

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

Jacek Wojtusik

**Wielomodele
diagnostyczne
maszyn
wirnikowych**

Gliwice 2006

Recenzenci

Prof. dr hab. inż. Jan Maciej Kościelny, Politechnika Warszawska

Prof. dr hab. Wojciech Moczulski, Politechnika Śląska

Redaktor zeszytów

Wojciech Cholewa

Redaktor techniczny

Marek Wyleźoń

Projekt okładki

Wojciech Cholewa, Marek Wyleźoń

ISBN 83–916957–2–7

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

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

Od autora

Zeszyt został opracowany na podstawie mojej rozprawy doktorskiej, wykonanej pod kierunkiem prof. dra hab. inż. Wojciecha Cholewy. Publiczna obrona rozprawy odbyła się 8 lutego 2006 roku przed Komisją powołaną przez Radę Wydziału Mechanicznego Technologicznego. W opracowaniu zostały uwzględnione uwagi recenzentów rozprawy doktorskiej: prof. dra hab. inż. Jana Macieja Kościelnego i prof. dra hab. Wojciecha Moczulskiego.

Niniejszą książkę dedykuje mojej żonie Aleksandrze oraz synkowi Bartusiowi w podziękowanie za wyrozumiałość i cierpliwość. Składam serdeczne podziękowania Koleżankom i Kolegom z Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej za okazaną mi pomoc i życzliwość w czasie wykonywania pracy. Szczególnie zaś dziękuję prof. dr. hab. inż. Wojciechowi Cholewie za pomoc w realizacji badań oraz cenne uwagi krytyczne.

Gliwice, marzec 2006

Jacek Wojtusik

Część badań opisanych w pracy wykonano w ramach projektu promotorskiego KBN 4 T07B 068 26 pod tytułem „Wielomodele diagnostyczne maszyn wirnikowych” finansowanego przez Komitet Badań Naukowych.

Spis treści

Od autora	3
Rozdział 1. Wstęp	9
Rozdział 2. Geneza badań	11
2.1. Pojęcia podstawowe	11
2.1.1. Cechy	11
2.1.2. Czas w diagnostyce technicznej	12
2.1.3. Cechy sygnałów diagnostycznych	12
2.1.4. Cechy stanu	14
2.1.5. Klasy stanu	15
2.1.6. Przestrzeń obrazów cech	15
2.2. Ocena stanu obiektów technicznych	16
2.2.1. Diagnostowanie stanu technicznego maszyn	16
2.2.2. Diagnostyka symptomowa	17
2.2.3. Diagnostyka bazująca na modelach	18
2.2.4. Proces diagnostowania z zastosowaniem modeli obiektów	19
2.2.5. Proces diagnostowania z zastosowaniem modeli diagnostycznych	19
2.3. Cel pracy	21
2.4. Tezy pracy	22
2.5. Zakres pracy	22
Rozdział 3. Modele w diagnostyce technicznej	23
3.1. Modele obiektów	23
3.1.1. Modele strukturalne	23
3.1.2. Modele relacji	24
3.1.3. Koncepcja „czarnej skrzynki”	25
3.1.4. Zastosowanie modeli obiektów	26
3.2. Modele diagnostyczne	28
3.3. Modele dokładne i przybliżone	30
3.3.1. Metody bazujące na klasyfikacji i grupowaniu	31
3.3.2. Sieci neuronalne	32
3.3.3. Zbiory rozmyte	32
3.3.4. Sieci przekonań	32

3.3.5. Metody odwzorowań	33
3.4. Wejścia i wyjścia modeli	34
Rozdział 4. Wielomodele	37
4.1. Etymologia nazwy	38
4.2. Klasyfikacja wielomodeli	39
4.3. Modele wielowarstwowe	40
4.3.1. Modele wieloaspektowe	41
4.3.2. Modele sekwencyjne	42
4.4. Modele wielostopniowe	44
4.5. Modele mieszane	45
Rozdział 5. Sposoby wyznaczania wyjścia wielomodelu	47
5.1. Uzgadnianie wyjść modeli składowych	49
5.2. Agregacja wyjść modeli składowych	50
5.2.1. Własności operatorów agregacji	50
5.2.2. Operatory agregacji	51
5.3. Metody głosowania	53
5.4. Metody zaawansowane	53
Rozdział 6. Przykład metody definiowania i identyfikowania wielomodelu	55
6.1. Obiekt badań	55
6.2. Model wielostopniowy	56
6.3. Model wielowarstwowy	59
6.4. Modele składowe	60
6.4.1. Liniowy model regresyjny - (m1)	62
6.4.2. Sieć neuronalna - (m2)	62
6.4.3. Interpolacyjne modele odwzorowań - (m3 - m6)	63
6.4.4. Sieć Bayesa - (m7)	65
6.4.5. Klasyfikator FkM - (m8)	65
6.5. Wyznaczenie wyjścia wielomodelu	67
6.5.1. Metoda I - wagi stałe	68
6.5.2. Metoda II - wagi zmienne	68
Rozdział 7. Badania weryfikacyjne	71
7.1. Dane uczące	71
7.2. Testowanie modeli składowych	72
7.2.1. Wyniki testów - TEST 1	76
7.2.2. Wyniki testów - TEST 2	77
7.3. Wyniki testowania wielomodelu	80
7.3.1. Wyniki testów - TEST 1	81
7.3.2. Wyniki testów - TEST 2	82
7.3.3. Wyniki testów - TEST 3	82

Rozdział 8. Podsumowanie i wnioski	85
8.1. Podsumowanie	85
8.2. Wnioski	85
8.2.1. Wniosek ogólny	85
8.2.2. Wnioski szczegółowe	86
8.3. Kierunki dalszych badań	87
Rozdział A. Wyniki testowania modeli składowych	89
A.1. Objasnienia	90
A.1.1. Oznaczenia klas położenia podpór łozyskowych	90
A.1.2. Identyfikatory przykładów testowych	90
A.1.3. Interpretacja wykresów słupkowych	90
A.2. Wyniki testowania modelu 2 - sieć neuronalna	91
A.3. Wyniki testowania modelu 3 - interpolacyjny model bazujący na algoryt- mie W11	92
A.4. Wyniki testowania modelu 4 - interpolacyjny model bazujący na algoryt- mie W12	94
A.5. Wyniki testowania modelu 5 - interpolacyjny model bazujący na algoryt- mie W13	95
A.6. Wyniki testowania modelu 6 - interpolacyjny model bazujący na algoryt- mie W14	97
A.7. Wyniki testowania modelu 7 - sieć Bayesa	98
A.8. Wyniki testowania modelu 8 - klasyfikator FkM	100
Rozdział B. Wyniki testowania wielomodelu	103
B.1. Objasnienia	104
B.2. Wyniki testowania wielomodelu - TEST 1	104
B.3. Wyniki testowania wielomodelu - TEST 2	106
B.4. Wyniki testowania wielomodelu - TEST 3	107
Bibliografia	109
Streszczenie	121

Rozdział 1

Wstęp

Współcześnie, maszyny stanowią nieodłączny element życia każdego człowieka. Na przestrzeni lat maszyny stawały się coraz bardziej złożone a człowiek powierzał im coraz bardziej odpowiedzialne zadania. Odpowiedzialność za życie ludzkie oraz uwarunkowania ekonomiczne doprowadziły do powstania stosunkowo nowej dziedziny wiedzy jaką jest *diagnostyka techniczna*. Słowo „diagnostyka” gr. *diagnosis* znaczeniowo zbliżone jest do terminów „rozpoznawanie”, „określanie” [15]. Rozpoznawanie i/lub określanie bieżącego stanu rzeczy jest podstawowym zadaniem diagnostyki, stosowanej głównie w medycynie (diagnostyka medyczna) i w technice (diagnostyka techniczna). Metody rozwijane w ramach diagnostyki technicznej opracowywane są w celu realizacji jej trzech podstawowych zadań:

- diagnozowanie;
- genezowanie;
- prognozowanie;

Diagnozowanie polega na rozpoznaniu bieżącego stanu obiektu. Ważną rolę odgrywa również genezowanie czyli określenie przyczyn zaistnienia bieżącego stanu. Pozwala to między innymi na lepsze zrozumienie procesów zachodzących w maszynie podczas jej działania oraz na weryfikację konstrukcji maszyny. Z punktu widzenia eksploatacji obiektów technicznych duże znaczenie ma prognoza dotycząca przede wszystkim horyzontu czasowego, w którym potencjalnie nastąpi zmiana stanu technicznego maszyny. Najważniejsze jednak jest diagnozowanie, gdyż nie można rozpatrywać przyczyn, ani formułować prognoz jeżeli bieżący stan obiektu jest rozpoznany niewłaściwie.

Diagnostyka techniczna może dotyczyć różnych obiektów:

- maszyn i urządzeń;
- procesów przemysłowych;

Diagnostyka maszyn i urządzeń rozwinęła się wcześniej w szczególności w inżynierii elektronicznej przenikając z czasem do innych dziedzin techniki [12]. Rozwój metod pomiaru i analizy sygnałów, w szczególności sygnałów wibroakustycznych, spowodował wzrost znaczenia diagnostyki przy projektowaniu i konstruowaniu, produkcji i podczas eksploatacji maszyny. Rozwój tzw. metod bezinwazyjnych umożliwił ocenę stanu technicznego bez konieczności demontażu czy nawet zatrzymywania maszyny. Możliwości

tych metod zostały dostrzeżone przez ekspertów zajmujących się sterowaniem procesami przemysłowymi, co przyczyniło się do rozwoju drugiego podstawowego nurtu diagnostyki technicznej, w którym obiektem diagnozowania nie jest maszyna czy urządzenie, lecz określony proces przemysłowy. Zadaniem diagnostyki procesów, w odróżnieniu od diagnostyki maszyn, nie jest rozpoznanie stanu technicznego, lecz najczęściej określenie stanu układu automatycznej regulacji procesu [66]. Stopień złożoności współczesnych maszyn wymusza jednak stosowanie równoległe metod wywodzących się z obydwu nurtów diagnostyki technicznej.

W niniejszej rozprawie autor skoncentrował swoją uwagę na wybranych metodach diagnozowania maszyn i urządzeń przydatnych do zastosowania w systemach doradczych. Moduły wnioskujące takich systemów zawierają najczęściej numeryczne modele obiektów lub modele diagnostyczne umożliwiające wnioskowanie o stanie technicznym. Stopień złożoności współczesnych maszyn oraz ograniczenia techniczno-ekonomiczne, jakie muszą być brane pod uwagę przy budowie systemów monitorowania tych maszyn wymuszają stosowanie szeregu uproszczeń podczas identyfikacji modeli diagnostycznych.

Pociąga to za sobą niejednoznaczność zależności, reprezentowanych przez te modele, pomiędzy stanami technicznymi a obserwowanymi sygnałami diagnostycznymi. To, z kolei, może obniżać jakość i poprawność uzyskiwanych na ich podstawie diagnoz. Poprawę skuteczności można uzyskać poprzez stosowanie bardzo złożonych, a przez to drogich w identyfikacji, modeli. Alternatywą dla takich modeli może być zastosowanie tzw. wielomodelu, czyli modelu złożonego z kilku prostszych modeli, które stosowane wspólnie odzwierciedlają relacje diagnostyczne umożliwiające określenie stanu technicznego maszyny.

W pracy przedstawiono wyniki badań, których celem było wykazanie przydatności wielomodeli w diagnostyce maszyn i ich zalet w porównaniu z modelami klasycznymi. W dalszej części pracy przedstawiono zagadnienie modelowania w diagnostyce technicznej. Zdefiniowano pojęcia cech sygnałów oraz cech stanu technicznego. Omówiono rodzaje relacji diagnostycznych a co za tym idzie rodzaje modeli diagnostycznych i wskazano ich przeznaczenie. Wskazano trudności występujące podczas identyfikowania modeli diagnostycznych oraz pokazano, w jaki sposób można te trudności ominąć w przypadku identyfikowania wielomodelu. Przedstawiono cechy charakterystyczne wielomodeli. Wskazano ich podział ze względu na ich strukturę na modele wielowarstwowe i wielostopniowe. Zagadnienia wielomodeli diagnostycznych przedstawiono na przykładzie dwustopniowego modelu klasyfikującego stan techniczny turbosespołu 200 MW w zakresie przemieszczeń podpór łożyskowych. Na podstawie uzyskanych wyników sformułowano wnioski.

Rozdział 2

Geneza badań

W dalszych rozważaniach szczególną uwagę zwrócono na diagnostykę techniczną maszyn bazującą na pomiarach sygnałów wibroakustycznych. Omówione definicje i pojęcia mogą być również stosowane w diagnostyce procesów, na przykład w odniesieniu do obserwacji zmiennych procesowych.

2.1. Pojęcia podstawowe

Celem diagnozowania jest rozpoznanie stanu technicznego maszyny. W rozważaniach opisanych w niniejszej pracy stan techniczny jak i sygnały diagnostyczne rozpatrywane są jako zbiory ich cech.

2.1.1. Cechy

Cecha jest atrybutem przypisywanym danemu obiektowi [20]. Każdą cechę można zapisać w postaci następującej pary:

$$\langle \textit{nazwa_cechy}, \textit{wartość_cechy} \rangle \quad (2.1)$$

Nazwa cechy powinna jednoznacznie opisywać to, co wyrażają jej wartości. Ze względu na zbiór wartości w literaturze [21] przedstawiono kilka niezależnych podziałów cech. Wyróżniamy cechy:

- *ciągłe*, wartości których należą do zbioru liczb rzeczywistych oraz cechy *dyskretne*, których wartości należą najczęściej do skończonego podzbioru liczb rzeczywistych;
- *uporządkowane*, czyli takie, dla których wartości obowiązuje relacja poprzedzania i *nieuporządkowane*, dla których sformułowanie takiej relacji nie jest możliwe;
- *funkcyjne*, których wartości mogą być przedstawione za pomocą odpowiednich wykresów lub zbiorów liczb. W odróżnieniu od nich wartości *cech punktowych* są pojedynczymi liczbami;
- *ilościowe*, których wartości wyrażane są liczbami i *jakościowe*, wartości których najczęściej wyrażane są poprzez zmienne lingwistyczne;

- *dokładne*, których wartości są znane z zadaną dokładnością i *przybliżone*, których wartościami mogą być na przykład przedziały o znanych lub nieznanymi granicach;

Pojęcie cechy w diagnostyce technicznej stosowane jest do opisu stanu rozpatrywanego obiektu (cechy stanu), do opisu obserwowanych skutków działania tego obiektu (cechy sygnałów), a także do opisu oddziaływania otoczenia na obiekt (wejścia/sterowanie).

