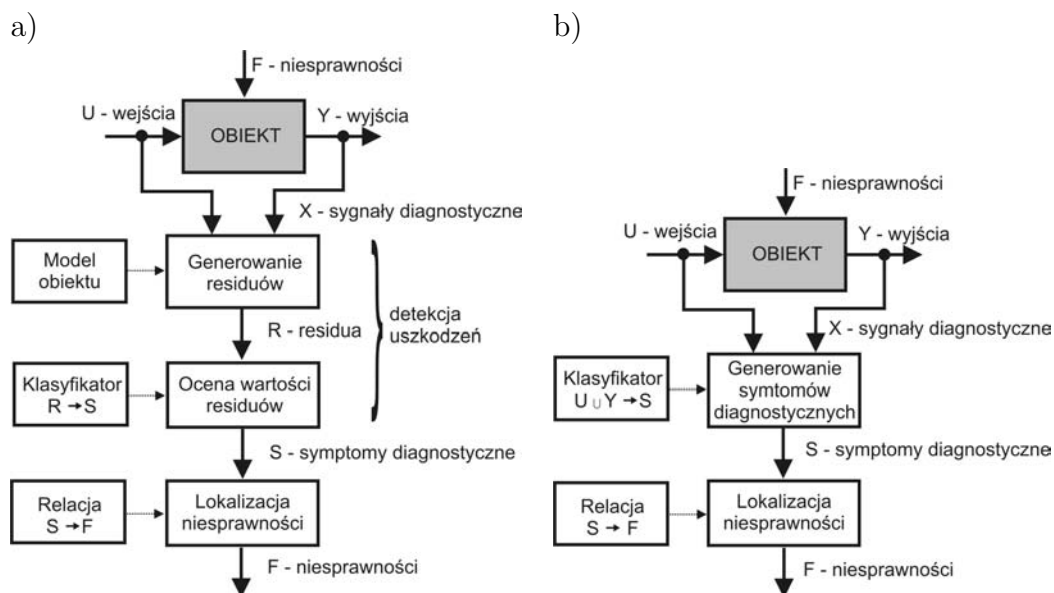


Rys. 3.6. Schemat procesu diagnozowania (na podstawie [102])

Proces detekcji niesprawności może być prowadzony na podstawie:

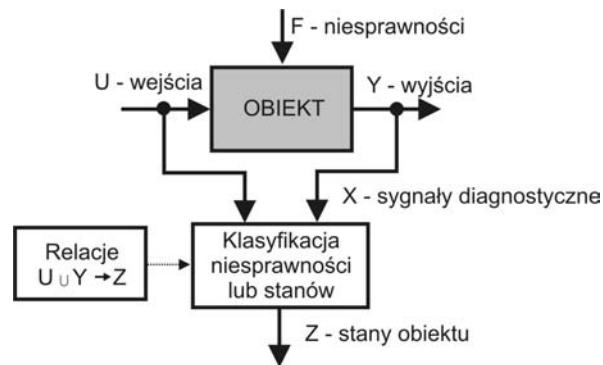
- jawnych modeli obiektów – faza detekcji niesprawności obejmuje generację residuów z wykorzystaniem różnych klas modeli obiektów, ocenę wartości residuów i podejmowanie decyzji diagnostycznej [145],[86], [74], [103, 102], [100], [147],
- niejawnych modeli obiektów – detekcja uszkodzeń oparta jest na metodach kontroli ograniczeń oraz prostych związkach zachodzących między sygnałami diagnostycznymi.

Diagnozowanie opierające się na modelach obiektów i bez wykorzystania modeli przedstawiono na rysunku 3.7.



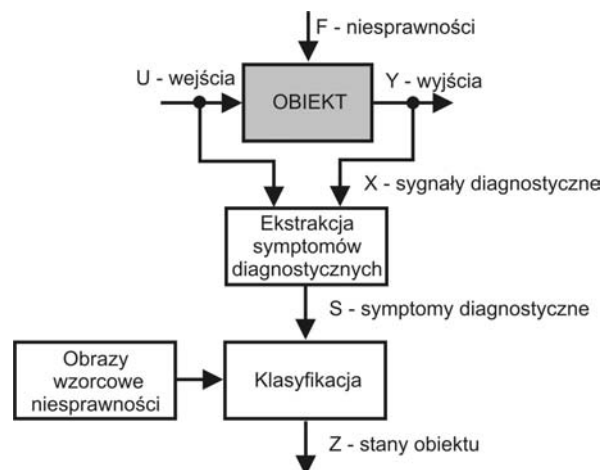
Rys. 3.7. Schemat procesu diagnozowania: a) z wykorzystaniem modelu obiektu, b) bez wykorzystania modelu obiektu (na podstawie [102])

Diagnozowanie może być prowadzone przy wykorzystaniu koncepcji opartej na połączeniu fazy detekcji i lokalizacji uszkodzeń (rys. 3.8). Dla potrzeb takiej koncepcji wykorzystywane są sieci neuronalne. Wymagają one znajomości odwzorowania wartości przestrzeni cech sygnałów w zbiór stanów obiektu. Dla obiektu dynamicznego, jakim jest maszyna wirnikowa, określenie takiego odwzorowania jest trudne, a często niemożliwe [102].



Rys. 3.8. Schemat procesu diagnozowania z połączoną fazą detekcji i lokalizacji niesprawności (na podstawie [102])

Diagnozowanie może być traktowane jako proces rozpoznawania wzorców (rys. 3.9). W tym przypadku, fazie detekcji uszkodzeń odpowiada faza ekstrakcji symptomów, natomiast lokalizacja niesprawności jest równoważna klasyfikacji stanu obiektu.



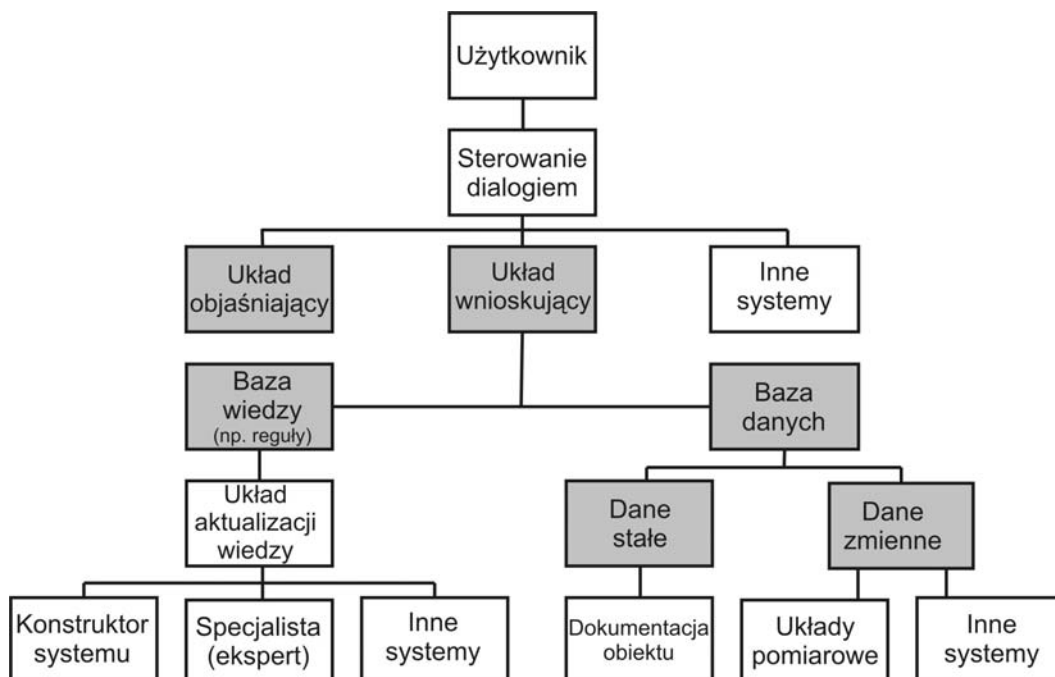
Rys. 3.9. Schemat procesu diagnozowania w oparciu o proces rozpoznawania wzorców (na podstawie [102])

### 3.7. Środki wspomagające podejmowanie decyzji diagnostycznej

Cechy sygnałów wyznaczone w wyniku ich analizy niosą dużą ilość informacji. Aby ułatwić proces podejmowania decyzji diagnostycznej, stosuje się dodatkowe środki wspomagające oparte na metodach przetwarzania, redukcji i selekcji informacji. W monitorowaniu niezłożonych obiektów w większości przypadków stosuje się rozwiązania polegające na czytelnym obrazowaniu wartości cech (wizualizacji cech) w postaci dwu- lub trójwymiarowych wykresów [48, 173] lub stosowaniu prostych układów ostrzegawczych reagujących na przekroczenie zadanych wartości progowych przez wybrane symptomy [52, 141]. W przypadku złożonych systemów diagnozujących, bazujących na modelach obiektu coraz, częściej stosowane są rozwiązania wspomagające podejmowanie decyzji diagnostycznej oparte na systemach ekspertowych, sieciach neuronalnych, teorii zbiorów rozmytych, rozpoznawaniu wzorców itp.

#### 3.7.1. Systemy doradcze

Systemy doradcze to programy komputerowe, przeznaczone do rozwiązywania specjalistycznych zadań, które wymagają profesjonalnej wiedzy i doświadczenia w stosowaniu tej wiedzy [45, 128, 127, 129, 130]. Systemy te znalazły zastosowanie przy realizacji zadań wspomagania decyzji operatorów maszyn oraz jako części składowe złożonych systemów diagnostycznych m. in. dla maszyn wirnikowych [48]. Główne elementy systemu doradczego zaprezentowano na rysunku 3.10. Umożliwiają one stosowanie i aktualizację wiedzy pozyskanej w sposób jawny w wyniku analizy sygnałów i ich cech, a także komunikację z użytkownikiem.



Rys. 3.10. Podstawowe elementy systemu doradczego [44]

Rozpatruje się dwie kategorie systemów doradczych: statyczne i dynamiczne, przy czym niezależnie od tego podziału rozróżnia się systemy o nieograniczonym czasie działania oraz systemy o ograniczonym i gwarantowanym czasie działania [44]. Szczególne znaczenie w procesie wspomagania wnioskowania diagnostycznego w systemach diagnostycznych maszyn wirnikowych [48] mają dynamiczne systemy doradcze. Są one przeznaczone do realizacji zadań w ograniczonym czasie działania. Głównym problemem stosowania dynamicznych systemów doradczych jest uwzględnienie dużej liczby sygnałów oraz ich cech. Ułatwieniem dla stosowania dynamicznych systemów doradczych może być zastosowanie cech łącznych pozyskanych w wyniku łącznej analizy większej liczby sygnałów.

### 3.7.2. Sztuczne sieci neuronowe

Sztuczne sieci neuronowe, zwane również sieciami neuronalnymi, stanowią próbę matematycznego odwzorowania działania ludzkiego mózgu oraz procesów w nim zachodzących. Najważniejszą cechą sieci neuronalnych jest to, że stanowią układ aproksymująco-odwzorowujący wielowymiarowe zbiory danych, co pozwala na równoległe przetwarzania informacji. Innymi własnościami są m. in.: umiejętność dochodzenia do rozwiązania bez znajomości algorytmu, zdolność do uogólniania przy wykorzystaniu niepełnej wiedzy, zdolność uczenia się i adaptacji do zmieniających się warunków. Stosowanie sieci neuronalnych wymaga określenia topologii sieci oraz przygotowania danych wejściowych, którymi mogą być zarówno sygnały diagnostyczne, jak również ich cechy. Istotną wadą sieci neuronalnych jest to, że użytkownik nie zna sposobu, w jaki sieć neuronalna doszła do konkluzji. Właściwości sieci neuronalnych powodują, że znalazły one zastosowanie do rozwiązania takich zadań, które w sposób formalny są trudne lub niemożliwe do rozwiązania. Sieci neuronalne stosowane są w wielu dziedzinach nauki, w tym w diagnostyce technicznej [102, 35, 96, 119, 118, 178, 93, 16, 14, 179, 33]. Zdolność do równoległego przetwarzania wielowymiarowych zbiorów danych czyni sieci neuronalne interesującym narzędziem do rozwiązania problemu łącznej analizy sygnałów diagnostycznych. Sieci neuronalne mogą być stosowane do łącznego przetwarzania wielu sygnałów samodzielnie lub mogą tworzyć element wchodzący w skład metody przetwarzania cech sygnałów.

### 3.7.3. Rozpoznawanie wzorców

Zagadnienia rozpoznawania wzorców w diagnostyce dotyczą wykrywania, percepcji i rozpoznawania prawidłowości w zbiorze cech opisujących obiekt. Celem rozpoznawania wzorców jest określenie przynależności wartości cech stanu obiektu wyznaczonych na podstawie dostępnych danych eksperymentalnych do odpowiedniej klasy. Przypisanie stanu obiektu do określonej pojedynczej unikatowej klasy jest traktowane jako identyfikacja, natomiast proces grupowania cech stanów obiektu do klas stanu nazywany jest klasyfikacją. W celu realizacji procesu rozpoznawania wzorców nie jest wymagana wcześniejsza wiedza o regułach przynależności obiektów do określonych klas. Jediną informacją wykorzystywaną przez system wnioskujący jest informacja zawarta w ciągu uczącym złożonym ze sklasyfikowanych przykładów uczących. Zatem rozpoznawanie jest formą wnioskowania na podstawie przykładów

uczących, a klasyfikacja jest formą uczenia [102]. System do rozpoznawania wzorców powinien składać się z co najmniej trzech podstawowych elementów:

- przetwornika – służącego do pozyskania i przygotowania sygnałów pomiarowych,
- bloku przetwarzania wstępnego – wyodrębniającego cechy opisujące obiekt,
- klasyfikatora – podejmującego decyzje o przynależności nieznanymi cech do ustalonych klas.

Do klasycznych metod rozpoznawania obrazów zalicza się metody odległościowe, aproksymacyjne i statystyczne. Problematyka ta znalazła szerokie odzwierciedlenie w licznej literaturze [63, 156, 170, 88, 146, 101, 102, 43, 162, 15].






## Rozdział 4

# Koncepcja łącznej analizy sygnałów

W rozdziale zaproponowano koncepcję łącznej analizy sygnałów, której istotą jest realizowanie analizy sygnałów zarówno w dziedzinie czasu "mikro", jak i czasu "makro". W celu ograniczenia liczby jednocześnie rozpatrywanych sygnałów oraz w celu umożliwienia badania relacji między wartościami cech sygnałów zaproponowano postępowanie polegające na stosowaniu dodatkowych sygnałów pomocniczych. Do wyznaczania wartości łącznych cech sygnałów i określania na ich podstawie stanu technicznego maszyny wprowadzono uogólnione okno danych.

### 4.1. Uogólnione okno danych

Celem badań diagnostycznych jest określenie stanu maszyny. Zrealizowanie tego celu na drodze bezpośredniej obserwacji cech stanu obiektu nie zawsze jest możliwe do wykonania. Odwzorowanie stanu maszyny, a tym samym zjawisk w niej zachodzących, może być zrealizowane na podstawie obserwacji oddziaływań zewnętrznych między maszyną i jej otoczeniem. Zgodnie z przedstawionym modelem diagnostycznym obiektu [46] (por. p.3.5.2) maszynę możemy opisać jako źródło takich oddziaływań i obserwować je za pośrednictwem sygnałów diagnostycznych (rys. 4.1), które obserwator jest w stanie rejestrować, a następnie oceniać ich cechy.



Rys. 4.1. Maszyna jako źródło sygnałów

Wartości chwilowe sygnałów zależą między innymi od stanu obiektu i zmieniają się w funkcji czasu. Stan badanego obiektu może również ulegać zmianom z upływem czasu, co w efekcie może pociągać za sobą zmienność wartości cech sygnałów opisujących efekty oddziaływania tego obiektu na otoczenie. Stwierdzenia te upoważniają do przypuszczenia, że na podstawie wyników obserwacji sygnałów i odpowiedniego ich przetworzenia możliwe jest wnioskowanie o stanie obiektu.

Dla uproszczenia rozważań wprowadzono pojęcia czasu "mikro"  $t$  i czasu "makro"  $\theta$  (por. rozdz. 3.2)<sup>1</sup>, pozwalające na rozpatrywanie "szybko zmieniających się" wartości chwilowych sygnałów, zależnych od "wolno zmieniających się" stanów technicznych obiektu. Zakładamy, że czas rzeczywisty  $\xi$

$$\xi = t + \theta \quad (4.1)$$

Wartości chwilowe sygnałów diagnostycznych rozpatrywane są na dostatecznie krótkich odciinkach czasu "mikro" pozwalających na przyjęcie stałej wartości czasu "makro", tzn.:

$$x(\xi) = x(t + \theta) = x(t)|_{\theta} \quad (4.2)$$

Założenie o "wolno zachodzących zmianach" stanu obiektu pozwala na uznanie, że stan nie zależy od czasu "mikro"  $t$ . Jest on jedynie funkcją czasu "makro"  $\theta$ .

$$s(t + \theta) = s(\theta) \quad (4.3)$$


Rozkład (4.1) czasu rzeczywistego  $\xi$  na składniki  $t$  i  $\theta$  jest oczywiście niejednoznaczny, pozwala jednak na przyjęcie odpowiedniej interpretacji znaczeń pojęć czasu "mikro" i czasu "makro".

Wynikiem obserwacji obiektu w ustalonej chwili czasu "makro"  $\theta_j$  są przebiegi zmian chwilowych wartości sygnałów zachodzących w czasie "mikro", dla których wyznaczane mogą być wartości cech sygnałów (rys. 4.2a). Wyznaczone wartości cech sygnałów nie zależą już od czasu "mikro", są one jedynie funkcjami czasu "makro"  $v_i(\theta_j)$ . Na podstawie tak wyznaczonych wartości cech sygnałów mogą być wyznaczane wartości cech stanu  $s(\theta_j)$  – jeśli znany jest i istnieje odpowiedni model diagnostyczny obiektu. Wynikiem obserwacji obiektu w kolejnej chwili czasu "makro"  $\theta_{j+1}$  będą wartości cech sygnałów w tej chwili  $v_i(\theta_{j+1})$ .

Obserwacja obiektu w kolejnych ustalonych chwilach czasu "makro"  $\dots, \theta_j, \theta_{j+1}, \dots$  umożliwia pozyskanie informacji o historii zmian wartości cech sygnałów, a zatem również historii zmian stanu technicznego (rys. 4.2b) – jeśli znany jest i istnieje diagnostyczny model obiektu. Posiadanie informacji o historii zmian stanu obiektu w czasie "makro" umożliwia między innymi rozpoznawanie zmian stanu technicznego, które są nierozpoznawalne wtedy, gdy obserwujemy obiekt wyłącznie w jednej chwili czasu.

Uwzględnienie czasu jako czynnika porządkującego umożliwia dynamiczne przedstawienie historii stanu obiektu jako pewnego rodzaju trajektorii w przestrzeni stanów, której identyfikacja umożliwia realizację zadań typu prognostycznego w analizie danych diagnostycznych [46]. Jednym ze sposobów prowadzącym do identyfikacji trajektorii obiektu w przestrzeni stanów może być łączna analiza  $k$  sygnałów pozyskanych w wyniku obserwacji oddziaływań zewnętrznych obiektu przez wielokanałowy układ diagnozujący. Dla potrzeb określenia sformalizowanej metody wyznaczania łącznych cech sygnałów diagnostycznych umożliwiających

<sup>1</sup> Podział czasu rzeczywistego na czas "mikro" i czas "makro" pozwala na rozpatrywanie różnych metod analizy sygnałów w tych dziedzinach. Fakt ten został bezpośrednio wykorzystany w dalszych rozważaniach dotyczących zaproponowanej koncepcji łącznej analizy sygnałów. Pojęcie dziedzin odnoszące się do czasu "mikro" i czasu "makro" przyjęto umownie i dotyczy ona tego samego czasu, z którym mamy do czynienia w rzeczywistości, lecz różnicuje tylko długości obserwacji sygnałów w tym czasie.



Rys. 4.2. Obiekt w ustalonych chwilach czasu makro. Zmiany stanów obiektu oraz zmiany cech oddziaływań zewnętrznych [46]

opisanie trajektorii w przestrzeni stanów wprowadzono uogólnione okno danych pozwalające na odwzorowanie zmian wartości cech sygnałów diagnostycznych obserwowanych jednocześnie w  $k$  kanałach pomiarowych w czasie "mikro" i w ustalonych chwilach czasu "makro".

Uogólnione okno danych (rys. 4.3) charakteryzują następujące cechy:

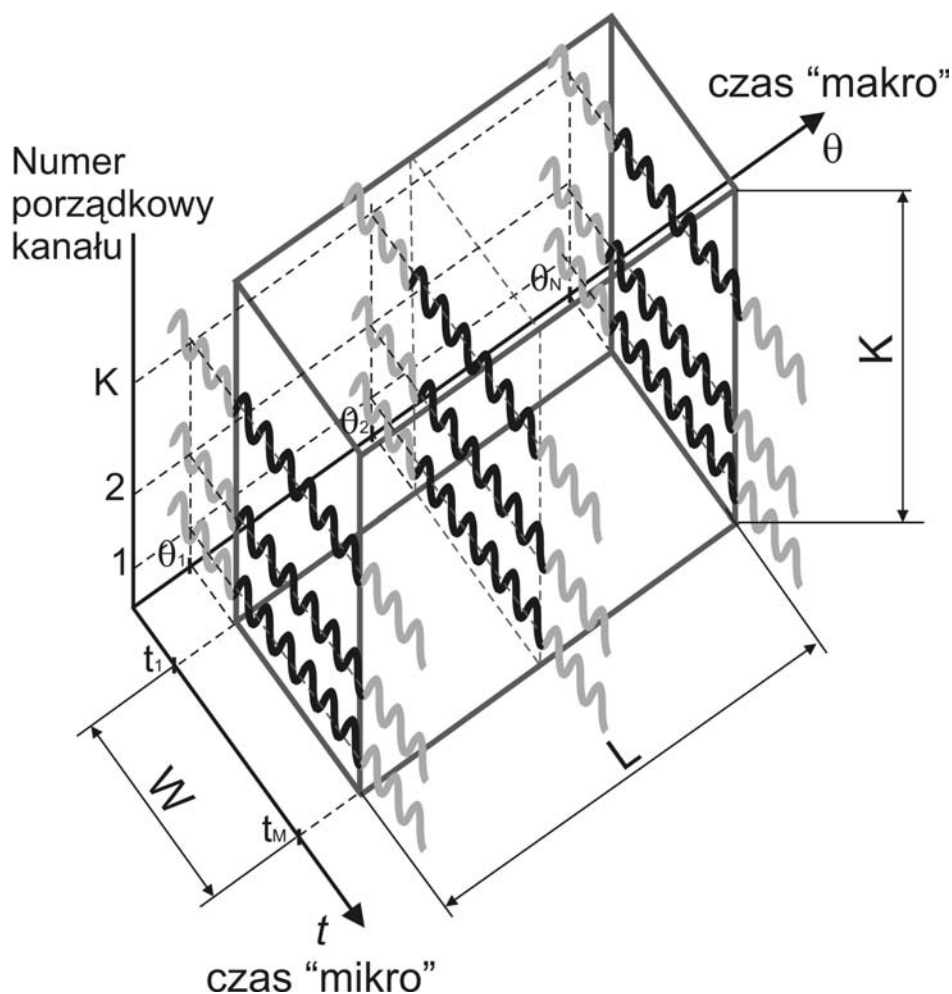
- wysokość  $K$  - związana z liczbą kanałów, w których sygnały obserwowane są jednocześnie,
- szerokość  $W$  - związana z czasem trwania obserwacji sygnałów w czasie "mikro",
- głębokość  $L$  - dotycząca czasu trwania lub liczby obserwacji obiektu w czasie "makro".

#### 4.1.1. Wysokość okna danych

Wysokość okna  $K$  jest uzależniona od przyjętej liczby kanałów  $k; k = 1, 2, \dots, K$ , w których prowadzona jest obserwacja sygnałów oddziaływań zewnętrznych – sygnałów diagnostycznych. Jeśli rozpatrujemy wielokanałowy sygnał diagnostyczny  $X(t, \theta)$  (por. roz. 3.3 rów. 3.3), którego wartości zapisywane są w postaci macierzy, to wysokość okna jest określona liczbą wierszy tej macierzy. Określenie liczby kanałów, ich selekcja i uporządkowanie często zależy od arbitralnej decyzji podejmowanej przez prowadzącego badania diagnostyczne i jest uwarunkowana wieloma czynnikami, np. stosowanym systemem diagnozującym, dostępnością punktów pomiarowych, stosowaną aparaturą pomiarową itp. W celu uniknięcia powszechnie znanych i opisanych w licznych publikacjach przypadków szczególnych (dla  $K = 1, K = 2$ ) przyjęto, że rozpatrywana w pracy liczba kanałów nie powinna być mniejsza od  $K \geq 3$ .

#### 4.1.2. Szerokość okna danych

Szerokość okna  $W$  odpowiada czasowi trwania równoczesnej obserwacji sygnałów diagnostycznych w  $K$  kanałach w czasie "mikro"  $t$ . Przyjęto, że rozpatrywane sygnały diagnostyczne obserwowane w skończonym czasie "mikro", w określonej chwili czasu "makro" są sygnałami stacjonarnymi w przedziale czasu obserwacji [50]. To, czy założenie o stacjonarności sygnałów rozpatrywanych w uogólnionym oknie danych jest spełnione, można weryfikować na podstawie statystycznej analizy wartości cech sygnałów wyznaczonych w wyniku ich estymacji. Szerokość okna czasowego związana jest z rodzajem stosowanego estymatora, dla którego odchylenie



Rys. 4.3. Kształt uogólnionego okna danych


wartości zależy od długości (czasu trwania) obserwacji. Długość ocenianego sygnału, a tym samym szerokość okna, może być dobrana na podstawie zaleceń wynikających z literatury lub z doświadczeń zebranych podczas wcześniej przeprowadzonych badań.

#### 4.1.3. Głębokość okna danych

Głębokość okna  $L$  jest określona liczbą obserwacji obiektu w dziedzinie czasu "makro" dla różnych chwil tego czasu. Dobór głębokości okna czasowego uzależniony jest od planu badań diagnostycznych obiektu. Głębokość okna można utożsamiać z liczbą badań diagnostycznych dokonanych w okresie eksploatacji obiektu. Okres ten może być związany z czasem życia obiektu, z okresem międzyremontowym lub okresem wyznaczonym rozruchem i zatrzymaniem maszyny itp. Rozstrzygnięcie dotyczące tego, jaka powinna być głębokość okna, czyli liczba obserwacji obiektu w dziedzinie czasu "makro", zależy od dostępności pomiarowej obiektu, dostępności danych pomiarowych, planu badań diagnostycznych itp.

## 4.2. Analiza sygnałów

Spośród wielu możliwości, wyboru odpowiedniej metody łącznej analizy sygnałów można dokonać, stosując metody oparte na porównywaniu stanów obiektów. Porównanie obiektów dokonywane jest na podstawie zbioru danych, nazywanych danymi uczącymi [46] uzyskiwanymi w wyniku badań tych obiektów. Elementami zbioru porównywanych obiektów  $\mathbf{O}_S \subset \mathbf{O}$  mogą być różne maszyny obserwowane w przypadkowych chwilach czasu "makro", czyli czasu ich eksploatacji. Możliwe jest również rozpatrywanie zbioru obiektów, którego elementami jest jedna maszyna (lub niewielka liczba maszyn) obserwowana w różnych chwilach czasu "makro". Dla uzasadnienia równoważności tak definiowanych zbiorów obiektów, na podstawie których wyznaczany jest zbiór danych uczących, konieczne jest przyjęcie hipotezy o ergodyczności procesu diagnozowanego, która mówi, że własności procesów można identyfikować zarówno na podstawie odpowiednio licznego zbioru realizacji obserwowanych procesów w wybranej chwili czasu, jak i na podstawie wybranej pojedynczej realizacji obserwowanego procesu na dostatecznie długim odcinku czasu [46]. Na podstawie zaproponowanego uogólnionego okna danych możliwe jest określenie zbioru danych uczących w wyniku identyfikacji "przekrojów" tego okna w odpowiednio wybranych chwilach czasu "makro". Przez "przekrój" uogólnionego okna danych w chwili czasu "makro" można rozumieć zbiór sygnałów w czasie "mikro" dla rozpatrywanej chwili czasu "makro" (rys. 4.4).



Rys. 4.4. Wybrany przekrój uogólnionego okna danych w określonej chwili czasu "makro"  $\theta_j$

Elementami rozpatrywanego zbioru sygnałów mogą być sygnały oddziaływań zewnętrznych oraz dodatkowe sygnały, dalej nazywane dodatkowymi sygnałami pomocniczymi, wyznaczone na podstawie wartości sygnałów oddziaływań zewnętrznych. Danymi, na podstawie których możliwa jest identyfikacja i porównanie chwilowych stanów obiektu, są wartości cech sygnałów określone dla wybranych przekrojów uogólnionego okna danych. Zbiór wartości wszystkich możliwych cech sygnałów wyznaczonych w  $j$ -tym przekroju uogólnionego danych jest nazywany przestrzenią wartości cech, której liczba wymiarów stanowi źródło wielu trudnych do rozwiązania problemów. Wykorzystanie do opisu stanu obiektu w określonej chwili czasu "makro" wszystkich możliwych wartości cech jest niemożliwe i niewskazane choćby z powodu znacznej redundancji informacyjnej. Z praktycznych powodów rozpatrywany jest pewien ograniczony zbiór cech pozwalający na rozpoznawanie stanu obiektu przy minimalnej liczbie popełnianych błędów wynikających z przyporządkowania chwilowego stanu maszyny do niewłaściwej klasy stanu. Przyporządkowanie stanu obiektu do jednej z możliwych klas stanów jest realizowane w wyniku klasyfikacji rozpoznawanych stanów maszyn. Wyniki klasyfikacji mogą stanowić podstawę do ograniczania liczby cech. Klasyfikacja prowadzona jest na podstawie danych uczących. Wyznaczany jest klasyfikator umożliwiający porównywanie obiektów (stanu jednego obiektu) w różnych chwilach czasu "makro".

Autorowi nie są znane metody pozwalające na jednoczesną analizę sygnałów w czasie "mikro", czasie "makro" oraz w wielu kanałach. Proponowana koncepcja łącznej analizy sygnałów rozdziela działania na dwa etapy. Etap pierwszy związany jest z analizą sygnałów w czasie "mikro", natomiast etap drugi obejmuje grupę działań na wartościach cech sygnałów w dziedzinie czasu "makro". Założono, że takie rozdzielanie działań jest możliwe. Schemat postępowania, obejmujący dwa wspomniane etapy, składający się na proponowaną koncepcję łącznej analizy sygnałów, można przedstawić jako szereg następujących kroków:

### **Etap I – Działania w dziedzinie czasu "mikro" w określonej chwili czasu "makro"** $\theta_j$ :

1. Określenie zbioru  $\mathbf{X}_K$ ,  $K$  sygnałów oddziaływań maszyny na otoczenie obserwowanych jednocześnie w  $K$  kanałach pomiarowych w dziedzinie czasu "mikro"  $t$ .
2. Określenie zbioru  $\mathbf{Y}_L$ ,  $L$  nowych sygnałów (dodatkowych sygnałów pomocniczych), wyznaczonych na podstawie wcześniej określonego zbioru  $\mathbf{X}_K$ ,  $K$  sygnałów oddziaływań zewnętrznych.
3. Określenie zbioru  $\mathbf{V}_m$  rozpatrywanych cech sygnałów, należących do zbiorów  $\mathbf{X}_K$  i  $\mathbf{X}_L$ .
4. Wyznaczenie  $m$  wymiarowej przestrzeni wartości cech  $V^m$  rozpatrywanych sygnałów.
5. Ograniczenie  $m$  wymiarowej przestrzeni wartości cech  $V^m$  przez przekształcenie jej do  $n$  wymiarowej przestrzeni wartości cech głównych  $G^n$ .

### **Etap II – Działania w dziedzinie czasu "makro":**

1. Określenie zbioru przykładów uczących i przeprowadzenie na każdym przykładzie działań z etapu I.
2. Wyznaczanie klasyfikatora na podstawie zgromadzonego zbioru danych uczących obejmujących wartości cech głównych.