2.1.2. Czas w diagnostyce technicznej

Ocena stanu technicznego maszyny jest możliwa tylko wówczas, gdy dostępna jest informacja o jej bieżących własnościach i właściwościach. Mogą być one określane z perspektywy zachowania się tej maszyny w znanych warunkach działania, na podstawie rejestrowanych sygnałów diagnostycznych.

Sygnałem nazywany jest dowolny materialny nośnik informacji [15]. Najczęściej jest to przebieg określonej wielkości fizycznej obserwowany z zastosowaniem odpowiedniej aparatury pomiarowej. Procesy zachodzące w maszynie podczas jej działania mają charakter dynamiczny, co oznacza, że do pełnego opisu tych procesów wymagane jest przyjęcie odpowiedniej definicji czasu.

W diagnostyce technicznej wprowadzone są dwa pojęcia czasu związane z jego skalą. Rozróżnia się czas *mikro* i czas *makro* [15]. Czas *mikro* (zwany również czasem dynamicznym [12]) związany jest z chwilowymi zmianami wartości obserwowanych sygnałów. Czas *mikro* jest najczęściej ograniczony do krótkiego (np. kilka sekund) odcinka czasu, w którym analizowany sygnał można uznać za stacjonarny.

Czas *makro* (zwany też czasem życia obiektu [12]) pozwala na opisywanie zjawisk długofalowych na przykład śledzenie zmiany stanu technicznego obiektu. Może być wyrażony w godzinach, dniach czy też w liczbie obrotów maszyny od czasu jej uruchomienia.

2.1.3. Cechy sygnałów diagnostycznych

Sygnał jest nośnikiem informacji o stanie obiektu [15, 23]. Może to być przebieg wielkości fizycznej, możliwej do zmierzenia i/lub obserwacji. Sygnałami mogą być przebiegi ciśnienia, temperatury, natężenia przepływu itp. Duże znaczenie zyskały metody diagnostyczne bazujące na pomiarach hałasu i/lub drgań maszyny mierzonych w różnych jej punktach. Ta gałąź diagnostyki jest nazywana *diagnostyką wibroakustyczną*. Sygnałami w przypadku diagnostyki wibroakustycznej są najczęściej wartości chwilowe przemieszczeń, prędkości lub przyspieszeń wybranych punktów maszyny (pomiar drgań) lub natężenie dźwięku (pomiar hałasu).

Obserwowane sygnały można zapisać zgodnie z (2.2) [15].

$$f : (\tau, t) \rightarrow r \in R \quad (2.2)$$


gdzie:

f - oznacza sygnał, τ - czas mikro, t - czas makro, rozpatrywany jako identyfikator realizacji procesu, R - zbiór liczb rzeczywistych.

W przypadku większej liczby sygnałów rejestrowanych synchronicznie (tj. w tym samym czasie mikro) można je rozpatrywać jako jeden sygnał wielowymiarowy (lub wielokanałowy) zgodnie z (2.3).

$$f = f^n : (\tau, t) \rightarrow r \in R^n \quad (2.3)$$

Przykładem sygnału wielowymiarowego może być sygnał trajektorii ruchu środka czopa w łożysku hydrodynamicznym. Sygnał ten powstaje poprzez synchroniczny pomiar przemieszczeń czopa w kierunku poziomym (x) i pionowym (y), a następnie złożenie tych sygnałów w jeden sygnał o wartościach zespolonych (rys. 2.1).



Rys. 2.1. Przykład sygnału wielowymiarowego - trajektoria ruchu środka czopa, [143]

W niniejszej pracy pojęcie sygnału zostało zawężone do sygnałów wibroakustycznych, będących nośnikiem informacji o drganiach mechanicznych badanej maszyny.

Przebiegi tych sygnałów są rejestrowane najczęściej w postaci dyskretnej, co umożliwia ich komputerowe przetwarzanie, w celu wyznaczenia wartości ich cech. Sygnał w postaci dyskretnej może być rozpatrywany jako wektor (w przypadku sygnałów jednowymiarowych) lub jako macierz (sygnały wielowymiarowe) liczb będących chwilowymi w skali mikro wartościami przebiegu mierzonej wielkości:

$$X(t) = \{x(\tau_1, t), x(\tau_2, t), \dots, x(\tau_N, t)\} \quad (2.4)$$

Tak zdefiniowane sygnały rozpatrywane są najczęściej jako realizacja procesu, przy założeniu, że sygnał w obserwowanym przedziale czasu był stacjonarny. W literaturze [23, 66] przedstawiono liczne definicje cech sygnałów takie, jak: wartość średnia, odchylenie standardowe, miary widmowe, współczynniki bezwymiarowe (kształtu, szczytu, impulsowości) itp. Podobnie jak w [20], w niniejszej pracy rozpatrywane są sygnały diagnostyczne. Sygnały diagnostyczne są to sekwencje w skali czasu makro wartości cech sygnałów wyznaczanych w skali czasu mikro.

Wartości cech sygnałów charakteryzują skutki działania obiektu będącego w określonym stanie techniczny. Obserwacja wartości wybranych cech sygnałów w trakcie eksploatacji obiektu technicznego może być podstawą wnioskowania o jego stanie technicznym. Przykładowo, przekroczenie przez wartość cechy sygnału określonej, znanej wartości progowej pozwala na stwierdzenie, że stan maszyny, będącej uprzednio w stanie zdatnym, uległ zmianie. Owe przekroczenie określonego progu przez wartość cechy sygnału jest nazywane *symptomem* stanu. Symptomy stanu w diagnostyce technicznej rozpatrywane są często jako odchylenia wartości cech sygnałów od nominalnych wartości, jakie przyjmują te cechy, gdy obiekt jest w określonym stanie, rozpatrywanym jak stan odniesienia.

Wybór cech, które umożliwiają ocenę stanu technicznego maszyny, jest niejednokrotnie bardzo trudnym zadaniem. Można wskazać liczne publikacje dotyczące poszukiwania cech relewantnych [13, 22, 26, 120–122, 126, 137, 140]. Poszukiwanie cech relewantnych jest najczęściej związane z badaniem wrażliwości diagnostycznej cech lub poszukiwaniem kryterium wyboru cech sygnałów. Celem badania wrażliwości cech sygnałów jest znalezienie zbioru cech, których wartości zmieniają się istotnie wraz ze zmianą stanu technicznego maszyny. Zbiór wartości cech sygnałów rejestrowanych w skali czasu makro jest zbiorem sygnałów diagnostycznych.

2.1.4. Cechy stanu

Każdy obiekt techniczny można scharakteryzować poprzez jego cechy. Cechami tymi mogą być jego własności i właściwości użytkowe takie, jak moc znamionowa, nominalny moment obrotowy, wydajność itp. Zbiór tych własności jest nieograniczony. Istnieje jednak pewien podzbiór cech obiektu, które mogą charakteryzować jego stan techniczny. Przykładem takich cech, nazywanych cechami stanu, mogą być wartości luzów, stopień zużycia, stan powierzchni lub wzajemne położenie elementów maszyny itp. Podczas eksploatacji maszyny wartości tych cech ulegają zmianie (w skali czasu makro), co przyczynia się na przykład do zmiany struktury częstotliwościowej obserwowanych sygnałów wibroakustycznych, umożliwiając rozpoznanie stanu technicznego obiektu.

Bieżący stan techniczny obiektu (maszyny) można opisać zbiorem wartości cech tego stanu określonych w rozpatrywanej chwili czasu makro.

$$S(t) = \{s_1(t), s_2(t), \dots, s_M(t)\} \quad (2.5)$$

gdzie:

S - zbiór cech stanu obiektu, s_i - cechy stanu, t - czas makro.

Zbiór cech opisujących stan techniczny maszyny podobnie jak zbiór jej własności jest nieograniczony. W badaniach diagnostycznych zbiór ten ogranicza się do takiego podzbioru, który umożliwia rozróżnienie najczęściej występujących klas stanu rozpatrywanej maszyny.

2.1.5. Klasy stanu

W większości przypadków niewielkie zmiany wartości cech stanu maszyny nie mają wpływu na jej zachowanie podczas działania w warunkach nominalnych. Zmiany wartości niektórych cech mogą wynikać z zadanych przez konstruktora dopuszczalnych odchyłek wymiarowych czy też niejednoznaczności montażu i różnic w wartościach dynamicznych cech konstrukcyjnych. Nie jest zasadne, w związku z tym, identyfikowanie każdej zmiany wartości cech stanu.

Częściej określa się tzw. klasy stanu. Klasą stanu nazywamy zbiór stanów (zbiór wartości cech stanu) nierozróżnialnych ze względu na zakres i cel prowadzonych badań diagnostycznych. Klasy stanu można zdefiniować:

- na podstawie posiadanej wiedzy;
- na podstawie zbioru przykładów uczących;

Bazując na wiedzy i/lub doświadczeniu osób zajmujących się obsługą wybranej grupy maszyn, a także na podstawie informacji zawartej w dokumentacji techniczno-ruchowej można określić na przykład przedziały wartości wybranych cech stanu, dla których stan maszyny będzie uznawany jako niezmienny (np. zdatny do eksploatacji).

Określenie klas stanu na podstawie przykładów uczących jest na ogół pośrednie. Dążąc do rozpoznania stanu technicznego maszyny bez konieczności jej zatrzymywania czy demontażu, nie można na przykład bezpośrednio sprawdzić stopni zużycia elementów maszyny. Bazuje się wtedy na zbiorze zgromadzonych sygnałów diagnostycznych zaobserwowanych podczas działania obiektu w określonych, znanych stanach. Liczba sygnałów diagnostycznych, a także liczba cech stanu może być bardzo duża, a niewielkie zmiany wartości tych ostatnich mogą nie wpływać znacząco na zachowanie obiektu, dlatego często grupuje się stany, które uznaje się za nierozróżnialne. Zbiór sygnałów diagnostycznych również może być podzielony na grupy w taki sposób, że każda grupa sygnałów diagnostycznych reprezentuje jedną zdefiniowaną grupę stanów. Uzyskane w ten sposób grupy sygnałów diagnostycznych są danymi wzorcowymi umożliwiającymi rozpoznanie poszczególnych klas stanu.

2.1.6. Przestrzeń obrazów cech

Klasy zdefiniowane na podstawie przykładów uczących w przestrzeni cech stanu stanowią skupiska punktów reprezentujących wartości tych cech dla poszczególnych stanów technicznych. Wyznaczenie skupisk punktów jest możliwe na podstawie danych uczących (grupowanie z nauczycielem) oraz grupowania punktów w przestrzeni cech stanu (grupowanie bez nauczyciela). Przyporządkowanie punktu do jednej z wcześniej zdefiniowanych grup następuje w wyniku klasyfikacji. Zarówno procedury grupowania, jak i klasyfikacji wymagają zdefiniowania sposobu porównywania elementów rozpatrywanej przestrzeni. W celu wyznaczenia ich podobieństw (lub odległości), wektor wartości cech rozpatrywanego przypadku może być porównywany z wszystkimi elementami lub wyłącznie z

reprezentantami klas. Wartości tych podobieństw stanowią współrzędne punktu reprezentującego rozpatrywany przypadek w nowej przestrzeni zwanej przestrzenią obrazów cech [15, 20, 45, 66]. Przekształcenie przestrzeni wartości cech, wymiarowość której jest na ogół bardzo duża, do przestrzeni ich obrazów umożliwia ograniczenie liczby wymiarów przestrzeni cech [15].

2.2. Ocena stanu obiektów technicznych

W przypadku diagnostyki technicznej maszyn, zbiór sygnałów możliwych do obserwacji jest nieograniczony. Zbiór ten uwarunkowany jest nieograniczonym zbiorem własności i właściwości rozpatrywanego obiektu (2.6) [15].

$$F = \varphi(W) \quad (2.6)$$

gdzie:

F - zbiór sygnałów, W - zbiór własności i właściwości obiektu, φ - operator transmitancji.

Określenie wszystkich własności i właściwości obiektu, które wpływają na jego zachowanie, a przez to na zmiany obserwowanych sygnałów nie jest możliwe. Zakłada się, w związku z tym, że obserwowane sygnały uwarunkowane są dwoma podzbiórami: znanymi (uwzględnianymi) i nieznanymi (pomijanymi) własnościami i właściwościami obiektu [15]. Obserwowane sygnały można wówczas zapisać na przykład w postaci:

$$f(\tau, t) = f_1(\tau, t) + f_2(\tau, t) \quad (2.7)$$

lub

$$f(\tau, t) = f_1(\tau, t) \cdot f_2(\tau, t) \quad (2.8)$$

Sygnał $f_2(\tau, t)$ uwarunkowany pomijanymi własnościami obiektu rozpatrywany jest jako szum. Konsekwencją takiego podejścia jest to, że operator transmitancji zdefiniowany w (2.6) jest wtedy wieloznaczny. Utrudnia to znalezienie zależności pomiędzy cechami obserwowanych sygnałów diagnostycznych a cechami stanu obiektu, gdyż nie można jednoznacznie stwierdzić jaki jest stan techniczny obiektu na podstawie uzyskanych wartości sygnałów. Jest jednak możliwe oszacowanie stanu bądź klasy stanu z odpowiednim stopniem pewności, na przykład poprzez zastosowanie metod sztucznej inteligencji (np. [66]).

2.2.1. Diagnozowanie stanu technicznego maszyn

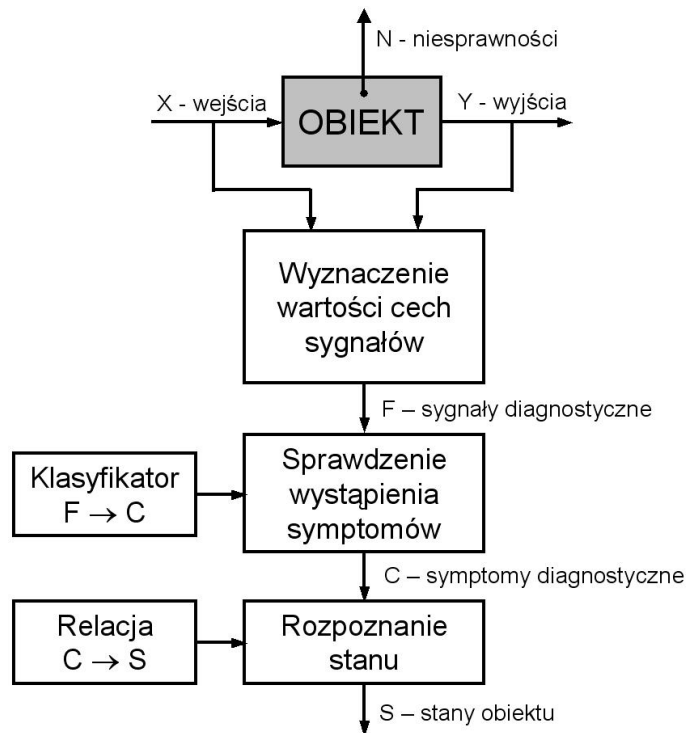
W obrębie diagnostyki maszyn można wyróżnić dwa nurty, które historycznie następowały po sobie i dziś są stosowane obok siebie:

- diagnostyka symptomowa,
- diagnostyka stosująca modele (bazująca na modelach).