3. Przeprowadzenie klasyfikacji stanu innego obiektu na podstawie wcześniej określonego klasyfikatora i wyznaczenie trajektorii w czasie "makro" w przestrzeni wartości cech głównych.


#### 4.2.1. Zbiór rozpatrywanych sygnałów

Oddziaływania maszyny na otoczenie obserwowane są pod postacią sygnałów diagnostycznych (por. rozdz. 3.3). Wprowadzone pojęcie uogólnionego okna danych pozwala zidentyfikować zbiór  $\mathbf{X}_K$  przebiegów zmian chwilowych wartości tych sygnałów w czasie "mikro" w  $j$  – tej chwili czasu "makro". Liczba rozpatrywanych sygnałów, będących elementami zbioru  $\mathbf{X}_K$ , uzależniona jest od wysokości uogólnionego okna danych, tzn. liczby rozpatrywanych kanałów pomiarowych  $K$ .

W celu ułatwienia stosowania odpowiednich łącznych ocen sygnałów zaproponowano wprowadzenie nowych sygnałów, w dalszym ciągu nazywanych dodatkowymi sygnałami pomocniczymi, których przebiegi wyznaczane są na podstawie wyników obserwacji w dziedzinie czasu "mikro" sygnałów oddziaływań zewnętrznych. Zbiór  $\mathbf{Y}_L$ ,  $L$  dodatkowych sygnałów pomocniczych stanowi uzupełnienie zbioru sygnałów oddziaływań zewnętrznych  $\mathbf{X}_K$ , i, podobnie jak w przypadku tych ostatnich, dodatkowe sygnały pomocnicze mogą być poddawane ocenie w celu wyznaczenia wartości ich cech. Określenie sposobu wyznaczania dodatkowych sygnałów pomocniczych jest najczęściej wynikiem badań heurystycznych, prowadzonych indywidualnie przez badacza i wymaga uwzględnienia własności i właściwości rozpatrywanych obiektów. Przykładem dodatkowego sygnału pomocniczego może być funkcja czasu "mikro"  $t$  opisująca chwilowe przemieszczenie wału (promień trajektorii  $r$ ) wyznaczana następująco:

$$r(t)|_{\theta_j} = \sqrt{x_1^2(t)|_{\theta_j} + x_2^2(t)|_{\theta_j}}; \quad j \in \{1, 2, \dots, N\} \quad (4.4)$$

gdzie  $\{x_1(t)|_{\theta_j}, x_2(t)|_{\theta_j}\}; j \in \{1, 2, \dots, N\}$  są sygnałami pochodzącymi z czujników przemieszczeń względnych umieszczonych w łożysku ślizgowym maszyny wirnikowej i pozwalających na obserwację trajektorii środka czopa (rys. 4.5).



Rys. 4.5. Wielkości opisujące trajektorię (na podstawie [173])

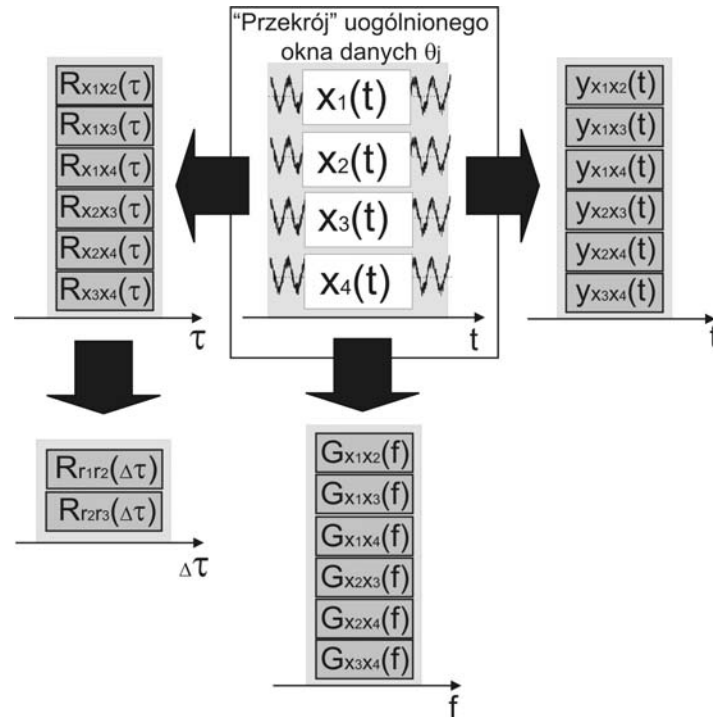
Na podstawie dodatkowego sygnału pomocniczego (4.4) opisującego chwilowe przemieszczenie wału (promień trajektorii  $r$ ) w czasie "mikro" możliwe jest np. wyznaczenie wartości cechy punktowej, którą może być "maksymalne przemieszczenie wału"  $r_{max}(\theta_j) = \max_t(r(t)|_{\theta_j})$ . Cecha ta jest przykładem cechy łącznej dwóch sygnałów.

Pokazany przykład wyznaczania dodatkowego sygnału pomocniczego jest jednym z wielu możliwych sposobów przekształcania wartości sygnałów określonych w tych samych chwilach czasu "mikro" do postaci nowego sygnału, którego wartości również określone są w tych samych chwilach czasu "mikro". Takie postępowanie jest poprawne, lecz ogranicza pole możliwych rozwiązań wyznaczania dodatkowych sygnałów pomocniczych. Można zauważyć, że jednym z zadań obejmowanych przez proponowaną koncepcję łącznej analizy sygnałów jest wyznaczanie cech punktowych zarówno sygnałów obserwowanych, jak i również dodatkowych sygnałów pomocniczych. Wyznaczenie cechy punktowej każdego sygnału określonego w czasie "mikro" w pewnej chwili czasu "makro" skutkuje tym, że otrzymuje się jedną wartość liczbową (wartość sygnału) określoną jedynie w czasie "makro". Wynika z tego, że dodatkowe sygnały pomocnicze, pomimo że wyznaczone są na podstawie wartości sygnałów opisanych w chwilach czasu "mikro" związanych z wartościami czasu rzeczywistego, takimi jak np. sekunda, mikrosekunda, wcale nie muszą być określane w tej samej dziedzinie czasu "mikro". Dziedzina czasu "mikro" dla dodatkowych sygnałów pomocniczych może być określona np. przez wartości opóźnień czasowych  $\tau = \Delta t = t_{i+1} - t_i$ , przy których określane są wartości funkcji korelacji wzajemnej dwóch sygnałów. Zatem w myśl powyższych rozważań cechy funkcyjne innych sygnałów, np. funkcja korelacji wzajemnej wyznaczona na podstawie dwóch dowolnych sygnałów obserwowanych, mogą być traktowane jako dodatkowy sygnał pomocniczy, na podstawie którego możliwe jest wyznaczenie cech punktowych, np. wartości średniej. Możliwe jest również traktowanie dodatkowych sygnałów pomocniczych jako cech funkcyjnych w dziedzinie częstotliwości, np. wzajemnych widm mocy wybranych par sygnałów obserwowanych. Cechami punktowymi takich sygnałów mogą być np. wartości mocy w pewnych określonych pasmach częstotliwości.

Możliwa jest również sytuacja, w której dodatkowe sygnały pomocnicze stanowią podstawę do wyznaczenia innych dodatkowych sygnałów pomocniczych. Przykład takiego postępowania można znaleźć m. in. w [173, 72, 71, 70]. Dodatkowymi sygnałami pomocniczymi były trajektorie środka czopa reprezentowane w postaci dwuwymiarowego sygnału zespolonego. Wyznaczane były korelacje oraz widma wzajemne tych sygnałów. Pozwalało to na wyznaczenie dodatkowych sygnałów pomocniczych jako funkcji modułu i argumentu funkcji korelacji wzajemnej oraz funkcji modułu i fazy widma wzajemnego sygnałów zespolonych. Z powyższych rozważań wynika, że wprowadzenie dodatkowych sygnałów pomocniczych pozwala (w szczególnych przypadkach) na zmianę dziedziny czasu "mikro", zatem można przyjąć, że zbiór dodatkowych sygnałów pomocniczych będzie obejmował podzbiory sygnałów opisanych w różnych dziedzinach czasu "mikro". Każdorazowe wyznaczenie zbioru dodatkowych sygnałów pomocniczych w innej dziedzinie czasu "mikro" związane jest z utworzeniem nowego uogólnionego okna danych. Należy zaznaczyć, że ze względu na trudności interpretacyjne nie jest możliwe wyznaczanie dodatkowych sygnałów pomocniczych na podstawie dodatkowych sygnałów pomocniczych opisanych w różnych dziedzinach czasu "mikro". Przykłady różnych



sposobów prowadzących do pozyskania dodatkowych sygnałów pomocniczych przedstawiono na rysunku 4.6.



Rys. 4.6. Możliwości wyznaczania dodatkowych sygnałów pomocniczych

Dodatkowe sygnały pomocnicze mogą być również wyznaczane na podstawie przetwarzania większej liczby sygnałów obserwowanych niż dwa. W [68] przedstawiono możliwość wyznaczania dodatkowych sygnałów pomocniczych na podstawie funkcji korelacji wzajemnej trzech sygnałów obserwowanych. Prowadzono również badania nad możliwością zastosowania jako dodatkowych sygnałów pomocniczych, innych cech funkcyjnych (np. koherencję wielokrotną, bispectrum, trispectrum itp.) Wyniki, które uzyskano, nie wykluczają możliwości stosowania takiego sposobu pozyskiwania dodatkowych sygnałów pomocniczych. Z przeprowadzonych badań wynikają jednak istotne trudności w interpretacji wyników, dlatego w dalszej części pracy nie rozważano tego typu sygnałów, ograniczając się do prostych przykładów ilustrujących znacznie lepiej istotę proponowanego postępowania. Możliwość definiowania dodatkowego sygnału pomocniczego na podstawie liczby sygnałów obserwowanych większej od dwóch może być przedmiotem odrębnych badań.

W pewnych przypadkach interpretacja niektórych dodatkowych sygnałów pomocniczych może być trudna, szczególnie wtedy, gdy utworzone zostały w wyniku systematycznego przeszukiwania pola możliwych rozwiązań. Sygnały te jednak mogą być źródłem istotnych wartości cech podczas prowadzenia procesu klasyfikacji stanu maszyny.

Istotą postępowania przy wyznaczaniu zbioru dodatkowych sygnałów pomocniczych jest pozyskanie jak największej liczby informacji o wzajemnych zależnościach między sygnałami obserwowanymi przy jednoczesnym ograniczeniu powtarzających się informacji. Zatem liczba dodatkowych sygnałów pomocniczych może (w pewnych przypadkach) przekraczać liczbę

sygnałów, na podstawie których zostały wyznaczone. Zbiór dodatkowych sygnałów pomocniczych należy traktować tylko i wyłącznie jako podstawę do wyznaczenia przestrzeni wartości łącznych cech punktowych, będących źródłami danych do dalszej analizy, prowadzącej do określania stanu technicznego maszyny.

#### 4.2.2. Zbiór rozpatrywanych cech sygnałów

Informację diagnostyczną niesioną przez sygnały oddziaływań zewnętrznych oraz dodatkowe sygnały pomocnicze można wydobyć poprzez ich ocenę. Aby dokonać estymacji cech tych sygnałów, należy określić zbiór rozpatrywanych cech, których wartości posłużą do oceny zmian stanu technicznego obiektu.

Przy określaniu zbioru uwzględnianych cech należy brać pod uwagę ilość informacji dostarczanych przez te cechy. Elementami rozpatrywanego zbioru cech mogą być zarówno cechy punktowe (np. amplituda skuteczna), jak i cechy funkcyjne (np. częstotliwościowe widmo gęstości mocy sygnału). Można przyjąć, że ze względu na stosowanie numerycznych metod przetwarzania wartości cech sygnałów wartości cech funkcyjnych zapisywane są jako zbiory wartości odpowiednio określonych cech punktowych (np. wartość widma zapisywana jest jako zbiór wartości prążków widma dyskretnego). Uproszczenie to pozwala na przyjęcie założenia, iż rozpatrywanym zbiorem cech będzie zbiór cech punktowych.

Większość informacji o progowych wartościach występujących w definicjach symptomów diagnostycznych maszyn wirnikowych [141, 31, 37] pozyskiwana jest na podstawie cech punktowych. Wśród dostępnych i znanych cech punktowych sygnałów są cechy amplitudowe [50], posiadające pewien wymiar fizyczny, oraz cechy bezwymiarowe. W gruncie rzeczy cechy bezwymiarowe wyznaczane są przy wykorzystaniu cech amplitudowych, posiadających swój wymiar fizyczny (np. współczynnik szczytu). Cechy punktowe wyznaczane są głównie poprzez stosowanie określonych statystycznych miar zmienności. Najczęściej stosowane w diagnostyce maszyn cechy punktowe sygnałów zestawiono w tabeli 4.1.

Zbiór rozpatrywanych cech nie musi się ograniczać tylko do cech punktowych przedstawionych powyżej. Możliwe jest stosowanie indywidualnego podejścia przy wyznaczaniu cech punktowych, wynikającego np. ze specyfiki prowadzonych badań.

Z uwagi na znaczną liczebność rozpatrywanego zbioru cech, mogącą wpływać niekorzystnie na sprawność klasyfikacji stanu maszyn, stosowane są metody poszukiwania optymalnego zbioru rozpatrywanych cech. Jednym z kryterium budowy optymalnego zbioru rozpatrywanych cech jest założenie, że cechy powinny charakteryzować się dużą wrażliwością na zmiany stanu technicznego maszyny, ponieważ zaobserwowane zmiany stwarzają szansę na odpowiednie wykrycie i rozpoznanie zmian stanu. Nie ma jednoznacznie opisanej metodyki określania optymalnego zbioru rozpatrywanych cech, z uwagi na różnorodność cech, będących w obszarze zainteresowania diagnostyki technicznej. W większości przypadków przy wyznaczaniu optymalnego zbioru cech wystarcza zastosowanie algorytmów heurystycznych. Stąd istnieje potrzeba podejścia do każdego zadania wyboru cech w sposób indywidualny, z uwzględnieniem wartości, jakie mogą przyjmować sygnały diagnostyczne i cechy stanu.

Wybór uwzględnianych cech można traktować jako zadanie, którego celem jest wyznaczenie przekształcenia  $m$  wymiarowej przestrzeni wartości cech w przestrzeń  $n$  wymiarową

Tab. 4.1. Wybrane cechy punktowe stosowane w diagnostyce maszyn

Nazwa cechy	Definicja cechy
Wartość średnia	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
Wartość średnia bezwzględna	$x_{ave} = \frac{1}{n} \sum_{i=1}^n  x_i $
Wartość średnio kwadratowa	$x_{ms} = \frac{1}{n} \sum_{i=1}^n (x_i)^2$
Wartość skuteczna	$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i)^2}$
Wariancja	$\sigma = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
Odchylenie standartowe	$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
Wartość szczytowa bezwzględna	$x_{peak} = \max\ x[n]\ $
Wartość szczytowa dodatnia	$x_{peak+} = \max(x[n])$
Wartość szczytowa ujemna	$x_{peak-} = \min(x[n])$
Wartość międzyszczytowa	$x_{p-p} = x_{peak+} - x_{peak-}$
Bezwymiarowy współczynnik kształtu	$K = \frac{x_{rms}}{\bar{x}}$
Bezwymiarowy współczynnik szczytu	$C = \frac{x_{peak}}{x_{rms}}$
Bezwymiarowy współczynnik impulsowości	$I = \frac{x_{peak}}{\bar{x}}$
Bezwymiarowy współczynnik luzu	$L = \frac{x_{peak}}{x_{sqrt}}$
Asymetria	$\mu_3 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^3$
Kurtoza	$\mu_4 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^4$

gdzie  $n < m$ . Wybór rozpatrywanych cech związany jest z określeniem kryteriów ich wyboru obejmujących między innymi następujące czynniki [46]:

- informację stanowiącą podstawę wyboru,
- rodzaj wybieranych cech,
- zależności między cechami.

### Podstawa wyboru cech

Za podstawę do wyboru rozpatrywanych cech można przyjąć dwie grupy metod: metody wyboru z nauczycielem oraz bez nauczyciela.

Wybór z nauczycielem realizowany jest na podstawie próby uczącej zawierającej  $p$  sklasyfikowanych zbiorów  $\mathbf{V}_m$  wartości  $m$  cech wraz z przypisanym do każdego z tych zbiorów identyfikatorem klasy stanu technicznego obiektu. Na podstawie dostępnych danych wzorcowych zawierających sklasyfikowane zbiory wartości cech możliwe jest określenie przekształcenia  $m$  wymiarowej przestrzeni wartości cech w przestrzeń  $n$  wymiarową, której wartości powinny spełniać następujące warunki:

- wartości cech powinny znacząco różnić się od wartości takich cech wyznaczonych dla przykładów innych klas stanów,

- wartości cech powinny nieznacznie różnić się od wartości takich cech wyznaczonych dla innych przykładów z tej samej klasy stanów.

Pojęcia "znaczaco" i "nieznacznie" są pojęciami nieprecyzyjnymi, można je sformalizować, bazując na pojęciach, takich jak rozproszenie w grupie i rozproszenie międzygrupowe, zaczerpniętych z algorytmów automatycznego grupowania obiektów [46, 88, 156].

Wszystkie metody wyboru wartości cech z nauczycielem można potraktować jako przypadki ogólnej koncepcji opartej na tzw. funkcjach dyskryminacyjnych i podzielić na trzy grupy [88]:

- metody wynikające z teorii statystycznych funkcji decyzyjnych, np. Bayesowska reguła klasyfikacyjna, metoda największej wiarygodności,
- metody oparte na funkcjach dyskryminacyjnych, np. metoda aproksymacji stochastycznej,
- metody oparte na pojęciu minimalnej odległości oraz analizie dyskryminacyjnej, np. metoda Fishera.

Wybór cech bez nauczyciela może obejmować dwa ogólne przypadki:

- gdy występuje tylko zbiór wartości  $m$  cech w określonej chwili czasu "makro".
- gdy oprócz zbioru wartości  $m$  cech w określonej chwili czasu "makro" występuje również tzw. niesklasyfikowana próba ucząca zawierająca  $p$  przykładów wartości cech  $\mathbf{V}_m$ , w przypadku których nie znamy identyfikatorów klas stanów opisujących te cechy. Mogą występować jednak (ale nie muszą) pewne dodatkowe informacje (np. dotyczące środków ciężkości klas).

W przypadku, gdy występuje niesklasyfikowana próba ucząca, można:

- w wyniku stosowania metod wyboru wartości cech bez nauczyciela dokonać klasyfikacji próby uczącej, a następnie, opierając się na metodach wyboru wartości cech z nauczycielem, znaleźć przekształcenie zbioru  $m$  wartości cech w przestrzeń  $n$  wartości cech.
- połączyć rozpatrywany zbiór wartości cech w określonej chwili czasu "makro" z próbą uczącą i za pomocą metod wyboru cech bez nauczyciela dokonać wyboru cech.

Metody wyboru wartości cech bez nauczyciela można podzielić na [88]:

- metody opisowe, obejmujące metody grupowania oraz uogólnione metody grupowania oparte na klasyfikacji rozmytej, np. skalowanie wielowymiarowe, analiza czynnikowa,
- metody stochastyczne; w zależności od możliwości adaptacji schematów losowania wartości cech podlegających wyborowi obejmują metody bazujące na podejściu "klasyfikacyjnym" oraz "mieszankowym",
- metody graficzne, polegające na przybliżonym przedstawianiu wielowymiarowego zbioru wartości cech na płaszczyźnie, tak aby można było dokonać wyboru wartości na podstawie wykresu (metodą wzrokową). Należą do nich np. analiza składowych głównych oraz głównych współrzędnych, metoda podwójnego wykresu.

### Rodzaj wybieranych cech

Do zbioru wartości cech  $\mathbf{V}_n$  mogą należeć:

- wartości będące elementami rozpartywanego zbioru wartości cech  $\mathbf{V}_m$ ,
- nowe wartości wyznaczane na podstawie transformacji zbioru wartości cech  $\mathbf{V}_m$ .

Wyznaczenie nowych wartości cech na podstawie zbioru wartości  $m$  cech wymaga zdefiniowania przekształcenia. Liczba możliwości przekształceń zbioru wartości sygnałów jest nieograniczona. Jednym z możliwych i najczęściej stosowanych przekształceń są przekształcenia liniowe.

### Zależności między wartościami cech

Przy wyborze wartości cech istotne jest uwzględnienie, czy istnieją zależności między tymi wartościami. W przypadku, gdy wartości cech nie są skorelowane, wybór uwzględnianych wartości cech dokonany może być na podstawie informacji o ich maksymalnej wariancji. Wybierane są zatem wartości cech charakteryzujące się maksymalną wariancją. Pomiedzy wartościami cech mogą zachodzić wzajemne relacje, zatem wybór cech powinien być poprzedzony identyfikacją wartości cech niezależnych przez poszukiwanie ortogonalnej przestrzeni wartości cech. Ze zbioru wartości cech niezależnych odrzucane są te wartości, które charakteryzują się najmniejszą wariancją.

#### 4.2.3. Optymalizacja przestrzeni wartości cech

Wynikiem oceny sygnałów oddziaływań zewnętrznych oraz dodatkowych sygnałów pomocniczych jest  $m$  wymiarowa przestrzeń wartości cech  $V^m$ . Liczba wymiarów przestrzeni wartości cech zależy od liczby rozpatrywanych cech, których może być bardzo dużo. Liczne badania opisywane w literaturze stwierdzają, że nadmierna liczba danych wejściowych pociąga za sobą wzrost szumów i zmniejszenie ogólnej sprawności klasyfikatora, dlatego konieczne jest ograniczenie liczby wymiarów przestrzeni wartości cech. Prosta sformalizowana metoda ograniczania liczby uwzględnianych cech polega na przekształceniu  $m$  wymiarowej przestrzeni wartości cech punktowych w  $n$  wymiarową przestrzeń cech głównych  $G^n$  i następnie określeniu ograniczonej przestrzeni wartości cech głównych.

Przestrzeń wartości cech głównych  $G^n$  charakteryzuje się tym, że jej osie są osiami głównymi rozpatrywanego zbioru punktów w przestrzeni wartości rozpatrywanych cech  $V^m$ . Przekształcenie przestrzeni wartości cech może być wyznaczone na podstawie macierzy kowariancji współrzędnych punktów w przestrzeni wartości cech, dla której wyznaczane są wartości własne i wektory własne. Wektory własne określają kierunki osi w przestrzeni cech głównych. Ze zbioru wyznaczonych wektorów własnych na podstawie kryteriów np. Kaisera i Cattela [52] dokonywany jest wybór tych wektorów własnych, którym odpowiadają największe wartości własne. Można posłużyć się innym kryterium wyboru wektorów własnych zgodnie z następującym wyrażeniem [43]

$$\frac{\lambda_h}{\lambda_1} \geq \beta \quad (4.5)$$

gdzie:

$\lambda_1$  – największa (pierwsza) wartość własna, w uporządkowanym ciągu nierosnących wartości własnych,

$\lambda_h$  – najmniejsza uwzględniana wartość własna w uporządkowanym ciągu nierosnących wartości własnych

$\beta$  – stała przyjmowana arbitralnie;  $0.1 \geq \beta \geq 0.01$ .

Na podstawie określonych wektorów własnych można ograniczyć przestrzeń wartości cech, poprzez zastosowanie przekształcenia liniowego opisanego następującym wyrażeniem:

$$g_n = \sum_{m=1}^{m=M} a_{n,m} v_m \quad (4.6)$$

gdzie:


$a_{n,m}$  –  $m$ -ty element  $n$ -tego wektora własnego,

$v_m$  – wartość  $m$ -tej cechy ,

$g_n$  – wartość nowej  $n$ -tej cechy ,

Współczynniki przekształcenia liniowego określone są na podstawie wektorów własnych przestrzeni wartości cech głównych. Innym sposobem ograniczenia przestrzeni wartości cech może być ich grupowanie w klasy cech podobnych i na ich podstawie określenie reprezentantów klas. Ograniczonym zbiorem uwzględnianych cech jest zbiór reprezentantów klas. Zaletą takiego postępowania jest to, że wybrane cechy są elementami wyznaczanego podczas badań zbioru cech, a nie liniowymi kombinacjami tych cech


Przyjęto, że podstawą do wyznaczania optymalnej przestrzeni wartości cech punktowych będzie zbiór danych uczących. Elementami zbioru danych uczących są cechy punktowe wyznaczone w wyniku estymacji sygnałów oddziaływań zewnętrznych oraz dodatkowych sygnałów pomocniczych w wybranych przekrojach uogólnionego okna danych. Zbiór danych uczących pozyskiwany jest w wyniku bezpośrednich badań obiektu lub eksperymentu numerycznego prowadzonego na modelu strukturalnym obiektu. Aby otrzymać optymalną przestrzeń wartości cech, należy poszukiwać maksimum funkcji kryterialnej. Przez optymalną przestrzeń wartości cech należy rozumieć taką, w której rozproszenie wartości cech należących do każdej z  $S$  klas stanów jest małe, natomiast rozproszenie między grupami cech należących do różnych klas stanów jest duże. Wyjaśnia to rysunek 4.7 przedstawiający dwuwymiarową przestrzeń wartości cech dla dwóch klas stanu.



Rys. 4.7. Optymalna dwuwymiarowa przestrzeń wartości cech

W celu rozwiązania problemu optymalizacji przestrzeni wartości cech można posłużyć się metodami opartymi na analizie dyskryminacyjnej, której twórcą jest Fisher. Jeśli ograniczyć rozważania do dwóch klas stanów reprezentowanych przez przestrzeń wartości cech wyznaczoną dla rozpatrywanych sygnałów, analiza dyskryminacyjna polega na znalezieniu

kierunku takiej osi, na którą rzutowane wartości cech będą maksymalnie oddalone w porównaniu z odległością między ich rzutami na dowolne inne proste. Zadanie polega zatem na rzutowaniu dwóch zbiorów na taką prostą, aby stosunek odległości między średnimi zbiorów do ich rozproszień wewnętrznych był maksymalny (rys. 4.8). Problem dwuklasowy można



Rys. 4.8. Idea analizy dyskryminacyjnej

uogólnić na przypadek wieloklasowy w  $n$ -wymiarowej przestrzeni wartości cech określonej na podstawie danych uczących. Problem sprowadza się do znalezienia takiej podprzestrzeni, w której rozproszenie całkowite wartości cech będzie maksymalne w porównaniu z zewnętrznymi rozproszeniami zbiorów w tej podprzestrzeni [156].

### Kryterium optymalizacji przestrzeni cech

Metody optymalizacji przestrzeni wartości cech wyznaczane na podstawie kryteriów dyskryminacyjnych można znaleźć w literaturze [156, 43]. Dla potrzeb badań przyjęto, że poszukiwanie optymalnej przestrzeni wartości cech będzie oparte na rozszerzonym kryterium Fishera. Rozszerzone kryterium Fishera dla problemu dwuklasowego pozwala na ocenianie dyskryminacji klas wzdłuż wektora  $\mathbf{d}$  przy uwzględnieniu statystyk pierwszego i drugiego rzędu. Wyraża się ono w następujący sposób:

$$F(\mathbf{d}) = \frac{\mathbf{d}^T \mathbf{B} \mathbf{d}}{\mathbf{d}^T \mathbf{C} \mathbf{d}} + \frac{|\mathbf{d}^T \mathbf{C}^{(-)} \mathbf{d}|}{\mathbf{d}^T \mathbf{C} \mathbf{d}} = \frac{[\mathbf{d}^T (\bar{\mathbf{x}}_1 - \bar{\mathbf{x}}_2)]^2}{\mathbf{d}^T \mathbf{C} \mathbf{d}} + \frac{|\mathbf{d}^T \mathbf{C}^{(-)} \mathbf{d}|}{\mathbf{d}^T \mathbf{C} \mathbf{d}} \quad (4.7)$$

gdzie:

$$\mathbf{C}^{(-)} = \mathbf{C}_1 - \mathbf{C}_2 \text{ lub } \mathbf{C}_2 - \mathbf{C}_1$$

$\mathbf{C}_1, \mathbf{C}_2$  – macierze kowariancji kolejno pierwszej i drugiej klasy wartości cech

$\mathbf{C}$  – macierz kowariancji całego zbioru wartości cech.

Wektor  $\mathbf{d}$ , dla którego miara (4.7) osiąga maksimum, wskazuje najlepszy kierunek dyskryminacyjny w sensie rozszerzonego kryterium Fishera. Optymalizacja transformacji według tego kryterium sprowadza się do rozwiązania zagadnienia własnego. Z uwagi na występowanie w (4.7) wartości bezwzględnej, rozwiązanie należy wyznaczyć na podstawie następujących dwóch równań:

$$\mathbf{C}^{-1}(\mathbf{B} + \mathbf{C}_{12}^{(-)})\mathbf{d}_1 = \lambda_1 \mathbf{d}_1, \quad \mathbf{C}_{12}^{(-)} = \mathbf{C}_1 - \mathbf{C}_2 \quad (4.8)$$

$$\mathbf{C}^{-1}(\mathbf{B} + \mathbf{C}_{21}^{(-)})\mathbf{d}'_1 = \lambda'_1 \mathbf{d}'_1, \quad \mathbf{C}_{21}^{(-)} = \mathbf{C}_2 - \mathbf{C}_1 \quad (4.9)$$

Po obliczeniu pierwszych największych wartości własnych, jako właściwe spośród (4.8),(4.9) wybiera się to, dla którego wartość własna spośród  $\lambda_1$  i  $\lambda'_1$  jest większa. Odpowiednio dla tej wartości własnej wyznacza się wektor własny,  $d_1$ . Wartość dyskryminacyjna wektora  $d_1$  jest określona przez jego wartość własną i wyraża się wzorem

$$F(\mathbf{d}_1) = \max\{\lambda_1, \lambda'_1\} = \frac{\mathbf{d}_1^T \mathbf{B} \mathbf{d}_1}{\mathbf{d}_1^T \mathbf{C} \mathbf{d}_1} + \frac{|\mathbf{d}_1^T \mathbf{C}^{(-)} \mathbf{d}_1|}{\mathbf{d}_1^T \mathbf{C} \mathbf{d}_1} \quad (4.10)$$

Rozpatrując problem wieloklasowy, można skorzystać z uogólnień miar dwuklasowych. Często stosowanym sposobem rozwiązywania problemów wieloklasowych jest odpowiednie sumowanie miar dwuklasowych obliczonych po wszystkich klasach. Prowadzi to do następującej miary wieloklasowej, którą można nazywać uogólnioną uśrednioną miarą Fishera:

$$F(\mathbf{d}) = \sum_{i=1}^S \sum_{j=1}^S F_{ij}(\mathbf{d}) \quad (4.11)$$

gdzie:

$$F_{ij}(\mathbf{d}) = \frac{\mathbf{d}^T \mathbf{B}_{ij} \mathbf{d}}{\mathbf{d}^T \mathbf{C}_{ij} \mathbf{d}} + \frac{|\mathbf{d}^T \mathbf{C}_{ij}^{(-)} \mathbf{d}|}{\mathbf{d}^T \mathbf{C}_{ij} \mathbf{d}} \quad (4.12)$$

jest kryterium Fishera dla pary klas  $x_i, x_j$

$$\mathbf{C}_{ij}^{(-)} = \mathbf{C}_i - \mathbf{C}_j$$

$$\mathbf{C}_{ij} = \mathbf{C}_i + \mathbf{C}_j$$

$$\mathbf{B}_{ij} = [(\bar{x}_i - \bar{x}_j)^2]$$

Do znajdowania optymalnych przestrzeni cech, zarówno dla problemów dwu jak i wieloklasowych, można stosować różne formy kryterium Fishera opisane m. in. w [156].

Znalezienie optymalnej przestrzeni wartości cech punktowych pozwala na ograniczenie przestrzeni wartości cech, a następnie na wyznaczenie klasyfikatora stanu obiektu na podstawie ograniczonej przestrzeni wartości cech.

#### 4.2.4. Klasyfikacja stanu obiektu

Podczas prowadzenia badań diagnostycznych maszyny wirnikowej nie posiadamy informacji a priori o przynależności wyznaczanych wartości cech sygnałów, w tym wartości cech głównych, do poszczególnych klas stanów. Jedyną informacją, na podstawie której możliwe jest określenie stanu obiektu i jego zmian, zawarta jest w zbiorze wartości cech wyznaczonych w przekrojach uogólnionego okna danych w określonych chwilach czasu "makro". Aby możliwe było wydobycie informacji o przynależności poszczególnych wartości cech w czasie "makro" do pewnych klas stanów, konieczne jest przeprowadzenie klasyfikacji. Klasyfikacja polega na przyporządkowaniu nieznannej wartości cechy do jednej ze wzorcowych klas stanu. O tym, w jaki sposób dokonywana będzie klasyfikacja, decydują kryteria jakimi, posłużono się przy budowie klasyfikatorów. Podstawowym kryterium decydującym o wyborze metody klasyfikacji jest informacja o charakterze rozpatrywanego zbioru danych. Dane służące do budowy klasyfikatora uzyskiwane są w wyniku badań, nazywanych badaniami uczącymi, które obejmują zbiór obiektów  $\mathbf{O}_S \subset \mathbf{O}$ . Wnioski, wynikające z analizy wyników badań uczących, uogólniane są na cały zbiór  $\mathbf{O}$ , co oznacza, że reguły klasyfikacji wyznaczone na podstawie tych danych będą uznawane za reguły klasyfikacji na cały zbiór obiektów  $\mathbf{O}$ . Badania uczące



obejmują zespół czynności pozwalających na identyfikację przynależności stanu obiektu do jednej z rozpatrywanych klas stanów. Wyniki takiej identyfikacji zapisywane są w postaci klasyfikatora  $\underline{c}^*(o)$ , nazywanego klasyfikatorem uczącym. Stosowane są następujące techniki wyznaczania klasyfikatorów uczących [46]:

- realizowany jest tzw. bierny eksperyment diagnostyczny [37], polegający na badaniu wybranych losowo maszyn bez wprowadzania modyfikacji ich stanu technicznego przez badacza, gdzie:
  - przynależność badanej maszyny do wybranej klasy określana jest na podstawie subiektywnej opinii specjalisty lub dodatkowych badań oceniających bezpośrednio stan obiektu,
  - przynależność badanych maszyn do klas określana jest na podstawie wyników grupowania ich cech, bez bezpośredniego oceniania stanów tych maszyn,
- realizowany jest tzw. czynny eksperyment diagnostyczny [37], polegający na badaniu maszyn, w których celowo wprowadzono odpowiednie zmiany symulujące rozpatrywane klasy stanów - w badaniach tych wartość klasyfikatora uczącego zadawana jest przez badacza.

Klasyfikację można przeprowadzić w oparciu o powszechnie znane metody rozpoznawania wzorców, opisane szeroko w literaturze [102, 43, 52, 53, 63, 156, 170, 88, 146]. Najczęściej stosowanymi metodami stosowanymi dla potrzeb klasyfikacji są klasyczne metody odległościowe. W metodach tych określenie relacji między wykrywanymi cechami sygnałów a cechami stanu jest związane z porównywaniem elementów przestrzeni wartości cech. Porównanie elementów polega na wyznaczeniu ich odległości i/lub podobieństw w przestrzeni cech. Związane jest to z wprowadzeniem odpowiedniej metryki zapisywanej jako odwzorowanie.

$$d : \mathbf{V} \times \mathbf{V} \longrightarrow \{r \in R^1 : r \geq 0\} \quad (4.13)$$

Problem doboru właściwej metryki (odległości) dla każdego zagadnienia należy rozpatrywać na drodze doświadczalnej. To, jaka miara odległości zostanie wybrana, ma znaczny wpływ na uzyskiwane wyniki klasyfikacji. Można rozpatrywać dwie najczęściej stosowane miary odległości: odległość euklidesową oraz odległość Mahalanobiusa.

Odległość euklidesowa jest najczęściej stosowaną metryką i wyznaczana jest na podstawie następującej zależności:

$$d_1^2 = (\mathbf{v}_1 - \mathbf{v}_2)(\mathbf{v}_1 - \mathbf{v}_2)^T \quad \forall \mathbf{v}_1, \mathbf{v}_2 \in \mathbf{V} \quad (4.14)$$

Metryka euklidesowa ma pewne niedogodności wynikające z dużego wpływu zmian skal współrzędnych na wyniki grupowania. O zastosowaniu metryki euklidesowej może decydować przyjęcie założenia o izotropowości przestrzeni cech oraz to, że przestrzeń wartości cech łącznych jest przestrzenią powstałą w wyniku obrotu układu współrzędnych do położenia, w którym jego osie pokrywają się z kierunkami osi głównych, wyznaczonych przez wektory własne.

Przyjęcie założenia o ortogonalności osi układu współrzędnych opisującego przestrzeń wartości cech głównych nie zawsze jest prawdziwe. Brak ortogonalności może być spowodowane niedokładnością obliczeń numerycznych prowadzących do wyznaczenia wartości i wektorów własnych. W takich przypadkach celowe wydaje się zastosowanie odległości Mahalanobisa zdefiniowanej jako:

$$d_3^2 = (\mathbf{v}_1 - \mathbf{v}_2)\mathbf{C}^{-1}(\mathbf{v}_1 - \mathbf{v}_2)^T \quad \forall \mathbf{v}_1, \mathbf{v}_2 \in \mathbf{V} \quad (4.15)$$

gdzie:

$\mathbf{C}^{-1}$  odwrotna macierz kowariancji

Przypisywanie elementu do określonej klasy stanu dokonywane jest na podstawie algorytmów odległościowych. Najczęściej spotykany jest algorytm najbliższego sąsiada NN (ang. Nearest Neighbour). Klasyfikacja polega na zaliczeniu rozpoznawanego obiektu do klasy uszkodzeń, z której wywodzi się wzorzec położony najbliżej w przestrzeni cech. Ze względu na dużą wrażliwość na błędy wynikające ze złej klasyfikacji lub znaczne błędy pomiarowe (powodujące znaczne oddalenie pojedynczej próbki od populacji danej klasy) stosuje się zmodyfikowany algorytm NN w postaci algorytmu  $k$  najbliższych sąsiadów ( $k$ -NN). Zalicza on rozpoznawany obiekt do tej klasy, która jest najliczniej reprezentowana wśród  $k$  najbliższych jemu obrazów cech ze zbioru uczącego [102]. Opisane algorytmy są proste w realizacji na maszynach cyfrowych oraz dają dobre wyniki rozpoznawania.

## Rozdział 5

# Przykład zastosowania proponowanej koncepcji

W rozdziale opisano jeden ze sposobów zastosowania koncepcji (por. rozdz. 4) łącznej analizy sygnałów diagnostycznych. Rozdział zawiera opis sposobu pozyskania sygnałów diagnostycznych, metodykę postępowania przy analizie sygnałów oraz obszernie zestawienie i opis uzyskanych wyników badań.

Początek niniejszego rozdziału obejmuje sformułowanie zadania badawczego oraz szczegółową charakterystykę sposobu realizacji czynnego eksperymentu diagnostycznego, w wyniku którego pozyskano sygnały diagnostyczne stanowiące podstawę dalszych badań. Opis dotyczący czynnego eksperymentu diagnostycznego obejmuje m. in.: charakterystykę stanowiska badawczego, które uruchomiono w Laboratorium Diagnostyki Technicznej Katedry Podstaw Konstrukcji Maszyn, rodzaje symulowanych niesprawności oraz charakterystykę i sposób budowy zbioru sklasyfikowanych przykładów uczących, niezbędnych do prowadzenia badań.

W drugiej części rozdziału szczegółowo przedstawiono metodykę analizy sygnałów diagnostycznych. Omówiono sposób wyznaczania dodatkowych sygnałów pomocniczych oraz zdefiniowano zbiory sygnałów poddawanych analizie. Wskazano cechy, które posłużyły do oceny sygnałów oraz omówiono sposób ograniczenia przestrzeni wartości cech. Określono także sposób, w jaki przekształcano wyznaczone przestrzenie wartości cech do przestrzeni wartości cech głównych oraz scharakteryzowano każdą z rozpatrywanych przestrzeni wartości cech głównych. Przedstawiono opis budowy klasyfikatora uczącego na podstawie wyznaczonych wartości cech głównych oraz sposób oceny jego sprawności.

Trzecia część rozdziału zawiera szczegółowy opis wyników uzyskanych badań. Zamieszczono w niej liczne rysunki przedstawiające przykłady dwuwymiarowych przestrzeni wartości cech głównych, wyznaczone dla sygnałów jedno- oraz wielokanałowych. Wyniki klasyfikacji stanu maszyny na podstawie wyznaczanych przestrzeni wartości cech głównych zestawiono w licznych tabelach. Dokonano porównania wyników klasyfikacji uzyskanych na podstawie analizy pojedynczych sygnałów z wynikami uzyskanymi na podstawie łącznej analizy wielu sygnałów. Rozdział zamyka opis i charakterystyka możliwości oceny zmian stanu technicznego maszyny na podstawie trajektorii w przestrzeni wartości cech głównych. Opis ten zilustrowano rysunkami przedstawiającymi przykładowe trajektorie wartości cech w dwuwymiarowych przestrzeniach wartości cech głównych. Trajektorie te wyznaczono na podstawie współczynników przekształcenia liniowego, uzyskanych w wyniku badań uczących dla wybranych sygnałów wielokanałowych.

## 5.1. Opis zadania badawczego

Z punktu widzenia systemów monitorowania maszyn wirnikowych istotną sprawą jest udostępnienie operatorowi jednoznacznej informacji o stanie technicznym obiektu i historii zmian tego stanu. Informacje te gromadzone są w diagnostycznych bazach danych [130]. Nowoczesne systemy nadzoru [48] dysponują modułem wspomaganie podejmowania decyzji diagnostycznych. W module tym głównym elementem jest dynamiczny system doradczy [45, 130]. Informacje diagnostyczne w postaci cech sygnałów stanowią bardzo liczny zbiór danych, które trzeba przetworzyć, gromadzić i analizować. Z punktu widzenia sprawności wnioskowania diagnostycznego dąży się do ograniczania cech sygnałów diagnostycznych [52], nie ograniczając tym samym informacji o stanie technicznym obiektu. Zadaniem badawczym realizowanym przez autora jest określenie jakościowo nowych cech sygnałów wielokanałowych (cech łącznych), stanowiących źródło nowej i/lub równoważnej informacji diagnostycznej o stanie obiektu w porównaniu do informacji, która może być zdobyta w wyniku analizy sygnałów jednokanałowych. Zadanie badawcze polegało na wyznaczeniu przestrzeni wartości cech głównych sygnału wielokanałowego oraz przestrzeni wartości cech głównych sygnałów obserwowanych oddzielnie w każdym kanale, przeprowadzeniu klasyfikacji stanu na podstawie wyznaczonych wartości cech, a następnie porównaniu uzyskanych wyników klasyfikacji. Postępowanie takie miało na celu udowodnienie, że łączna analiza sygnałów daje lepsze wyniki przy określaniu stanu technicznego obiektu niż wielokrotne, niezależne analizy sygnałów jednokanałowych.

## 5.2. Plan badań

Określenie metody łącznej analizy sygnałów na podstawie zaproponowanej koncepcji wymagało przeprowadzenia licznych działań, których celem było:

- zaplanowanie czynnego eksperymentu badawczego mającego na celu pozyskanie zbioru sygnałów diagnostycznych,
- pozyskanie sygnałów diagnostycznych,
- określenie sposobu analizy pozyskanych sygnałów,
- przyjęcie szczegółowych rozwiązań dotyczących sposobu wyznaczania dodatkowych sygnałów pomocniczych, sposobu wyznaczania wartości cech dodatkowych sygnałów pomocniczych i ograniczania przestrzeni cech oraz sposobu budowy klasyfikatora,
- przygotowanie oprogramowania realizującego algorytmy obliczeniowe, według których prowadzono łączną analizę sygnałów,
- przeprowadzenie obliczeń, mających na celu wyznaczenie przestrzeni wartości cech głównych oraz przeprowadzenie klasyfikacji,
- ocena jakościowa i ilościowa uzyskanych wyników klasyfikacji.

### 5.3. Pozyskiwanie sygnałów diagnostycznych

Pozyskanie sygnałów diagnostycznych, niezbędnych do weryfikacji zaprezentowanej koncepcji łącznej analizy sygnałów, wymagało przeprowadzenia eksperymentu diagnostycznego.

Istnieją trzy rodzaje eksperymentu diagnostycznego [37]:

- czynny eksperyment diagnostyczny,
- czynno – bierny eksperyment diagnostyczny,
- bierny eksperyment diagnostyczny.

Eksperyment diagnostyczny obejmuje również badania opierające się na modelach numerycznych obiektów rzeczywistych, co pozwala na prowadzenie czynnego numerycznego eksperymentu diagnostycznego [104], polegającego na symulacji stanów i obserwacji ich symptomów.

Autor zdecydował się na prowadzenie czynnego eksperymentu diagnostycznego na obiekcie rzeczywistym, reprezentowanym przez laboratoryjny model maszyny wirnikowej znajdujący się w Laboratorium Diagnostyki Technicznej Katedry Podstaw Konstrukcji Maszyn.

Czynny eksperyment diagnostyczny polega na celowej zmianie dostępnych parametrów stanu (przyczyn) i dokonywaniu obserwacji skutków, jakie te zmiany powodują [37]. Prowadzenie tego typu eksperymentu na obiektach rzeczywistych w warunkach przemysłowych wymaga ingerencji w strukturę maszyny, co nie zawsze jest możliwe, a jeśli staje się możliwe, to jest niekorzystne (zmiana parametrów pracy maszyny) i nie zawsze jest źródłem mierzalnych informacji. Powyższe krytyczne podejście do sposobu prowadzenia czynnego eksperymentu diagnostycznego można złagodzić, przyjmując, że obiektem badań nie jest maszyna rzeczywista, lecz jej model laboratoryjny, w którym bez ingerencji w jego budowę możliwe jest zadawanie określonych rodzajów niesprawności i wpływanie w ten sposób na zmianę jego stanu.


#### 5.3.1. Stanowisko badawcze

Przygotowano stanowisko badawcze, które umożliwiło pozyskanie sygnałów niezbędnych do testowania i weryfikacji metody łącznej analizy sygnałów. W skład stanowiska badawczego weszły:

- obiekt poddawany badaniom,
- układ pomiarowy,
- układ akwizycji i analizy sygnałów.

Obiektem, na którym prowadzono badania, był model maszyny wirnikowej Rotor Kit (rys. 5.1) (w dalszych rozważaniach nazywany maszyną) firmy Bently Nevada.

W rozpatrywanym modelu wirnik posadowiony jest w dwóch łożyskach ślizgowych. Na wale możliwe jest zamontowanie w dowolnym miejscu jednej lub dwóch tarcz wirnikowych. Wirnik napędzany jest silnikiem, którego prędkość obrotowa może być zmieniana w szerokim zakresie. Układ sterowania silnika, poza płynną regulacją obrotów, zapewnia również pomiar prędkości obrotowej. Maszyna została posadowiona na ramie i zamocowana za pomocą czterech śrub do sztywnego fundamentu.



Rys. 5.1. Model maszyny wirnikowej poddany badaniom

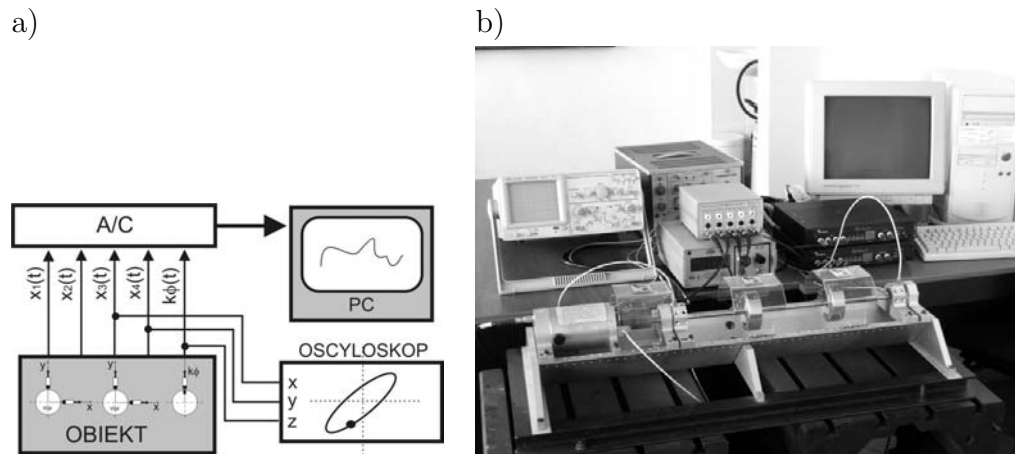
Rozpatrywany model maszyny umożliwia symulację takich typowych niesprawności maszyn wirnikowych jak:

- niewyważenie – przez montaż wkrętów o odpowiednich masach w równomiernie (co  $15^\circ$ ) rozmieszczonych otworach w tarczach wirnikowych. Możliwe jest symulowanie takich typowych przypadków niewyważenia jak: niewyważenie statyczne, momentowe i niewyważenie dynamiczne,
- przycieranie – przez wywoływanie tarcia pomiędzy powierzchnią wału maszyny i śrubą mosiężną zamocowaną na specjalnym suporcie,
- przeciążenie – przez montaż specjalnie do tego przystosowanej przystawki umożliwiającej wprowadzanie dodatkowych sił promieniowych w dowolnym punkcie wału,
- precesję hydrodynamiczną – przez montaż specjalnie zaprojektowanego łożyska hydrodynamicznego pozwalającego na sterowanie ciśnieniem i przepływem medium smarującego.

Poza badanym obiektem, w skład stanowiska wszedł również układ pomiarowy umożliwiający obserwację i rejestrowanie sygnałów drgań emitowanych przez działającą maszynę.

Układ pomiarowy (rys. 5.2) składał się z następujących elementów:

- cztery czujniki drgań względnych umożliwiające obserwację trajektorii środka czopa w dwóch podporach łożyskowych,
- czujnik wyróżnionego położenia kąowego wału,
- wielokanałowy układ demodulatora obsługujący wiroprądowe czujniki przemieszczeń,
- wielokanałowy układ przetwarzania, akwizycji i analizy sygnałów, na który składał się czterokanałowy przetwornik analogowy Siglab firmy DSP wraz z oprogramowaniem pracującym pod kontrolą oprogramowania MATLAB,
- oscyloskop,
- okablowanie.



Rys. 5.2. Schemat układu pomiarowego (a) i stanowisko badawcze (b)

### 5.3.2. Zakres czynnego eksperymentu badawczego

Eksperyment obejmował działania mające na celu pozyskanie zbioru sygnałów diagnostycznych podczas działania maszyny w różnych zadanych stanach technicznych. Zarejestrowane sygnały posłużą do wyznaczenia takiego zbioru przykładów uczących, na podstawie którego prowadzona będzie klasyfikacja stanu obiektu. Zdecydowano, że w ramach eksperymentu symulowane będą takie niesprawności jak niewyważenie i przycieranie. Wybór tych niesprawności podyktowany był tym, że występują one najczęściej w maszynach wirnikowych i dają się łatwo symulować na rozpatrywanym modelu laboratoryjnym maszyny wirnikowej.


Obiekt został skonfigurowany w taki sposób, aby możliwe było symulowanie różnych stanów wywołanych występowaniem niewyważenia oraz przycierania. W przypadku niewyważenia zdecydowano, że będzie symulowane niewyważenie statyczne oraz niewyważenie momentowe. Podczas występowania niewyważenia statycznego reakcje w sąsiadujących ze sobą podporach łożyskowych są zgodne co do faz. W przypadku niewyważenia momentowego reakcje łożysk są w przeciwfazie, co pozwala łatwo rozróżnić ten przypadek niewyważenia od niewyważenia statycznego. Przyjęcie wyżej wymienionych przypadków niewyważenia zapewniło pozyskanie sygnałów, których cechy pozwalały na czytelne rozróżnianie występujących stanów.

W przypadku symulacji przycierania nie dążono do uzyskania typowych symptomów występowania tego stanu. Symulowane było tylko lekkie przycieranie w celu wprowadzania niewielkich zakłóceń w działaniu maszyny. Założono, że zakłócenia te w niewielkim i niezauważalnym stopniu wpływają na zmianę stanu obiektu i są słabo rozpoznawalne podczas oceny sygnałów metodami powszechnie stosowanymi.

Pomiarów dokonywano na odpowiednio skonfigurowanym modelu maszyny, opierając się na przygotowanym planie eksperymentu.

### 5.3.3. Plan eksperymentu czynnego

Dla ustalonej konfiguracji obiektu (rys. 5.3) przyjęto stałą wartość prędkości wirowania wału 3000 [obr/min]. Na wale umieszczono dwie tarcze wirnikowe.



Rys. 5.3. Konfiguracja maszyny wirnikowej do badań

Po wstępnych badaniach przyjęto, że sygnały drgań obserwowane będą w pięciu kanałach. Kanały od nr 1 do nr 4 pozwalały na obserwację sygnałów z czujników drgań względnych, przy czym sygnały w kanałach nr 1 i nr 2 pozwalały na obserwację trajektorii środka czopa w łożysku  $L_1$ , natomiast sygnały w kanałach nr 3 i nr 4 na obserwację trajektorii środka czopa w łożysku  $L_2$ . Kanał nr 5 pozwalał na obserwację sygnału pochodzącego z czujnika wyróżnionego położenia wału. Wszystkie sygnały obserwowano w paśmie od 0 do 500Hz i próbkowano z częstotliwością  $f_s = 1280\text{Hz}$ . Rozdzielczość częstotliwościowa analizy wynosiła  $df = 0,156\text{Hz}$ . Liczba zarejestrowanych chwilowych wartości amplitud sygnałów w każdym kanale wynosiła 8192. Wartości sygnałów zapisano w plikach tekstowych o odpowiednim formacie.

Zarejestrowano zbiór przykładów sygnałów będących wynikiem 120 eksperymentów sklasyfikowanych w następujący sposób:

- $S_1$  – Obiekt sprawny – 24 przykłady,
- $S_2$  – Obiekt z występującym lekkim przycieraniem – 24 przykłady,
- $S_3$  – Obiekt z występującym niewyważeniem statycznym – 24 przykłady,
- $S_4$  – Obiekt z występującym niewyważeniem momentowym – 24 przykłady,
- $S_5$  – Obiekt z występującym niewyważeniem momentowym i lekkim przycieraniem – 24 przykłady,

Pliki z danymi oznaczano identyfikatorami, w których zakodowano informacje niezbędne dla dalszych badań. Przyjęto następujące kodowanie nazwy pliku:

**xxx-sx-mxx-pxx**



gdzie:

**xxx** – numer porządkowy przykładu,

**sx** – identyfikator stanu technicznego,

**mxx** – informacja o wartości masy niewyważenia,

**pxx** – identyfikator numeru przykładu w obrębie danej klasy stanu.

#### Stan $S_1$ – Obiekt sprawny

Za obiekt sprawny uznano maszynę, której wirnik został wyważony i maszyna działała bez żadnych dodatkowych zewnętrznych zakłóceń. Dane zapisano w plikach o następujących identyfikatorach:

001-s1-m00-p01, 002-s1-m00-p02, ... 024-s1-m00-p24


#### Stan $S_2$ – Obiekt z występującym lekkim przycieraniem

Za obiekt działający z lekkim przycieraniem uznano maszynę z wyważonym wirnikiem, pośrodku którego przyłożono aluminiową blachę, która stykając się z wirnikiem, wywoływała tarcie o jego powierzchnię. Dane zapisano w plikach o następujących identyfikatorach:

025-s2-m00-p01, 026-s2-m00-p02, ... 048-s2-m00-p24

#### Stan $S_3$ – Obiekt z występującym niewyważeniem statycznym

Za obiekt z występującym niewyważeniem statycznym uznano maszynę, w której tarczach wirnikowych umieszczono masy niewyważenia  $m = m_1 = m_2$  zgodnie z rysunkiem 5.4.



Rys. 5.4. Rozkład mas niewyważenia dla przypadku niewyważenia statycznego

Wartości mas niewyważenia zmieniano w celu symulacji różnych wariantów niewyważenia statycznego. Zbiór danych zapisano w plikach o następujących identyfikatorach:

049-s3-m01-p01, 050-s3-m01-p02, ... 054-s3-m01-p06 dla  $m_1 = m_2 = 0.1$  [g]

055-s3-m04-p01, 056-s3-m04-p02, ... 060-s3-m04-p06 dla  $m_1 = m_2 = 0.4$  [g]


061-s3-m08-p01, 062-s3-m08-p02, ... 066-s3-m08-p06 dla  $m_1 = m_2 = 0.8$  [g]

067-s3-m12-p01, 068-s3-m12-p02, ... 072-s3-m12-p06 dla  $m_1 = m_2 = 1.2$  [g]

Dla każdego z wariantów niewyważenia statycznego zarejestrowano po 6 przykładów.

### Stan $S_4$ – Obiekt z występującym niewyważeniem momentowym

Za obiekt z występującym niewyważeniem momentowym uznano maszynę, w której tarczach wirnikowych umieszczono masy niewyważań  $m = m_1 = m_2$  zgodnie z rysunkiem 5.5.



Rys. 5.5. Rozkład mas niewyważań dla przypadku niewyważenie momentowe

Wartości mas niewyważań zmieniano w celu symulacji różnych przypadków niewyważenia momentowego. Zbiór danych zapisano w plikach o następujących identyfikatorach:

073-s4-m01-p01, 074-s4-m01-p02, ... 078-s4-m01-p06 dla  $m_1 = m_2 = 0.1$  [g]

079-s4-m04-p01, 080-s4-m04-p02, ... 084-s4-m04-p06 dla  $m_1 = m_2 = 0.4$  [g]

085-s4-m08-p01, 086-s4-m08-p02, ... 090-s4-m08-p06 dla  $m_1 = m_2 = 0.8$  [g]

091-s4-m12-p01, 092-s4-m12-p02, ... 096-s4-m12-p06 dla  $m_1 = m_2 = 1.2$  [g]

Dla każdego z przypadków niewyważenia momentowego zarejestrowano po 6 przykładów.

### Stan $S_5$ – Obiekt z występującym niewyważeniem momentowym i lekkim przycieraniem

Stan ten jest stanem złożonym ( $S_2 + S_4$ ) i uzyskano go, symulując wcześniej opisane przypadki niewyważenia momentowego oraz przycierania. Zbiór danych zapisano w plikach o następujących identyfikatorach:

097-s5-m01-p01, 098-s5-m01-p02, ... 102-s5-m01-p06 dla  $m_1 = m_2 = 0.1$  [g]

103-s5-m04-p01, 104-s5-m04-p02, ... 108-s5-m04-p06 dla  $m_1 = m_2 = 0.4$  [g]

109-s5-m08-p01, 110-s5-m08-p02, ... 114-s5-m08-p06 dla  $m_1 = m_2 = 0.8$  [g]

115-s5-m12-p01, 116-s5-m12-p02, ... 120-s5-m12-p06 dla  $m_1 = m_2 = 1.2$  [g]

Dla każdego z rozpatrywanych przypadków stanu  $S_5$  zarejestrowano również po 6 przykładów.

Zaproponowany dobór niewyważań był celowy. Małe wartości mas niewyważań miały celowo w niewielkim stopniu pobudzać układ do drgań po to, aby uzyskać stan niewiele odbiegający od stanu uznanego za sprawny, czyli bez występujących sztucznie zadanych niewyważań. Celowo dążono do uzyskania stanów słabo od siebie rozróżnialnych (np. stany  $S_1$  i  $S_2$ ), aby

można było zweryfikować czy zaproponowana metoda pozwala i w jakim stopniu na rozpoznawanie stanów nierozróżnialnych. Wartość dopuszczalnej masy niewyważenia, jaka może zostać zamontowana na stanowisku badawczym, zależy od konfiguracji stanowiska tzn. od rozstawu podpór łożyskowych, liczby tarcz i zastosowanego zestawu łożysk ślizgowych). Dla konfiguracji stosowanej podczas badań, wartość dopuszczalna wynosiła 2 [g], przy czym nie zdecydowano się na stosowanie tak dużej masy niewywagi ze względu na techniczne bezpieczeństwo czujników drgań względnych - podczas przechodzenia wirnika modelu maszyny przez rezonans amplituda drgań wału w miejscu zamocowania czujników jest tak duża, że powierzchnia wału uderza w końcówkę czujnika wiroprowadowego. Może to uszkodzić osłonę cewki, a nawet doprowadzić do uszkodzenia czujnika.

## 5.4. Przykład zastosowania metody

Na podstawie zaproponowanej koncepcji łącznej analizy sygnałów (por. rozdz. 4) w dalszej części pracy rozpatrzono, jedną z wielu możliwych, metodę łącznej analizy sygnałów. Zdefiniowano zbiór rozpatrywanych sygnałów, przedstawiono szczegółowy sposób oceny tych sygnałów oraz przekształcania otrzymanych przestrzeni wartości cech. Opierając się na wyznaczonych wartościach cech sygnałów pozyskanych w wyniku czynnego eksperymentu diagnostycznego, określono zbiór uczący, na podstawie którego przeprowadzono klasyfikację stanu maszyny.

### 5.4.1. Zbiór rozpatrywanych sygnałów

Zgodnie z proponowaną koncepcją łącznej analizy sygnałów przyjęto, że dla potrzeb badań rozpatrywane będą zbiory sygnałów obejmujące sygnały oddziaływań zewnętrznych (sygnały obserwowane) oraz dodatkowe sygnały pomocnicze.

#### Zbiór sygnałów obserwowanych

Przeprowadzenie czynnego eksperymentu diagnostycznego pozwoliło przyjąć, że zbiór sygnałów obserwowanych jest zbiorem zawierającym sygnały oddziaływań zewnętrznych maszyny na otoczenie, zarejestrowane podczas jej działania jednocześnie w pięciu kanałach pomiarowych. Zatem, dla każdego przykładu należącego do zbioru przykładów uczących zbiór sygnałów obserwowanych można zdefiniować następująco:

$$\mathbf{X}(t)|_{\theta_j} = \{x_1(t)|_{\theta_j}, x_2(t)|_{\theta_j}, x_3(t)|_{\theta_j}, x_4(t)|_{\theta_j}, x_5(t)|_{\theta_j}\} \quad (5.1)$$

gdzie zgodnie z planem eksperymentu diagnostycznego (por. rozdz. 5.3.3):

$x_1(t)|_{\theta_j}$  – jest sygnałem obserwowanym w kanale nr 1, pochodzącym z czujnika drgań względnych umieszczonego w łożysku  $L1$  w kierunku poziomym  $x$ ,

$x_2(t)|_{\theta_j}$  – jest sygnałem obserwowanym w kanale nr 2, pochodzącym z czujnika drgań względnych umieszczonego w łożysku  $L1$  w kierunku pionowym  $y$ ,

$x_3(t)|_{\theta_j}$  – jest sygnałem obserwowanym w kanale nr 3, pochodzącym z czujnika drgań względnych umieszczonego w łożysku  $L2$  w kierunku poziomym  $x$ ,

$x_4(t)|_{\theta_j}$  – jest sygnałem obserwowanym w kanale nr 4, pochodzącym z czujnika drgań względnych umieszczonego w łożysku  $L2$  w kierunku poziomym  $y$ ,

$x_5(t)|_{\theta_j}$  – jest sygnałem obserwowanym w kanale nr 5, pochodzącym z czujnika znacznika wyróżnionego położenia kąтового wału.

Biorąc pod uwagę pary następujących sygnałów:  $x_1(t), x_2(t)$  i  $x_3(t), x_4(t)$ , możliwe jest wyznaczenie trajektorii środka czopa w łożyskach  $L1$  i  $L2$ .