Początkowo, zwłaszcza w diagnostyce symptomowej, wnioskowanie o stanie było prowadzone przez człowieka na podstawie cech sygnałów wyznaczonych na podstawie statystyki matematycznej. W licznych pracach (np. [5, 62]) opisujących przetwarzanie sygnałów diagnostycznych zarówno w dziedzinie czasu jak i częstotliwości pokazano sposób wnioskowania o stanie obiektu badań na podstawie wyznaczonych wartości cech. Dużą rolę w diagnostyce odgrywają metody rozpoznawania wzorców [38, 64].

2.2.2. Diagnostyka symptomowa

Diagnostyka symptomowa maszyn może być bezpośrednio porównana z diagnostyką medyczną. W przypadku diagnostyki medycznej, lekarz badając konkretnego pacjenta określa jego stan na podstawie zaobserwowanych objawów, na przykład podwyższonej temperatury ciała. W przypadku diagnostyki symptomowej obiektem badań jest konkretna maszyna, a objawami symptomy stanu technicznego. Na rysunku 2.2 pokazano schemat procesu wnioskowania najczęściej stosowany w diagnostyce symptomowej.



Rys. 2.2. Schemat procesu wnioskowania w diagnostyce symptomowej (na podstawie [66] oraz [45])

Obserwowane sygnały wejść i wyjść obiektu są podstawą do wyznaczenia sygnałów diagnostycznych F . Podobnie jak w [20], sygnałem diagnostycznym mogą być, w tym przypadku, wartości wyznaczanych cech obserwowanych sygnałów wejściowych i wyjściowych. Następnie, poprzez stosowanie odpowiedniego klasyfikatora, sprawdzane jest wystąpienie symptomów określonych stanów na podstawie uzyskanych wartości sygnałów diagnostycznych. Rozpoznanie stanu następuje na podstawie zebranego zbioru symptomów, które najczęściej stanowią przesłanki reguł wnioskowania.

Ze względu na niejednoznaczność relacji zachodzącej pomiędzy symptomami stanu a cechami tego stanu, nie jest to zadanie łatwe. Należy w tym miejscu wyraźnie podkreślić różnice pomiędzy diagnostyką maszyn i urządzeń a diagnostyką procesów przemysłowych. W diagnostyce procesów przemysłowych diagnozowanie składa się z trzech podstawowych zadań [66]:

- detekcji uszkodzenia,
- lokalizacji uszkodzenia,
- identyfikacji uszkodzenia,

Detekcja ma na celu wykrycie nieprawidłowości w przebiegu procesu. Drugim etapem po detekcji jest lokalizacja uszkodzenia (w diagnostyce maszyn rozpatrywane są niesprawności). W tym przypadku badania koncentrują się na ustaleniu rodzaju uszkodzenia i miejscu jego występowania. Identyfikacja uszkodzenia polega na ocenie stopnia zaawansowania uszkodzenia, co umożliwi podjęcie decyzji co do dalszego sterowania procesem.

Takie podejście w diagnostyce technicznej maszyn nie zawsze jest możliwe. Wynikiem diagnozowania maszyny jest ocena jej stanu technicznego, która często sprowadza się do określenia klasy tego stanu. W związku z tym, nie zawsze jest możliwe i/lub zasadne realizowanie wszystkich trzech etapów badań jak to ma miejsce w diagnostyce procesów. W diagnostyce maszyn najczęściej drugi (lokalizacja niesprawności) i trzeci (identyfikacja niesprawności) etap są nierozłączne. Wskazanie bieżącej klasy stanu jest często równoznaczne z określeniem, który element maszyny wykazuje niesprawność. Na przykład w przekładni zębatej może to być niesprawność łożysk jednego z wałów lub zużycie zębów kół itp.

Dzieje się tak dlatego, że ocena stanu technicznego maszyny na podstawie symptomów, w postaci charakterystycznych dla tego stanu technicznego wartości cech sygnałów diagnostycznych, wymaga pomiarów i/lub obserwacji tej maszyny. Zgromadzone w ten sposób dane dostarczają informacji o zachowaniu się maszyny w określonym stanie technicznym działającej w określonych warunkach.

Zdobyta tą drogą wiedza może jednak być niewystarczająca do określenia zachowania się maszyny w innych warunkach działania lub w przypadku, gdy stan techniczny ulegnie zmianie na inny, który w trakcie wcześniejszych badań nie wystąpił. Problem ten jest bardzo istotny ze względu na to, że współczesne maszyny są coraz bardziej złożone, pełniąc zarazem coraz bardziej odpowiedzialne funkcje. Stąd, konieczne są badania, których celem jest ocena zachowania się maszyny działającej w określonych warunkach lub określonych stanach technicznych. Prowadzenie takich badań na fizycznym obiekcie najczęściej nie jest możliwe. Dlatego przez szereg lat rozwijano różne metody symulacyjne, w których stosowany był model (np. [71, 128, 139]).

2.2.3. Diagnostyka bazująca na modelach

Gałąź diagnostyki technicznej, w której podczas wnioskowania o stanie technicznym rozpatruje się nie tylko wyniki obserwacji i/lub pomiarów przeprowadzonych bezpośrednio

na obiekcie, ale również stosuje się model obiektu, nazywana jest diagnostyką bazującą na modelach lub inaczej diagnostyką stosującą model. W badaniach diagnostycznych stosowane są różne klasy modeli, które reprezentują obiekty badań, sposoby wnioskowania o stanie, a także sygnały diagnostyczne. Stosowane modele można podzielić na dwie podstawowe grupy:

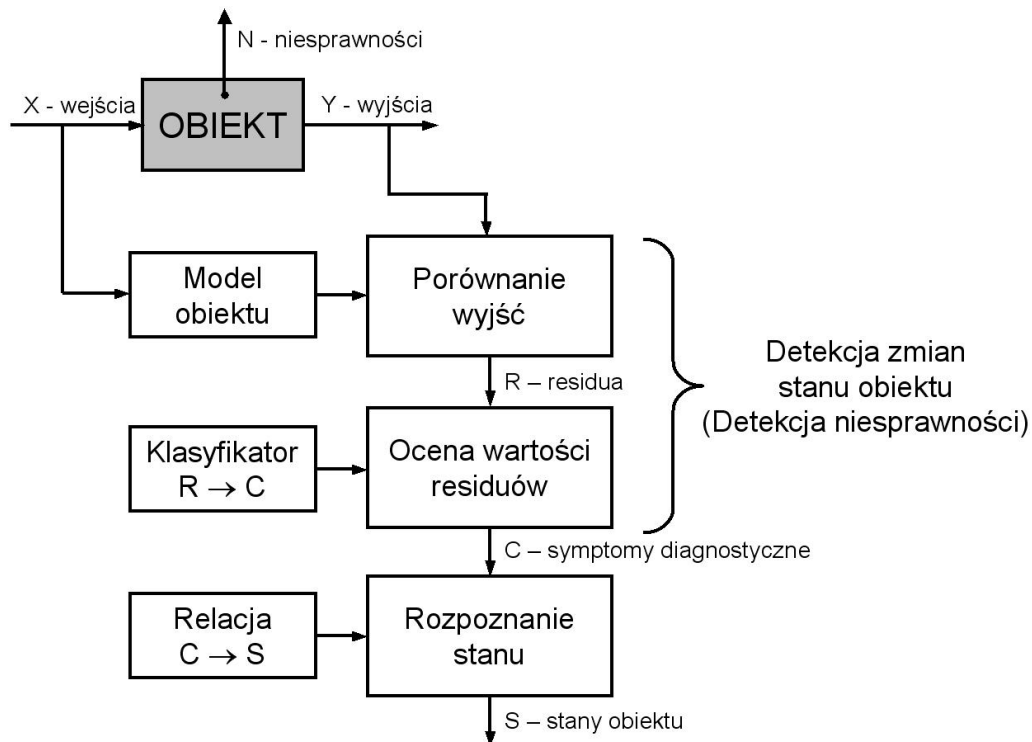
- modele obiektów,
- modele diagnostyczne.

2.2.4. Proces diagnozowania z zastosowaniem modeli obiektów

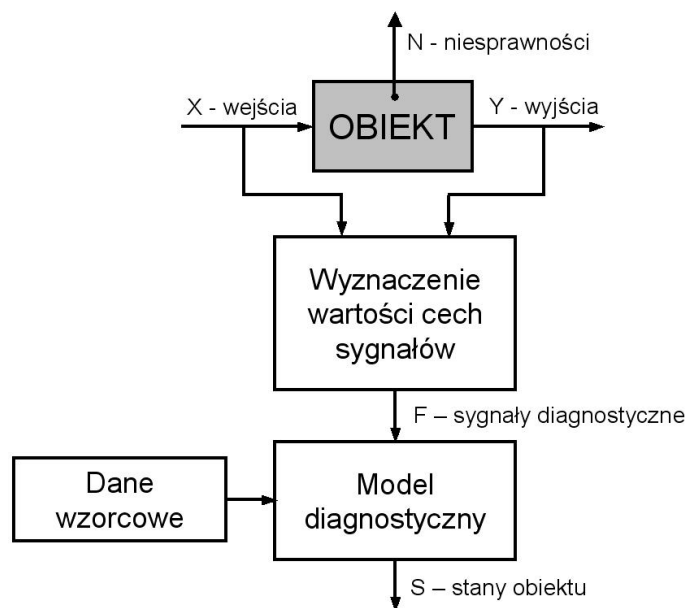
Wnioskowanie o stanie technicznym na podstawie modeli obiektów pokazano na rysunku 2.3. Zakłada się, że model obiektu posiada wejścia i wyjścia odpowiadające wybranym wejściom i wyjściom maszyny oraz, że przekształca on te wejścia w wyjścia w podobny sposób jak się to dzieje w maszynie o określonym stanie technicznym. Modele te są szczególnie przydatne do detekcji niesprawności. Zadaniem modelu obiektu jest odzwierciedlanie zachowania, w określonych warunkach działania, maszyny będącej w znanym stanie technicznym. Jeżeli model obiektu został prawidłowo zidentyfikowany to między sygnałem wyjściowym z obiektu a sygnałem z modelu nie powinny występować znaczące różnice. Wynikiem porównania sygnałów wyjściowych maszyny i jej modelu jest nowy, dodatkowy sygnał nazywany residuum. W procesie diagnozowania maszyny z zastosowaniem modelu obiektu ocena wartości residuów jest podstawą przy określaniu zbioru symptomów diagnostycznych. Jeżeli wartości residuów znacznie przewyższają zakładane wartości progowe może to świadczyć o zaistnieniu niesprawności w obiekcie. Oczywiście wniosek taki jest słuszny tylko w przypadku, gdyby model odzwierciedlał obiekt w stanie zdatnym. Uzyskane z zastosowaniem sygnałów residuum symptomy diagnostyczne są podstawą do wnioskowania o stanie technicznym obiektu analogicznie jak ma to miejsce w diagnostyce symptomowej.

2.2.5. Proces diagnozowania z zastosowaniem modeli diagnostycznych

Schemat procesu diagnozowania stanu technicznego z zastosowaniem modeli diagnostycznych pokazano na rysunku 2.4. Model diagnostyczny wyznacza cechy stanu technicznego obiektu na podstawie wartości wybranych cech sygnałów diagnostycznych. W związku z tym, w pierwszej kolejności wybierane są odpowiednie cechy sygnałów diagnostycznych i wyznaczane są ich wartości. Wnioskowanie o stanie następuje na podstawie wiedzy zawartej w modelu diagnostycznym. Wiedza ta może być reprezentowana na przykład w postaci reguł wskazujących klasy stanu na podstawie wartości poszczególnych cech sygnałów diagnostycznych. Często korzysta się również z danych zgromadzonych w wyniku eksperymentów, które są źródłem wzorcowych obrazów cech. Wówczas diagnozowanie stanu polega na klasyfikacji do klasy zawierającej obrazu cech najbardziej podobne (lub najmniej odmienne) do obrazu aktualnego stanu technicznego.



Rys. 2.3. Schemat procesu wnioskowania z zastosowaniem modelu obiektu (na podstawie [66] oraz [45])



Rys. 2.4. Schemat procesu wnioskowania z zastosowaniem modelu diagnostycznego (na podstawie [66] oraz [45])

Zarówno modele obiektów jak i modele diagnostyczne są stosowane w diagnostyce technicznej w celu identyfikacji stanu bądź zmian stanu technicznego rozpatrywanego obiektu - maszyny lub procesu przemysłowego. Stosowanie szeregu uproszczeń takich, jak już wspomniane uwzględnianie wyłącznie wybranych wejść obiektu, czy ograniczenie

zbioru identyfikowanych własności obiektu, powoduje pominięcie pewnej porcji często istotnej informacji, co z kolei ogranicza zakres stosowania modelu i wymusza konieczność dostrajania modelu do obiektu. Dostrajanie (dopasowywanie) modelu wymaga jednak dużej wiedzy, a także intuicji i doświadczenia badacza. W wyniku dostrajania model reprezentuje obiekt z określoną dokładnością. Dokładność odwzorowania obiektu zależy zarówno od klasy stosowanego modelu, jak i od metody jego identyfikacji. W miarę rozwoju techniki cyfrowego przetwarzania danych coraz większe znaczenie zaczęły odgrywać modele identyfikowane z zastosowaniem zbioru danych zgromadzonych w wyniku obserwacji obiektu. Opracowano szereg metod identyfikacji modeli bazujących na danych uczących (np. [30, 49, 75]). Zidentyfikowanie jednego ogólnego modelu o charakterze globalnym staje się coraz trudniejsze i coraz bardziej kosztowne. W pracach [21, 22, 25] wykazano, że rozwiązaniem znacznie prostszym jest zastosowanie modeli o charakterze lokalnym, tzn. takich modeli, które są identyfikowane i przeznaczone do stosowania wyłącznie w pewnym obszarze wartości danych uczących. Wymagane może być jednak identyfikowanie wielu takich modeli lokalnych.