### Dodatkowe sygnały pomocnicze

Przyjęto, że na podstawie sygnałów należących do zbioru sygnałów obserwowanych  $\mathbf{X}$  wyznaczy się dodatkowe sygnały pomocnicze tworzące następujące zbiory:

- Zbiór  $\mathbf{R}$  dodatkowych sygnałów pomocniczych będących funkcjami korelacji wzajemnych sygnałów obserwowanych. Zbiór ten można zdefiniować następująco:

$$\mathbf{R}(\tau)|_{\theta_j} = \{R_{1,2}(\tau), R_{1,3}(\tau), R_{1,4}(\tau), R_{1,5}(\tau), R_{2,3}(\tau), R_{2,4}(\tau), \dots, R_{2,5}(\tau), R_{3,4}(\tau), R_{3,5}(\tau), R_{4,5}(\tau)\} \quad (5.2)$$

Indeksy w oznaczeniach każdej z funkcji korelacji wzajemnej są zgodne z indeksami sygnałów obserwowanych. Proponowany zbiór  $\mathbf{R}$  dodatkowych sygnałów pomocniczych korelacji wzajemnych sygnałów obserwowanych jest górną macierzą trójkątną macierzy 5.3 wszystkich możliwych korelacji wzajemnych sygnałów obserwowanych:

$$\mathbf{R}(\tau)|_{\theta_j} = \begin{bmatrix} R_{1,1}(\tau) & R_{1,2}(\tau) & R_{1,3}(f) & R_{1,4}(\tau) & R_{1,5}(\tau) \\ R_{2,1}(\tau) & R_{2,2}(\tau) & R_{2,3}(f) & R_{2,4}(\tau) & R_{2,5}(\tau) \\ R_{3,1}(\tau) & R_{3,2}(\tau) & R_{3,3}(f) & R_{3,4}(\tau) & R_{3,5}(\tau) \\ R_{4,1}(\tau) & R_{4,2}(\tau) & R_{4,3}(f) & R_{4,4}(\tau) & R_{4,5}(\tau) \\ R_{5,1}(\tau) & R_{5,2}(\tau) & R_{5,3}(f) & R_{5,4}(\tau) & R_{5,5}(\tau) \end{bmatrix} \quad (5.3)$$

- Zbiór  $\mathbf{U}$ , zawierający dodatkowe sygnały pomocnicze, będące sygnałami opisującymi zmiany w funkcji czasu wartości promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  badanej maszyny (rys. 5.3 rozdz. 5.3.3). Zbiór ten ma następującą postać:

$$\mathbf{U}(t)|_{\theta_j} = \{u_{1,2}(t), u_{3,4}(t)\} \quad (5.4)$$

Indeksy dodatkowych sygnałów pomocniczych są zgodne z indeksami sygnałów obserwowanych, na podstawie których zostały wyznaczone. Dodatkowe sygnały pomocnicze  $u_{1,2}(t), u_{3,4}(t)$  promieni trajektorii środka czopa w łożyskach  $L1$  i  $L2$  wyznaczone zostały na podstawie zależności (4.4) (por. rozdz. 4.2.1).

- Zbiór  $\mathbf{RU}\phi$  dodatkowych sygnałów pomocniczych, będących funkcjami korelacji wzajemnych dodatkowych sygnałów pomocniczych  $u_{1,2}(t), u_{3,4}(t), x_5(t)$  promieni trajektorii środka czopa oraz sygnału wyróżnionego położenia wału. Zbiór ten można zdefiniować w następujący sposób:

$$\mathbf{RU}\phi(\tau)|_{\theta_j} = \{ru\phi_{1,2-3,4}(\tau), ru\phi_{1,2-5}(\tau), ru\phi_{3,4-5}(\tau)\} \quad (5.5)$$

- Zbiór  $\mathbf{RU}$ , zawierający jeden element, którym jest dodatkowy sygnał pomocniczy będący funkcją korelacji wzajemnej dodatkowych sygnałów pomocniczych  $u_{1,2}(t)$ ,  $u_{3,4}(t)$  opisujących promienie trajektorii obserwowanych w łożyskach  $L1$  i  $L2$  rozpatrywanego obiektu badań.

$$\mathbf{RU}(\tau)|_{\theta_j} = \{ru_{1,2-3,4}(\tau)\} \quad (5.6)$$

#### 5.4.2. Zbiór rozpatrywanych cech sygnałów

W celu określenia przestrzeni wartości cech  $V^m$ , która zgodnie z przyjętą koncepcją łącznej analizy sygnałów zostanie przekształcona do ograniczonej przestrzeni cech głównych  $G^n$ , konieczne jest zdefiniowanie zbioru  $\mathbf{V}$  rozpatrywanych cech. Przyjęto, że sygnały należące do zbioru  $\mathbf{X}$  sygnałów obserwowanych oraz do zbiorów  $\mathbf{R}$ ,  $\mathbf{U}$ ,  $\mathbf{RU}\phi$ ,  $\mathbf{RU}$  dodatkowych sygnałów pomocniczych zostaną poddane analizie. Analiza sygnałów polegała na wyznaczeniu ich cech punktowych<sup>1</sup>. Jako zbiór  $\mathbf{V}$  rozpatrywanych cech przyjęto zbiór, do którego należą cechy o nazwach i identyfikatorach wyszczególnionych w tabeli 5.1.

Tab. 5.1. Rozpatrywane cechy punktowe

Identyfikator	Nazwa cechy
$v_1$	Wartość średnia
$v_2$	Wartość średnia bezwzględna
$v_3$	Wartość średnio - kwadratowa
$v_4$	Wartość skuteczna
$v_5$	Wariancja
$v_6$	Odchylenie standardowe
$v_7$	Wartość szczytowa bezwzględna
$v_8$	Wartość szczytowa dodatnia
$v_9$	Wartość szczytowa ujemna
$v_{10}$	Wartość między-szczytowa
$v_{11}$	Współczynnik kształtu
$v_{12}$	Współczynnik szczytu
$v_{13}$	Współczynnik impulsowości
$v_{14}$	Współczynnik luzu
$v_{15}$	Asymetria
$v_{16}$	Kurtoza

Wartości cech obliczano na podstawie definicji poszczególnych cech przedstawionych w tabeli 4.1.

Rozpatrywany zbiór cech  $\mathbf{V}$  nie wyczerpuje wszystkich możliwości. Stosowanie przyjętego zbioru cech wobec niektórych z dodatkowych sygnałów pomocniczych może nie wnosić nowych

<sup>1</sup> Ograniczenie się tylko do cech punktowych wynikało z faktu, że cechy funkcyjne mogą być traktowane jako dodatkowe sygnały pomocnicze.

informacji i/lub prowadzić do trudności w interpretowaniu znaczenia wyznaczonych wartości. Z punktu widzenia własności funkcji korelacji wzajemnych, które traktowano jako dodatkowe sygnały pomocnicze, stosowanie niektórych ocen punktowych (np. wartość średniokwadratowa itp.) jest nieuzasadnione i ich wartości mogą zaszumiać informację diagnostyczną. Ze względu na przyjętą metodykę polegającą na systematycznym i konsekwentnym stosowaniu jednego zbioru wartości cech do wszystkich rozpatrywanych zbiorów sygnałów, zdecydowano, że w pierwszym etapie badań cechy te będą wyznaczane pomimo ich małej pojemności informacyjnej.

W celu estymacji dodatkowych sygnałów pomocniczych konieczne jest przeprowadzenie selekcji cech. Selekcji cech dokonano w dalszej części pracy. Przesłankami prowadzącymi do wyboru cech powinny być własności i właściwości wyznaczonych dodatkowych sygnałów pomocniczych. Bezkrytyczne i nieprzemyślane stosowanie do każdego z rozpatrywanych dodatkowych sygnałów pomocniczych wszystkich cech z przedstawionego zbioru  $\mathbf{V}$  może wprowadzać niepożądany szum informacyjny, wpływający niekorzystnie na sprawność klasyfikacji.

### 5.4.3. Przestrzeń wartości cech sygnałów

Na podstawie przyjętego zbioru  $\mathbf{V}$  rozpatrywanych cech przeprowadzono ocenę określonych zbiorów sygnałów dla każdego przykładu należącego do zbioru przykładów uczących. Wynikiem oceny były wielowymiarowe przestrzenie wartości cech  $V^m$ . Ze względu na cel badań, jakim było porównanie wyników analizy sygnałów jednokanałowych z wynikami łącznej analizy sygnałów wielokanałowych, rozważano wiele przypadków wielowymiarowych przestrzeni cech. Wyznaczane przestrzenie cech różniły się między sobą wartościami cech i liczbą wymiarów  $m$ . Wartości cech zależą od tego, który sygnał (sygnały) analizowano. Liczba wymiarów  $m$  przestrzeni wartości cech zależna jest od liczby rozpatrywanych cech oraz liczby rozpatrywanych sygnałów  $m = v * K$ . W tabeli 5.2 scharakteryzowano, wyznaczone w trakcie badań przestrzenie wartości cech, opierając się na zbiorze  $\mathbf{V}$  zawierającym  $v = 16$  cech. Podano również dane charakterystyczne wskazujące sposób wyznaczenia określonej przestrzeni wartości cech.

Rozpatrywane przestrzenie wartości cech oznaczono następująco:

$V_{x_1}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych w kanale nr 1,

$V_{x_2}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych w kanale nr 2,

$V_{x_3}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych w kanale nr 3,

$V_{x_4}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych w kanale nr 4,

$V_{x_{1,2}}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych jednocześnie w dwóch kanałach nr 1 i 2,

$V_{x_{2,4}}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych jednocześnie w dwóch kanałach nr 2 i 4,

Tab. 5.2. Charakterystyka wyznaczanych przestrzeni wartości cech

Oznaczenie przestrzeni $V^m$	$m$	Liczba sygnałów $K$	Liczba cech $v$	Zbiór ocenianych sygnałów
$V_{x_1}^m$	16	1	16	$\mathbf{X} = \{x_1\}$
$V_{x_2}^m$				$\mathbf{X} = \{x_2\}$
$V_{x_3}^m$				$\mathbf{X} = \{x_3\}$
$V_{x_4}^m$				$\mathbf{X} = \{x_4\}$
$V_{x_{1,2}}^m$	32	2	16	$\mathbf{X} = \{x_1, x_2\}$
$V_{x_{2,4}}^m$	32	2	16	$\mathbf{X} = \{x_2, x_4\}$
$V_{x_{1,2,3,4}}^m$	64	4	16	$\mathbf{X} = \{x_1, x_2, x_3, x_4\}$
$V_X^m$	80	5	16	$\mathbf{X}$
$V_R^m$	160	10	16	$\mathbf{R}$
$V_{R_{1,2}}^m$	16	1	16	$\mathbf{R} = \{R_{1,2}\}$
$V_{R_{2,4}}^m$	16	1	16	$\mathbf{R} = \{R_{2,4}\}$
$V_U^m$	32	2	16	$\mathbf{U}$
$V_{RU\phi}^m$	48	3	16	$\mathbf{RU}\phi$
$V_{X-U}^m$	112	7	16	$\mathbf{X} \cup \mathbf{U}$
$V_{X-R}^m$	240	15	16	$\mathbf{X} \cup \mathbf{R}$
$V_{X-RU\phi}^m$	128	8	16	$\mathbf{X} \cup \mathbf{RU}\phi$
$V_{U-RU\phi}^m$	80	5	16	$\mathbf{U} \cup \mathbf{RU}\phi$
$V_{U-R-RU\phi}^m$	240	15	16	$\mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$
$V_{X-U-R-RU\phi}^m$	320	20	16	$\mathbf{X} \cup \mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$

$V_{x_{1,2,3,4}}^m$  – Przestrzeń wartości cech wyznaczona na podstawie sygnałów obserwowanych jednocześnie w czterech kanałach nr 1, 2, 3 i 4,

$V_X^m$  – Przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{X}$  sygnałów obserwowanych

$V_R^m$  – Przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{R}$  dodatkowych sygnałów pomocniczych korelacji wzajemnych sygnałów obserwowanych,

$V_{R_{1,2}}^m$  – Przestrzeń wartości cech wyznaczona na podstawie dodatkowego sygnału pomocniczego  $R_{1,2}(\tau)$  korelacji wzajemnej sygnałów obserwowanych  $x_1(t)$  i  $x_2(t)$ ,

$V_{R_{2,4}}^m$  – Przestrzeń wartości cech wyznaczona na podstawie dodatkowego sygnału pomocniczego  $R_{2,4}(\tau)$  korelacji wzajemnej sygnałów obserwowanych  $x_2(t)$  i  $x_4(t)$ ,

$V_U^m$  – Przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{U}$  dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ ,

$V_{RU\phi}^m$  – Przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{RU}\phi$  dodatkowych sygnałów pomocniczych korelacji wzajemnych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz sygnału znacznika wyróżnionego położenia wału,

$V_{X-U}^m$  – Przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów

$\mathbf{X}$ ,  $\mathbf{U}$  sygnałów obserwowanych i dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ ,

$V_{X-R}^m$  – Przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów  $\mathbf{X}$ ,  $\mathbf{R}$  sygnałów obserwowanych i dodatkowych sygnałów pomocniczych korelacji wzajemnych sygnałów obserwowanych,

$V_{X-RU\phi}^m$  – Przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów  $\mathbf{X}$ ,  $\mathbf{RU}\phi$  sygnałów obserwowanych i dodatkowych sygnałów pomocniczych korelacji wzajemnych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz sygnału znacznika wyróżnionego położenia wału,

$V_{U-RU\phi}^m$  – Przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów  $\mathbf{U}$ ,  $\mathbf{RU}\phi$  dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa i dodatkowych sygnałów pomocniczych korelacji wzajemnych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz sygnału znacznika wyróżnionego położenia wału,

$V_{U-R-RU\phi}^m$  – Przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów  $\mathbf{U}$ ,  $\mathbf{R}$ ,  $\mathbf{RU}$  wszystkich dodatkowych sygnałów pomocniczych,

$V_{X-U-R-RU\phi}^m$  – Przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów  $\mathbf{X}$ ,  $\mathbf{U}$ ,  $\mathbf{R}$ ,  $\mathbf{RU}$  wszystkich sygnałów zarówno obserwowanych jak i dodatkowych sygnałów pomocniczych.

### Ograniczenie zbioru rozpatrywanych cech

W wyniku prowadzonych badań stwierdzono, że między elementami rozpatrywanego zbioru cech istnieją pewne ukryte zależności między cechami w rozpatrywanym zbiorze cech. Przyjęto zatem, że do oceny dodatkowych sygnałów pomocniczych nie jest konieczne wyznaczanie wszystkich wartości cech spośród proponowanego zbioru  $\mathbf{V}$  cech. Zdecydowano, że przeprowadzone zostaną badania, na podstawie których, dodatkowe sygnały pomocnicze podda się ocenie za pomocą odpowiednio przygotowanych ograniczonych zbiorów cech. Ograniczony zbiór cech może powstać w wyniku ograniczenia wcześniej rozpatrywanego zbioru cech  $\mathbf{V}$ . Może on również zawierać nowe cechy zdefiniowane na podstawie badań heurystycznych oraz być zbiorem mieszanym, w skład którego wchodzi nowe i wcześniej znane cechy. Przyjęto, że dla oceny dodatkowych sygnałów pomocniczych, będących funkcjami korelacji wzajemnych, czyli wszystkie sygnały należące do zbiorów  $\mathbf{R}$ ,  $\mathbf{RU}\phi$ ,  $\mathbf{RU}$ , zdefiniowany będzie nowy zbiór cech, którego elementy scharakteryzowano w tabeli 5.3.

Tab. 5.3. Rozpatrywane cechy punktowe dodatkowych sygnałów pomocniczych korelacji wzajemnych

Identyfikator	Nazwa cechy
$v_8$	Wartość szczytowa dodatnia
$v_{8a}$	Opóźnienie $\tau_{8a}$ przy którym występuje wartość $v_8$
$v_{17}$	Wartość przy której funkcja korelacji wzajemnej uzyskuje 50% wartości
$v_{17a}$	Opóźnienie $\tau_{17a}$ przy którym występuje wartość $v_{17}$



Proponowany zbiór cech, służący do oceny zbioru dodatkowych sygnałów pomocniczych korelacji wzajemnych, zawiera trzy nowe cechy, które określono na podstawie badań polegających na wizualnej analizie własności wykresów funkcji korelacji wzajemnej różnych par sygnałów.

Do oceny sygnałów należących do zbioru  $\mathbf{U}$  dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  wykorzystano zbiór cech (tab. 5.4) powstały w wyniku ograniczenia zbioru  $\mathbf{V}$  rozpatrywanych cech.

Tab. 5.4. Rozpatrywane cechy punktowe dodatkowych sygnałów pomocniczych promieni trajektorii

Identyfikator	Nazwa cechy
$v_8$	Wartość szczytowa dodatnia
$v_9$	Wartość szczytowa ujemna
$v_{16}$	Kurtoza

Biorąc pod uwagę ograniczone zbiory cech, wyznaczono następujące ograniczone przestrzenie wartości cech dodatkowych sygnałów pomocniczych:

$VO_R^m$  – ograniczona przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{R}$  dodatkowych sygnałów pomocniczych korelacji wzajemnych sygnałów obserwowanych,

$VO_U^m$  – ograniczona przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{U}$  dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ ,

$VO_{RU\phi}^m$  – ograniczona przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{RU}\phi$  dodatkowych sygnałów pomocniczych korelacji wzajemnych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz sygnału znacznika wyróżnionego położenia wału,

$VO_{RU}^m$  – ograniczona przestrzeń wartości cech wyznaczona na podstawie zbioru  $\mathbf{RU}$  dodatkowych sygnałów pomocniczych korelacji wzajemnych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ ,

$VO_{U-RU}^m$  – ograniczona przestrzeń wartości cech wyznaczona na podstawie łącznie rozpatrywanych zbiorów  $\mathbf{U}$ ,  $\mathbf{RU}$  dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa i dodatkowych sygnałów pomocniczych korelacji wzajemnych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ .

Charakterystykę wyznaczanych ograniczonych przestrzeni wartości cech zestawiono w tabeli 5.5.

#### 5.4.4. Przestrzeń wartości cech głównych

Przyjęto, że podstawą do wyznaczania przestrzeni wartości cech głównych  $G^m$  będzie zbiór tzw. "sklasyfikowanych danych uczących", pozyskany w wyniku przeprowadzonego czynnego eksperymentu diagnostycznego. Elementami zbioru "danych uczących" są wartości cech punktowych tworzące przestrzeń wartości cech  $V^m$ . W poprzednim podrozdziale (5.4.3) scha-

Tab. 5.5. Charakterystyka wyznaczanych ograniczonych przestrzeni wartości cech

Oznaczenie przestrzeni $VO^m$	$m$	Liczba sygnałów $K$	Liczba cech $v$	Zbiór ocenianych sygnałów
$VO_R^m$	40	10	4	<b>R</b>
$VO_U^m$	6	2	3	<b>U</b>
$VO_{RU\phi}^m$	12	3	4	<b>RU</b> $\phi$
$VO_{RU}^m$	4	1	4	<b>RU</b>
$VO_{U-RU}^m$	10	3	$v_U = 3, v_{RU} = 4$	<b>R</b> $\cup$ <b>RU</b>

rakteryzowano wszystkie przypadki rozpatrywanych przestrzeni wartości cech poddawanych przekształceniu do przestrzeni wartości cech głównych  $G^n$ .

Wyznaczenie ograniczonej przestrzeni wartości cech głównych dla każdej z rozpatrywanych przestrzeni wartości cech polegało na znalezieniu maksymalnej wartości kryterium dyskryminacyjnego Fishera, co było jednoznaczne z określeniem najlepszego kierunku dyskryminacyjnego klas stanów w przestrzeni wartości cech.

Przed operacją wyznaczania przestrzeni wartości cech głównych, wartości rozpatrywanych cech poddano operacji normalizacji, co było wskazane w celu uwolnienia się od jednostek miary poszczególnych wartości cech, a także ujednoczenia rzędów wielkości tych wartości. Wykorzystano najczęściej stosowany sposób normalizacji polegający na standaryzacji.

Na podstawie optymalnego wektora dyskryminacyjnego określono wartości własne i wektory własne definiujące kierunki osi głównych przestrzeni wartości cech głównych  $G^n$ . Wzięto pod uwagę trzy największe wartości własne i odpowiadające im wektory własne wyznaczone na podstawie kryterium dyskryminacyjnego Fishera i dokonano przekształcenia liniowego każdej z wyznaczonych wcześniej przestrzeni wartości cech do nowej przestrzeni wartości cech głównych.

Dokonano następujących przekształceń:

- $V_{x_1}^m \longrightarrow G_{x_1}^n$
- $V_{x_2}^m \longrightarrow G_{x_2}^n$
- $V_{x_3}^m \longrightarrow G_{x_3}^n$
- $V_{x_4}^m \longrightarrow G_{x_4}^n$
- $V_{x_{1,2}}^m \longrightarrow G_{x_{1,2}}^n$
- $V_{x_{2,4}}^m \longrightarrow G_{x_{2,4}}^n$
- $V_{x_{1,2,3,4}}^m \longrightarrow G_{x_{1,2,3,4}}^n$
- $V_X^m \longrightarrow G_X^n$
- $V_R^m \longrightarrow G_R^n$
- $V_{R_{1,2}}^m \longrightarrow G_{R_{1,2}}^n$
- $V_{R_{2,4}}^m \longrightarrow G_{R_{2,4}}^n$
- $V_U^m \longrightarrow G_U^n$
- $V_{RU\phi}^m \longrightarrow G_{RU\phi}^n$
- $V_{X-U}^m \longrightarrow G_{X-U}^n$

- $V_{X-R}^m \longrightarrow G_{X-R}^m$
- $V_{X-RU\phi}^m \longrightarrow G_{X-RU\phi}^m$
- $V_{U-RU\phi}^m \longrightarrow G_{U-RU\phi}^m$
- $V_{U-R-RU\phi}^m \longrightarrow G_{U-R-RU\phi}^m$
- $V_{X-U-R-RU\phi}^m \longrightarrow G_{X-U-R-RU\phi}^m$
- $VO_R^m \longrightarrow GO_R^n$
- $VO_U^m \longrightarrow GO_U^n$
- $VO_{RU\phi}^m \longrightarrow GO_{RU\phi}^n$
- $VO_{RU}^m \longrightarrow GO_{RU}^n$
- $VO_{U-RU}^m \longrightarrow GO_{U-RU}^n$

W oparciu o wcześniej przeprowadzone badania wstępne przyjęto, że dla potrzeb dalszych rozważań wystarczające jest rozpatrywanie przestrzeni wartości cech głównych o liczbie wymiarów kolejno  $n = 1$ ;  $n = 2$  i  $n = 3$ . Rozpatrywanie większej liczby wymiarów nie wpływało znacząco na poprawę wyników i utrudniłoby interpretację uzyskiwanych wyników. Rozpatrywano zatem przestrzenie opisane przez jedną  $G_{id}^1$ , dwie  $G_{id}^2$  i trzy  $G_{id}^3$  osie główne, przy czym  $id$  oznacza identyfikator przestrzeni, np.:  $G_X^1$ .

#### 5.4.5. Klasyfikacja stanu maszyny

Biorąc pod uwagę każdą z wyznaczonych przestrzeni wartości cech głównych  $G_{id}^m$ , przeprowadzono klasyfikację stanu maszyny. Wykorzystano metody odległościowe opisane w rozdziale 4.2.4. Ze względu na stosowanie procedury normalizacji rozpatrywanych wartości cech, do określania podobieństwa między obiektami w przestrzeni wartości cech głównych wykorzystano metrykę Euklidesa. Z badań własnych [73] oraz z badań literaturowych [15] wynika, że metryka ta jest wystarczająca dla celów klasyfikacji i ma mniejszy wpływ na błąd klasyfikatora niż w przypadku stosowania metryki Mahalanobisa. Stosowano algorytm  $k$ -NN, przy czym wartość  $k$  przyjmowała wartości ze zbioru  $k = \{1, 2, 3\}$ . W celu określenia zdolności klasyfikatora do generalizacji zdobytej wiedzy zastosowano metodę *leave-one-out* estymacji błędu klasyfikatora. Metoda ta polega na podziale zbioru uczącego o liczebności  $N$  elementów, którymi w tym przypadku były wartości cech głównych, na dwa rozłączne zbiory, przy czym zbiór testujący zawiera tylko jedną wartość, podczas gdy uczący pozostałe  $N - 1$  wartości cech. Uczenie i testowanie przeprowadzono  $N$ -krotnie. O przyjęciu metody *leave-one-out* zdecydowała jej zdolność do uzyskiwania górnej granicy oszacowania prawdopodobieństwa błędu oraz mała liczebność zbioru danych uczących. Miarą sprawności klasyfikatora, na podstawie której porównywano wyniki badań, była względna liczba błędnych klasyfikacji, wyznaczona z następującej zależności:

$$err = \frac{N_e}{N} \quad (5.7)$$

gdzie:

$N$  – liczba rozpatrywanych przykładów,

$N_e$  – liczba przykładów klasyfikowanych błędnie,

$err$  – względna liczba błędnych klasyfikacji.

Na podstawie względnej liczby błędnych klasyfikacji wyznaczano sprawność klasyfikatora  $eff$  w następujący sposób:

$$eff = (1 - err) * 100\% \quad (5.8)$$

Dla potrzeb opisu wyników klasyfikacji wprowadzono następujące stopnie oceny sprawności klasyfikatora zależne od jego procentowej wartości:

95% – 100% – celująco,

90% – 95% – bardzo dobrze,

80% – 90% – dobrze,

70% – 80% – dostatecznie,

60% – 70% – miernie,

0% – 60% – niedostatecznie.

Procentowe progi ocen ustalone zostały arbitralnie.

#### 5.4.6. Narzędzia wykorzystane do obliczeń

Do prowadzenia obliczeń oraz wizualizacji uzyskanych wyników wykorzystano środowisko obliczeniowe *MATLAB*. Dla potrzeb badań opracowano zbiór funkcji oraz skryptów, w których za pomocą języka programowania *MATLAB*, zakodowano większość algorytmów obliczeniowych niezbędnych dla poprawnej realizacji zaproponowanej koncepcji łącznej analizy sygnałów. Do prowadzenia obliczeń częściowo wykorzystano standardowe funkcje oferowane przez środowisko *MATLAB*, jak również funkcje oferowane w ramach toolbox-u *Pattern Recognition Toolbox* [64].

### 5.5. Ogólna charakterystyka przeprowadzonych badań

W wyniku przeprowadzonego eksperymentu czynnego na stanowisku badawczym pozyskano dane uczące niezbędne do weryfikacji proponowanej metody. Przykłady należące do zbioru uczącego opisują pięć różnych stanów technicznych modelu maszyny wirnikowej:

$S_1$  – Obiekt sprawny.

$S_2$  – Obiekt z występującym lekkim przycieraniem.

$S_3$  – Obiekt z występującym niewyważeniem statycznym.

$S_4$  – Obiekt z występującym niewyważeniem momentowym.

$S_5$  – Obiekt z występującym niewyważeniem momentowym i lekkim przycieraniem.

Wśród rozpatrywanych stanów technicznych istnieją takie stany, które z założenia powinny być słabo rozróżnialne. Stanami tymi są stany  $S_1$ –obiekt sprawny,  $S_2$ –obiekt z występującym lekkim przycieraniem oraz  $S_4$ –obiekt niewyważony momentowo,  $S_5$ –obiekt niewyważony momentowo wraz z lekkim przycieraniem. Dla potrzeb badań przykłady uczące, opisujące różne stany techniczne, podzielono na dwa zestawy danych.

Pierwszy zestaw danych uczących obejmował stany:

$S_1$  – Obiekt sprawny.

$S_2$  – Obiekt z występującym lekkim przycieraniem.

$S_3$  – Obiekt z występującym niewyważeniem statycznym.

$S_4$  – Obiekt z występującym niewyważeniem momentowym.

Drugi zestaw danych obejmował przykłady uczące opisujące takie stany techniczne jak:

$S_1$  – Obiekt sprawny.

$S_3$  – Obiekt z występującym niewyważeniem statycznym.

$S_4$  – Obiekt z występującym niewyważeniem momentowym.

$S_5$  – Obiekt z występującym niewyważeniem momentowym i lekkim przycieraniem.

Podział na dwa zestawy danych uczących miał na celu zbadanie zdolności proponowanej metody łącznej analizy sygnałów do rozróżniania stanów technicznych, które mogą w niektórych przypadkach być nierozróżnialne. W pierwszym zestawie danych uczących przypadek taki zapewniają stany  $S_1$  oraz  $S_2$ , natomiast w zestawie drugim stany  $S_4$  i  $S_5$ . Ponadto w drugim zestawie danych uczących istnieje stan  $S_5$ , który można uznać za stan złożony.

Przyjęto, że badania polegające na wyznaczeniu przestrzeni wartości cech głównych oraz klasyfikacji stanu technicznego maszyny prowadzone będą niezależnie na każdym z dwóch proponowanych zestawach uczących w dwóch etapach:

**Etap I** – klasyfikacja stanu technicznego obiektu na podstawie przestrzeni wartości cech głównych sygnałów jednokanałowych wyznaczonych oddzielnie w kanałach do 1 do 4,

**Etap II** – klasyfikacja stanu technicznego obiektu na podstawie przestrzeni wartości cech głównych wyznaczonych w wyniku łącznej analizy sygnałów wielokanałowych należących do zbioru sygnałów obserwowanych, zbioru dodatkowych sygnałów pomocniczych oraz zbioru zawierającego sygnały obserwowane jak i dodatkowe sygnały pomocnicze.

Rozdzielenie działań na dwa wskazane wyżej etapy miało na celu porównanie, w jakim stopniu łączna analiza sygnałów daje lepsze wyniki niż analiza każdego z sygnałów z osobna. Ponadto analiza uzyskanych wyników dla tych przypadków, w których sygnały rozpatrywane były łącznie, miała odpowiedzieć na pytanie, w jakim stopniu analiza dodatkowych sygnałów pomocniczych może wspomóc proces określania stanu technicznego obiektu oraz w jakim stopniu pozwala na poprawę jakości wnioskowania w porównaniu z sytuacją, gdy rozpatrywane są tylko i wyłącznie sygnały obserwowane. Zbadano również przypadki, gdy sygnały obserwowane oraz dodatkowe sygnały pomocnicze rozpatrywane są łącznie.

Dla potrzeb opisu wyników badań wszystkie wyniki, które w dalszej części pracy zostały przedstawione, dotyczą dwuwymiarowych przestrzeni wartości cech głównych  $G_{id}^2$ . Wyniki klasyfikacji przedstawiane są w postaci wartości sprawności klasyfikatora. Prezentowane wartości sprawności klasyfikacji wyznaczono przy stosowaniu algorytmu 2– $NN$ . Do wyznaczania przestrzeni wartości cech głównych stosowano wieloklasowe (czteroklasowe) kryterium Fishera.

## 5.6. Wyniki analizy pojedynczych sygnałów

W wyniku przeprowadzonych obliczeń, na podstawie pierwszego i drugiego zestawu danych uczących, dla każdego z sygnałów  $x_1(t)$ ,  $x_2(t)$ ,  $x_3(t)$ ,  $x_4(t)$  wyznaczono przestrzenie wartości cech głównych. Opierając się na otrzymanych przestrzeniach wartości cech głównych, przeprowadzono klasyfikację stanu maszyny. Wyniki klasyfikacji dla pierwszego i drugiego zestawu danych uczących zestawiono kolejno w tabelach 5.6 i 5.7. Aby ocenić ogólną sprawność klasyfikacji przykładów do poszczególnych klas, obliczono wartość średnią sprawności klasyfikatora.

Tab. 5.6. Sprawność klasyfikacji dla przestrzeni wartości cech głównych wyznaczonych oddzielnie dla każdego z sygnałów – pierwszy zestaw danych uczących

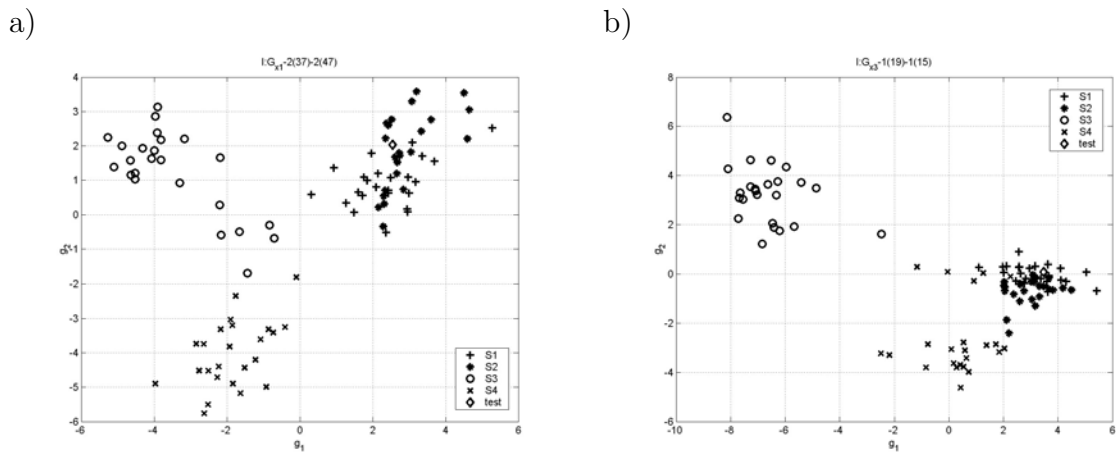
Rozpatrywana przestrzeń wartości cech głównych	Sprawność klasyfikacji [%]			
	Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
$G_{x_1}^2$	83.33	87.50	91.67	95.83
$G_{x_2}^2$	100.00	100.00	91.67	79.17
$G_{x_3}^2$	79.17	87.50	95.83	91.67
$G_{x_4}^2$	100.00	100.00	95.83	91.67
Średnia	90.63	93.75	93.75	89.59

Tab. 5.7. Sprawność klasyfikacji dla przestrzeni wartości cech głównych wyznaczonych oddzielnie dla każdego z sygnałów – drugi zestaw danych uczących

Rozpatrywana przestrzeń wartości cech głównych	Sprawność klasyfikacji [%]			
	Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
$G_{x_1}^2$	100.00	91.67	70.83	75.00
$G_{x_2}^2$	95.83	79.17	75.00	79.17
$G_{x_3}^2$	87.50	95.83	62.50	83.33
$G_{x_4}^2$	100.00	95.83	75.00	87.50
Średnia	95.83	90.63	70.83	81.25

Na rysunkach 5.6, 5.7 i 5.8, przedstawiono przykładowe dwuwymiarowe przestrzenie wartości cech głównych wyznaczone na podstawie pierwszego zestawu danych uczących. Na rysunkach zaznaczono punkty opisywane przez wartości cech należące do przykładów uczących


oraz jeden z przykładów testujących. W przypadku przestrzeni wartości cech głównych sygnału  $x_1(t)$  obserwowanego w kanale nr 1 (rys. 5.6a) oraz przestrzeni wartości cech głównych sygnału  $x_3(t)$  obserwowanego w kanale nr 3 (rys. 5.6b) zaobserwowano podobny rozkład i położenie przykładów opisujących poszczególne stany techniczne. Przykłady należące do klas  $S_1$  oraz  $S_2$  tworzą jedną wspólną grupę. W obrębie tej grupy możliwe jest rozróżnienie wzajemnie przenikających się skupisk przykładów związanych z każdą z tych klas. W przypadku przykładów należących do klas  $S_3$  i  $S_4$  wyraźnie rozróżnialne są dwie grupy. Odległości między grupami przykładów reprezentującymi poszczególne klasy są niewielkie. Wyniki klasyfikacji uzyskane na podstawie przestrzeni wartości cech sygnałów  $x_1(t)$  i  $x_3(t)$  zestawiono w tabeli 5.6. Sprawności klasyfikatora w przypadku wszystkich rozpatrywanych klas niewiele się od siebie różnią. Sprawność klasyfikacji dla klas  $S_1$  i  $S_2$  jest gorsza od sprawności uzyskanych dla klas  $S_3$  i  $S_4$ . Zgodnie z przyjętą skalą oceny (por. rozdz.5.4.5) sprawność klasyfikacji dla klas  $S_1$  i  $S_2$  można uznać za dobrą, natomiast dla klas  $S_3$  i  $S_4$  za bardzo dobrą.



Rys. 5.6. Przykład przestrzeni wartości cech głównych  $G_{x_1}^2$  a) i  $G_{x_3}^2$  b), sygnałów  $x_1(t)$  i  $x_3(t)$  – pierwszy zestaw danych uczących


Na rysunku 5.7 obrazującym przestrzeń wartości cech głównych sygnału  $x_2(t)$  zaobserwowano sytuację odwrotną niż w przypadku, gdy analizie poddano sygnały  $x_1(t)$  i  $x_3(t)$ . Przykłady opisujące klasy  $S_1$  oraz  $S_2$  tworzą wyraźne grupy punktów, natomiast przykłady opisujące klasy  $S_3$  i  $S_4$  tworzą jedną wspólną grupę. Wyniki klasyfikacji (tab. 5.6) potwierdzają dobrą rozróżnialność klas  $S_1$  i  $S_2$ , dla których sprawność klasyfikacji jest celująca i wynosi 100%. Pomimo dostrzegalnej na rysunku 5.7 słabej selektywności grup przykładów opisujących klasy  $S_3$  i  $S_4$ , sprawność klasyfikacji stanu obiektu do klasy  $S_3$  jest bardzo dobra i wynosi 91.67%. Dostatecznie rozpoznawalnym stanem był stan  $S_4$ , dla którego sprawność klasyfikacji wynosi 79.17%.

Z analizy rysunku (rys. 5.8) przedstawiającego przykładową przestrzeń wartości cech głównych wyznaczoną na podstawie sygnału  $x_4(t)$  wynika, że możliwe jest rozróżnienie grup przykładów reprezentujących wszystkie z rozpatrywanych klas stanów. Należy zwrócić uwagę na fakt, że odległości między poszczególnymi grupami są nieznaczne. Wyniki klasyfikacji (tab.



Rys. 5.7. Przykład przestrzeni wartości cech głównych  $G_{x_2}^2$  sygnału  $x_2(t)$  obserwowanego w kanale nr 2 – pierwszy zestaw danych uczących

5.6) dla przestrzeni wartości cech głównych sygnału  $x_4(t)$  potwierdzają fakt, że sprawność klasyfikacji, a tym samym rozróżnialność klas  $S_1$  i  $S_2$ , jest celująca, w obu przypadkach wynosiła ona 100%. Sprawność klasyfikacji przykładów należących do klas  $S_3$  i  $S_4$  była niewiele niższa, kolejno 95.83% i 91.67%.




Rys. 5.8. Przykład przestrzeni wartości cech głównych  $G_{x_4}^2$  sygnału  $x_4(t)$  obserwowanego w kanale nr 4 – pierwszy zestaw danych uczących

Na rysunkach (rys. 5.9, 5.10, 5.11, 5.12) przedstawiono przykładowe dwuwymiarowe przestrzenie wartości cech głównych sygnałów  $x_1(t)$ ,  $x_2(t)$ ,  $x_3(t)$ ,  $x_4(t)$ . Na podstawie analizy wykresów dostrzeżono występowanie pewnej prawidłowości polegającej na tym, że przykłady opisujące stany  $S_4$  i  $S_5$  tworzą jedną wspólną grupę przykładów.




W przypadku przestrzeni wartości cech głównych sygnału  $x_1$  (rys. 5.9) przykłady opisujące stany  $S_1$  i  $S_3$  tworzą dwie rozdzielone od siebie grupy. Wzajemne odległości między grupami przykładów opisujących stany  $S_1$  i  $S_3$  oraz grupą skupiającą przykłady stanów  $S_4$  i  $S_5$  są niewielkie. Zaobserwowano również, że rozrzut punktów w tych grupach jest znaczny. Uzyskane wyniki klasyfikacji (tab. 5.7) wskazują, że przykłady opisujące stan  $S_1$  rozróżniane są celująco, gdyż sprawność klasyfikacji wynosi 100%. Bardzo dobrze rozpoznawalna była klasa stanu  $S_3$ , sprawność klasyfikatora jest wysoka (91.67%). Słaba rozpoznawalność stanów  $S_4$  i  $S_5$  na rysunku 5.9 znalazła swoje odzwierciedlenie w dostatecznych wynikach klasyfikacji. Sprawność klasyfikatora dla stanu  $S_4$  wynosiła zaledwie 70.83%, a dla stanu  $S_5$  niewiele więcej, bo tylko 75%.




Rys. 5.9. Przykład przestrzeni wartości cech głównych  $G_{x_1}^2$  sygnału  $x_1(t)$  obserwowanego w kanale nr 1 – drugi zestaw danych uczących

Analizując rysunek 5.10, przedstawiający przykładową przestrzeń wartości cech głównych sygnału  $x_2(t)$ , można powiedzieć, że przykłady należące do klasy  $S_1$  tworzą wyraźnie rozróżnialną grupę. Możliwe jest również wyodrębnienie skupiska punktów opisywanych przez wartości cech związanych ze stanem  $S_3$ . Punkty te znajdują się bardzo blisko skupiska przykładów opisujących stany  $S_4$  i  $S_5$ . Na pozostałych, nieprzedstawionych tutaj rysunkach przestrzeni wartości cech głównych sygnału  $x_2$ , występowały liczne przypadki, gdzie przykłady opisujące stan  $S_3$  tworzyły wraz z przykładami opisującymi stany  $S_4$ ,  $S_5$  jedną dużą grupę. Potwierdzeniem tego faktu mogą być wyniki klasyfikacji (tab. 5.7), które tylko dla stanu  $S_1$  można ocenić jako celujące (95.83%). Pozostałe stany  $S_3$ ,  $S_4$  i  $S_5$  rozpoznawalne są w sposób dostateczny i sprawność klasyfikacji dla tych klas wynosiła kolejno 79.17%, 75.00%, 79.17%.




Rys. 5.10. Przykład przestrzeni wartości cech głównych  $G_{x_2}^2$  sygnału  $x_2(t)$  obserwowanego w kanale nr 2 – drugi zestaw danych uczących

Analiza rysunku 5.11, przedstawiającego przestrzeń wartości cech głównych wyznaczonych w wyniku analizy sygnału  $x_3(t)$ , wskazuje na to, że przykłady reprezentujące klasę stanu  $S_2$  tworzą wyraźnie dostrzegalne skupisko. Punkty opisywane przez wartości cech przynależne do pozostałych klas stanów  $S_1$ ,  $S_3$  i  $S_4$  nie tworzą wyraźnie rozróżnialnych skupisk, lecz jedną wspólną grupę obiektów. Potwierdzeniem wniosków płynących z analizy wykresu są wyniki klasyfikacji (tab. 5.7). Sprawność klasyfikatora dla stanu  $S_2$  jest celująca i wynosi 95.83%. Wyniki klasyfikacji dla stanów  $S_1$  i  $S_4$  można uznać za dobre. Sprawność klasyfikacji dla tych stanów wynosiła kolejno 87.50% i 83.33%. Najslabiej rozpoznawalnym stanem był stan  $S_3$ . Sprawność klasyfikacji dla tego stanu była mierna i wynosiła 62.50 %.



Rys. 5.11. Przykład przestrzeni wartości cech głównych  $G_{x_3}^2$  sygnału  $x_3(t)$  obserwowanego w kanale nr 3 – drugi zestaw danych uczących

Na wykresie (rys. 5.12), przedstawiającym przestrzeń wartości cech głównych sygnału  $x_4$ , dostrzeżono, że przykłady opisujące stany  $S_1$  i  $S_3$  tworzą wyraźne grupy, podczas gdy przykłady opisujące stany  $S_4$  i  $S_5$  należą do jednej grupy. Wyniki klasyfikacji dla klas  $S_1$  i  $S_3$  uzyskane na podstawie przestrzeni wartości cech sygnału  $x_4(t)$  są celujące (tab. 5.7). Gorzej rozpoznawalne były stany  $S_4$  i  $S_5$ . W przypadku przestrzeni wartości cech sygnału  $x_4(t)$  sprawność klasyfikatora dla stanu  $S_4$  była dostateczna i wynosiła 75.00%, natomiast sprawność klasyfikatora dla klasy  $S_5$  była dobra i wynosiła 87.50%.



Rys. 5.12. Przykład przestrzeni wartości cech głównych  $G_{x_4}^2$  sygnału  $x_4(t)$  obserwowanego w kanale nr 4 – drugi zestaw danych uczących

Zauważalnie słabsze wyniki klasyfikacji uzyskane dla wartości cech sygnałów obserwowanych w kanałach nr 1 i nr 3 mogą być związane ze sposobem montażu czujników pomiarowych. Sygnały  $x_1(t)$  i  $x_3(t)$  pochodzą z czujników umieszczonych w kierunku poziomym, w którym sztywność podpór łożyskowych jest mniejsza. W takiej sytuacji pewne zjawiska dynamiczne zachodzące w maszynie mogą być częściowo tłumione, co znajduje swoje odzwierciedlenie w obserwowanych sygnałach i ich cechach.

## 5.7. Wyniki łącznej analizy sygnałów

Wzięto pod uwagę dwa zestawy danych uczących i na tej podstawie przeprowadzono łączną analizę sygnałów, wyznaczając dwuwymiarowe przestrzenie wartości cech głównych. Łączna analiza sygnałów obejmowała kilkanaście przypadków różniących się liczebnością i zawartością zbioru sygnałów poddawanych analizie. Szczegółowy opis rozpatrywanych zbiorów sygnałów analizowanych łącznie przedstawiono w rozdziale 5.4. W dalszej części rozdziału opisane będą wyniki klasyfikacji stanu maszyny otrzymane na podstawie przestrzeni wartości cech głównych sygnałów rozpatrywanych łącznie.

Na podstawie analizy rysunków przedstawiających dwuwymiarowe przestrzenie wartości cech głównych różnych zbiorów sygnałów analizowanych łącznie dostrzeżono ogólne prawidłowości dotyczące rozróżnialności wartości cech przynależnych do poszczególnych klas stanów. W przypadku pierwszego zestawu danych uczących przykłady opisujące stany techniczne  $S_3$  i  $S_4$  we wszystkich rozpatrywanych przypadkach tworzą grupy rozróżnialne, natomiast wartości cech opisujące stany  $S_1$  i  $S_2$  w większości przypadków są słabo rozróżnialne. W drugim zestawie uczącym cechy opisujące stany techniczne  $S_4$  i  $S_5$  we wszystkich przypadkach są bardzo słabo rozróżnialne, tzn. grupy przykładów opisujące te stany albo zachodzą na siebie tworząc wspólną grupę, albo są usytuowane blisko siebie. Ponadto zaobserwowano, że grupy przykładów opisujących stany  $S_1$  i  $S_3$  we wszystkich rozpatrywanych przypadkach są dobrze rozróżnialne i dostatecznie od siebie oddalone.

Słaba rozróżnialność stanów  $S_3$  i  $S_4$  w przypadku pierwszego zestawu danych uczących oraz stanów  $S_4$  i  $S_5$  w przypadku drugiego zestawu danych uczących jest związana z założeniami dotyczącymi charakterystyki danych uczących rejestrowanych podczas czynnego eksperymentu diagnostycznego.


Spostrzeżenia wynikające z analizy rysunków przedstawiających przestrzenie wartości cech głównych znajdują potwierdzenie w wynikach klasyfikacji, które umieszczono przy każdym z rozpatrywanych przykładów.

### 5.7.1. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru X

Badania, dotyczące zagadnienia w jakim stopniu analiza sygnałów wielokanałowych daje lepsze wyniki w rozpoznawaniu stanu maszyny niż analiza sygnałów jednokanałowych, rozpoczęto od wyznaczenia przestrzeni wartości cech głównych  $G_{x_{1,2}}^2$  na podstawie analizy pary sygnałów  $x_1(t)$  i  $x_2(t)$  w obrębie jednego węzła łożyskowego  $L1$  oraz przestrzeni wartości cech głównych  $G_{x_{2,4}}^2$  na podstawie analizy sygnałów  $x_2(t)$  i  $x_4(t)$  pochodzących z sąsiadujących ze sobą węzłów łożyskowych  $L1$  i  $L2$ .

Na rysunkach 5.13 i 5.14 przedstawiono przykładowe przestrzenie wartości cech głównych  $G_{x_{1,2}}^2$  i  $G_{x_{2,4}}^2$  uzyskane na podstawie pierwszego zestawu danych uczących oraz wyniki klasyfikacji.

Pierwszy zestaw danych uczących			
$G_{x_{1,2}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
100.00	100.00	87.50	95.83




Rys. 5.13. Wyniki klasyfikacji dla przestrzeni wartości cech głównych  $G_{x_{1,2}}^2$  wyznaczonej w wyniku analizy pary sygnałów obserwowanych  $x_1(t)$  i  $x_2(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Na przedstawionych rysunkach 5.13, 5.14 przykłady opisujące rozpatrywane klasy stanów maszyny, skupione są w wyraźnie rozróżnialne grupy. Dobrą rozróżnialność poszczególnych

stanów potwierdzają uzyskane wyniki klasyfikacji. Sprawność klasyfikacji dla stanów  $S_1$  i  $S_2$  w obu rozpatrywanych przypadkach jest celująca.

Pierwszy zestaw danych uczących			
$G_{x_{2,4}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
100.00	95.83	95.83	100.00




Rys. 5.14. Wyniki klasyfikacji dla przestrzeni wartości cech głównych  $G_{x_{2,4}}^2$  wyznaczonej w wyniku analizy pary sygnałów obserwowanych  $x_2(t)$  i  $x_4(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

W przypadku przestrzeni wartości cech głównych  $G_{x_{1,2}}^2$  (rys. 5.13) celującą sprawność klasyfikacji, bo aż 95.83 %, zanotowano dla stanu  $S_4$ , natomiast stan  $S_3$  był dobrze rozpoznawalny, o czym świadczy sprawność klasyfikacji wynosząca 87.50 %. W przypadku przestrzeni wartości cech głównych  $G_{x_{2,4}}^2$  (rys. 5.14) wyniki klasyfikacji otrzymane dla stanów  $S_3$  i  $S_4$  są celujące, gdyż sprawności klasyfikatora wynoszą kolejno 95.83 % i 100 %.


Rysunki 5.15 i 5.16 przedstawiają przykładowe przestrzenie wartości cech głównych  $G_{x_{1,2}}^2$  i  $G_{x_{2,4}}^2$ , uzyskane na podstawie drugiego zestawu danych uczących, oraz odpowiadające im wyniki klasyfikacji. Przedstawione przykłady (rys. 5.15, 5.16) wskazują na dobrą rozróżnialność stanów  $S_1$  i  $S_3$ . Potwierdzają to wyniki klasyfikacji, które można uznać za celujące. Stany  $S_4$  i  $S_5$  w obu przedstawionych przypadkach są rozpoznawalne dostatecznie, co potwierdza sprawność klasyfikatora wynosząca w obu przypadkach kolejno 75.00 % i 79.17 %.

Drugi zestaw danych uczących			
$G_{x_{1,2}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	91.67	75.00	75.00



Rys. 5.15. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{x_{1,2}}^2$  wyznaczonej w wyniku analizy pary sygnałów obserwowanych  $x_1(t)$  i  $x_2(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

Drugi zestaw danych uczących			
$G_{x_{2,4}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	95.83	79.17	79.17




Rys. 5.16. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{x_{2,4}}^2$  wyznaczonej w wyniku analizy pary sygnałów obserwowanych  $x_2(t)$  i  $x_4(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących



Uwzględniając wyniki klasyfikacji uzyskane na podstawie przestrzeni wartości cech głównych wyznaczonych w wyniku analizy par sygnałów, dla obu rozpatrywanych zestawów danych uczących, przeprowadzono klasyfikację na podstawie przestrzeni wartości cech głównych  $G_{x_{1,2,3,4}}^2$ , wyznaczonej w wyniku analizy czterech sygnałów.

Pierwszy zestaw danych uczących			
$G_{x_{1,2,3,4}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
100.00	100.00	95.83	100.00




Rys. 5.17. Wyniki klasyfikacji dla przestrzeni wartości cech głównych  $G_{x_{1,2,3,4}}^2$  wyznaczonej w wyniku analizy sygnałów obserwowanych  $x_1(t)$ ,  $x_2(t)$ ,  $x_3(t)$  i  $x_4(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Uzyskane wyniki klasyfikacji oraz przykładowe przestrzenie wartości cech głównych, kolejno dla pierwszego i drugiego zestawu danych uczących, przedstawiono na rysunkach 5.17 oraz 5.18. Na rysunkach dostrzegalne są dobrze odseparowane i wyraźne skupiska przykładów reprezentujące rozpatrywane klasy stanów. W przypadku pierwszego zestawu danych uczących (rys. 5.17) o dobrej rozróżnialności stanu maszyny świadczą przedstawione wyniki klasyfikacji, które dla każdej z klas można uznać za celujące.

Dla przykładu przestrzeni wartości cech (rys. 5.18) uzyskanego dla drugiego zestawu danych uczących, grupy przykładów opisujące stany  $S_4$  i  $S_5$  są położone blisko siebie, co ma bezpośredni wpływ na uzyskane wyniki klasyfikacji. Sprawność klasyfikacji dla stanów  $S_4$  i  $S_5$  wynosiła kolejno 75.00 i 66.67 %, co pozwala stwierdzić, że stan  $S_4$  jest rozpoznawalny dostatecznie, natomiast rozpoznawalność stanu  $S_5$  jest mierna. Stany  $S_1$  i  $S_3$  rozróżnialne

były celująco, sprawność klasyfikatora dla tych stanów osiągnęła wartość maksymalną 100 %.

Drugi zestaw danych uczących			
$G_{x_{1,2,3,4}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	100.00	75.00	66.67




Rys. 5.18. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{x_{1,2,3,4}}^2$  wyznaczonej w wyniku analizy sygnałów obserwowanych  $x_1(t)$ ,  $x_2(t)$ ,  $x_3(t)$  i  $x_4(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

### 5.7.2. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{R}$

W celu zweryfikowania idei stosowania dodatkowych sygnałów pomocniczych wyznaczono zbiór  $\mathbf{R}$  dodatkowych sygnałów pomocniczych funkcji korelacji wzajemnych sygnałów obserwowanych. Przykładowe przestrzenie wartości cech głównych  $G_R^2$  uzyskane na podstawie analizy dodatkowych sygnałów pomocniczych należących do zbioru  $\mathbf{R}$  dla pierwszego i drugiego zestawu danych uczących wraz z wynikami klasyfikacji przedstawiono na rysunkach 5.19 i 5.20.

Pierwszy zestaw danych uczących			
$G_R^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
91.67	79.17	95.83	95.83




Rys. 5.19. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_R^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych będących funkcjami korelacji wzajemnych sygnałów obserwowanych oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Zaobserwowano, że wartości cech są skupione w dobrze rozróżnialne grupy punktowe. Punktowa postać grupy przykładów wynika z bardzo dużych odległości między grupami. Możliwe jest rozróżnienie wszystkich stanów. Zgodnie z przyjętą skalą ocen sprawność klasyfikacji w przypadku pierwszego zestawu danych uczących oceniono następująco:  $S_1$  – bardzo dobrze (91.67%),  $S_2$  – dostatecznie (79.17%),  $S_3$  i  $S_4$  – celująco (95.83%). Przestrzenie warto-

ści cech wyznaczone na podstawie drugiego zestawu danych uczących pozwoliły na uzyskanie następujących wyników klasyfikacji:  $S_1$  i  $S_3$  – celująco (95.83%),  $S_4$  i  $S_5$  – niedostatecznie, gdyż sprawności klasyfikatora wynosiły kolejno 54.17 i 41.67 %.


Drugi zestaw danych uczących			
$G_R^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	95.83	54.17	41.67



Rys. 5.20. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_R^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych będących funkcjami korelacji wzajemnych sygnałów obserwowanych oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

W celu sprawdzenia przydatności stosowania pojedynczych dodatkowych sygnałów pomocniczych do oceny stanu technicznego maszyny przeprowadzono klasyfikację, analizując przestrzenie wartości cech głównych  $G_{R_{1,2}}^2$  oraz  $G_{R_{2,4}}^2$ . Przestrzenie te wyznaczono na podstawie dodatkowych sygnałów pomocniczych  $R_{1,2}(\tau)$  i  $R_{2,4}(\tau)$  zarówno dla pierwszego jak i drugiego zestawu danych uczących.

Pierwszy zestaw danych uczących			
$G_{R_{1,2}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
91.67	79.17	95.83	91.67




Rys. 5.21. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{R_{1,2}}^2$  wyznaczonej w wyniku analizy dodatkowego sygnału pomocniczego  $R_{1,2}(\tau)$  będącego funkcją korelacji wzajemnej sygnałów obserwowanych  $x_1(t)$  i  $x_2(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Dla pierwszego zestawu danych uczących wyniki klasyfikacji oraz przykładowe przestrzenie wartości cech głównych dodatkowych sygnałów pomocniczych  $R_{1,2}(\tau)$  i  $R_{2,4}(\tau)$  przedstawiono kolejno na rysunkach 5.21 i 5.22. Przykłady reprezentujące stany  $S_1$  i  $S_2$  tworzą grupy położone bardzo blisko siebie, podczas gdy przykłady reprezentujące klasy  $S_3$  i  $S_4$  tworzą dwie niezależne grupy. Grupa przykładów należących do klasy  $S_4$  jest położona blisko grup przykładów opisujących stany  $S_1$  i  $S_2$ , co znalazło odzwierciedlenie w wynikach klasyfikacji.

W obu rozpatrywanych przypadkach celująco rozpoznawalny był stan  $S_3$ , dla którego sprawność klasyfikacji wyniosła 100 %, bardzo dobrze rozpoznawalny był stan  $S_1$ , dla któ-

Pierwszy zestaw danych uczących			
$G_{R_{2,4}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
95.83	91.67	100.00	87.50




Rys. 5.22. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{R_{2,4}}^2$  wyznaczonej w wyniku analizy dodatkowego sygnału pomocniczego  $R_{2,4}(\tau)$  będącego funkcją korelacji wzajemnej sygnałów obserwowanych  $x_2(t)$  i  $x_4(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

rego sprawność klasyfikacji dla przestrzeni wartości cech głównych  $G_{R_{1,2}}^2$  i  $G_{R_{2,4}}^2$  wynosiła kolejno 91.67 % i 95.83 %. Stan  $S_4$  można uznać za dobrze rozpoznawalny, gdyż sprawność klasyfikatora dla przestrzeni wartości cech  $G_{R_{1,2}}^2$  wynosiła 91.67%, a dla przestrzeni  $G_{R_{2,4}}^2$  - 87.50 %. W przypadku przestrzeni wartości cech głównych  $G_{R_{1,2}}^2$  stan  $S_2$  był rozpoznawalny dostatecznie i sprawność klasyfikatora wynosiła 79.17 %. Bardzo dobre wyniki klasyfikacji dla stanu  $S_2$  uzyskano na podstawie przestrzeni wartości cech głównych  $G_{R_{2,4}}^2$ , sprawność klasyfikatora wyniosła 91.67 %.

Wyniki klasyfikacji oraz przykładowe przestrzenie wartości cech głównych  $G_{R_{1,2}}^2$  i  $G_{R_{2,4}}^2$  dla drugiego zestawu danych uczących przedstawiono kolejno na rysunkach 5.23 i 5.24.

Drugi zestaw danych uczących			
$G_{R_{1,2}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	87.50	75.00	50.00




Rys. 5.23. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{R_{1,2}}^2$  wyznaczonej w wyniku analizy dodatkowego sygnału pomocniczego  $R_{1,2}(\tau)$  będącego funkcją korelacji wzajemnej sygnałów obserwowanych  $x_1(t)$  i  $x_2(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

Przykłady opisujące wszystkie z rozpatrywanych stanów tworzą grupy rozmieszczone bardzo blisko siebie. Rozrzut przykładów w grupach jest duży, co ma wpływ na wyniki klasyfikacji. Przykłady opisujące klasy  $S_1$  i  $S_3$  tworzą rozróżnialne grupy. Znajduje to potwierdzenie w wynikach klasyfikacji.

W przypadku obu rozpatrywanych przestrzeni wartości cech, sprawność klasyfikacji dla stanu  $S_1$  jest celująca i wynosi 95.83%. W przypadku przestrzeni wartości cech  $G_{R_{1,2}}^2$  przykłady opisujące stan  $S_3$  są dobrze rozpoznawalne i sprawność klasyfikatora dla tego stanu wynosi 87.50%, natomiast sprawność klasyfikacji dla stanu  $S_3$  wyznaczona na podstawie przestrzeni wartości cech  $G_{R_{2,4}}^2$  jest celująca i wynosi 100%. Dla obu rozpatrywanych przestrzeni stan  $S_4$  był rozpoznawalny w sposób dostateczny. Najslabiej rozpoznawalne były przykłady opi-

Drugi zestaw danych uczących			
$G_{R_{2,4}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	100.00	70.83	87.50




Rys. 5.24. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{R_{2,4}}^2$  wyznaczonej w wyniku analizy dodatkowego sygnału pomocniczego  $R_{2,4}(\tau)$  będącego funkcją korelacji wzajemnej sygnałów obserwowanych  $x_2(t)$  i  $x_4(t)$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

sujące stany  $S_5$  w przestrzeni wartości cech  $G_{R_{1,2}}^2$ . W tym przypadku sprawność klasyfikacji była niedostateczna, gdyż wynosiła ona tylko 50.00%. Sprawność klasyfikatora dla stanu  $S_5$  wyznaczona w przestrzeni wartości cech  $G_{R_{2,4}}^2$  była dobra i jej wartość wynosiła 87.50%.



Zbiór  $\mathbf{R}$  dodatkowych sygnałów pomocniczych będących funkcjami korelacji wzajemnych sygnałów obserwowanych został poddany ponownej ocenie za pomocą ograniczonego zbioru estymat, co tym samym pozwoliło na wyznaczenie ograniczonej przestrzeni wartości cech głównych  $GO_R^2$ . Podobnie jak poprzednio, rozpatrywano pierwszy i drugi zestaw danych uczących. Wyniki klasyfikacji oraz przykładowe przestrzenie wartości cech głównych kolejno dla pierwszego i drugiego zestawu danych uczących przedstawiono na rysunkach 5.25 i 5.26.

Pierwszy zestaw danych uczących			
$GO_R^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
79.17	79.17	95.83	100.00




Rys. 5.25. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_R^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych będących funkcjami korelacji wzajemnych sygnałów obserwowanych oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Na podstawie przestrzeni wartości cech głównych (rys. 5.25) wyznaczonej dla pierwszego zestawu danych uczących stwierdzono, że wartości cech przynależne do stanów  $S_1$  i  $S_3$  tworzą grupy położone blisko siebie. Wyniki klasyfikacji wskazują, że stany  $S_1$  i  $S_2$  rozróżnialne są w sposób dostateczny, co potwierdza sprawność klasyfikatora wynosząca w obu przypadkach 79.17 %. W przypadku stanów  $S_3$  i  $S_4$  wyniki klasyfikacji są celujące i wynoszą odpowiednio 95.83 i 100.00 %.

W przypadku ograniczonej przestrzeni wartości cech głównych  $GO_R^2$  (rys. 5.26), wyznaczonej na podstawie drugiego zestawu danych uczących, przykłady stanów  $S_4$  i  $S_5$  tworzą

Drugi zestaw danych uczących			
$GO_R^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	100.00	62.50	66.67




Rys. 5.26. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_R^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych będących funkcjami korelacji wzajemnych sygnałów obserwowanych oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

jedną wspólną grupę, co świadczy o małej rozpoznawalności tych stanów. Znajduje to swoje potwierdzenie w miernych wynikach klasyfikacji. Sprawność klasyfikatora dla stanu  $S_4$  wynosi 62.50%, natomiast dla stanu  $S_5$ –66.67%. Wyniki klasyfikacji uzyskane dla stanów  $S_1$  i  $S_3$  wskazują na ich celującą rozpoznawalność, o czym świadczy sprawność klasyfikacji wynosząca dla obu tych stanów 100%.

### 5.7.3. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru U

W wyniku analizy dodatkowych sygnałów pomocniczych reprezentowanych przez funkcje promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ , dla pierwszego i drugiego zestawu danych uczących uzyskano przykładowe przestrzenie wartości cech głównych  $G_U^2$ , które wraz z wynikami klasyfikacji przedstawiono na rysunkach 5.27 i 5.28.