2.3. Cel pracy

Możliwości rozpoznawania stanu technicznego zarówno na podstawie wyników obserwacji działania maszyny, jak i poprzez obserwację parametrów procesu przemysłowego, wpłynęły na wzrost niezawodności współczesnych maszyn. Równocześnie wzrosły wymagania stawiane maszynom, które są eksploatowane w coraz bardziej ekstremalnych warunkach. Maszyny strategiczne z punktu widzenia zakładu wytwórczego, czyli takie, których ciągłość i pewność działania ma duże znaczenie nazywane są maszynami krytycznym [12]. Wymagają one stałego nadzoru ze względu na ich znaczenie w procesie przemysłowym oraz ze względu na to, że w przypadku awarii stanowią zagrożenie dla obsługujących je ludzi i otoczenia. Do takiej grupy maszyn należy zaliczyć maszyny wirnikowe takie, jak na przykład turboszespoły energetyczne.

Celem niniejszej pracy jest zbadanie zalet i wad wielomodeli. Wielomodel jest to model o strukturze modułowej, w którym przynajmniej dwa moduły są modelami, które można identyfikować niezależnie od siebie. W niniejszej rozprawie badania wielomodeli omawiane będą na przykładzie maszyn wirnikowych. Podejście do modelowania z punktu widzenia wielomodeli umożliwia dekompozycję złożonego zadania modelowania na kilka zadań prostszych. Ułatwieniem jest zarówno prostsza struktura modeli jak i uproszczenie ich identyfikacji. Uproszczenie metod identyfikowania poszczególnych modeli składowych wielomodelu może przyczynić się również do tego, że identyfikowanie tych modeli będzie możliwe również przy ograniczonym zbiorze przykładów uczących.

2.4. Tezy pracy

W pracy postawiono następujące tezy:

- 1 Zastosowanie wielomodelu diagnostycznego pozwala na uzyskanie lepszych wyników rozpoznawania stanu technicznego maszyny wirnikowej niż niezależne stosowanie modeli składowych wielomodelu.
- 2 Dekompozycja modelu na kilka prostszych modeli składowych wielomodelu, pozwala na ich identyfikację nawet w przypadku małej liczby danych uczących, dla której identyfikacja jednego modelu złożonego jest utrudniona.

2.5. Zakres pracy

W pracy przedstawiono koncepcję wielomodelu diagnostycznego, rozpatrywanego jako zbiór równocześnie stosowanych modeli, dla których określono sposób wyznaczenia jednego wspólnego wyjścia.

W rozdziale 3 dokonano przeglądu modeli stosowanych w diagnostyce technicznej wraz z omówieniem koncepcji dotyczącej rozpatrywania obiektu w diagnostyce technicznej w postaci tzw. „czarnej skrzynki”. Omówiono ich systematykę z uwzględnieniem podziału na modele obiektów i modele diagnostyczne. Przedstawiono ich zastosowania. W dalszych rozważaniach omówiony został problem wyboru sygnałów stanowiących wejścia i wyjścia obydwu grup modeli.

W rozdziale 4 wprowadzono definicję i koncepcję wielomodelu. Wprowadzono systematykę wielomodeli ze względu na zastosowanie i sposób wyznaczania wyjścia wielomodelu. Dokonano podziału wielomodeli na: modele wielowarstwowe oraz modele wielostopniowe. Omówiono wielomodele wielowarstwowe, stosowane przy łączeniu informacji z różnych źródeł bądź z jednego źródła, lecz wyodrębnionej różnymi metodami. Opisano również szczególną grupę modeli wielostopniowych umożliwiających podział zadania identyfikacji relacji diagnostycznej na podzadania.

W rozdziale 5 omówiono zagadnienie łączenia wyjść modeli składowych w jedno wspólne wyjście wielomodelu. Rozpatrywano dwie podstawowe grupy metod stosowanych w modelach wielowarstwowych: uzgadniania i agregacji wyjść modeli składowych.

Koncepcje wielomodelu diagnostycznego wprowadzono w rozdziale 6. Zaproponowano metodę identyfikacji wielomodelu diagnostycznego, jako modelu wielowarstwowego i pokazano jej zastosowanie do klasyfikacji stanu technicznego maszyny wirnikowej w zakresie przemieszczeń podpór łożyskowych. Proponowany wielomodel jest częścią modelu wielostopniowego, którego pierwszy stopień opisano w [133]. Opisano modele składowe oraz sposób łączenia ich wyjść w jedno wspólne wyjście wielomodelu. Metodę identyfikacji zweryfikowano na podstawie danych uczących będących wynikiem symulacji działania maszyny wirnikowej z zastosowaniem jej modelu numerycznego.

Uzyskane wyniki zostały przedstawione w rozdziale 7. Przeprowadzono również dyskusję wyników. W rozdziale 8 zestawiono wnioski.

Rozdział 3

Modele w diagnostyce technicznej

W poprzednim rozdziale przy omawianiu schematów wnioskowania w diagnostyce technicznej zasygnalizowano istnienie podstawowych klas modeli. Pierwszą klasę stanowią modele obiektów, drugą modele diagnostyczne.

3.1. Modele obiektów

Modele obiektów są identyfikowane i stosowane w celu symulacji zachowania rozpatrywanego obiektu w znanych warunkach jego działania i w określonym stanie technicznym.

3.1.1. Modele strukturalne

Liczną grupą modeli stosowanych do reprezentacji obiektów technicznych są modele strukturalne. Są najczęściej formalnym opisem odzwierciedlającym zachowanie obiektu w określonych warunkach działania i/lub określonym stanie technicznym. Podstawą jest tu znajomość praw fizyki oraz procesów zarówno użytkowych jak i resztkowych zachodzących podczas działania maszyny. Przykładem takich modeli mogą być modele identyfikowane na podstawie równań różniczkowych ruchu [50, 88, 101]. Są to modele matematyczne odzwierciedlające wewnętrzną strukturę maszyny. Umożliwiają uwzględnianie takich elementów związanych z działaniem maszyny, jak [50]:

- inercje, sprężystości i tłumienia elementów maszyny,
- ruchy precesyjne związane z niewyrównoważeniami mas wirujących, efektami groskopowymi, tarcie wewnętrzne oraz siłami hydro- i aerodynamicznymi.

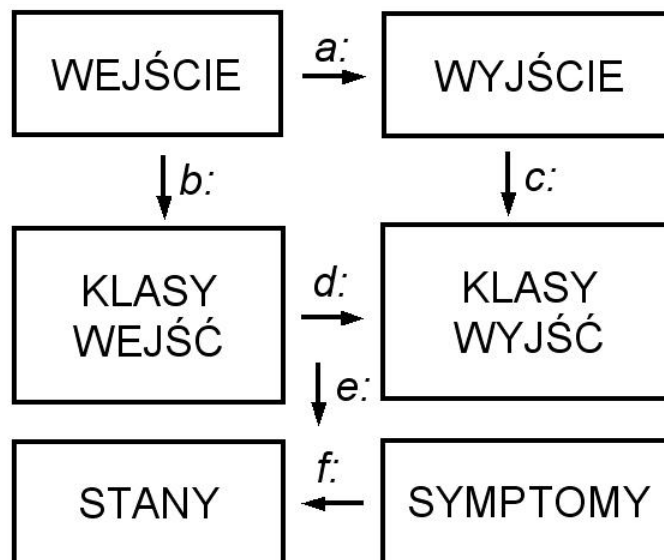
Modele strukturalne znajdują szerokie zastosowanie w badaniach diagnostycznych ze względu na to, że wyniki uzyskane na ich podstawie mogą posłużyć do identyfikacji relacji między stanami technicznymi a symptomami tych stanów. Ponadto, umożliwiają pozyskanie danych do budowy zbioru możliwych stanów technicznych obiektu. Cecha ta jest szczególnie przydatna, gdy nie jest możliwe prowadzenie takich badań na rzeczywistym obiekcie. Z uwagi na to, że odzwierciedlają one zachowanie się maszyny z uwzględnieniem

jej wewnętrznej struktury możliwe jest również pozyskiwanie na ich podstawie sygnałów diagnostycznych z różnych punktów pomiarowych.

Trzeba jednak pamiętać, że modele te wymagają stosowania szeregu uproszczeń. Uproszczenia te mogą spowodować, że wyniki uzyskane na ich podstawie w porównaniu z wynikami z eksperymentów mogą różnić się, zwłaszcza przy formułowaniu wniosków szczegółowych [15].

3.1.2. Modele relacji

Drugą grupą modeli stosowanych w diagnostyce technicznej są tzw. modele relacji. Modele te nie reprezentują zachowania obiektu, lecz relacje zachodzące w szczególności pomiędzy jego wejściami i wyjściami. Na rysunku 3.1 pokazano relacje jakie można identyfikować w trakcie badań diagnostycznych [21].



Rys. 3.1. Klasy identyfikowanych relacji, [21]

gdzie:

- a : - relacja *wejście* - *wyjście* (model obiektu);
- b : - klasyfikator wejściowych cech modelu, umożliwiającą przekształcenie cech ilościowych w cechy jakościowe;
- c : - klasyfikator wyjściowych cech modelu, umożliwiającą klasyfikację wyjść modelu, identyfikowany najczęściej na drodze grupowania;
- d : - przybliżony model obiektu;
- e : - operacja odwracania modelu;
- f : - model odwrotny określający stan techniczny obiektu na podstawie dostępnych symptomów;

W rozważaniach dotyczących identyfikowania modeli relacji główny nacisk kładzie się na poszukiwanie relacji pomiędzy wejściami i wyjściami obiektu. Pomija się przy tym strukturę wewnętrzną rozpatrywanego obiektu. W takim przypadku obiekt rozpatrywany jest jako tzw. „czarna skrzynka”.

3.1.3. Koncepcja „czarnej skrzynki”

Koncepcja „czarnej skrzynki”, zaproponowana przez N. Wienera, polega na wyróżnieniu tylko wejścia i wyjścia modelowanego obiektu bez uwzględniania jego wewnętrznej struktury. W modelu „czarnej skrzynki” obiekt stanowi integralną całość i jako taka jest wyodrębniony z otaczającego go środowiska. Muszą być jednak poczynione następujące założenia (na podstawie [20]):

- Oddziaływanie otoczenia na obiekt odbywa się wyłącznie za pośrednictwem wejść obiektu;
- Oddziaływanie obiektu na otoczenie odbywa się wyłącznie za pośrednictwem wyjść obiektu;
- Wejścia i wyjścia obiektu stanowią zbiory rozłączne.

Brak możliwości oddziaływania na stan maszyny w trakcie jej działania w szczególności na jej stan techniczny spowodował, że większość modeli w diagnostyce technicznej była stosowana głównie do budowy tzw. obserwatorów stanu. Zadaniem obserwatora stanu jest określenie i/lub przybliżenie stanu obiektu, najczęściej dynamicznego na podstawie sygnałów wejściowych i wyjściowych tego obiektu [66]. Takie podejście nie jest tylko domeną diagnostyki technicznej. Zastosowania różnego typu modeli można napotkać na przykład w meteorologii [123] lub w diagnostyce medycznej [34, 80, 130]. Rysunek 3.2 przedstawia koncepcję „czarnej skrzynki” w rozumieniu diagnostyki technicznej [84]. W przypadku diagnostyki technicznej, gdzie obiektem jest maszyna lub urządzenie, wyróżnione mogą być następujące zbiory wejść i wyjść:

X_1 - wejścia związane z procesami użytecznymi (masa, energia);

X_2 - wejścia sterowania (ustalenie warunków działania maszyny);

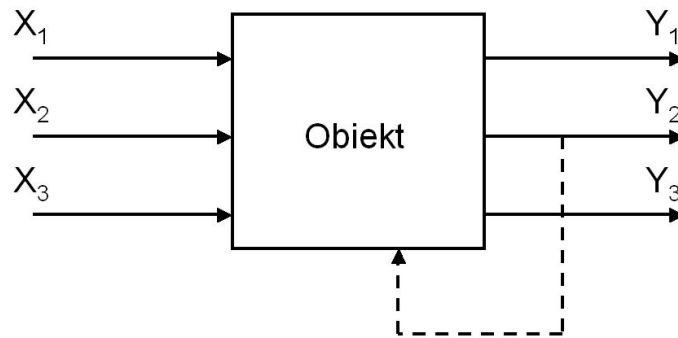
X_3 - wejścia nieznane - celowo pominięte lub niemożliwe do określenia;

Y_1 - wyjścia będące wynikiem użytecznego działaniem obiektu;

Y_2 - wyjścia stanowiące nieodczowne efekty uboczne działania obiektu (drgania, hałas) wraz z możliwym sprzężeniem zwrotnym o charakterze autodestrukcyjnym dla obiektu;

Y_3 - wyjścia nieznane - celowo pominięte lub niemożliwe do określenia;

Na rysunku 3.2 wyróżniono zarówno nieznane sygnały wejściowe jak i wyjściowe obiektu. Informacje zawarte w tych sygnałach są trudne do określenia poprzez pomiar i/lub obserwację, albo też celowo pomijane w procesie modelowania celem uproszczenia struktury modelu. Sygnały te są zazwyczaj ujmowane podczas modelowania jako szum. Postępowanie takie prowadzi jednak do sytuacji, w której model reprezentuje badany




Rys. 3.2. Obiekt w diagnostyce technicznej, [84]

obiekt w sposób przybliżony z określoną dokładnością, zależną od klasy zastosowanego modelu i od zastosowanej metody jego identyfikacji. Dlatego też nie można traktować modele relacji jako *przyczynowo-skutkowe*, ponieważ nie zawsze można jednoznacznie stwierdzić, czy zmiana sygnału wyjściowego modelu, przy niezmiennych wartościach rozpatrywanych wejść, wywołana jest zmianą stanu obiektu czy zmianą wartości pominiętych wejść.

3.1.4. Zastosowanie modeli obiektów

Detekcja niesprawności

Model obiektów stosowane są przede wszystkim do detekcji niesprawności. Schemat wnioskowania diagnostycznego z zastosowaniem modeli obiektów przedstawiono już wstępnie w rozdziale 2.2.3. Rozpatrując maszynę jako „czarną skrzynkę”, model obiektu jest identyfikowany na podstawie wejść i wyjść maszyny. Na rysunku 3.3 pokazano koncepcję modelu obiektu.