Pierwszy zestaw danych uczących			
$G_U^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
75.00	83.33	100.00	95.83




Rys. 5.27. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_U^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

W przypadku przestrzeni wartości cech głównych (rys. 5.27) powstałej na podstawie pierwszego zestawu danych uczących przykłady należące do klas  $S_3$  oraz  $S_4$  tworzą odseparowane od siebie grupy, natomiast przykłady przynależne do klas  $S_1$  i  $S_2$  tworzą jedną wspólną grupę. W obrębie grup opisujących poszczególne klasy występuje znaczny rozrzut przykładów. Wyniki klasyfikacji wskazują, że cechy należące do klasy  $S_1$  są rozpoznawalne dostatecznie, o czym świadczy sprawność klasyfikacji wynosząca 75.00 %. Przykłady z klasy  $S_2$  są rozpoznawalne dobrze, sprawność klasyfikatora wynosi 83.33 % . Przykłady należące

do klasy  $S_3$  oraz  $S_4$  są rozpoznawalne celująco, sprawność klasyfikatora dla tych klas wynosi kolejno 100 i 95.83 %.

Drugi zestaw danych uczących			
$G_U^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	100.00	79.17	87.50




Rys. 5.28. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_U^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

W przypadku przestrzeni wartości cech głównych (rys. 5.28) powstałej na podstawie drugiego zestawu danych uczących wyniki klasyfikacji pozwalają stwierdzić, że cechy należące do klas  $S_1$  i  $S_3$  są rozpoznawalne celująco (100%), podczas gdy należące do klasy  $S_4$  - dostatecznie (79.17%) a do klasy  $S_5$  – dobrze (87.50%).

Sygnaly ze zbioru  $\mathbf{U}$  dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyska  $L1$  i  $L2$  poddano ponownej analizie z zastosowaniem ograniczonego zbioru estymat punktowych, co w efekcie końcowym pozwoliło wyznaczyć ograniczoną przestrzeń wartości cech głównych  $GO_U^2$ . Rozpatrywano również pierwszy i drugi zestaw danych uczących. Przykładowe ograniczone przestrzenie wartości cech głównych  $GO_U^2$  oraz

wyniki klasyfikacji stanu maszyny uzyskane na ich podstawie przedstawiono na rysunkach 5.29 i 5.30.

Pierwszy zestaw danych uczących			
$GO_U^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
91.67	95.83	87.50	95.83




Rys. 5.29. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_U^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Na rysunkach dostrzegalny jest duży rozrzut przykładów w obrębie grup opisujących poszczególne stany. Zauważono, że ograniczenie przestrzeni wartości cech wpłynęło na wzrost selektywności w obrębie grup przykładów opisujących różne intensywności występowania określonego stanu.

W przypadku przestrzeni wartości cech (rys. 5.29) wyznaczonej na podstawie pierwszego zestawu danych uczących sprawność klasyfikacji oceniono następująco stan  $S_1$  - bardzo dobrze (91.67%), stan  $S_2$  - celująco (95.83%), stan  $S_3$  - dobrze (87.50%), stan  $S_4$  - celująco (95.83%).

Dla przestrzeni wartości cech (rys. 5.30) wyznaczonej na podstawie drugiego zestawu danych uczących wyniki klasyfikacji można uznać za wystarczające. Sprawność klasyfikacji oceniono następująco stany  $S_1$  i  $S_3$  - celująco (95.83 i 100.00%), stan  $S_4$  - dostatecznie (75.00%), stan  $S_5$  - dobrze (83.33%).

Drugi zestaw danych uczących			
$GO_U^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	100.00	75.00	83.33




Rys. 5.30. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_U^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

#### 5.7.4. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{RU}\phi$

Zgodnie z przyjętymi założeniami (por. rozdz. 5.4.1) dodatkowe sygnały pomocnicze należące do zbioru  $\mathbf{U}$  skorelowano wzajemnie ze sobą i z sygnałem znacznika wyróżnionego położenia wału. Otrzymany w ten sposób zbiór  $\mathbf{RU}\phi$  sygnałów poddano analizie, wyznaczając dla pierwszego i drugiego zestawu danych uczących przedstawione na rysunkach 5.31 i 5.32 przestrzenie wartości cech głównych  $G_{RU\phi}^2$ .


Pierwszy zestaw danych uczących			
$G_{RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
95.83	79.17	100.00	100.00



Rys. 5.31. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{RU\phi}^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych należących do zbioru  $\mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Przestrzeń wartości cech  $G_{RU\phi}^2$  (rys. 5.31) uzyskana na podstawie pierwszego zestawu danych uczących wskazuje na to, że przykłady opisujące stany  $S_1$  oraz  $S_2$  tworzą skupiska położone bardzo blisko siebie, podczas gdy grupy przykładów przynależne do klas  $S_3$  i  $S_4$  są dobrze rozdzielalne. Sprawność klasyfikacji oceniono następująco: dla klas  $S_1$ ,  $S_3$  i  $S_4$  – celująco, sprawność klasyfikatora wynosiła kolejno 95.83, 100.00 i 100.00%; dla klasy  $S_2$  – dostatecznie przy sprawności klasyfikatora 79.17%.

Drugi zestaw danych uczących			
$G_{RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	100.00	79.17	66.67



Rys. 5.32. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{RU\phi}^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych należących do zbioru  $\mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących


W przypadku przestrzeni wartości cech głównych (rys. 5.32) wyznaczonej na podstawie drugiego zestawu danych uczących dostrzegalne są trzy dobrze odseparowane od siebie grupy przykładów. Dwie z nich opisują stany  $S_1$  i  $S_3$ , trzecia grupa zawiera przykłady należące do klas  $S_4$  i  $S_5$ . Wyniki klasyfikacji potwierdzają dobrą rozpoznawalność stanów  $S_1$  i  $S_3$  oraz gorszą rozpoznawalność stanów  $S_4$  i  $S_5$ . Sprawność klasyfikacji oceniono następująco: dla klas  $S_1$  i  $S_3$  - celująco (100%), dla klasy  $S_4$  - dostatecznie (79.17%), dla klasy  $S_5$  - miernie (66.67%).

W wyniku analizy sygnałów ze zbioru  $\mathbf{RU}\phi$  dodatkowych sygnałów pomocniczych z zastosowaniem ograniczonego zbioru ocen punktowych otrzymano ograniczone przestrzenie wartości cech głównych  $GO_{RU\phi}^2$ . Przykładowe przestrzenie wyznaczone dla pierwszego i drugiego zestawu danych uczących przedstawiono na rysunkach 5.33 i 5.34. Na zamieszczonych rysunkach można dostrzec duży rozrzut przykładów opisujących poszczególne stany. Zaobserwowano



istnienie skupisk przykładów opisujących różne intensywności występowania poszczególnych stanów.

Pierwszy zestaw danych uczących			
$GO_{RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
87.50	83.33	83.33	100.00




Rys. 5.33. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_{RU\phi}^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych należących do zbioru  $\mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

W przypadku przestrzeni wartości cech (rys. 5.33) wyznaczonej na podstawie pierwszego zestawu danych uczących wyniki klasyfikacji przedstawiają się interesująco i tak sprawność klasyfikacji dla stanów  $S_1$ ,  $S_2$  i  $S_3$  została oceniona jako dobra i wynosi kolejno 87.50, 83.33 i 83.33 %. Rozpoznawalność klasy  $S_4$  była celująca, co potwierdza sprawność klasyfikatora wynosząca 100%.

W przypadku przestrzeni wartości cech (rys. 5.33) wyznaczonej dla drugiego zestawu danych uczących uzyskane wyniki klasyfikacji przedstawiają się następująco: sprawność klasyfikacji dla stanów  $S_3$  i  $S_4$  została oceniona jako dobra i wynosiła kolejno 87.50 i 83.33%. Przykłady należące do klasy  $S_1$  były rozpoznawalne celująco i sprawność klasyfikatora wynosi 95.83%. Niedostateczna jest sprawność klasyfikacji w przypadku klasy  $S_5$ , która wynosi 54.17%.


Drugi zestaw danych uczących			
$GO_{RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	87.50	83.33	54.17



Rys. 5.34. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_{RU\phi}^2$  wyznaczonej w wyniku analizy dodatkowych sygnałów pomocniczych należących do zbioru  $\mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

Kolejnym zbiorem sygnałów, który poddano ocenie z zastosowaniem ograniczonego zbioru ocen punktowych i wyznaczono ograniczoną przestrzeń wartości cech głównych  $GO_{RU}^2$ , był jednoelementowy zbiór  $\mathbf{RU}$ , zawierający dodatkowy sygnał pomocniczy  $ru\phi_{1,2-3,4}(\tau)$  będący funkcją korelacji wzajemnej sygnałów promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$ . Wyznaczone na podstawie pierwszego i drugiego zestawu danych uczących przykładowe przestrzenie wartości cech głównych (rys. 5.35 i rys. 5.36) charakteryzują się dużym rozrzutem przykładów opisujących rozpatrywane stany. Dostrzegalne są skupiska wartości cech przynależne każdemu ze stanów, przy czym położenie tych skupisk zależy od intensywności występowania niesprawności opisującej dany stan.

Pierwszy zestaw danych uczących			
$GO_{RU}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
87.50	95.83	91.67	87.50




Rys. 5.35. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_{RU}^2$  wyznaczonej w wyniku analizy dodatkowego sygnału pomocniczego należącego do zbioru  $\mathbf{RU}$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Dla pierwszego zestawu danych uczących przedstawione wyniki klasyfikacji (rys. 5.35) są stosunkowo dobre, sprawność klasyfikacji dla stanów  $S_1$ ,  $S_4$  oceniono jako dobrą, gdyż wynosiła dla obu stanów 87.50%. Rozpoznawalność stanu  $S_3$  była bardzo dobra, o czym świadczy sprawność klasyfikacji wynosząca 91.67%. Celująco można ocenić sprawność klasyfikacji dla stanu  $S_2$ , która wynosi 95.83%.

Z przedstawionych wyników klasyfikacji dla drugiego zestawu danych uczących (rys. 5.36) wynika, że stan  $S_1$  jest rozpoznawalny celująco, uzyskana dla niego wartość sprawności klasyfikacji wynosi 95.83%. Sprawność klasyfikacji dla stanu  $S_3$  jest niedostateczna i jej wartość wynosi 58.33%. Stan  $S_4$  jest rozpoznawalny dostatecznie (75.00%), natomiast stan  $S_5$  dobrze (83.33%).

Drugi zestaw danych uczących			
$GO_{RU}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	58.33	75.00	83.33




Rys. 5.36. Wyniki klasyfikacji uzyskane dla ograniczonej przestrzeni wartości cech głównych  $GO_{RU}^2$  wyznaczonej w wyniku analizy dodatkowego sygnału pomocniczego należącego do zbioru  $\mathbf{RU}$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

### 5.7.5. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X} \cup \mathbf{R}$

Łączna analiza zbioru sygnałów obserwowanych  $\mathbf{X}$  i dodatkowych sygnałów pomocniczych korelacji wzajemnych sygnałów obserwowanych należących do zbioru  $\mathbf{R}$  pozwoliła wyznaczyć przestrzeń wartości cech głównych  $G_{\mathbf{X}-\mathbf{R}}^2$ , których przykłady dla pierwszego i drugiego zestawu danych uczących przedstawiono na rysunkach 5.37 i 5.38. Wartości cech opisujące poszczególne klasy stanów tworzą punkty które skupione są w dobrze odseparowane od siebie grupy punktowe.

Pierwszy zestaw danych uczących			
$G_{\mathbf{X}-\mathbf{R}}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
91.67	91.67	100.00	95.83




Rys. 5.37. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{\mathbf{X}-\mathbf{R}}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{X} \cup \mathbf{R}$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Klasyfikacja stanu technicznego na podstawie tak wyznaczonych przestrzeni wartości cech wskazuje na ogólnie zadowalającą rozróżnialność klas stanów, co znajduje potwierdzenie w przedstawionych wynikach klasyfikacji.

W przypadku pierwszego zestawu danych uczących sprawność klasyfikacji dla stanów  $S_1$  i  $S_2$  oceniono jako bardzo dobrą i wynoszącą 91.67% dla obu stanów, natomiast dla stanów  $S_3$  i  $S_4$  sprawność klasyfikacji jest celująca i wynosi kolejno 100.00 i 95.83%.

Dla drugiego zestawu danych uczących sprawność klasyfikacji dla stanów  $S_1$  i  $S_3$  jest celująca, przy niedostatecznej sprawności klasyfikacji dla stanu  $S_4$  i dostatecznej dla stanu  $S_5$ .

Drugi zestaw danych uczących			
$G_{X-R}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	100.00	50.00	75.00




Rys. 5.38. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{X-R}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{XUR}$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

### 5.7.6. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X} \cup \mathbf{RU}\phi$

Analiza sygnałów należących do zbioru sygnałów obserwowanych  $\mathbf{X}$  i zbioru  $\mathbf{RU}\phi$  dodatkowych sygnałów pomocniczych będących korelacjami wzajemnymi promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$  i  $L2$  oraz sygnału znacznika wyróżnionego położenia wału pozwoliła na wyznaczenie przestrzeni wartości cech głównych  $G_{\mathbf{X}-\mathbf{RU}\phi}^2$ , których przykłady dla pierwszego oraz drugiego zestawu danych uczących przedstawiono na rysunkach 5.39 i 5.40. Przykłady opisujące poszczególne klasy stanów skupione są w rozróżnialne grupy punktowe.

Pierwszy zestaw danych uczących			
$G_{\mathbf{X}-\mathbf{RU}\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
83.33	66.67	91.67	91.67




Rys. 5.39. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{\mathbf{X}-\mathbf{RU}\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{X} \cup \mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Przedstawione wyniki klasyfikacji dla pierwszego zestawu danych uczących (rys. 5.39) wskazują na dobrą rozróżnialność stanu  $S_1$  – 83.33%, mierną rozróżnialność stanu  $S_2$  – 66.67% oraz bardzo dobrą rozróżnialność stanów  $S_3$  i  $S_4$  sprawność klasyfikacji w dla obu klas wynosi 91.67%.

W przypadku drugiego zestawu danych uczących wyniki klasyfikacji (rys. 5.40) dla stanów  $S_1$  i  $S_3$  są celujące, ponieważ sprawność klasyfikatora wynosiła kolejno 95.83 i 100.00%. Dostateczna jest rozróżnialność stanu  $S_4$ , dla której sprawność klasyfikacji wynosi 79.17%. Za niedostateczne uznano wyniki klasyfikacji dla stanu  $S_5$ , ponieważ sprawność klasyfikacji wynosi tylko 50.00%.

Drugi zestaw danych uczących			
$G_{X-RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	100.00	79.17	50.00




Rys. 5.40. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{X-RU\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{X} \cup \mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących



### 5.7.7. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $U \cup RU\phi$

Jednoczesna analiza dodatkowych sygnałów pomocniczych należących do zbiorów  $U$  i  $RU\phi$ , pozwoliła na wyznaczenie przestrzeni wartości cech głównych  $G_{U-RU\phi}^2$ , których przykłady wyznaczone dla pierwszego i drugiego zestawu danych uczących przedstawiono na rysunkach 5.41 i 5.42.

Pierwszy zestaw danych uczących			
$G_{U-RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
87.50	70.83	100.00	100.00




Rys. 5.41. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{U-RU\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $U \cup RU\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Na przedstawionych rysunkach można zidentyfikować grupy przykładów opisujące wszystkie rozpatrywane stany techniczne.

W przypadku przestrzeni wartości cech (rys. 5.41) wyznaczonej na podstawie pierwszego zestawu danych uczących grupy punktów przynależnych do stanów  $S_1$  i  $S_2$  są położone bardzo blisko siebie, co może wpłynąć na sprawność klasyfikacji. Otrzymane wyniki klasyfikacji wskazują, że sprawność klasyfikatora dla przykładów opisujących stan  $S_1$  jest dobra i wynosi 87.50%. Tak jak się spodziewano, stan  $S_2$  nie był tak dobrze rozróżnialny i jego sprawność kla-

syfikatora, wynoszącą 70.83%, oceniono dostatecznie. Stany  $S_3$  i  $S_4$  były rozróżniane celująco i w obu przypadkach sprawność klasyfikacji wyniosła 100%.

Drugi zestaw danych uczących			
$G_{U-RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	95.83	79.17	66.67




Rys. 5.42. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{U-RU\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{U} \cup \mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

Dla drugiego zestawu danych uczących wyniki klasyfikacji wskazują, że przykłady opisujące stan  $S_1$  oraz stan  $S_3$  rozpoznawalne są celująco. Sprawność klasyfikacji dla tych stanów wynosi kolejno 100 i 95.83%. Stan  $S_4$  jest rozróżnialny dostatecznie, natomiast stan  $S_5$  jest rozpoznawalny miernie.

Ostatnim zbiorem sygnałów, które zostały poddane analizie z zastosowaniem ograniczonego zbioru ocen punktowych, był zbiór  $\mathbf{U} \cup \mathbf{RU}$ , utworzony z dodatkowych sygnałów pomocniczych promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$ ,  $L2$  i dodatkowego sygnału pomocniczego, będącego funkcją korelacji wzajemnej promieni trajektorii środka czopa obserwowanych w łożyskach  $L1$ ,  $L2$ .

Pierwszy zestaw danych uczących			
$GO_{U-RU}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$	Stan $S_2$	Stan $S_3$	Stan $S_4$
sprawny	przycieranie	niewyważenie statyczne	niewyważenie momentowe
87.50	95.83	91.67	87.50




Rys. 5.43. Wyniki klasyfikacji dla przestrzeni wartości cech głównych  $GO_{U-RU}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{U} \cup \mathbf{RU}$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Wyznaczono przestrzeń wartości cech głównych  $GO_{U-RU}^2$ , których przykłady oraz wyniki klasyfikacji dla pierwszego i drugiego zestawu danych uczących przedstawiono na rysunkach 5.43 i 5.44. Analiza rysunków wskazuje na występowanie selektywnych skupisk przykładów opisujących różną intensywność występowania określonego stanu technicznego. Ogólnie mówiąc, punkty opisywane przez wartości cech są rozrzucone i wizualne oględziny nie pozwalają na wyodrębnienie zwartych i dobrze odseparowanych grup punktów.

W przypadku pierwszego zestawu danych uczących sprawność klasyfikacji aż dla trzech stanów  $S_1$  – 95.83%,  $S_3$  – 95.83%,  $S_4$  – 100% osiągnęła ocenę celującą. Natomiast sprawność klasyfikacji dla stanu  $S_2$  oceniono tylko dostatecznie i wynosiła ona 75.00%.

Drugi zestaw danych uczących			
$GO_{U-RU}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	95.83	79.17	83.33




Rys. 5.44. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $GO_{U-RU}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{U} \cup \mathbf{RU}$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

Dla drugiego zestawu danych uczących ocena wyników klasyfikacji jest zadowalająca i stany  $S_1$  i  $S_3$  są klasyfikowane celująco. Sprawność klasyfikacji dla tych stanów wynosi kolejno 100 i 95.83%. Stan  $S_4$  jest rozpoznawalny dostatecznie (79.17%), natomiast stan  $S_5$  jest rozróżniany dobrze (83.33%).

### 5.7.8. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $U \cup R \cup RU\phi$

W wyniku analizy zbioru sygnałów utworzonego z dodatkowych sygnałów pomocniczych należących do zbiorów  $U$ ,  $R$  i  $RU\phi$  uzyskano przestrzeń wartości cech głównych  $G_{U-R-RU\phi}^2$ , których przykłady dla pierwszego i drugiego zestawu danych uczących przedstawiono na rysunkach 5.45 i 5.46.

Pierwszy zestaw danych uczących			
$G_{U-R-RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
95.83	79.17	95.83	100.00




Rys. 5.45. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{U-R-RU\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $U \cup R \cup RU\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Przykłady reprezentujące poszczególne klasy stanu skupione są w grupy punktowe. Można zaobserwować dobrą separację międzygrupową, co potwierdzają przedstawione wyniki klasyfikacji.

Dla pierwszego zestawu danych uczących sprawność klasyfikacji dla poszczególnych stanów przedstawiają się następująco:  $S_1$ ,  $S_3$  i  $S_4$  celująco, natomiast  $S_3$  - dostatecznie.

W przypadku drugiego zestawu danych uczących sprawność klasyfikacji dla stanów  $S_1$  i  $S_3$  jest celująca i w obu przypadkach wynosi 100%. Stan  $S_4$  jest rozpoznawalny dobrze i sprawność klasyfikatora wynosi 87.50%. Rozpoznawalność stanu  $S_5$  była dostateczna, o czym świadczy wartość sprawności wynosząca 70.83%.

Drugi zestaw danych uczących			
$G_{U-R-RU\phi}^2$ - Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
100.00	100.00	87.50	70.83




Rys. 5.46. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{U-R-RU\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $UURURU\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

### 5.7.9. Wyniki klasyfikacji dla przestrzeni wartości cech głównych sygnałów ze zbioru $\mathbf{X} \cup \mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$

Analiza zbioru sygnałów, w którego skład wchodziły sygnały obserwowane oraz wszystkie zbiory rozpatrywanych dodatkowych sygnałów pomocniczych, pozwoliła na utworzenie przestrzeni wartości cech głównych  $G_{\mathbf{X}-\mathbf{U}-\mathbf{R}-\mathbf{RU}\phi}^2$ , których przykłady dla pierwszego i drugiego zestawu danych uczących wraz z wynikami klasyfikacji przedstawiono na rysunkach 5.47 i 5.48. Na podstawie rysunków zaobserwowano, że przykłady przynależne do poszczególnych stanów tworzą wyraźnie rozróżnialne grupy o punktowym skupieniu.


Pierwszy zestaw danych uczących			
$G_{\mathbf{X}-\mathbf{U}-\mathbf{R}-\mathbf{RU}\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
87.50	91.67	100.00	100.00



Rys. 5.47. Wyniki klasyfikacji uzyskane dla przestrzeni wartości cech głównych  $G_{\mathbf{X}-\mathbf{U}-\mathbf{R}-\mathbf{RU}\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{X} \cup \mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – pierwszy zestaw danych uczących

Przedstawione wyniki klasyfikacji dla pierwszego zestawu danych uczących (rys. 5.47) wskazują, że stan  $S_1$  jest rozróżnialny dobrze, sprawność klasyfikacji dla tego stanu wynosi 87.50%. Sprawność klasyfikatora dla stanu  $S_2$  jest bardzo dobra i wynosi 91.67%. Celujące wyniki uzyskano dla stanów  $S_3$  i  $S_4$ , sprawność klasyfikatora wynosi 100%.

Drugi zestaw danych uczących			
$G_{X-U-R-RU\phi}^2$ – Sprawność klasyfikacji [%]			
Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
95.83	95.83	79.17	50.00



Rys. 5.48. Wyniki klasyfikacji dla przestrzeni wartości cech głównych  $G_{X-U-R-RU\phi}^2$  wyznaczonej w wyniku analizy sygnałów należących do zbioru  $\mathbf{X} \cup \mathbf{U} \cup \mathbf{R} \cup \mathbf{RU}\phi$ , oraz przykładowy wykres obrazujący tę przestrzeń – drugi zestaw danych uczących

W przypadku drugiego zestawu danych uczących (rys. 5.48) wyniki klasyfikacji wskazują, że stany  $S_1$  i  $S_3$  są rozróżnialne celująco, o czym świadczą wartości sprawności klasyfikatora wynoszące dla obu stanów 95.83%. Stan  $S_4$  jest rozpoznawalny dostatecznie, sprawność klasyfikatora wynosi 79.11%. Wyniki klasyfikacji uzyskane dla stanu  $S_5$  były niedostateczne, gdyż sprawność klasyfikatora była równa 50.00%.



## 5.8. Porównanie wyników klasyfikacji

Celem pracy było m. in. zbadanie, w jakim stopniu analiza większej liczby sygnałów niż dwa może poprawić jakość wnioskowania diagnostycznego. W tym celu dokonano porównania wyników badań otrzymanych dla pojedynczych sygnałów z wynikami badań uzyskanymi dla sygnałów wielokanałowych budowanych na podstawie różnych, wcześniej zaproponowanych, zbiorów (por p. 5.4). Porównywano wyniki klasyfikacji uzyskane na podstawie różnych przestrzeni wartości cech głównych. Miarą, która służyła w analizie porównawczej, była procentowa wartość sprawności klasyfikacji. W celu porównania wyników klasyfikacji uzyskanych dla łącznie analizowanych sygnałów z wynikami uzyskanymi dla pojedynczych sygnałów posłużono się średnią sprawnością klasyfikacji, wyznaczoną na podstawie wartości sprawności klasyfikatora obliczonego dla każdego kanału osobno. Celem przeprowadzonych badań porównawczych było określenie wpływu stosowania dodatkowych sygnałów pomocniczych na jakość klasyfikacji. Badano również wpływ ograniczenia zbioru cech dodatkowych sygnałów pomocniczych na sprawność klasyfikacji stanu maszyny. Porównując otrzymane wyniki badań, starano się odpowiedzieć na następujące pytania:

- na podstawie których z wyznaczonych przestrzeni wartości cech głównych uzyskano najlepsze wyniki klasyfikacji,
- na podstawie których z wyznaczonych przestrzeni wartości cech głównych możliwe było dobre rozpoznawanie stanów uznawanych za nierozróżnialne,
- na podstawie których z wyznaczonych przestrzeni wartości cech głównych sygnałów wielokanałowych uzyskano wyniki lepsze od średnich wyników klasyfikacji otrzymanych na podstawie przestrzeni wartości cech głównych sygnałów jednokanałowych.

Aby porównać wyniki klasyfikacji, wartości sprawności klasyfikatorów wyznaczone na podstawie rozpatrywanych przestrzeni wartości cech zestawiono w tabelach. W tabeli 5.8 przedstawiono wyniki klasyfikacji uzyskane dla pierwszego zestawu danych uczących, natomiast w tabeli 5.9 przedstawiono wyniki klasyfikacji uzyskane dla drugiego zestawu danych uczących.

W przypadku pierwszego zestawu danych uczących (tab. 5.8) zaobserwowano, że najwyższą (celującą) sprawność klasyfikacji we wszystkich rozpatrywanych stanach otrzymano dla przestrzeni wartości cech głównych  $G_{x_{2,4}}^2$  oraz  $G_{x_{1,2,3,4}}^2$ . W przypadku przestrzeni wartości cech głównych  $G_{RU\phi}^2$  i  $GO_{U-RU}^2$  wyniki klasyfikacji mogą być uznane za bardzo dobre, ponieważ, aż trzy z czterech klas były rozróżnialne celująco. Na ogólnie dobrą rozpoznawalność stanów wskazują wyniki klasyfikacji uzyskane na podstawie następujących przestrzeni cech głównych:  $G_{X-R}^2$ ,  $G_R^2$ ,  $G_{U-R-RU\phi}^2$ ,  $G_{X-U-R-RU\phi}^2$  i  $GO_U^2$ . Sprawność klasyfikatora dla tych przestrzeni w co najmniej dwóch z czterech rozpatrywanych klas stanów była celująca i co najmniej w jednej bardzo dobra.

Wyniki klasyfikacji (tab. 5.9) otrzymane w drugim zestawie danych uczących wskazują, że bardzo dobrą sprawność klasyfikacji w co najmniej dwóch klasach otrzymano dla przestrzeni wartości cech głównych  $G_{x_{2,4}}^2$ ,  $G_U^2$  i  $GO_{U-RU}^2$ . W co najmniej w dwóch pozostałych klasach sprawność klasyfikatora uznano za bardzo dobrą. Na ogólnie dobrą rozpoznawalność stanów wskazują wyniki klasyfikacji uzyskane na podstawie następujących przestrzeni wartości cech głównych:  $G_{R_{2,4}}^2$ ,  $G_{RU\phi}^2$ ,  $G_{X-RU\phi}^2$ ,  $G_{U-RU\phi}^2$ ,  $G_{U-R-RU\phi}^2$ ,  $G_{X-U-R-RU\phi}^2$  i  $GO_U^2$ . Wartości kla-

Tab. 5.8. Porównanie wyników klasyfikacji dla pierwszego zestawu danych uczących

Rozpatrywana przestrzeń wartości cech głównych	Sprawność klasyfikacji [%]			
	Stan $S_1$ sprawny	Stan $S_2$ przycieranie	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe
$G_{x_{1,2}}^2$	100.00	100.00	87.50	95.83
$G_{x_{2,4}}^2$	100.00	95.83	95.83	100.00
$G_{x_{1,2,3,4}}^2$	100.00	100.00	95.83	100.00
$G_R^2$	91.67	79.17	95.83	95.83
$G_{R_{1,2}}^2$	91.67	79.17	95.83	91.67
$G_{R_{2,4}}^2$	95.83	91.67	100.00	87.50
$G_U^2$	75.00	83.33	100.00	95.83
$G_{RU\phi}^2$	95.83	79.17	100.00	100.00
$G_{X-R}^2$	91.67	91.67	100.00	95.83
$G_{X-RU\phi}^2$	83.33	66.67	91.67	91.67
$G_{U-RU\phi}^2$	87.50	70.83	100.00	100.00
$G_{U-R-RU\phi}^2$	95.83	79.17	95.83	100.00
$G_{X-U-R-RU\phi}^2$	87.50	91.67	100.00	100.00
$GO_R^2$	79.17	79.17	95.83	100.00
$GO_U^2$	91.67	95.83	87.50	95.83
$GO_{RU\phi}^2$	87.50	83.33	83.33	100.00
$GO_{RU}^2$	87.50	95.83	91.67	87.50
$GO_{U-RU}^2$	95.83	75.00	95.83	100.00
Średnia sprawność klasyfikatora dla sygnałów jednokanałowych	90.63	93.75	93.75	89.59

syfikatora w co najmniej dwóch z rozpatrywanych klas stanów były celujące i w co najmniej jednej z pozostałych klas sprawność klasyfikatora uznano za bardzo dobrą.

Pierwszy i drugi zestaw danych uczących obejmowały przykłady opisujące klasy, które z zamysłu autora miały być klasami słabo rozróżnialnymi. W przypadku pierwszego zestawu danych uczących stanami tymi były  $S_1$  i  $S_2$ , natomiast w drugim zestawie uczącym były to stany  $S_4$  i  $S_5$ . Przeprowadzona analiza wyników klasyfikacji wskazuje, że w przypadku pierwszego zestawu danych uczących celującą rozpoznawalność stanów  $S_1$  i  $S_2$  uzyskano na podstawie następujących przestrzeni wartości cech głównych:  $G_{x_{1,2}}^2$ ,  $G_{x_{2,4}}^2$  i  $G_{x_{1,2,3,4}}^2$ . Niewiele gorzej rozpoznawane były stany  $S_1$  i  $S_2$  w przypadku przestrzeni  $G_{R_{2,4}}^2$ ,  $GO_U^2$  i  $G_{X-R}^2$ .

Tab. 5.9. Porównanie wyników klasyfikacji dla drugiego zestawu danych uczących

Rozpatrywana przestrzeń wartości cech głównych	Sprawność klasyfikacji [%]			
	Stan $S_1$ sprawny	Stan $S_3$ niewyważenie statyczne	Stan $S_4$ niewyważenie momentowe	Stan $S_5$ niewyważenie momentowe i przycieranie
$G_{x_{1,2}}^2$	95.83	91.67	75.00	75.00
$G_{x_{2,4}}^2$	95.83	95.83	79.17	79.17
$G_{x_{1,2,3,4}}^2$	100.00	100.00	75.00	66.67
$G_R^2$	95.83	95.83	54.17	41.67
$G_{R_{1,2}}^2$	95.83	87.50	75.00	50.00
$G_{R_{2,4}}^2$	95.83	100.00	70.83	87.50
$G_U^2$	100.00	100.00	79.17	87.50
$G_{RU\phi}^2$	100.00	100.00	79.17	66.67
$G_{X-R}^2$	95.83	100.00	50.00	75.00
$G_{X-RU\phi}^2$	95.83	100.00	79.17	50.00
$G_{U-RU\phi}^2$	100.00	95.83	79.17	66.67
$G_{U-R-RU\phi}^2$	100.00	100.00	87.50	70.83
$G_{X-U-R-RU\phi}^2$	95.83	95.83	79.17	50.00
$GO_R^2$	100.00	100.00	62.50	66.67
$GO_U^2$	95.83	100.00	75.00	83.33
$GO_{RU\phi}^2$	95.83	87.50	83.33	54.17
$GO_{RU}^2$	95.83	58.33	75.00	83.33
$GO_{U-RU}^2$	100.00	95.83	79.17	83.33
Średnia sprawność klasyfikatora dla sygnałów jednokanałowych	95.83	90.63	70.83	81.25

W drugim zestawie danych uczących dobrą rozpoznawalność stanów  $S_4$  i  $S_5$  uzyskano na podstawie następujących przestrzeni wartości cech głównych:  $G_{x_{2,4}}^2$ ,  $G_U^2$  i  $GO_{U-RU}^2$ . Zadowalające wyniki klasyfikacji uzyskano na podstawie przestrzeni wartości cech  $GO_{U-RU}^2$ ,  $GO_U^2$  i  $GO_{RU}^2$ . Wskazują one na dobrą rozróżnialność klas  $S_4$  lub  $S_5$ . Pozostałe wyniki zestawiono w tabelach 5.8 i 5.9.

W wyniku porównania średniej wartości sprawności klasyfikatora sygnałów jednokanałowych z wynikami klasyfikacji uzyskanymi dla przestrzeni wartości cech głównych sygnałów wielokanałowych stwierdzono, że w przypadku pierwszego zestawu danych uczących sprawność klasyfikacji we wszystkich rozpatrywanych stanach  $S_1$ ,  $S_2$ ,  $S_3$  i  $S_4$  wyznaczona dla prze-

strzeni wartości cech głównych  $G_{x_{2,4}}^2$  i  $G_{x_{1,2,3,4}}^2$  była wyższa niż średnia sprawność klasyfikacji uzyskana w wyniku analizy sygnałów jednokanałowych. W drugim zestawie danych uczących lepsze wyniki klasyfikacji dla wszystkich rozpatrywanych stanów uzyskano na podstawie przestrzeni wartości cech głównych  $G_U^2$  i  $GO_{U-RU}^2$ .

W obu rozpatrywanych zestawach danych uczących lepsze wyniki klasyfikacji niż w przypadku analizy sygnałów jednokanałowych, dla co najmniej trzech z czterech rozpatrywanych stanów, uzyskano na podstawie następujących przestrzeni wartości cech:  $G_{RU\phi}^2$  i  $G_{U-R-RU\phi}^2$ .

Dla co najmniej dwóch stanów sprawność klasyfikatora uzyskanego na podstawie przestrzeni wartości cech sygnałów wielokanałowych  $G_{R_{1,2}}^2$ ,  $GO_R^2$  była wyższa od średniej sprawności klasyfikatora wyznaczonego dla sygnałów jednokanałowych.

Dobre wyniki klasyfikacji i najlepszą rozróżnialność stanów uznanych za nierozróżnialne zapewniły przestrzenie wartości cech wyznaczone w wyniku analizy sygnałów wielokanałowych utworzonych na podstawie elementów zbioru  $\mathbf{X}$  sygnałów obserwowanych.

Dostrzeżono, że dobre wyniki klasyfikacji uzyskano dla przypadków, gdy analizie poddawano sygnały wielokanałowe utworzone z dodatkowych sygnałów pomocniczych. Nie uzyskano dobrych wyników klasyfikacji wówczas, gdy analizowano sygnały wielokanałowe utworzone zarówno z sygnałów obserwowanych, jak i dodatkowych sygnałów pomocniczych.

## 5.9. Trajektorie wartości cech głównych

Przedstawiona koncepcja łącznej analizy sygnałów (por. rozdz. 4), dzięki wprowadzeniu uogólnionego okna danych, obejmuje problem łącznej analizy sygnałów zarówno w dziedzinie czasu "mikro" jak i czasu "makro". Dotychczasowe rozważania dotyczyły metodyki postępowania przy wyznaczaniu optymalnej przestrzeni wartości cech w określonej chwili czasu "makro"  $\theta_j$ , tzn. w  $j$ -tym przekroju uogólnionego okna danych.

W wyniku badań uczących wyznaczono parametry przekształcenia przestrzeni wartości cech do przestrzeni wartości cech głównych. Badania uczące polegały na rejestracji sygnałów w wielu kanałach w różnych chwilach czasu "makro". Chwile czasu "makro" nie muszą być chwilami równoodległymi. Obserwowane podczas badań uczących sygnały nie muszą pochodzić z obserwacji jednego obiektu, tylko np. z różnych obiektów tej samej klasy o podobnej konstrukcji i działaniu. Źródłem danych uczących może być również model maszyny (np. model matematyczny). Przyjęto, że przekształcenie przestrzeni wartości cech do przestrzeni wartości cech głównych nie jest zależne od czasu "makro". Uznano, że przyjęcie takiego założenia jest konieczne, ponieważ w praktycznych zastosowaniach rozpatrywanych metod aktualna wartość czasu "makro" nie jest znana. Dysponując parametrami przekształcenia, możliwe jest wyznaczenie wartości cech głównych w dowolnych chwilach czasu "makro" (dowolnych przekrojach uogólnionego okna danych). Pozwala to na wyznaczenie trajektorii wartości cech głównych w dziedzinie czasu "makro". Wyznaczone trajektorie mogą być cennym źródłem informacji o zachodzących zmianach stanu technicznego maszyny podczas jej eksploatacji. Trajektorie te można potraktować również jako sygnały, które poddane analizie, np. z zastosowaniem ocen łącznych sygnałów, pozwolą na podniesienie skuteczności diagnozowania i prognozowania stanu maszyn.

W celu wyznaczenia trajektorii wartości cech głównych, na obiekcie, na którym wcześniej przeprowadzono badania uczące (por. rozdz. 5.3), zrealizowano dodatkowy czynny eksperyment diagnostyczny, mający na celu pozyskanie sygnałów wielokanałowych w różnych chwilach czasu "makro" działania tego obiektu. Aby zachować konsekwencję w postępowaniu, wyznaczono również dwa zestawy danych obejmujące takie same stany techniczne, jakie symulowano podczas prowadzenia badań uczących.

Pierwszy oraz drugi zestaw danych obejmowały po 64 przykłady. W przypadku pierwszego zestawu danych przykłady zostały sklasyfikowane następująco:

- $S_1$  – Obiekt sprawny – 16 przykładów.
- $S_2$  – Obiekt z występującym lekkim przycieraniem – 16 przykładów.
- $S_3$  – Obiekt z występującym niewyważeniem statycznym – 16 przykładów.
- $S_4$  – Obiekt z występującym niewyważeniem momentowym – 16 przykładów.

W przypadku drugiego zestawu danych przykłady zostały sklasyfikowane następująco:

- $S_1$  – Obiekt sprawny – 16 przykładów.
- $S_3$  – Obiekt z występującym niewyważeniem statycznym – 16 przykładów.
- $S_4$  – Obiekt z występującym niewyważeniem momentowym – 16 przykładów.
- $S_5$  – Obiekt z występującym niewyważeniem momentowym i lekkim przycieraniem – 16 przykładów.

Podczas symulacji niewyważenia statycznego oraz momentowego zmieniane były wartości mas niewyważień. Dane rejestrowano w równoodległych chwilach czasu "makro" co około 120 sekund. Dla potrzeb dalszych rozważań przyjęto, że czas "makro" będzie przedstawiany w postaci numerów porządkowych chwil czasu "makro". W tabelach 5.10 i 5.11 przyporządkowano przykłady opisujące poszczególne stany do numerów chwil czasu "makro" lub przekrojów uogólnionego okna danych.

Tab. 5.10. Uporządkowanie przykładów z pierwszego zestawu danych opisujących stan techniczny maszyny względem chwil czasu "makro"

Numery chwil czasu "makro"	Stan obiektu
1-16	$S_1$ – sprawny
17-32	$S_2$ – przycieranie
33-36	$S_3$ – niewyważenie statyczne masa niewyważenia $m = 0.1$ [g] masa niewyważenia $m = 0.4$ [g] masa niewyważenia $m = 0.8$ [g] masa niewyważenia $m = 1.2$ [g]
37-40	
41-44	
45-48	
49-52	$S_4$ – niewyważenie momentowe masa niewyważenia $m = 0.1$ [g] masa niewyważenia $m = 0.4$ [g] masa niewyważenia $m = 0.8$ [g] masa niewyważenia $m = 1.2$ [g]
53-56	
57-60	
61-64	

Przyjęto, że wartości cech głównych, tworzących trajektorie w przestrzeni wartości cech głównych, wyznaczone będą na podstawie parametrów przekształceń przestrzeni wartości cech do przestrzeni wartości cech głównych, uzyskane w trakcie wcześniejszych badań uczących (por. rozdz. 5.5). Opierając się na wcześniej określonych przekształceniach dla pierwszego i drugiego zestawu danych, wyznaczono trajektorie w przestrzeni wartości cech głównych  $G_X^2$  i  $GO_{U-RU}^2$ . Ponadto dla pierwszego zestawu danych uczących wyznaczono trajektorie w przestrzeni  $G_{RU\phi}^2$ , natomiast dla drugiego zestawu danych w przestrzeni  $G_U^2$ .

Na rysunkach 5.49, 5.50, 5.51 przedstawiono kolejno przebiegi trajektorii wyznaczone dla pierwszego zestawu danych, na podstawie przestrzeni wartości cech  $G_X^2$ ,  $G_{RU\phi}^2$  i  $GO_{U-RU}^2$ .

Rysunki 5.52, 5.53, 5.54 przedstawiają trajektorie w przestrzeniach  $G_X^2$ ,  $G_U^2$  oraz  $GO_{U-RU}^2$  wyznaczone dla drugiego zestawu danych.

Każdy z rysunków zawiera rzuty trajektorii na płaszczyzny  $\theta-g_1$  i  $\theta-g_2$ , na których zaznaczono obszary wskazujące przedziały czasu "makro" występowania rozpatrywanych stanów technicznych. Dzięki temu możliwa jest identyfikacja występowania zmian stanu technicznego.

Na podstawie wszystkich przedstawionych wykresów przedstawiających rzuty trajektorii na płaszczyzny  $\theta-g_1$  i/lub  $\theta-g_2$  możliwe jest zidentyfikowanie wystąpienia stanu  $S_3$ . Stan  $S_1$  jest stanem charakteryzującym się małymi fluktuacjami w zmianach wartości cech głównych

Tab. 5.11. Uporządkowanie przykładów z drugiego zestawu danych opisujących stan techniczny maszyny względem chwil czasu "makro"


Numery chwil czasu "makro"	Stan obiektu
1-16	$S_1$ – sprawny
17-20	$S_3$ – niewyważenie statyczne masa niewyważenia $m = 0.1$ [g] masa niewyważenia $m = 0.4$ [g] masa niewyważenia $m = 0.8$ [g] masa niewyważenia $m = 1.2$ [g]
21-24	
25-28	
29-32	
33-36	
37-40	$S_4$ – niewyważenie momentowe masa niewyważenia $m = 0.1$ [g] masa niewyważenia $m = 0.4$ [g] masa niewyważenia $m = 0.8$ [g] masa niewyważenia $m = 1.2$ [g]
41-44	
45-48	
49-52	
53-56	$S_5$ – niewyważenie momentowe wraz z przycieraniem masa niewyważenia $m = 0.1$ [g] masa niewyważenia $m = 0.4$ [g] masa niewyważenia $m = 0.8$ [g] masa niewyważenia $m = 1.2$ [g]
57-60	
61-64	

w funkcji czasu "makro", zatem występowanie tego stanu na większości z przedstawionych rysunków również może być łatwo zidentyfikowane.


W przypadku pierwszego i drugiego zestawu danych rozróżnienie na przedstawionych wykresach stanów  $S_1$  i  $S_2$  oraz  $S_4$  i  $S_5$  uznawanych z założenia za nierozróżnialne jest niemożliwe. Bardzo trudna natomiast, ale możliwa, jest identyfikacja wystąpienia zmiany stanu  $S_1$  na  $S_2$  oraz  $S_4$  na  $S_5$ . Dobrze identyfikowalne były okresy czasu "makro", gdy następowało przejście do stanu  $S_3$  oraz opuszczenie tego stanu.

Występowanie lokalnych skokowych zmian wartości cech głównych w obrębie stanów  $S_3$ ,  $S_4$  i  $S_5$  może wynikać ze zmian intensywności występowania niesprawności opisującej dany stan.

a)




b)




Rys. 5.49. Trajektoria w przestrzeni wartości cech głównych  $G_X^2$  w dziedzinie czasu "makro"  $\theta$  (a), oraz jej rzuty na płaszczyzny  $\theta - g_1$  i  $\theta - g_2$  – pierwszy zestaw danych uczących (b)



a)




b)




Rys. 5.50. Trajektoria w przestrzeni wartości cech głównych  $G_{RU\phi}^2$  w dziedzinie czasu "makro"  $\theta$  (a), oraz jej rzuty na płaszczyzny  $\theta - g_1$  i  $\theta - g_2$  – pierwszy zestaw danych uczących (b)

a)




b)




Rys. 5.51. Trajektoria w przestrzeni wartości cech głównych  $GO_{U-RU}^2$  w dziedzinie czasu "makro"  $\theta$  (a), oraz jej rzuty na płaszczyzny  $\theta - g_1$  i  $\theta - g_2$  – pierwszy zestaw danych uczących(b)

a)




b)




Rys. 5.52. Trajektoria w przestrzeni wartości cech głównych  $G_X^2$  w dziedzinie czasu "makro"  $\theta$  (a), oraz jej rzuty na płaszczyzny  $\theta - g_1$  i  $\theta - g_2$  – drugi zestaw danych uczących (b)

a)




b)




Rys. 5.53. Trajektoria w przestrzeni wartości cech głównych  $G_U^2$  w dziedzinie czasu "makro"  $\theta$  (a), oraz jej rzuty na płaszczyznę  $\theta - g_1$  i  $\theta - g_2$  – drugi zestaw danych uczących (b)

a)



b)



Rys. 5.54. Trajektoria w przestrzeni wartości cech głównych  $GO_{U-RU}^2$  w dziedzinie czasu "makro"  $\theta$  (a), oraz jej rzuty na płaszczyzny  $\theta - g_1$  i  $\theta - g_2$  – drugi zestaw danych uczących (b)

### 5.9.1. Uwagi ogólne

Wyznaczone trajektorie w przestrzeni cech głównych oraz wykresy tworzące rzuty trajektorii na płaszczyzny  $\theta - g_1$  i  $\theta - g_2$  poddano analizie wizualnej (wzrokowej). Na podstawie takiej analizy możliwe było zidentyfikowanie występowania zmian lokalnych w obrębie każdego z rozpatrywanych stanów oraz zmian dotyczących przejścia jednego ze stanów w drugi. Taki sposób analizy w głównej mierze uzależniony jest od intuicji i subiektywnych odczuć badacza. Wydaje się celowe poddanie analizie przebiegów wartości cech głównych opisujących trajektorię z zastosowaniem metod analizy sygnałów, w tym metod łącznej analizy sygnałów. Można się spodziewać, że wykorzystanie tych metod dla potrzeb analizy przebiegów wartości cech głównych w dziedzinie czasu "makro" może umożliwić pozyskanie cennych informacji o dynamice i naturze zmian stanu maszyny. Problematyka ta zostanie podjęta w przyszłych badaniach autora.

## Rozdział 6

# Uwagi końcowe i wnioski

### 6.1. Podsumowanie

W pracy podjęto próbę określenia metody pozwalającej na łączną analizę większej liczby niż dwóch sygnałów diagnostycznych pochodzących z maszyny wirnikowej. W wyniku prowadzonych badań zaproponowano ogólną koncepcję łącznej analizy sygnałów, na podstawie której możliwe jest formułowanie wielu szczegółowych metod. Sformułowanie konkretnej metody na podstawie przyjętej koncepcji łącznej analizy sygnałów wymaga przyjęcia szczegółowych rozwiązań dotyczących m. in. takich zagadnień jak:

- określenie zbioru rozpatrywanych sygnałów,
- określenie zbioru rozpatrywanych cech,
- ograniczenie przestrzeni wartości cech,
- poszukiwanie optymalnej ograniczonej przestrzeni wartości cech głównych,
- określenie zbioru przykładów uczących,
- określenie metod klasyfikacji.

W pracy zaproponowano szczegółową metodę, która wykorzystuje znane i sprawdzone rozwiązania związane z przedstawionymi powyżej zagadnieniami. Celem pracy było pokazanie, że łączna analiza sygnałów pozwala na pozyskanie równoważnej lub nowej informacji diagnostycznej w stosunku do tej, która jest pozyskiwana w wyniku analizy każdego sygnału niezależnie. W pracy opisano badania związane z realizacją postawionego celu. Autor zdaje sobie sprawę, że droga, którą podążał, dochodząc do postawionego celu, jest jedną z wielu możliwych. Nie ulega wątpliwości, że możliwe jest odmienne spojrzenie na rozpatrywany problem oraz uzyskane wyniki.

### 6.2. Wnioski wynikające z pracy

Na podstawie przeprowadzonych rozważań i otrzymanych wyników badań możliwe było sformułowanie ogólnych wniosków odnoszących się do przedstawionych tez pracy oraz do zaproponowanej koncepcji łącznej analizy sygnałów. Ponadto sformulowano również wnioski szczegółowe, odnoszące się do metody, którą autor zastosował w celu weryfikacji zaproponowanej koncepcji łącznej analizy sygnałów.

### 6.2.1. Wnioski ogólne

W kontekście sformułowanych w punkcie 2.5 tez pracy możliwe było sformułowanie następujących stwierdzeń:

1. Słuszność tezy 1. wykazano poprzez wyznaczenie sprawności klasyfikatora na podstawie przestrzeni wartości cech głównych powstałych w wyniku analizy wielokanałowych dodatkowych sygnałów pomocniczych. Na podstawie badań można sądzić, że wartości łącznych cech wielokanałowych sygnałów diagnostycznych obserwowanych równocześnie pozwalają na budowanie klasyfikatorów diagnostycznych o sprawności większej od sprawności klasyfikatorów uwzględniających wartości cech sygnałów wyznaczanych oddzielnie, w każdym kanale lub w parze kanałów.
2. Słuszność tezy 2. wykazano poprzez opracowanie szczegółowej metody łącznej analizy sygnałów (por. rozdz. 4) oraz przeprowadzenie licznych badań weryfikujących tę metodę. Metodę oraz wyniki uzyskanych badań przedstawiono w rozdziale 5. Wynika z nich, że możliwe jest systematyczne poszukiwanie definicji łącznych cech sygnałów wielokanałowych, polegające na hierarchicznym łączeniu ogólnie znanych funkcyjnych cech sygnałów dwukanałowych. Skuteczność takiego postępowania nie jest bezpośrednio uzależniona od intuicji badacza.

Przedstawione wnioski opracowano na podstawie eksperymentów wykonanych w warunkach laboratoryjnych. Ogranicza to możliwość uogólniania wniosków.

Ponadto sformułowano następujące dodatkowe wnioski ogólne:

- Łączne cechy wielokanałowych sygnałów diagnostycznych mogą być definiowane "ad hoc" na podstawie wiedzy, doświadczenia i intuicji badacza. Trudno ocenić skuteczność takich działań 'a priori'.
- Stosowanie cech sygnałów wielokanałowych wyznaczonych w wyniku łącznego oceniania wartości punktowych cech sygnałów jedno- i dwukanałowych nie prowadzi do istotnej poprawy sprawności klasyfikatorów diagnostycznych w porównaniu z klasyfikatorami uwzględniającymi wartości cech sygnałów wyznaczanych oddzielnie w każdym kanale lub parze kanałów. Tak wyznaczone wartości cech sygnałów wielokanałowych nie są ich cechami łącznymi.
- Na podstawie trajektorii wartości cech wyznaczonych w dziedzinie czasu "makro" możliwe jest wnioskowanie o stanie technicznym maszyny i jego zmianach.
- Sygnały trajektorii w dziedzinie czasu "makro" mogą zostać poddane dalszej analizie. Analiza ta może być prowadzona łącznie na podstawie różnych trajektorii wartości cech głównych.

Przedstawiona w pracy koncepcja łącznej analizy sygnałów, a w jej obrębie rozwiązania polegające na budowie uogólnionego okna danych oraz określaniu zbioru dodatkowych sygnałów pomocniczych, można uznać za nowatorskie i oryginalne. Według autora zaproponowana koncepcja łącznej analizy sygnałów i będące w jej obrębie zagadnienia związane z budową uogólnionego okna danych oraz wyznaczaniem dodatkowych sygnałów pomocniczych są rozwinięciem zagadnień dotyczących łącznej analizy sygnałów. Dzięki przyjętym rozwiązaniom



możliwe jest ocenianie stanu technicznego i jego zmian. Zaproponowana koncepcja łącznej analizy sygnałów pozwala sformułować wiele nowych i ciekawych rozwiązań, obejmujących zagadnienia analizy sygnałów diagnostycznych oraz diagnozowania stanu technicznego maszyny.

### 6.2.2. Wnioski szczegółowe

Na podstawie wyników badań sformułowano następujące wnioski szczegółowe:

- Na podstawie wyników przeprowadzonych badań możliwe jest stwierdzenie, że dla badanego modelu maszyny wirnikowej sprawność klasyfikatora diagnostycznego wyznaczona na podstawie wartości cech głównych sygnału wielokanałowego określonego przez sygnały obserwowane oraz dodatkowe sygnały pomocnicze jest porównywalna, a w niektórych wypadkach większa, niż sprawności klasyfikatora wyznaczonego na podstawie przestrzeni wartości cech głównych sygnałów jednokanałowych.
- Dla rozpatrywanego zbioru danych, uzyskanego w wyniku prowadzenia czynnego eksperymentu diagnostycznego na modelu maszyny wirnikowej, dobre wyniki klasyfikacji stanu maszyny uzyskano, analizując dodatkowe sygnały pomocnicze.
- Na sprawność klasyfikatora diagnostycznego negatywny wpływ ma przyjmowanie przestrzeni wartości cech o dużej liczbie wymiarów. Celowe jest zatem ograniczanie zbioru rozpatrywanych ocen punktowych, stosowanego do oceny wielokanałowych dodatkowych sygnałów pomocniczych.
- Podczas określania zbiorów rozpatrywanych sygnałów, szczególnie dodatkowych sygnałów pomocniczych, należy uwzględniać własności i właściwości badanego obiektu.
- Przestrzeń wartości cech głównych może posłużyć do wyznaczenia trajektorii opisujących zmiany stanu technicznego w czasie "makro".
- Możliwa jest identyfikacja stanu technicznego oraz jego zmian na podstawie przebiegów wartości cech głównych w czasie "makro".

## 6.3. Kierunki dalszych badań

Przedstawiona ogólna koncepcja łącznej analizy sygnałów oraz zachęcające wyniki badań uzyskane za pomocą metody, opierającej się na powszechnie znanych rozwiązaniach i algorytmach, otwierają szerokie pole badań nad testowaniem i rozwijaniem problemów dotyczących m. in.: poszukiwania nowych cech punktowych sygnałów diagnostycznych, ograniczania przestrzeni wartości cech, poszukiwania optymalnych przekształceń przestrzeni wartości cech oraz wyboru efektywniejszych metod klasyfikacji stanu obiektu. Dużym obszarem, w obrębie którego możliwe jest podjęcie wielu interesujących badań, jest problematyka analizy sygnałów wartości cech głównych w czasie "makro".

Podczas prowadzenia badań zwrócono uwagę, że szerokie zastosowanie, przy uszczegóławianiu proponowanej koncepcji łącznej analizy sygnałów, mogą znaleźć metody sztucznej inteligencji.



# Bibliografia

- [1] Allianz. *Allianz Handbook of loss prevention*, Dusseldorf 1987.
- [2] ABB Alstom Power. *AIDA II - Modułowy system diagnostyki bloków energetycznych*, 1994.
- [3] Adamczyk J., Krzyworzeka P., Łopacz H.: *Systemy synchronicznego przetwarzania sygnałów diagnostycznych*. Collegium Columbinum, Kraków, 1999.
- [4] Affes S., Gazor S., Grenier Y.: *An algorithm for multisource beamforming and multi-target tracking*. IEEE Transaction on Signal Processing, 44(6):1512–1520, 1996.
- [5] Angelo M.: *Vibration monitoring of machines*. Brüel & Kjær, 1997. Technical Review.
- [6] API std. 617: *Centrifugal Compressors for Refinery Services*. American Petroleum Institute, 1979. Washington D.C. 20037.
- [7] API std. 670: *Vibration, Axial Position and Bearing Temperature Monitoring Systems*. American Petroleum Institute, 1985. Washington D.C. 20037.
- [8] API std. 611: *General-Purpose Steam Turbines for Refinery Service*. American Petroleum Institute, 1997. Washington D.C. 20037.
- [9] Arthur N., Penman J., McLean A., Parsons A.: *Induction Machine Condition Monitoring with Higher Order Spectra. I. Fundamentals and Fixed Frequency Operation*. Industrial Electronics Society. IECON '98. Proceedings of the 24th Annual Conference of the IEEE, tom 3, str. 1889–1894, 1998.
- [10] Attias H.: *Independent factor analysis*. Neural Computation, 11:803–851, 1998.
- [11] Barker R.W., Hinich M.J.: *Statistical Monitoring of Rotating Machinery by Cumulant Spectral Analysis*. Higher-Order Statistics, IEEE Signal Processing Workshop on, str. 187–191, 1993.
- [12] Barschdorff D.: *Signal processing for medical diagnostics*. 9th International Conference on Technical Diagnostics IMEKO TC-10, 22-54 September, Wrocław, Poland, 1999.
- [13] Barschdorff D., Femmer U.: *Signal processing and pattern recognition methods for biomedical sound analysis*. 2nd International Symposium Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques, 10-12 October, Senlis, France, 1995.
- [14] Batko W., Gibiec M.: *Diagnozowanie stanu maszyn procesowych z wykorzystaniem sieci neuronowych*. Seminarium Przegląd Projektów Badawczych KBN Akustyka w Technice Medycynie i Kulturze, Komitet Akustyki PAN, 1999.
- [15] Batko W., Gibiec M.: *Zastosowanie technik rozpoznawania obrazów oraz metod sztucznej inteligencji do klasyfikacji stanu maszyn*. IV Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych, Kazimierz Dolny, 1999.

- [16] Batko W., Gibiec M.: *Neural Networks for Automatic Machine Condition Assessment*. Lasted International Conference Modelling Identification and Control, str. 578–584, Innsbruck, 2000.
- [17] Batko W., Krzyworzeka P.: *Selection of Symptomatic Trajectories for Rapid Fault Evolution of Slide Bearings*. Machine Dynamics Problems, tom 1(25), str. 5–16, 2000.
- [18] Batko W., Mikulski A.: *Wavelet Transform of Impulse Signals*. Machine Dynamics Problems, tom 2(23), str. 139–146, 1999.
- [19] Batko W., Uhl T.: *Wybrane problemy diagnostyki maszyn*. Wyd. AGO, Cracow Centre for Advanced Training in Information Engineering, Kraków, 1996.
- [20] Batko W., Ziółko M.: *Zastosowanie teorii falek w diagnostyce technicznej*. AGH, Kraków, 2002.
- [21] Beauchamp K.G.: *Przetwarzanie sygnałów metodami analogowymi i cyfrowymi*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1978.
- [22] Bell A.J., Sejnowski T.J.: *An information-maximisation approach to blind separation and blind deconvolution*. Neural Computation, 7(6):1004–1034, 1995.
- [23] Bendat J.S., Piersol A.G.: *Metody analizy i pomiaru sygnałów losowych*. Wydawnictwo Naukowe PWN, Warszawa, 1976.
- [24] Bently Nevada. *Rotating Machinery Information System and Services*, 1991.
- [25] Bently Nevada: *Where should a Keyphasor transducer be mounted?* Orbit, 15(2):26–27, 1994.
- [26] Bently Nevada Corporation. *System 1*. <http://www.bently.com>, 2000.
- [27] Bielińska E., Bismor D., Figwer J., Kasprzak J., Legierski T., Ogonowski Z., Pawełczyk M.: *Identyfikacja procesów*. Skrypt Politechniki Śląskiej nr 2048, Gliwice, 1997.
- [28] Bielińska E., Figwer J.: *Analiza, identyfikacja i predykcja ciągów czasowych*. Skrypt Politechniki Śląskiej nr 1923, Gliwice, 1995.
- [29] Box G.E.P., Jenkins G.M.: *Analiza szeregów czasowych: prognozowanie i sterowanie*. Wydawnictwo Naukowe PWN, Warszawa, 1983.
- [30] Bracewell R.: *Przekształcenie Fouriera i jego zastosowania*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1965.
- [31] Broch J. T.: *Mechanical Vibration and Shock Measurements*. Brüel&Kjær, Denmark, 1984.
- [32] Brooks D.H., Nikias Ch.L.: *Multichannel adaptive blind deconvolution using the complex cepstrum of higher order cross-spectra*. IEEE Transaction on Signal Processing, 41(9):2928–2934, 1993.
- [33] Brotherton T., Pollard T., Jones D.: *Applications of Time-Frequency and Time-Scale Representations to Fault Detection and Classification*. Time-Frequency and Time-Scale Analysis. Proceedings of the IEEE-SP International Symposium, str. 95–98, 1992.
- [34] Brzózka G., Śliwiński A.: *Korelacyjne metody w akustyce*. Skrypt Uniwersytetu Gdańskiego nr B125, Gdańsk, 1974.
- [35] Byung-Geun Hyun, Kwanghee Nam: *Faults Diagnoses of Rotating Machines by Using Neural Nets: GRNN and BPN*. Proceedings of the IEEE IECON 21st International Con-

- ference on Industrial Electronics, Control, and Instrumentation, tom 2, str. 1456–1461, 1995.
- [36] Cempel Cz.: *Detection of clearances in machine kinematics pours by a coherence method*. Journal of Sound and Vibration, 60(3):411–416, 1978.
- [37] Cempel Cz.: *Podstawy wibroakustycznej diagnostyki maszyn*. WNT, Warszawa, 1982.
- [38] Cempel Cz.: *Diagnostyka wibroakustyczna maszyn*. PWN, Warszawa, 1989.
- [39] Cempel Cz.: *Wibroakustyka stosowana*. PWN, Warszawa, 1989.
- [40] Cempel Cz., Tomaszewski F. nad Redakcja pracy zbiorowej.: *Diagnostyka maszyn. Zasady ogólne. Przykłady zastosowań*. MCNEMT, Radom, 1992.
- [41] Choi S., Lyu Y., Berthommier F., Glotin H., Cichocki A. *Blind separation of delayed and superimposed acoustic sources: learning algorithm and experimental study*. <http://www.cnl.salk.edu/tewon/blind/demos>, 1995.
- [42] Cholewa W.: *Metoda oceny sygnału akustycznego przekładni zębatych dla badań konstrukcyjnych*. Instytut Podstaw Konstrukcji Maszyn – Politechnika Śląska, Zeszyt 22/56, Gliwice, 1974.
- [43] Cholewa W.: *Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych*. Mechanika – Zeszyty Naukowe Politechniki Śląskiej, z.764. Wydawnictwo Politechniki Śląskiej, Gliwice, 1983.
- [44] Cholewa W.: *Bazy danych w diagnostyce technicznej*. II Międzynarodowy Kongres Diagnostyki Technicznej *Diagnostyka 2000*, str. 156–164, Warszawa, 2000.
- [45] Cholewa W.: *Dynamiczne systemy doradcze*. Symposium on Methods of Artificial Intelligence in Mechanics and Mechanical Engineering AI-MECH 2000, str. 37–54, Gliwice, 2000.
- [46] Cholewa W., Kaźmierczak J.: *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów*. Skrypt Politechniki Śląskiej nr 1693, Gliwice, 1992.
- [47] Cholewa W., Kiciński J.: *Diagnostyka techniczna. Odwrotne modele diagnostyczne*. Wydawnictwo Politechniki Śląskiej, Gliwice, 1997.
- [48] Cholewa W., Kiciński J., Redakcja pracy zbiorowej: *DT200-1. System diagnostyczny dla turbozespołów energetycznych o mocy 200MW*. KPKM Pol. Śląskiej i IMP PAN, Gdańsk, listopad 1998. Projekt Badawczy Zamawiany PBZ 038-06.
- [49] Cholewa W., Kiciński J., Redakcja pracy zbiorowej: *Diagnostyka techniczna. Metody odwracania nieliniowych modeli obiektów*. Zeszyty Naukowe Katedry Podstaw Konstrukcji Maszyn, z.120. Katedra Podstaw Konstrukcji Maszyn-Politechnika Śląska, Gliwice, 2001.
- [50] Cholewa W., Moczulski W.: *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów*. Skrypt Politechniki Śląskiej nr 1758, Gliwice, 1993.
- [51] Cholewa W., Wysogład B.: *Characteristics of orbits*. Zeszyt Wydziału Mechanicznego Technologicznego Politechniki Śląskiej, 2000.
- [52] Chrzanowski P.: *Metody jakościowej oceny cech sygnałów diagnostycznych*. Zeszyty Naukowe Katedry Podstaw Konstrukcji Maszyn, z.117. Katedra Podstaw Konstrukcji Maszyn-Politechnika Śląska, Gliwice, 2001.
- [53] Ciupke K.: *Metoda selekcji i redukcji informacji w diagnostyce maszyn*. Zeszyty Na-