Rys. 3.3. Model obiektu, [20]

Dysponując zidentyfikowanym modelem obiektu oraz znając wartości cech stanu i wartości wejść modelu można przedstawić wyjście modelu obiektu w postaci relacji (3.1) [45].

$$Y = X \times S \quad (3.1)$$

Diagnozowanie stanu technicznego maszyny z zastosowaniem modelu obiektu może polegać na obserwacji wyjść obiektu i modelu. Jeżeli model jest zidentyfikowany po-

prawnie i dobrze dostrojony do obiektu można założyć, że pomiędzy wyjściami modelu i obiektu nie występują znaczące różnice. Pojawienie się takich różnic przy nie zmienionych warunkach działania obiektu oznacza zmianę jego stanu technicznego. Dodatkowy sygnał, będący wynikiem porównania wyjść modelu i obiektu, nazywany jest sygnałem residuum (por. rozdz. 2.2.3). W literaturze opisano szereg przykładów różnych metod diagnozowania stanu technicznego maszyn lub procesów przemysłowych poprzez analizę sygnałów residuum (np. [5, 68, 69, 127]).

Identyfikacja relacji diagnostycznych

Wnioskowanie diagnostyczne bazuje przede wszystkim na zidentyfikowanych relacjach diagnostycznych. Podstawą wnioskowania są relacje typu *symptom-stan*. Tego rodzaju relacje można określić mianem *skutkowo-przyczynowych*. Obserwowane sygnały diagnostyczne w połączeniu z odpowiednim układem kryteriów umożliwiają określenie zbioru symptomów stanu, będących skutkami działania obiektu w określonym stanie, który w niezmiennych warunkach działania maszyny stanowi przyczynę zaistnienia tych symptomów. Jako, że celem wnioskowania jest rozpoznanie stanu technicznego (rozpoznanie przyczyn) w przypadku znanych symptomów (skutków) wywołanych tym stanem, istnieje potrzeba prowadzenia badań, w których dla znanego (dobrze rozpoznanego) stanu technicznego obiektu obserwowane są skutki, jakie ten stan wywołuje. W diagnostyce technicznej można wyróżnić cztery podstawowe sposoby prowadzenia tych badań [21]:

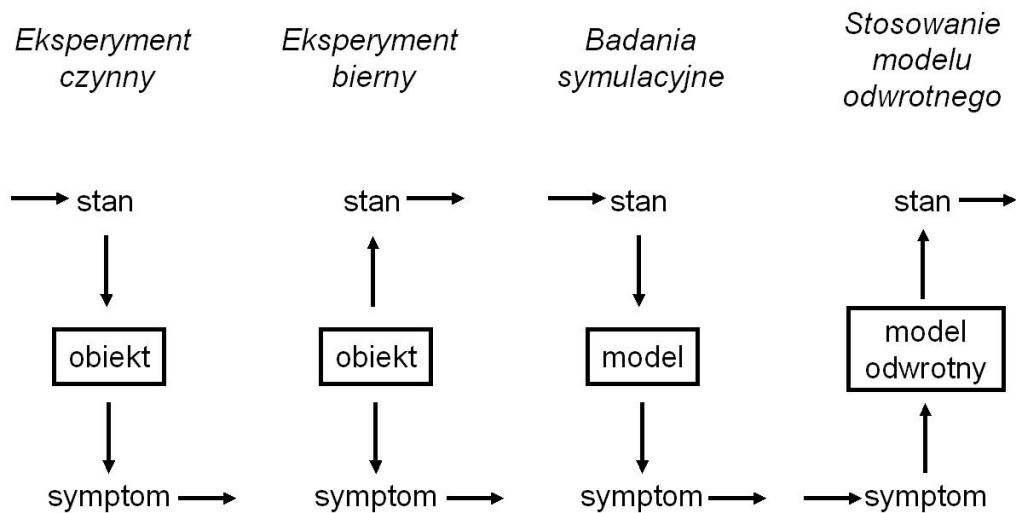
- eksperyment czynny;
- eksperyment bierny;
- prowadzenie badań symulacyjnych (z zastosowaniem modeli obiektów);
- odwracanie modeli i stosowanie modelu odwrotnego;

Idee poszczególnych metod prowadzenia badań diagnostycznych pokazano na rysunku 3.4. W diagnostyce technicznej rozróżnia się dwa rodzaje eksperymentów: eksperyment czynny i bierny [13].

Eksperyment czynny polega na świadomym wprowadzeniu niesprawności w obiekcie na przykład poprzez wymianę zdalnych elementów maszyny na niezdatne (np. [9]). Wówczas badania maszyny w poszczególnych stanach technicznych pozwalają na identyfikację symptomów tych stanów, które mogą służyć do definiowania relacji [21]. Jednak nie zawsze istnieje możliwość oddziaływania na stan techniczny obiektu badań z uwagi na duże koszty takiego postępowania. Częściej stosowany jest eksperyment bierny.

Eksperyment bierny ogranicza się do obserwacji maszyny bez ingerencji w jej stan. Na podstawie zgromadzonych w ten sposób danych identyfikowane są relacje diagnostyczne. Poszukiwane są relacje między stanami maszyny a odpowiadającymi im symptomami określonymi na podstawie sygnałów diagnostycznych.

Jeżeli dysponuje się odpowiednio dobrym modelem obiektu, może on zostać użyty do generowania danych do identyfikacji modeli klasyfikujących stany (rys. 3.4). Mogą to być przebiegi analogicznych sygnałów jak w przypadku rzeczywistego obiektu. Zaletą badań symulacyjnych w porównaniu z badaniami na rzeczywistym obiekcie są niewątpliwie



Rys. 3.4. Metody identyfikacji relacji w diagnostyce technicznej, [21]

nizsze koszty prowadzenia tych badań oraz możliwość łatwego zmieniania wartości cech stanu obiektu stanowiących najczęściej parametry modelu. Jednak należy pamiętać, że wszystkie niedokładności metody identyfikowania modelu obiektu służącego do symulacji działania maszyny, będą wpływać na wyniki klasyfikacji stanu w zidentyfikowanym modelu diagnostycznym. W pracach [71, 128, 139] opisano przykłady zastosowania badań symulacyjnych do diagnozowania obiektów technicznych.

Zbiory danych uzyskanych w wyniku eksperymentów lub badań symulacyjnych umożliwiają zidentyfikowanie relacji diagnostycznych typu *stan-symptom*. Jednak wnioskowanie diagnostyczne bazuje na relacjach odwrotnych (*symptom-stan*). Jednym ze sposobów reprezentowania tych relacji jest zastosowanie tzw. modelu odwrotnego ([21, 22]). Ideę modelu odwrotnego pokazano na rysunku 3.4. Identyfikowanie modelu odwrotnego jest możliwe dwoma metodami:

- poprzez odwracanie analitycznego modelu obiektu,
- poprzez identyfikację na podstawie danych uczących.

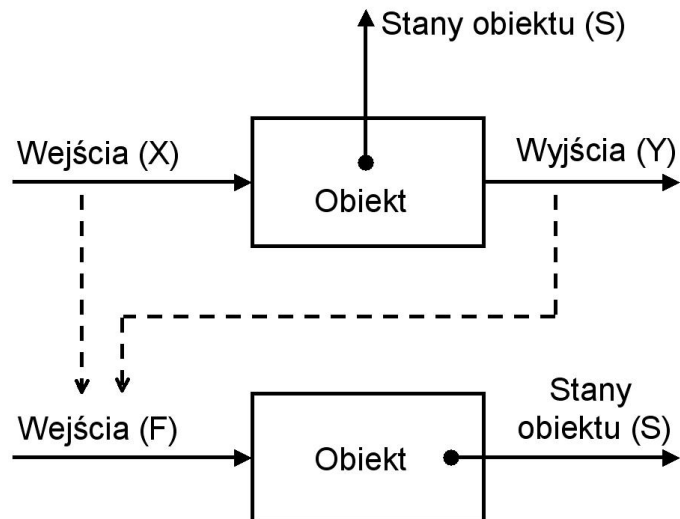
Identyfikowanie modelu odwrotnego poprzez odwracanie analitycznego modelu obiektu jest stosowane w ograniczonym zakresie. Przyczyną tego stanu rzeczy jest fakt, że uzyskanie modelu matematycznego złożonego obiektu jest zadaniem trudnym, a sam model jest bardzo złożony. To, z kolei, utrudnia również analityczne odwracanie tego modelu. Dlatego rozwiązaniem częściej stosowanym jest identyfikacja modelu na podstawie zgromadzonego zbioru danych uczących.

3.2. Modele diagnostyczne

Przedstawione w poprzednim rozdziale modele odwrotne należą do grupy modeli diagnostycznych. Modele diagnostyczne w odróżnieniu od modeli obiektów nie służą do reprezentowania zachowania się obiektu w określonym stanie i warunkach działania, lecz

do rozpoznawania tego stanu.

Podobnie jak w przypadku modelowania obiektów, maszyna rozpatrywana jest jako „czarna skrzynka” z wyodrębnionymi wejściami i wyjściami. Owe wejścia i wyjścia stanowią wejścia modelu diagnostycznego. Wyjściem modelu diagnostycznego jest stan lub klasa stanu obiektu. Jako, że maszyna również w tym przypadku rozpatrywana jest jako „czarna skrzynka”, to model diagnostyczny można uznać za przekształcenie modelu obiektu. Na rysunku 3.5 pokazano ideę tego przekształcenia.



Rys. 3.5. Model diagnostyczny, [20]

Dzięki przekształceniu modeli pokazanemu na rysunku 3.5 model przedstawiony w zależności (3.1) można zapisać w postaci relacji (3.2) [20].

$$\mathbf{M} \subset X \times Y \times S \quad (3.2)$$

gdzie:

- \mathbf{M} - model;
- X - przestrzeń cech wejściowych;
- Y - przestrzeń cech wyjściowych;
- S - przestrzeń cech stanów.

W ten sposób w jednej relacji można zawrzeć wpływ oddziaływań zewnętrznych obiektu (przestrzeń cech wejściowych i wyjściowych) w połączeniu z cechami stanu. Wówczas relację reprezentowaną przez model diagnostyczny można zapisać w postaci (3.3).

$$\mathbf{D} \subset F \times S \quad (3.3)$$

gdzie:

- \mathbf{D} - model diagnostyczny;
- F - przestrzeń cech oddziaływań zewnętrznych zdefiniowana w zależności 3.4.

$$F = X \times Y \quad (3.4)$$

Modele diagnostyczne stosowane są przede wszystkim w modułach wnioskujących systemów doradczych do rozpoznawania stanu technicznego. Stan techniczny obiektu z zastosowaniem tych modeli może być zidentyfikowany na podstawie [66]:

- sygnałów residuum uzyskanych na przykład na podstawie modeli obiektu;
- sygnałów uzyskanych na podstawie klasycznych metod detekcji uszkodzeń (nie-sprawności);
- na podstawie wyznaczonych cech sygnałów diagnostycznych;
- na podstawie zmiennych procesowych lub ich cech.

W licznych pracach stosowano zarówno modele identyfikujące stan obiektu na podstawie sygnałów residuum [68], jak i na podstawie zmiennych procesowych [5, 49] oraz sygnałów wibroakustycznych [70, 72]. Inne przykłady identyfikacji modeli na podstawie danych eksperymentalnych opisano w [49, 75].

Rozważania opisane w dalszej części rozprawy dotyczą modeli diagnostycznych zidentyfikowanych na podstawie danych uczących w postaci wyznaczonych wartości cech sygnałów diagnostycznych.

3.3. Modele dokładne i przybliżone

W rozdziale 2 stwierdzono, że nie jest możliwa obserwacja wszystkich własności i właściwości badanego obiektu. Nie zawsze jest możliwe i/lub konieczne wyznaczanie dokładnych wartości sygnałów diagnostycznych, a także nie zawsze znane są dokładne wartości sygnałów wyjściowych. Ponadto, złożoność obiektów technicznych powoduje, że nie zawsze znana jest dokładna relacja pomiędzy sygnałami wejściowymi i wyjściowymi zidentyfikowanego modelu. Dlatego wyróżnić należy grupę modeli przybliżonych. Metody identyfikacji tych modeli pozwalają na uwzględnienie niedoborów informacji zarówno o wartościach sygnałów wejściowych i wyjściowych modelu, ale także o relacjach pomiędzy tymi sygnałami. Z modelami przybliżonymi mamy do czynienia między innymi w przypadku, gdy dysponujemy:

- przybliżonymi wejściami i/lub wyjściami przy znanej, dokładnej relacji między wejściami i wyjściami;
- dokładnymi wejściami dla których wyjścia określane są na podstawie przybliżonej relacji wejść i wyjść;
- przybliżonymi wejściami i wyjściami oraz przybliżoną relacją tych wejść i wyjść.

W przeciwieństwie do modeli przybliżonych o modelach dokładnych mówimy wówczas, gdy dysponujemy dokładnymi wejściami i wyjściami oraz znaną, dokładną relacją między wejściami i wyjściami modelu. Wejścia i wyjścia modeli przybliżonych są na ogół zdefiniowane przez odpowiednie klasy wartości wejść i wyjść.

Zastosowanie modeli przybliżonych umożliwia znaczne uproszczenie identyfikowania relacji diagnostycznych przy zapewnieniu poprawności wyników rozpoznawania stanu,

uzyskiwanych z zastosowaniem tych modeli. Najczęściej stosowanymi modelami tego typu są modele identyfikowane z zastosowaniem:

- statystyki matematycznej i analizy regresji;
- metod klasyfikacji i grupowania;
- sieci neuronalnych;
- teorii rozpoznawania wzorców;
- teorii zbiorów i relacji rozmytych;
- metod probabilistycznych i sieci przekonań;
- metod odwzorowań.

Wszystkie dziedziny niejednokrotnie przenikają się wzajemnie i służą głównie do formalnego zapisu informacji diagnostycznej, która powinna być reprezentowana w postaci modelu. Modele w diagnostyce technicznej stosowane są przede wszystkim do poszukiwania zależności (relacji) pomiędzy wartościami sygnałów diagnostycznych określonymi na podstawie dostępnych obserwacji obiektu a stanem maszyny lub klasą stanu.