- ukowe Katedry Podstaw Konstrukcji Maszyn, z.118. Katedra Podstaw Konstrukcji Maszyn-Politechnika Śląska, 2001.
- [54] Collis W.B., White P.R., Hammond J.K.: *Higher order spectra and condition monitoring*. 2nd International symposium Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques, 10-12 October, Senlis, France, 1995.
- [55] Collis W.B., White P.R., Hammond J.K.: *Higher-order spectra: The bispectrum and trispectrum*. Mechanical Systems and Signal Processing, 12(3):375–394, 1998.
- [56] Couche J., Fuller Ch.: *Active control of power train and road noise in the cabin of a sport utility vehicle with advanced speakers*. Active 99, 02-04 December, Fort Lauderdale, Florida, USA, 1999.
- [57] Czop P.: *Linear and nonlinear diagnostic model of rotating machine under transient operating conditions – A comparison*. Symposium on Methods of Artificial Intelligence in Mechanics and Mechanical Engineering AI-MECH 2001, str. 49–56, Gliwice, 2001.
- [58] Czop P.: *Diagnostic models of rotating machinery under transient operating conditions*. Zeszyty Naukowe Katedry Podstaw Konstrukcji Maszyn, z.122. Katedra Podstaw Konstrukcji Maszyn-Politechnika Śląska, 2002.
- [59] Dalle Molle J.W., Hinich M.J.: *The trispectrum*. Proceedings of the Workshop Higher Order Spectral Analysis, str. 68–72, Vail, 1989.
- [60] Davis S.S.: *Vibration analysis of rotating machinery using the spectral distribution function*. Journal of Sound and Vibration, 214(5):805–815, 1998.
- [61] Dietrych J.: *System i konstrukcja*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1978.
- [62] Ding J., Krodkiewski J.M.: *Inclusion of static indetermination in the mathematical model non-linear dynamic analysis of multi-bearing rotor system*. Journal of Sound and Vibration, 164(2):267–280, 1993.
- [63] Duda R., Hart P.E.: *Pattern Classification and Scene Analysis*. John Wiley & Sons Inc., New York-London-Sydney-Toronto, 1973.
- [64] Duin R.P.W. *A Matlab toolbox for pattern recognition*. <http://www.ph.tn.tudelft.nl/prtools>, 2000.
- [65] Fackrell J.W.A., McLaughlin S., Collis W.B., White P.R.: *Nonlinearity detection for condition monitoring using higher-order statistics*. Proceedings of COMADEM96, str. 519–528, 1996.
- [66] Fackrell J.W.A., White P.R., Hammond J.K., Pinnington R.J., Parsons A.T.: *The interpretation of the bispectra of vibration signals – I. Theory*. Mechanical Systems and Signal Processing, 9(3):257–274, 1995.
- [67] Fidali M.: *Identyfikacja niesprawności maszyn wirnikowych w warunkach stacjonarnych oraz podczas rozruchu i wybiegu*. Praca przejściowa II, Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska w Gliwicach, 1996.
- [68] Fidali M.: *Metody łącznej analizy sygnałów w wielokanałowych układach diagnozujących dla maszyn wirnikowych*. IV Krajowa Konferencja Naukowo-Techniczna. Diagnostyka Procesów Przemysłowych, Kazimierz Dolny 13-16 wrzesień, 1999.
- [69] Fidali M.: *Metoda adaptacyjnej detekcji zmiany stanu technicznego maszyny wirnikowej*

- do zastosowania w wielokanałowych układach dla maszyn wirnikowych.* Proceedings of the Symposium on Methods of Artificial Intelligence in Mechanics and Mechanical Engineering AI-MECH 2000, Gliwice 15th-17th November, 2000.
- [70] Fidali M.: *Łączne cechy wielokanałowych sygnałów diagnostycznych maszyn wirnikowych.* XXVIII Ogólnopolskie Sympozjum Diagnostyka Maszyn, Węgierska Górka 26 luty - 3 marzec, 2001.
- [71] Fidali M.: *Joint signal analysis in the multichannel diagnosis systems for rotating machinery.* Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques Conference - Surveillance 4., Compiègne - France, 16-18 October, 2001.
- [72] Fidali M.: *Widmo wzajemne gęstości mocy sygnałów zespolonych w wielokanałowych układach diagnozujących dla maszyn wirnikowych.* V Krajowa Konferencja Naukowo-Techniczna DPP'2001, Łągów Lubuski 17-19 wrzesień, 2001.
- [73] Fidali M.: *Joint analysis of signals. The general idea.* Proceedings of the Symposium on Methods of Artificial Intelligence AI-METH 2002, Gliwice 13th-15th November, 2002.
- [74] Frank P.M., Ding S.X., Köppen-Seliger B.: *Current Trends in FDI Theory.* V Krajowa Konferencja Naukowo-Techniczna "Diagnostyka Procesów Przemysłowych", str. 3–16, Łągów Lubuski, 2001.
- [75] Fuller C.R., von Flotow A.H.: *Active control of sound and vibration.* IEEE Control Systems Journal, 15(6):9–19, 1995.
- [76] Gade S., Herlufsen H.: *Windows to FFT analysis (Part I, II).* Technical Review No.3, 4 Brüel & Kjær, Naerum, 1987.
- [77] Gade S., Herlufsen H., Konstantin-Hansen H., Wismer N.J.: *Order tracking analysis.* Technical Review No.2 Brüel & Kjær, Naerum, 1995.
- [78] Gelle G., Colas M., Delaunay G.: *Blind sources separation applied to rotating machines monitoring by acoustical and vibrations analysis.* Mechanical Systems and Signal Processing, 14(3):427–442, 2000.
- [79] Gershman A.B., Turchin V.I., Zverev V.A.: *Experimental results of localization of moving underwater signal by adaptive beamforming.* IEEE Transaction on Signal Processing, 43(10):2749–2267, 1995.
- [80] Giergiel J., Uhl T.: *Identyfikacja układów mechanicznych.* Wydawnictwo Naukowe PWN, Warszawa, 1990.
- [81] Goldman P., Muszyńska A.: *Application of Full Spectrum to Rotating Machinery Diagnostics.* Orbit, Bentley Nevada Corporation, kwiecień 1999.
- [82] Gosiewski Z., Muszyńska A.: *Dynamika maszyn wirnikowych.* Wyższa Szkoła Inżynierska w Koszalinie, Koszalin, 1992.
- [83] Gray S.D., Preisig J.C., Brady D.: *Multiuser detection in horizontal underwater acoustic channel using array observations.* IEEE Transaction on Signal Processing, 45(1):48–160, 1997.
- [84] Gryboś R.: *Dynamika maszyn wirnikowych.* IPPT PAN, Warszawa, 1994.
- [85] Hagel R., Szuta J.: *Podstawy miernictwa wielkości stochastycznych.* Skrypt Politechniki Śląskiej nr 1187, Gliwice, 1985.

- [86] Isermann R.: *Supervision, Fault-Detection and Fault-Diagnosis Methods - an Introduction*. Control Eng. Practice, 5(5):639–652, 1997.
- [87] Jajuga K.: *Korelacyjne metody pomiarowe i ich dokładności*. Wydawnictwo Wyższej Szkoły Inżynierskiej w Zielonej Górze, Zielona Góra, 1995.
- [88] Jajuga K.: *Statystyczna teoria rozpoznawania obrazów*. Wydawnictwo Naukowe PWN, Warszawa, 1990.
- [89] Jajuga K.: *Statystyczna analiza wielowymiarowa*. Wydawnictwo Naukowe PWN, Warszawa, 1993.
- [90] Janczak A.: *Parametric and neural network models for fault detection and isolation of industrial process sub-modules*. 5th IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes, Budapest, Hungary, 14-16 June, 2000.
- [91] Jankowska A., Mendis W.: *Sztuczna sieć neuronowa w zadaniu predykcji parametrów drgań tarciowych*. IV Krajowa Konferencja Naukowo-Techniczna. Diagnostyka Procesów Przemysłowych, Łagów k/Zielonej Góry, 8-11 wrzesień, 1997.
- [92] Janson M., Göransson B., Ottersten B.: *A subspace method for direction of arrival estimation of uncorrelated emitter signals*. IEEE Transaction on Signal Processing, 47(4):945–956, 1999.
- [93] Jaw L.C.: *Neural Networks for Model-Based Prognostics*. Aerospace Conference. Proceedings, tom 3, str. 21–28. IEEE, 1999.
- [94] Kaczorek T.: *Teoria sterowania i systemów*. Wydawnictwo Naukowe PWN, Warszawa, 1999.
- [95] Kay S.M.: *Modern spectral estimation: theory and application*. Prentice Hall, New Jersey, 1988.
- [96] Kerezsi B., Howard I.: *Vibration Fault Detection of Large Turbogenerators Using Neural Networks*. IEEE International Conference on Neural Networks. Proceedings, tom 1, str. 121–126, 1995.
- [97] Kiciński J.: *Model-Based Diagnostics in Rotating Machinery*. 9th IMEKO TC-10 International Conference on Technical Diagnostics, str. 56–67, Wrocław, 1999.
- [98] Klimek A.: *Metody doskonalenia odwrotnych modeli diagnostycznych*. Mechanika – Zeszyty Naukowe Politechniki Śląskiej, z.134. Wydawnictwo Politechniki Śląskiej, Gliwice, 1999.
- [99] Ko Ch.-W., Lin Y.D., Chung H.W., Jan G.J.: *An EEG spike detection algorithm using artificial neural network with multi-channel correlation*. Proceedings of the 20th annual international conference of the IEEE Engineering in Medicine and Biology Society, 20(4):2070–2073, 1998.
- [100] Kościelny J.M.: *Diagnostyka zautomatyzowanych procesów przemysłowych*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2001.
- [101] Korbicz J.: *Metody rozpoznawania obrazów w diagnostyce procesów przemysłowych*. Krajowa Konferencja Naukowo Techniczna. Diagnostyka Procesów Przemysłowych, Jurata k/Gdańska, 1998.
- [102] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., Redakcja pracy zbiorowej: *Dia-*



- gnostyka procesów: Modele. Metody sztucznej inteligencji. Zastosowania.* Wydawnictwa Naukowo-Techniczne, Warszawa, 2002.
- [103] Korbicz J., Obuchowicz A., Uciński D.: *Sztuczne sieci neuronowe. Podstawy i zastosowania.* Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1994.
- [104] Kostka P.: *Eksperyment numeryczny dla potrzeb odkrywania relacji diagnostycznych.* II Międzynarodowy Kongres Diagnostyki Technicznej Diagnostyka 2000, Warszawa, 2000.
- [105] Kostka P.: *Metody klasyfikacji postaci kinetostatycznych linii wałów maszyn wirnikowych.* Zeszyty Naukowe Katedry Podstaw Konstrukcji Maszyn, z.121. Katedra Podstaw Konstrukcji Maszyn-Politechnika Śląska, 2002.
- [106] Kowalczyk Z., Gunawickrama K.: *Metoda korelacyjno-mpdelowa wykrywania przecieków z estymacją współczynnika tarcia.* IV Krajowa Konferencja Naukowo-Techniczna. Diagnostyka Procesów Przemysłowych, Łagów k/Zielonej Góry, 8-11 wrzesień, 1997.
- [107] Lambert R.H.: *Multichannel blind deconvolution: FIR matrix algebra and separation of multipath mixtures.* PhD thesis, Faculty of the Graduate School, University of Southern California, 1996.
- [108] Lee S.K., White P.R.: *Higher-order time-frequency analysis and its application to fault detection in rotating machinery.* Mechanical Systems and Signal Processing, 11(4):637–650, 1997.
- [109] Ljung L.: *System Identification Toolbox For Use with MATLAB.* The MathWorks Inc., 2001.
- [110] Lyons R.G.: *Wprowadzenie do cyfrowego przetwarzania sygnałów.* Wydawnictwa Komunikacji i Łączności, Warszawa, 2000.
- [111] Łączkowski R.: *Wyważanie elementów wirujących.* Wydawnictwa Naukowo-Techniczne, Warszawa, 1979.
- [112] Łączkowski R.: *Wibroakustyka maszyn i urządzeń.* Wydawnictwa Naukowo-Techniczne, Warszawa, 1983.
- [113] Mańczak K.: *Metody identyfikacji wielowymiarowych obiektów sterowania.* Wydawnictwa Naukowo-Techniczne, Warszawa, 1979.
- [114] Marcu T., Mirea L., Ferariu L., Frank P.M.: *Miscellaneous neural networks applied to fault detection and isolation of an evaporation station.* 4th IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes, Budapest, Hungary, 14-16 June, 2001.
- [115] Mas P., Delmotte P., Sas P.: *Noise source identification based on measurements of cross-correlation functions.* Proc. of IEEE Instrumentation and Measurement Technology Conference, Brussels, June 4-6, 1996.
- [116] Masłowski A.: *Wprowadzenie do analizy dynamiki układów fizycznych, cz. III Identyfikacja.* Skrypt Politechniki Białostockiej, Białystok, 1991.
- [117] McCormick A.C.: *Cyclostationary and higher-order statistical signal processing algorithms for machine condition monitoring.* PhD thesis, University of Strathclyde, 1998.
- [118] McCormick A.C., Nandi A.K.: *Neural Network Autoregressive Modeling of Vibrations for Condition Monitoring of Rotating Shafts.* Neural Networks. International Conference on, tom 4, str. 2214–2218. IEEE, 1997.

- [119] McCormick A.C., Nandi A.K.: *Real-time Classification of Rotating Shaft Loading Conditions Using Artificial Neural Networks*. IEEE Transactions on Neural Networks, Volume 8, Issue 3:748–757, maj 1997.
- [120] McCormick A.C., Nandi A.K.: *Bispectral and trispectral features for machine condition diagnosis*. IEE Proc-Vis Image Signal Processing, 146(5):229–234, October 1999.
- [121] Mendel J.M.: *Tutorial on Higher-Order Statistics (Spectra) in Signal Processing and System Theory: Theoretical Results and Some Applications*. Proceedings of the IEEE, 79(3):278–305, 1991.
- [122] Menon K.S., Parlos A.G., Atiya A.F.: *Nonlinear state filtering for fault diagnosis and prognosis in complex systems using recurrent neural networks*. 4th IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes, Budapest, Hungary, 14-16 June, 2000.
- [123] Mertins A.: *Signal analysis: wavelets, filter banks, time-frequency transforms and applications*. John Wiley & Sons, Chichester, 1999.
- [124] Moczulski W.: *Metoda wibroakustycznych badań maszyn wirnikowych w warunkach rozruchu lub zatrzymania*. Praca Doktorska, IMiPKM, Politechnika Śląska, Gliwice, 1984.
- [125] Moczulski W.: *The digital synchronous filtering technique*. Mechanical Systems and Signal Processing, 1(2):197–210, 1987.
- [126] Moczulski W.: *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*. Mechanika – Zeszyty Naukowe Politechniki Śląskiej, z.130. Politechnika Śląska, Gliwice, 1997.
- [127] Moczulski W.: *Acquisition of Diagnostic Knowledge from Databases of Examples*. 9th IMEKO TC-10 International Conference on Technical Diagnostics, str. 190–197, Wrocław, 1999.
- [128] Moczulski W.: *Automated Search for Diagnostic Knowledge on Rotating Machinery*. J. M. Żytkow, W. Klösgen, editors, *Handbook of Data Mining and Knowledge Discovery*, chapter 46.6. Oxford University Press, 2000.
- [129] Moczulski W.: *Pozyskiwanie wiedzy deklaratywnej i proceduralnej*. Symposium on Methods of Artificial Intelligence in Mechanics and Mechanical Engineering AI-MECH 2000, str. 55–69, Gliwice, 2000.
- [130] Moczulski W.: *Diagnostyka techniczna. Metody pozyskiwania wiedzy*. Monografie - Budowa i Eksploatacja Maszyn. Wydawnictwo Politechniki Śląskiej, Gliwice, 2002.
- [131] Moczulski W., Wysogład B., J. Maraszewski, R. Wyczółkowski: *Przykład oceny nadmiernych drgań turbozespołu*. Przegląd Mechaniczny, 6(1–2):38–41, 1995.
- [132] Morel J.: *Drgania maszyn i diagnostyka ich stanu technicznego*. Polskie Towarzystwo Diagnostyki Technicznej, Warszawa, 1994.
- [133] Morrison D.F.: *Wielowymiarowa analiza statystyczna*. Wydawnictwo Naukowe PWN, Warszawa, 1990.
- [134] Mosher J.C., Leahy R.M.: *Source localization using recursively applied and projected (RAP) MUSIC*. IEEE Transaction on Signal Processing, 47(2):332–340, 1999.
- [135] Nandi A.K., Dickie J.A., Smith J.A., Tutschku K.: *Classification of conditions of rotating machines using higher order statistics*. IEE Colloquium on HOS, 1995.

- [136] Niederliński A., Kasprzyk J., Figwer J.: *Multi-Edip analizator wielowymiarowych sygnałów i obiektów*. Skrypt Politechniki Śląskiej nr 2017, Gliwice, 1997.
- [137] Nikias Ch.L., Petropulu A.P.: *Higher - order spectra analysis. A nonlinear signal processing framework*. Prentice Hall, New Jersey, 1993.
- [138] Nikis Ch.L., Mendel J.M.: *Signal Procesing with Higher-Order spectra*. IEEE Signal Processing Magazine, July:10–37, 1993.
- [139] Nocoń G., Wrodarczyk H.: *Pierwszy polski stacjonarny system do nadzoru i diagnostyki turbogeneratorów*. Technicad. Nadzór i diagnostyka maszyn, 6, 1996.
- [140] Nocoń G., Wrodarczyk H., Spyra A.: *Stacjonarny system do nadzoru i wibrodiagnostyki maszyn wirnikowych*. Technicad. Nadzór i diagnostyka maszyn, 8/9, 1999.
- [141] Orłowski Z.: *Diagnostyka w życiu turbin parowych*. Wydawnictwa Naukowo-Techniczne, Warszawa, 2001.
- [142] Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1996.
- [143] Parszewski Z.: *Drgania i dynamika maszyn*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1982.
- [144] Patan K., Korbicz J.: *Application of dynamic neural networks in ad industrial plant*. 4th IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes, 14-16 June, Budapest, Hungary, 2000.
- [145] Patton R.J.: *Fault diagnosis of a simulated model of an industrial gas turbine prototype using identification techniques*. 4th IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes, Budapest, Hungary, 14-18 June, 2000.
- [146] Pavlidis T.: *Grafika i przetwarzanie obrazów*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1987.
- [147] Pieczyński A.: *Komputerowe systemy diagnostyczne procesów przemysłowych. Monografia*. Politechnika Zielonogórska, Zielona Góra 1999.
- [148] Radkowski S.: *Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych*. Wydawnictwo Instytutu Technologii Eksploatacji, Warszawa-Radom, 2002.
- [149] Randall R.B., Tech B., B.A.: *Frequency analysis*. Brüel & Kjær, Denmark, 1987.
- [150] Ridlle L.R., Lease S.A. Murray J.J.: *Active noise control architecture for the smart sleeve demonstration*. Active 92, Fort Lauderdale, Florida, USA, 2-4 December, 1999.
- [151] Rutkowski L.: *Filtry adaptacyjne i adaptacyjne przetwarzanie sygnałów*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1994.
- [152] Sabry-Rizk M., Romare D., Zgallai W., Grattan K.T.V., Hardiman P., Oriordan J.: *Higher order statistics (HOS) in signal processing. Are they of any use?* IEE Colloquium on HOS, str. 1–7, 1995.
- [153] Schenck C.: *Methods, Applications and Solutions of Conventional and Vibration-Diagnostic Condition Monitoring of Turbo-Sets in Power Stations and Industrial Plants*. SCHENCK, Darnstadt, 1995.
- [154] Sekihara K., Nagarajan S., Poeppel D., Miyashita Y.: *Time-frequency MEG-MUSIC algorithm*. IEEE Transaction on Medical Imaging, 18(1):92–97, 1999.

- [155] Shan J.M.: *Vibration analysis of rotating machinery using a bispectrum*. Journal of Sound and Vibration, 4(200):533–539, 1997.
- [156] Sobczak W. Malina W.: *Metody selekcji i redukcji informacji*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1985.
- [157] Soderstrom T., Stoica P.: *Identyfikacja systemów*. Wydawnictwo Naukowe PWN, Warszawa, 1997.
- [158] Srivastava A., Miller M.I., Grenander U.: *Multiple target direction of arrival tracking*. IEEE Transaction on Signal Processing, 43(5):0282–1285, 1995.
- [159] Swami A., Giannakis G.B., Zhou G.: *Bibliography on higher-order statistics*. Signal Processing, 60 (1993):95–166, 1997.
- [160] Swami A., Mendel J.M., Nikias Ch.L.: *Higher-order spectral analysis toolbox*. Math-Works, 1998. Matlab user's guide.
- [161] Szabatin J.: *Podstawy teorii sygnałów*. Wydawnictwa Komunikacji i Łączności, 2000.
- [162] Tadeusiewicz R., Flasiński M.: *Rozpoznawanie obrazów*. Wydawnictwo Naukowe PWN, Warszawa, 1991.
- [163] Timofiejczuk A.: *Metoda badania maszyn wirnikowych w warunkach rozruchu, rozbiegu i wybiegu*. Mechanika – Zeszyty Naukowe Politechniki Śląskiej, z.133. Wydawnictwo Politechniki Śląskiej, Gliwice, 1999.
- [164] Tugnait J.K.: *On time delay estimation with unknown spatially correlated gaussian noise fourth-order cumulants and cross cumulants*. IEEE Transaction on Signal Processing, 39(6):1258–1267, 1991.
- [165] Uhl T.: *Współczesne rozwiązania systemów monitorowania stanu maszyn*. V Krajowa Konferencja Naukowo-Techniczna DPP'2001, Łągów Lubuski 17-19 wrzesień, 2001.
- [166] Wan Q., Koch D.B.: *Multichannel spectral analysis for tube leak detection*. Proceedings of the IEEE, 1993.
- [167] Widrow B., Glover J.R., McCool J.M., Kaunitz J., Williams Ch.S., Hearn R.H., Zeidler J.R., Dong E., Goodlin R.C.: *Adaptive Noise Cancelling: Principles and Applications*. Proceedings of the IEEE, 63(12):1692–1716, 1975.
- [168] Wiener N.: *Extrapolation, interpolation and smoothing of stationary time series, with engineering applications*. Wiley, New York, 1949.
- [169] Wojnar A.: *Teoria sygnałów*. Wydawnictwa Naukowo-Techniczne, Warszawa, 1980.
- [170] Wróbel Z., Koprowski R.: *Przetwarzanie obrazu w programie MATLAB*. Wydawnictwo Uniwersytetu Śląskiego, Katowice, 2001.
- [171] Wu R., Ma Y., James R.D.: *Array pattern synthesis and robust beamforming for a complex sonar system*. IEE Proc.–Radar, Sonar Navig., 144(6):370–376, 1997.
- [172] Wysogład B.: *Zastosowanie dyskretnej transformacji Fouriera do analizy sygnałów dwuwymiarowych opisujących trajektorie ruchu środka czopa w łożysku ślizgowym*. III Intern. Conf. Achievements in Mechanical and Material Engineering, T I:389–316, 1992.
- [173] Wysogład B.: *Metody reprezentacji drgań wałów maszyn wirnikowych w diagnostycznych bazach danych*. Mechanika – Zeszyty Naukowe Politechniki Śląskiej, z.126. Wydawnictwo Politechniki Śląskiej, Gliwice, 1996.

- [174] Yang H.H., Amari S., Cichocki A.: *A new learning algorithm for blind signal separation. In: Advances in neural information processing systems.* MIT Press, Cambridge, 1996.
- [175] Yang H.H., Amari S., Cichocki A.: *Information-theoretic approach to blind separation of sources in non-linear mixture.* Signal Processing, 64:291–300, 1998.
- [176] Yuan Ch., Azimi-Sadjadi M.R., Wilbur J., Dobeck G.J.: *Underwater target detection using multichannel subband adaptive filtering and high-order correlation schemes.* IEEE Journal of Oceanic Engineering, 25(1):192–205, 2000.
- [177] Zhang W., Raghuveer M.: *Nonparametric bispectrum-based time delay estimators for multiple sensor data.* IEEE Transaction on Signal Processing, 39(3):770–774, 1991.
- [178] Zhao L., Sheng Z.: *Combination of Discrete Cosine Transform with Neural Network in Fault Diagnosis for Rotating Machinery.* Proceedings of The IEEE International Conference on Industrial Technology (ICIT '96), str. 450–454, 1996.
- [179] Zhenya He, Meng Wu, Bi Gong: *Neural Network and its Application on Machinery Fault Diagnosis.* IEEE International Conference on Systems Engineering, str. 576–579, 1992.
- [180] Żółkowski B.: *Podstawy diagnostyki technicznej maszyn.* Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej w Bydgoszczy, Bydgoszcz 1996.

# Metody łącznej analizy sygnałów w wielokanałowych układach diagnozujących maszyny wirnikowych

(Streszczenie)

Celem badań było opracowanie i weryfikacja metody łącznej analizy sygnałów wibroakustycznych obserwowanych jednocześnie w wielu kanałach podczas działania maszyny wirnikowej.

W ramach przeprowadzonych działań opracowano ogólną koncepcję łącznej analizy sygnałów. Zaproponowana koncepcja łącznej analizy sygnałów może stanowić podstawę do formułowania wielu różnych metod łącznej analizy sygnałów. W przedstawionej koncepcji zaproponowano rozwiązanie oparte na uogólnionym oknie danych, które pozwala na jednoczesne opisanie sygnałów diagnostycznych obserwowanych w  $k$  kanałach pomiarowych w czasie „mikro” oraz w czasie „makro”. Danymi, w rozpatrywanym oknie danych, są wartości sygnałów, poddawane przetwarzaniu i analizie w dwóch etapach. Pierwszy etap dotyczy analizy sygnałów w czasie „mikro”, dokonanej w celu wyznaczenia wartości cech punktowych. Etap drugi polega na identyfikacji zmiany stanu obiektu w czasie „makro” na podstawie wartości cech sygnałów wyznaczonych w etapie pierwszym. Dla potrzeb łącznej analizy sygnałów wprowadzono pojęcie dodatkowego sygnału pomocniczego, którego wartości określane są na podstawie wartości wybranych par sygnałów obserwowanych w  $k$  kanałach w dziedzinie czasu „mikro”. Na podstawie zbioru obserwowanych sygnałów, uzupełnionego o dodatkowe sygnały pomocnicze, możliwe jest wyznaczenie wielowymiarowej przestrzeni wartości cech oraz ograniczenie liczby jej wymiarów poprzez transformację do przestrzeni wartości cech głównych. Opierając się na zaproponowanej koncepcji łącznej analizy sygnałów, sformułowano szczegółową metodę analizy sygnałów. Dla potrzeb weryfikacji zaproponowanej metody przeprowadzono czynny eksperyment diagnostyczny, na specjalnie do tego celu przygotowanym stanowisku laboratoryjnym. Pozyskano sklasyfikowany zbiór przykładów uczących niezbędnych do budowy klasyfikatora uczącego. Następnie przeprowadzono klasyfikację stanu obiektu. Dokonano porównania wyników badań uzyskanych na podstawie łącznej analizy sygnałów oraz analizy każdego z tych sygnałów z osobna. Na podstawie otrzymanych wyników klasyfikacji stwierdzono, że wartości łącznych cech wielokanałowych sygnałów diagnostycznych obserwowanych równocześnie pozwalają na budowanie klasyfikatorów diagnostycznych o sprawności większej od sprawności klasyfikatorów uwzględniających wartości cech sygnałów wyznaczanych oddzielnie w każdym kanale lub parze kanałów. Stwierdzono, że możliwe jest systematyczne poszukiwanie definicji łącznych cech sygnałów wielokanałowych, polegające na hierarchicznym łączeniu ogólnie znanych funkcyjnych cech sygnałów dwukanałowych. Skuteczność takiego postępowania nie jest bezpośrednio uzależniona od intuicji badacza.

Opracowana metoda może znaleźć zastosowanie w wielokanałowym układzie diagnozującym dla maszyn wirnikowych i umożliwić poprawną klasyfikację stanu technicznego maszyny oraz detekcję zmian stanu technicznego.

**Słowa kluczowe:** diagnostyka maszyn, maszyny wirnikowe, analiza sygnałów, wielokanałowe układy diagnozujące, łączne cechy sygnałów, klasyfikacja stanu maszyny.

**Dziedziny:** diagnostyka maszyn, eksploatacja maszyn, analiza sygnałów.

# Joint signal analysis in the multichannel diagnosis systems of rotating machinery

(Summary)

The goal of the research was to elaborate and verify a method of joint analysis of signals, which are observed in several channels while a rotating machine operates.

Within the confines of research carried out, a concept of the joint signal analysis was worked out. On the basis of the proposed concept of this analysis a few methods of joint analysis of signals can be formulated. In the case of the presented conception a solution basing on the generalized data window was proposed. The window enables us to describe simultaneously observed diagnostic signals within  $k$  channels in the "micro" and "macro" time domains. In the generalized data window there are data, which are signal values. They are processed and analyzed within two stages. The first stage concerns the analysis of signals in the "micro" time domain in order to obtain point feature values. The second stage consists in identification of changes of object state in the "macro" time domain on the basis of the feature values estimated in the first stage. In order to apply the joint signal analysis some kinds of new signals were introduced. They are called additional virtual signals. Values of these signals are obtained as a result of observation of pairs of signal in  $k$  channels in the "micro" time domain. The set of observed signals, completed with the virtual signals, makes it possible to estimate a multidimensional space of the feature values. On the basis of the general idea of the joint analysis a detailed method of signal analysis was proposed. In order to verify the proposed method the active diagnostic experiment with the use of (special prepared) a laboratory stand was carried out. A classified set of learning examples needed for building a learning classifier was obtained. Basing on the learning data set the classification of the object technical state was made. Comparison of research results obtained with the use of the joint analysis and the results obtained on the basis of separate analysis of these signals was made. Obtained results of this classification let us to state that values of the joint features of the multichannel signals, which are simultaneously observed, allow building diagnostic classifiers. Their efficiencies are greater than such classifiers that are built on the basis of feature values of signals, which are estimated separately within each channel or within two channels. One can also state that systematic searching for the joint features of the multichannel signal definitions is possible. It can be performed by means of hierarchical connection of commonly known function features of two-channel signals. Effectiveness of such the approach does not directly depend on intuition of a researcher.

The method, which has been worked out may find an application in the multichannel diagnostic system of rotating machinery. Moreover, the method allows good classifying and detecting changes of technical states of the machines, which were investigated.

**Keywords:** machinery diagnostics, rotating machinery, multichannel diagnostic system, joint signal features, machine state classification.

**Domains:** machinery diagnostics, machinery operating, signal analysis.