3.3.1. Metody bazujące na klasyfikacji i grupowaniu

Liczną grupą modeli stosowanych w diagnostyce technicznej są klasyfikatory stanu. Model klasyfikujący stan obiektu nie określa precyzyjnie wartości cech stanu, lecz przyporządkowuje stan obiektu do określonego uprzednio zbioru stanów, które z punktu widzenia diagnostyki technicznej rozpatrywane są jako nierozróżnialne. Zdefiniowanie tych zbiorów, nazywanych klasami, może odbywać się na podstawie wiedzy eksperckiej, w wyniku analizy metodami matematycznymi lub na podstawie danych uczących. Ten ostatni sposób stosowany jest szczególnie w przypadkach, gdy zależności pomiędzy wartościami cech sygnałów diagnostycznych a stanem maszyny nie są do końca znane i gdy dostępny jest odpowiednio liczny zbiór sygnałów diagnostycznych. Wówczas wyznaczenie klas stanów podobnych odbywa się przez grupowanie danych uczących [15].

Głównym problemem podczas grupowania jest właściwa definicja kryterium grupowania zapewniającego odpowiednią rozdzielność grup. W przypadku podziału na zadaną liczbę grup każdy element jest przypisany do określonego podzbioru. Może okazać się jednak, że rzeczywista liczba grup różni się od zadanej. Wówczas w wyniku grupowania będzie powstawać kilka podzbiorów bardzo do siebie podobnych, albo grupy zawierające elementy do siebie niepodobne. Stąd, może się okazać, że podział na podzbiory nie jest optymalny. W przypadku, gdy grupy są tworzone z elementów spełniających określone, najczęściej progowe kryterium, może dojść do sytuacji, w której pewna liczba elementów nie będzie należeć do żadnego z utworzonych podzbiorów, tworząc w ten sposób dodatkowe grupy jednoelementowe. Może też zaistnieć sytuacja, w której pewna liczba elementów powinna znaleźć się w więcej niż jednej grupie, co oznaczałoby „sklejanie się” grup. W wyniku grupowania otrzymuje się podział danych uczących na zbiory, wewnątrz których wartości cech są nierozróżnialne w świetle przyjętych kryteriów. Zestawiając te zbiory razem z kryterium oceny przynależności nowych elementów do poszczególnych

grup zostaje zdefiniowany klasyfikator służący w diagnostyce technicznej do określenia klasy stanu obiektu. Przykłady zastosowania tych metod opisano między innymi w [30, 75].

3.3.2. Sieci neuronalne

Sieci neuronalne swoją genezę mają w licznych badaniach neurofizjologów i biotechników zgłębiających zagadnienia matematycznego opisu komórki nerwowej i wiążącego się z tym procesu myślowego (przetwarzania danych) [129]. Jednym z pierwszych przykładów sieci neuronalnej był *perceptron* opracowany przez F. Rosenblatta [115].

W literaturze przedstawiono wiele strategii uczenia sieci zarówno z nauczycielem jak i bez w zależności od założonej struktury sieci oraz funkcji przejścia neuronów [42, 78]. W przypadku diagnostyki technicznej sieci neuronalne są stosowane stosunkowo często ze względu na łatwość modelowania za ich pomocą złożonych zależności przyczynowo skutkowych (np. [54, 72, 89, 100]). Trudności nastręcza jednak zgromadzenie odpowiednio dużego zbioru danych uczących.

3.3.3. Zbiory rozmyte

Zbiory rozmyte zostały zaproponowane przez L. Zadeha w 1965 roku [148]. Główną zaletą zbiorów rozmytych w porównaniu do zbiorów w ujęciu klasycznym jest to, że mogą być stosowane do opisu szeregu zagadnień w sposób przybliżony lub nieprecyzyjny, analogiczny do sposobu postrzegania rzeczy przez człowieka. Cecha ta sprawia, że algorytmy modelowania bazujące na zbiorach rozmytych niejednokrotnie sprawdzają się lepiej w warunkach niedoborów informacji niż modele bazujące na wartościach ostrych. Stąd, modele bazujące na zbiorach rozmytych są bardzo popularne w diagnostyce technicznej. Zbiory rozmyte były stosowane zarówno do identyfikowania modeli obiektów (np. [49]) jak i do identyfikowania klasyfikatorów stanu (np. [91, 105]).

3.3.4. Sieci przekonań

Sieci Bayesa, inaczej zwane sieciami przekonań, są ostatnio coraz częściej stosowane do wnioskowania przybliżonego [66] bazującego na prawdopodobieństwie warunkowym. Sieć Bayesa jest grafem acyklicznym, w którym węzły są zmiennymi, a gałęzie odzwierciedlają zależności pomiędzy tymi zmiennymi [55].

Niewątpliwą zaletą sieci Bayesa jest to, że każdy węzeł sieci może być wejściem procesu wnioskowania w zależności od dostępnej informacji. Ponadto, wnioskowanie może przebiegać, na przykład, od przyczyn do skutków i od skutków do przyczyn, co umożliwia stosunkowo łatwe odwracanie modelu zaimplementowanego w postaci sieci Bayesa.

Wadą sieci Bayesa może być fakt, że liczba działań matematycznych koniecznych w trakcie wnioskowania rośnie znacznie szybciej niż rozmiar zadania modelowania.

Sieci Bayesa w diagnostyce technicznej nie są jeszcze tak popularne jak na przykład sieci neuronalne czy zbiory rozmyte. Stosowane były dotychczas między innymi w

rozpoznawaniu obrazów [53], w diagnostyce medycznej. Bardzo popularne są w dziedzinie sztucznej inteligencji, szczególnie w zagadnieniach związanych z wnioskowaniem przybliżonym [17].

3.3.5. Metody odwzorowań

Metody odwzorowań polegają na poszukiwaniu funkcji odwzorowującej dane uczące w wielowymiarowej przestrzeni. Z uwagi na to, że znalezienie takiej funkcji na podstawie ograniczonego zbioru danych uczących jest często niemożliwe, stosuje się algorytmy wielowymiarowej aproksymacji lub interpolacji. Głównym problemem, jaki należy rozwiązać podczas identyfikowania modeli tej klasy, jest właściwy dobór danych uczących. Powodem tego jest fakt, że modele te nie reprezentują relacji, lecz odwzorowanie. Oznacza to, że pomiędzy danymi wejściowymi a wyjściowymi musi być tzw. jednoznaczność [21]. Przykłady zastosowań modeli interpolacyjnych przedstawiono w [21, 22, 63].

Każda metoda modelowania oprócz szeregu zalet ma też swoje wady. Dlatego można znaleźć szereg publikacji, w których autorzy przedstawiają różne sposoby łączenia kilku metod identyfikowania modeli stosowanych dotychczas oddzielnie. Celem takiego działania jest połączenie zalet różnych metod modelowania w jednej. Bardzo popularnym połączeniem są na przykład rozmyte sieci neuronalne [92] lub sieci neuronalne, których parametry były dobierane z zastosowaniem algorytmów ewolucyjnych [98]. Metody te nazywane są mieszanymi lub hybrydowymi.

Dynamicznie rozwijają się także metody modelowania heurystycznego. Zastosowanie metod heurystycznych polega na poszukiwaniu i/lub odkrywaniu nowej, nieznannej dotąd wiedzy o obiekcie. Wiedza ta może być identyfikowana w formie zależności pomiędzy pewnymi cechami stanu i cechami obserwowanych sygnałów. Są to najczęściej metody przybliżone stosujące na przykład teorię zbiorów rozmytych, sieci neuronalnych itp. Wymagają zdefiniowania sformalizowanych form zapisu/reprezentacji wiedzy, która pozwala na zastosowanie tej wiedzy, na przykład w procedurach wnioskowania o stanie obiektu. Badania związane z zastosowaniem metod modelowania heurystycznego, rozpatrujące różne sposoby odkrywania wiedzy w bazach danych, opisano między innymi w [85–87, 138].

Wynikiem zastosowania modelu przybliżonego może być wskazanie jednej klasy stanu, w której znajduje się bieżący stan obiektu lub zbioru rozmytego, w którym nośnikami są identyfikatory klas stanu a wartości funkcji przynależności zbioru rozmytego określają stopnie przekonania z jakimi bieżący stan techniczny może być uznany jako element danej klasy stanu. W badaniach opisanych w niniejszej rozprawie rozpatrywano modele diagnostyczne, które dla określonych klas sygnałów diagnostycznych rozpoznawały stan w wyniku klasyfikacji.

3.4. Wejścia i wyjścia modeli

Podczas identyfikowania modelu diagnostycznego ważne jest określenie sygnałów wejściowych i wyjściowych modelu. W przypadku modeli diagnostycznych wejściami są sygnały diagnostyczne. Sygnałem diagnostycznym może być wartość cechy określonego sygnału, będącego na przykład wynikiem obserwacji obiektu. W niniejszej pracy zakłada się, że sygnały diagnostyczne mają wartości dyskretne i są nimi cechy punktowe.

Rozpatrywanie sygnałów dyskretnych wynika z faktu, że większość współczesnych układów pomiarowych i analizatorów sygnałów bazuje na metodach cyfrowych.

Cechy punktowe to takie, których wartości są pojedynczymi liczbami. Przykładem cechy punktowej może być wartość średnia, kurtoza, itp. Rozpatrywanie wyłącznie cech punktowych w niczym nie ogranicza dalszych rozważań, ponieważ cechy funkcyjne w przypadku wartości dyskretnych można rozpatrywać jako sekwencje cech punktowych.

Cechy sygnałów rozpatrywane w badaniach diagnostycznych mogą być dwójakiego rodzaju. Wyróżnia się:

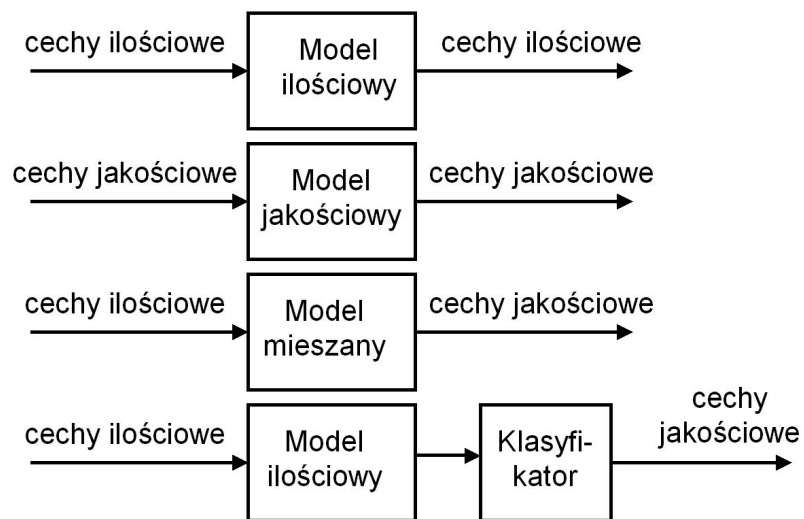
- cechy ilościowe;
- cechy jakościowe;

Cechy ilościowe są to cechy, których wartości są liczbami. Mogą to być wyniki obliczeń lub pomiarów. Wartości cech jakościowych najczęściej są w postaci lingwistycznej. Przykładem cechy lingwistycznej może być cecha o nazwie „kolor”, której wartość dla danego obiektu może wynosić „czerwony”. Cechy jakościowe są intuicyjnie bardziej zrozumiałe dla człowieka, jednak trudniej jest przedstawić ich wartości w postaci sformalizowanej dla potrzeb modelowania. Dlatego często wartości cech jakościowych są kodowane w postaci liczbowej, co ułatwia ich przetwarzanie [15]. Biorąc pod uwagę klasy cech występujące w diagnostyce technicznej na przykład można wyróżnić następujące klasy modeli:

- Modele ilościowe;
- Modele jakościowe;
- Modele mieszane - np. ilościowo jakościowe.

Na rysunku 3.6 pokazano schematycznie ideę podziału modeli diagnostycznych ze względu na rodzaj wartości cech. Model ilościowy to model przekształcający przestrzeń wartości cech ilościowych w przestrzeń wartości innych cech ilościowych. Model jakościowy, podobnie jak ilościowy, przekształca przestrzeń wartości jednych cech jakościowych na przestrzeń wartości innych cech jakościowych. Model mieszany może przekształcać przestrzeń wartości cech ilościowych w przestrzeń wartości cech jakościowych. Podobne przekształcenie można uzyskać stosując model ilościowy, a następnie wyniki otrzymane na jego podstawie poddać klasyfikacji.

Wyjściem modeli diagnostycznych są cechy stanu. Cechami stanu również są najczęściej cechy punktowe, które określają wartości luzów, stopnie zużycia, wzajemne położenie elementów maszyny itp.



Rys. 3.6. Klasy modeli, [21]

Rozdział 4

Wielomodele

W poprzednich rozdziałach przedstawiono koncepcję rozpatrywania maszyny w postaci „czarnej skrzynki”, której wejścia i wyjścia są wykorzystywane do identyfikowania modelu. Z uwagi na to, że wewnętrzna struktura badanego obiektu jest w takim przypadku pomijana bardzo ważną rolę odgrywa właściwa identyfikacja modelu. W przypadku diagnostyki technicznej pojawia się jednak problem zidentyfikowania wejść modelu i obiektu. Brak możliwości obserwowania lub też konieczność pomijania niektórych wejść obiektu podczas identyfikowania jego modelu powoduje, że model może nie w pełni odzwierciedlać zachowanie badanego obiektu.

W związku z tym, identyfikowanie modeli diagnostycznych wymaga w dużej mierze podejścia bazującego na intuicji i doświadczeniu badacza. Dodatkowy problem pojawiający się podczas identyfikowania modelu to złożoność obiektu, a co za tym idzie, złożoność modelu.

Zarówno identyfikowanie, jak i stosowanie złożonego modelu może być trudne. Rozwiązaniem alternatywnym jest zastąpienie jednego złożonego modelu zbiorem modeli prostszych. Takie rozwiązania nazywane są wielomodelami. Definicję wielomodelu wprowadzono po raz pierwszy w [95] i rozwinięto w [96]. Wielomodel był tam zdefiniowany w następujący sposób:

Wielomodelem nazywamy model składający się z wielu niezależnych modeli, które wspólnie reprezentują zachowanie modelu

Powyższa definicja opisuje jednoznacznie czym różni się model od wielomodelu. W badaniach opisanych w niniejszej pracy wprowadzono jednak nową, zmodyfikowaną definicję wielomodelu.

Wielomodelem nazywamy model składający się z co najmniej dwóch, stosowanych łącznie, modeli składowych, które mogą być identyfikowane oddzielnie, najczęściej z zastosowaniem różnych metod i kryteriów

Zgodnie z wprowadzoną definicją wielomodele są specyficzną klasą modeli, w których można zadanie modelowania relacji diagnostycznej podzielić na podzadania, a następnie

każde z tych podzadań realizować niezależnie.

Jako, że *wielomodel* także jest modelem, dlatego w dalszych rozważaniach termin *wielomodel* będzie stosowany jedynie wtedy, kiedy użycie słowa *model* prowadzić będzie do niejednoznaczności.

Wprowadzone w powyższej definicji *modele składowe* spotykane są w diagnostyce procesów pod nazwą modeli cząstkowych. Modele cząstkowe są wynikiem dekompozycji złożonego obiektu (procesu) na składniki prostsze. Jest to przykład tzw. dekompozycji przestrzennej, w przypadku której modele cząstkowe reprezentują poszczególne fragmenty obiektu. W badaniach opisywanych w niniejszej pracy, modele składowe nie są wynikiem dekompozycji przestrzennej. Dlatego w pracy jest stosowana nazwa *modele składowe*, jako określenie modeli wynikających z ogólnie pojętej dekompozycji. Modele cząstkowe stanowią w tym wypadku podzbiór możliwych rozwiązań modeli składowych wyróżniony ze względu na zastosowany sposób dekompozycji, w tym przypadku dekompozycji przestrzennej.

4.1. Etymologia nazwy

W trakcie prezentowania fragmentów badań, podczas konferencji lub sympozjów, zwracano uwagę autorowi, że nazwa *wielomodel* jest nieodpowiednia i że lepszymi nazwami byłyby terminy: *model szeregowy (równoległy)*, *model o strukturze szeregowej (równoległej)*, itp. Z wielu jednak przyczyn autor postanowił stosować nazwę *wielomodel*, a przekazane uwagi przyczyniły się do powstania niniejszego rozdziału.

Głównym powodem stosowania nazwy *wielomodel* jest rodowód tego terminu. Jest on tłumaczeniem z języka angielskiego terminu *multi-model* (czasem *multiple model*, *multimodel*). Sposób tłumaczenia jest analogiczny do tłumaczeń często stosowanych przymiotników takich, jak:

- *wielowymiarowy* (ang. *multidimensional*);
- *wielokanałowy* (ang. *multichannel*);
- *wielopunktowy* (ang. *multipoint*);
- itp.

Słowo *wielomodel* jest rzeczownikiem złożonym z dwóch członów. Temat *-model* określa rzecz, której nazwa ta dotyczy. Przedrostek *wielo-* określa występowanie czegoś w liczbie mnogiej pomimo tego, że sam rzeczownik występuje w liczbie pojedynczej.

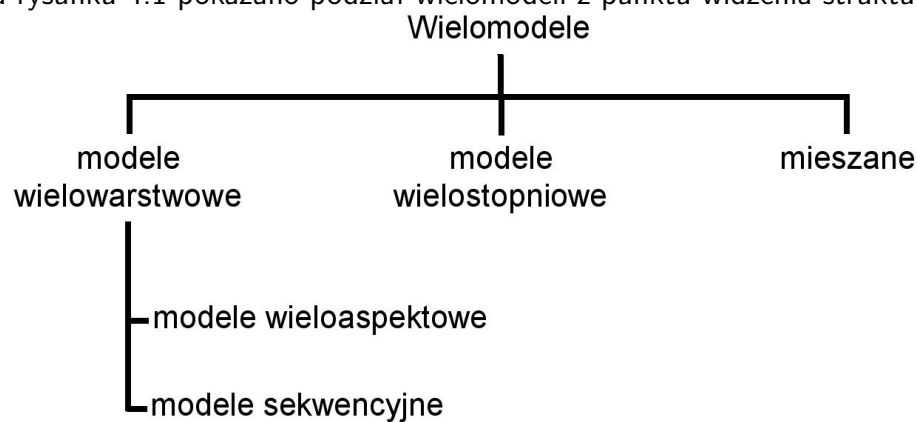
Ponadto, nazwa *wielomodel* występuje już w literaturze polskiej w odniesieniu do modeli, jak te będące przedmiotem tej rozprawy, a stosowanych przede wszystkim w teorii sterowania [106].

W niniejszej pracy stosowana jest nazwa *wielomodel* w celu podkreślenia, że modele składowe mogą być identyfikowane niezależnie jako osobne zadania, zgodnie z wprowadzoną definicją. Jeżeli możliwe jest równoczesne identyfikowanie modeli składowych tj. połączenie dwóch lub więcej podzadań i realizowanie ich jako jedno „większe”, to taki model nie jest wielomodelem.

Wszystkie przedstawione w dalszych rozważaniach wielomodele będą nazywane modelami.

4.2. Klasyfikacja wielomodeli

Wielomodele to modele posiadające zdefiniowaną strukturę wewnętrzną, w której występują co najmniej dwa niezależnie identyfikowane modele składowe. Identyfikacja wielomodeli polega na dekompozycji zadania modelowania na kilka pod-zadań. Od tego, jak zostanie przeprowadzona dekompozycja, zależy struktura wielomodelu tj. liczba modeli wchodzących w jego skład i ich wzajemne powiązanie. Wprowadzona na wstępie definicja wielomodelu umożliwia sklasyfikowanie wielomodeli ze względu na ich strukturę. Na rysunku 4.1 pokazano podział wielomodeli z punktu widzenia struktury.



Rys. 4.1. Klasy wielomodeli ze względu na ich strukturę

Z punktu widzenia struktury i wzajemnych powiązań modeli składowych, wielomodele można podzielić na:

- modele wielowarstwowe, w których modele składowe są połączone równoległe¹
- modele wielostopniowe, w których modele składowe są połączone ze sobą szeregowo.


Równoległe powiązanie modeli pokazano na rysunku 4.2a. Jeżeli modele składowe są do siebie równoległe, oznacza to, że mają takie same wejścia i wyjścia. Każdy z tych modeli stanowi warstwę.

Jeżeli natomiast modele składowe są ze sobą powiązane w taki sposób, że wyjście jednego modelu składowego stanowi wejście modelu kolejnego, to mówimy o szeregowym powiązaniu modeli składowych (por. rys. 4.2b).

Główną trudnością podczas budowania modeli wielowarstwowych jest określenie sposobu łączenia wyjść modeli składowych w jedno wspólne wyjście. Opracowano szereg metod wyznaczenia wyjścia wielomodelu na podstawie wyjść modeli składowych (por. rozdz. 5). Wiele spośród nich zostało opracowanych dla szczególnej grupy wielomodeli

¹terminy: *równoległe* i *szeregowo powiązania modeli* stosowane są przez analogię do łączenia odpowiednio równoległego i szeregowego elementów systemów (układów) posiadających wejścia i wyjścia

zwanych modelami sekwencyjnymi. W wielomodelach tego typu wyjście jednego wybranego modelu składowego jest zarazem wyjściem wielomodelu. Inną szczególną grupę wielomodeli stanowią modele wieloaspektowe. Charakteryzują się one tym, że modele składowe identyfikowane są na podstawie różnych kryteriów.



Rys. 4.2. Idea wielomodelu o równoległym (a) i szeregowym (b) powiązaniu modeli składowych

4.3. Modele wielowarstwowe


Modele wielowarstwowe są najczęściej stosowaną klasą wielomodeli. Są to wielomodele, w których modele składowe mają jednakowe wyjścia, które są łączone w jedno, wspólne wyjście wielomodelu. Stosowane są na ogół w następujących przypadkach (na podstawie [97]):

- zmienne scenariusze symulacji uwarunkowane obserwowanymi zmianami w modelowanym obiekcie;
- dysponowanie zbiorem modeli, których wyjścia są wzajemnie sprzeczne;
- niejednoznaczności, wynikającej z niedoboru informacji o modelowanych relacjach;
- modelowania złożonych zależności, gdzie dużą rolę odgrywa intuicja.

Ideę tych modeli pokazano na rysunku 4.3. Wyznaczenie wyjścia wielomodelu polega, w tym przypadku, na takim połączeniu wyjść modeli składowych, aby wyjście wielomodelu było najbardziej reprezentatywne dla modelowanego obiektu bazując przy tym na wyjściach poszczególnych modeli składowych.

Ogólną procedurę identyfikowania modeli wielowarstwowych można przedstawić w trzech podstawowych etapach:

- Wybór odpowiednich modeli składowych;
- Zidentyfikowanie modeli składowych;



Rys. 4.3. Idea modeli wielowarstwowych

- Opracowanie sposobu łączenia wyjść modeli składowych.

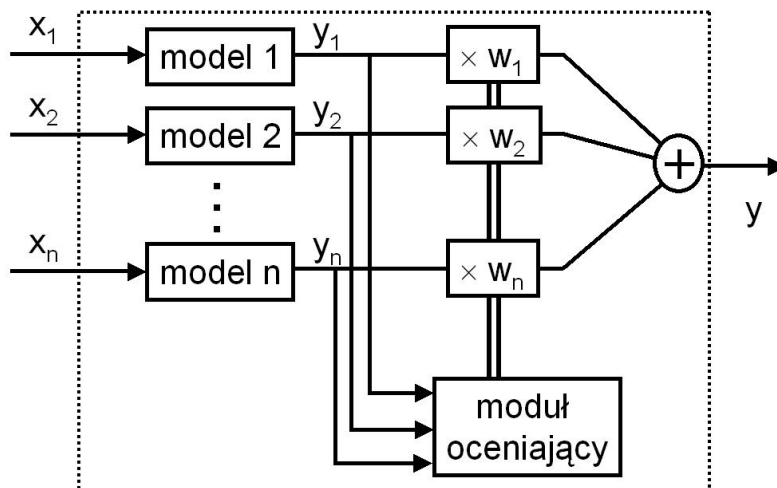
Modele wielowarstwowe stosowane mogą być w sytuacji, gdy dysponujemy modelami, reprezentującymi modelowaną relację, a wyniki uzyskane z tych modeli uniemożliwiają wskazanie, który z nich jest najlepszy. Przykłady zastosowań wielomodeli tej klasy opisano między innymi w [27, 53, 142]. Ponadto, istnieją dwa szczególne przypadki zastosowań modeli wielowarstwowych:

- modele wieloaspektowe,
- modele sekwencyjne.

4.3.1. Modele wieloaspektowe

Wielomodel można nazwać modelem wieloaspektowym, gdy modele składowe identyfikowane są na podstawie różnych założeń tj. na podstawie różnych zbiorów sygnałów diagnostycznych (na przykład na podstawie sygnałów wibroakustycznych, na podstawie obserwacji parametrów procesu użytecznego zachodzącego w maszynie itp.), bądź wtedy, kiedy wiedza potrzebna do określenia symptomów stanów technicznych pochodzi z różnych źródeł (na przykład wiedza eksperta, wyniki badań symulacyjnych, wyniki eksperymentu biernego, itp.). Ideę modeli wieloaspektowych pokazano na rysunku 4.4. W tym przypadku modele składowe odpowiadają odrębnym aspektom, w których może być rozpatrywana modelowana relacja.

Modele wieloaspektowe mogą być bardzo przydatne w badaniach diagnostycznych. Umożliwiają równoczesne zastosowanie wiedzy eksperta dotyczącej wyników badań symulacyjnych czy wyników obserwacji. Mogą być również przydatne, gdy sygnały diagnostyczne są rezultatem obserwacji różnych procesów związanych z działaniem obiektu, na przykład drgań wibroakustycznych zmierzonych na korpusie maszyny, temperatury cieczy chłodzącej itp.




Rys. 4.4. Idea modeli wieloaspektowych

4.3.2. Modele sekwencyjne

Koncepcja modeli sekwencyjnych jest pokazana na rysunku 4.5. Cechą charakterystyczną tych wielomodeli jest to, że modele składowe są identyfikowane na przykład na podstawie różnych zakresów danych uczących. Wynika to głównie z przeznaczenia tych wielomodeli. Są one stosowane w szczególności w przypadkach, gdy:

- poszukiwana zależność jest nieliniowa,
- poszukiwana zależność jest niejednoznaczna.

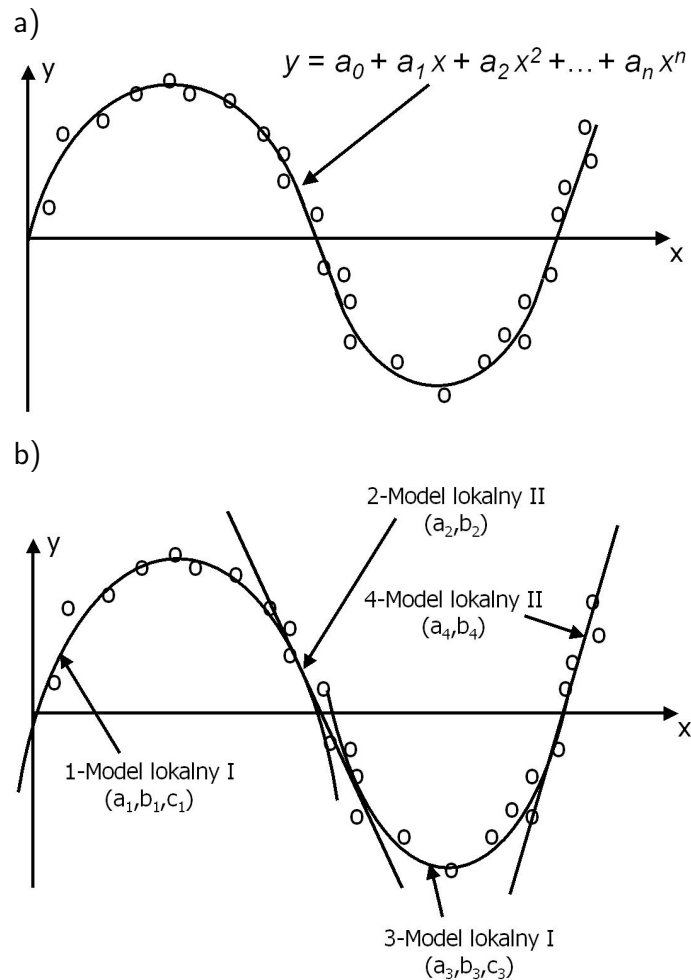


Rys. 4.5. Idea modeli sekwencyjnych

Pierwszy z przypadków, w których stosowane są modele sekwencyjne można zobrazować na przykładzie prostego zadania aproksymacji (rys. 4.6a). Poszukiwanych jest $n+1$ współczynników $\{a_0, \dots, a_n\}$ funkcji wielomianowej, będącej modelem aproksymującym dostępne dane. Zaletą identyfikowania jednej takiej funkcji jest to, że opisuje ona dane uczące w całym ich zakresie. Może być jednak bardzo złożona.

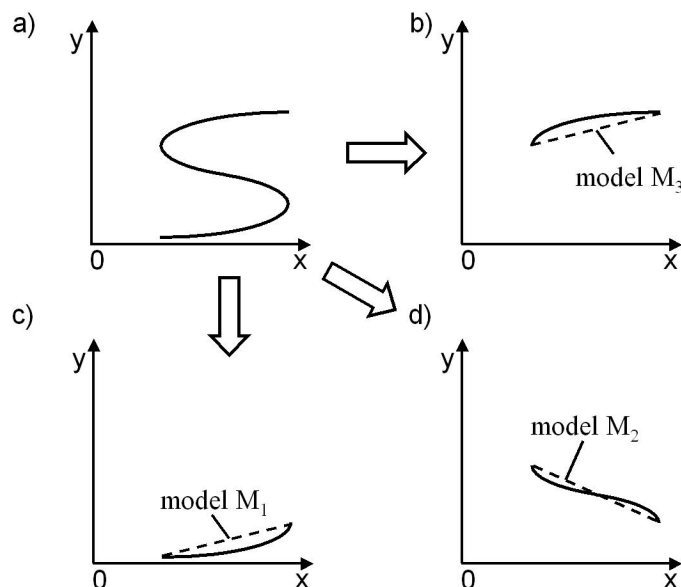
Na rysunku 4.6b przedstawiono sposób aproksymacji tego samego zbioru danych uczących za pomocą nie jednej, lecz czterech funkcji (dwóch liniowych i dwóch drugiego

stopnia). W takim przypadku przed wyznaczeniem współczynników funkcji aproksymujących należy zdefiniować zakresy stosowania poszczególnych modeli składowych. Wyznaczenie wyjścia modelu polega na określeniu zakresów wejść, dla których stosowane mają być kolejne modele składowe. Wówczas, wyjściem wielomodelu jest wyjście modelu składowego zidentyfikowanego w tym zakresie. Taka procedura nazywana jest przełączanie wyjść (*ang. output switching*).



Rys. 4.6. Modelowanie zależności nieliniowych - przykład (a) - aproksymacji za pomocą jednej funkcji (model globalny) i (b) - aproksymacji odcinkowej za pomocą kilku funkcji (modele lokalne), (na podstawie [56])

Drugą przyczynę stosowania wielomodeli tej klasy opisano w [102] wprowadzając wielomodele rozmyte. Na rysunku 4.7a przedstawiono przykład zależności wyjścia y i wejścia x . Zależność ta jest niejednoznaczna. Rysunki (4.7b, c, d) przedstawiają kolejne modele składowe wielomodelu, dzięki którym poszukiwana zależność staje się jednoznaczna w zakresach wartości danych uczących odpowiadających dziedzinom poszczególnych modeli. Zastosowanie wielomodeli w opisanych sytuacjach jest szczególnie uzasadnione, gdyż zastosowanie układu jednomodelowego mogło by prowadzić do błędnych interpretacji wyników [106].



Rys. 4.7. Niejednoznaczna zależność wejścia x i wyjścia y (a) i sposób jej modelowania za pomocą wielomodelu złożonego z modeli lokalnych M_1, M_2, M_3 (b,c,d) [102, 106]

Modele sekwencyjne stosowane są głównie w teorii sterowania. Szczególnie popularne są metody MPC (*ang. Model Predictive Control*) [94, 107, 114, 125, 135]. Często stosowane są również metody rozmyte bazujące na modelach TSK (Takagi-Sugano-Kang) [6, 28, 29]. Zaletą wielomodeli rozmytych jest to, że zakresy wartości danych uczących mogą posiadać część wspólną tj. mogą na siebie zachodzić. Umożliwia to zastosowanie „miękkiego” przełączania modeli. Znane są przykłady stosowania modeli sekwencyjnych w badaniach nad uzdatnianiem wody morskiej [46], rozpoznawaniem obrazów ruchomych [81, 90], w lotnictwie [33]. Inne wielomodele stosowane w teorii sterowania opisano w [37, 41, 65, 104, 113]. Opisano szereg propozycji optymalizujących wielomodele i poprawiających ich odporność na wszelkie zakłócenia (np. [10, 11, 58, 124]). Przedstawiono również wyniki badań porównawczych wielomodeli z innymi modelami (np. [134]). W diagnostyce technicznej są stosowane głównie jako modele obiektów. Z uwagi na to, że przedmiotem rozważań tej rozprawy są modele diagnostyczne, wielomodele sekwencyjne nie będą rozpatrywane w dalszej części.

4.4. Modele wielostopniowe

Odmianą grupą wielomodeli są modele wielostopniowe. Ideę modelu wielostopniowego jako szeregowego połączenia modeli składowych pokazano już na rysunku 4.2b.

W modelu wielostopniowym wyjście jednego modelu składowego jest wejściem innego modelu składowego, stanowiącego kolejny stopień wielomodelu. Zastosowanie wielomodeli tej klasy jest zasadne w przypadku, gdy istnieje możliwość dekompozycji zadania modelowania złożonej zależności na pod-zadania, które mają charakter etapowy. Wymagane jest jednak zdefiniowanie przestrzeni sygnałów pomocniczych.

Sygnałami pomocniczymi lub też sygnałami pośrednimi są wyjścia kolejnych stopni wielomodelu [19]. W przypadku wielomodelu z rysunku 4.2b rozpatrywanych jest $N - 1$ przestrzeni pomocniczych, w których należy określić wartości sygnałów pomocniczych od X_1 do X_{N-1} . Są to najczęściej sygnały odpowiadające rzeczywistym lub wirtualnym oddziaływaniom. Mogą to być sygnały, które nie były brane pod uwagę przy definiowaniu zbioru sygnałów wejściowych wielomodelu.

Jeżeli zostały zdefiniowane wszystkie sygnały pośrednie można rozpocząć identyfikowanie wielomodelu. Podczas identyfikowania wielomodelu, wszystkie modele składowe rozpatruje się odrębnie. Procedurę identyfikowania można przedstawić następująco:

- Określenie zbioru dodatkowych sygnałów możliwych do obserwacji, które mogłyby stanowić zbiór sygnałów pomocniczych;
- Zdefiniowanie modeli składowych poszczególnych stopni wielomodelu;
- Na podstawie dostępnych danych zidentyfikowanie wszystkich modeli składowych;
- Szeregowe zestawienie modeli składowych;

Przykłady zastosowań modeli wielostopniowych w różnych dziedzinach badań naukowych przedstawiono między innymi w [19, 35, 108, 136, 150].

4.5. Modele mieszane

Przedstawione klasy wielomodeli można traktować jako wielomodele o strukturach elementarnych. Modułowość wielomodeli umożliwia różnorodną konfigurację ich elementów składowych, co powoduje, że modele te mogą mieć strukturę mieszaną, będącą jednak zawsze wynikiem dekompozycji złożonego modelu na kilka modeli prostszych.

Rozdział 5

Sposoby wyznaczania wyjścia wielomodelu

Jedną z cech wielomodeli, która wyróżnia je spośród innych modeli stosowanych w diagnostyce technicznej, jest możliwość niezależnego identyfikowania modeli składowych. W wyniku identyfikacji modeli składowych uzyskuje się zbiór niezależnych modeli. Zbiór tych modeli nie jest jeszcze wielomodelem. Konieczne jest jeszcze odpowiednie powiązanie tych modeli ze sobą w taki sposób, aby wspólnie reprezentowały relację, która powinna być odzwierciedlona przez wielomodel.

Struktura wielomodeli jest określona przez sposób dekompozycji zadania modelowania. W przypadku modeli wielostopniowych powiązania między modelami są określone przez wejścia i wyjścia tych modeli. Wyjście modelu, będącego ostatnim stopniem jest zarazem wyjściem modelu wielostopniowego.

Bardziej skomplikowana sytuacja występuje w przypadku modeli wielowarstwowych. Podobnie, jak dla modeli wielostopniowych, struktura tych modeli jest wynikiem dekompozycji zadania modelowania. Jednak w tym przypadku, wyjścia modeli składowych są wartościami z tej samej przestrzeni. W diagnostyce technicznej może to być przestrzeń wartości cech stanu lub przestrzeń obrazów tych cech. Dysponując wyjściami wielu modeli składowych istnieje potrzeba połączenia tych wyjść w jedno wyjście modelu wielowarstwowego.

Problem łączenia wyjść dogodnie jest przedstawić poprzez analogię modeli wielowarstwowych do grupy ekspertów opracowujących wspólne stanowisko w określonej sytuacji [141]. W tabeli 5.1 przedstawiono podobieństwa wielomodelu i zespołu ekspertów.

Tab. 5.1. Przyrównanie modeli wielowarstwowych do grupy ekspertów

Wielomodel	Zespół ekspertów
Model składowy	Ekspert
Wyjście modelu składowego	Opinia eksperta
Wyjście wielomodelu	Stanowisko grupy ekspertów

Stanowisko grupy wypracowuje się najczęściej na drodze negocjacji, gdzie każdy członek grupy (ekspert) przedstawia własne stanowisko i/lub opinię, a następnie poszukuje się kompromisu korzystnego dla możliwie szerokiej grupy uczestników dyskusji. Wypracowanie opinii grupy bazuje jednak na skończonej liczbie wariantów rozwiązania zadania rozpatrywanego przez grupę. W związku z tym, opinia eksperta może być wyrażona na trzy sposoby [111]:

- ekspert wskazuje rozwiązanie jego zdaniem najlepsze,
- ekspert przedstawia listę rozwiązań uporządkowaną od rozwiązania najlepszego do najgorszego,
- ekspert przedstawia uporządkowaną listę rozwiązań wraz z ilościowym oszacowaniem stopnia przekonania o słuszności poszczególnych rozwiązań.

Zgodnie z tym, co zostało założone w rozdziale 3 wyjścia rozpatrywanych modeli są wartościami punktowymi, określającymi na przykład przynależność poszczególnych wartości cech stanu maszyny do określonych klas. W związku z tym, opinię wyrażoną przez eksperta może być w tym przypadku stwierdzenie prawdziwości następującej hipotezy:

Wartość j -tej cechy stanu technicznego obiektu należy do klasy S_{ij} .

Każdy ekspert wyraża swoją opinię o prawdziwości tego stwierdzenia poprzez przypisanie mu liczby z przedziału od 0 do 1, która jest stopniem przekonania tego eksperta o tym, że stwierdzenie jest prawdziwe. Ekspert wyraża swoją opinię dla każdej rozpatrywanej cechy i każdej rozpatrywanej klasy wartości tej cechy. Powstaje w ten sposób zbiór rozmyty jego opinii o prawdziwości poszczególnych stwierdzeń (5.1) [16].

$$A_g = \{(u, a_g(u)) : u \in U\} \quad (5.1)$$

Wypracowanie opinii grupowej polega wówczas na znalezieniu następującego zbioru rozmytego opinii grupy:

$$A_G = \{(u, a_G(u)) : u \in U\} \quad (5.2)$$

takiego, że

$$A_G = \bigoplus_{g \in G} A_g \quad (5.3)$$

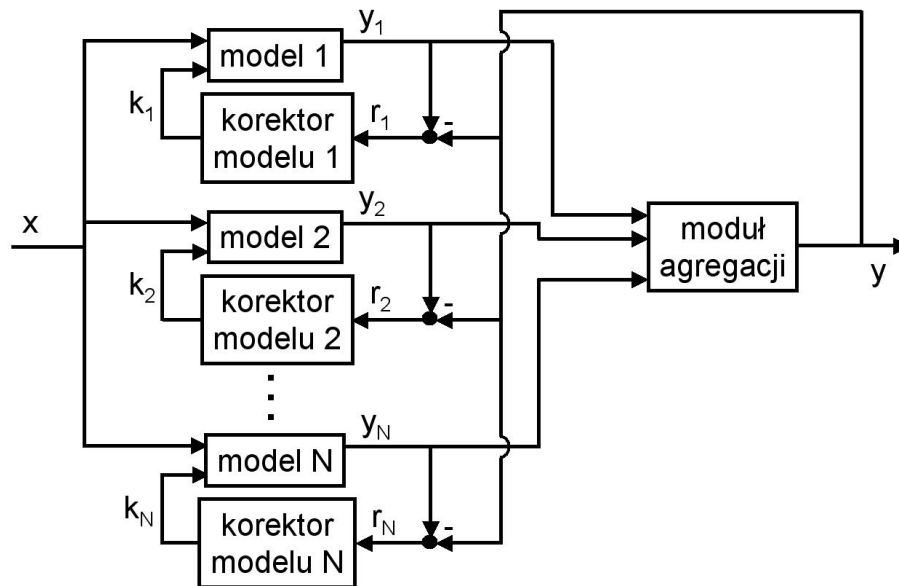
gdzie: \bigoplus oznacza operator agregacji.

W przypadku modelu wielowarstwowego jest podobnie. Jeżeli założymy, że każdy model jest ekspertem, wówczas oczekujemy jego opinii o stanie obiektu. W przypadku modeli przybliżonych będących klasyfikatorami stanu jest to wynik klasyfikacji. Metody łączenia wyjść modeli składowych w modelach wielowarstwowym można podzielić na dwie kategorie:

- uzgadnianie wyjść,
- agregacja wyjść.

5.1. Uzgadnianie wyjść modeli składowych

Zaproponowany sposób wyznaczania wyjścia wielomodelu, bazujący na uzgadnianiu wyjść modeli składowych, polega na modyfikowaniu wyjść modeli składowych w taki sposób, aby po zakończeniu procesu uzgadniania wszystkie wyjścia były równe i co za tym idzie tożsame z wyjściem wielomodelu. Rysunek 5.1 przedstawia koncepcję wielomodelu, którego wyjście jest wynikiem uzgadniania wyjść modeli składowych.



Rys. 5.1. Koncepcja modelu wielowarstwowego uzgadniającego wyjścia modeli składowych

Przedstawiona koncepcja polega na modyfikowaniu wyjść modeli składowych za pomocą ich dodatkowych wejść. Dodatkowe wejścia tych modeli wynikają z pętli sprzężeń zwrotnych, gdzie na podstawie wyjścia wielomodelu i wyjść modeli składowych wyznaczane są sygnały residuum r_i . Sygnały te stanowią wejścia modułów, zadaniem których jest przekształcenie sygnałów r_i w dodatkowe sygnały wejściowe k_i modeli składowych.

Procedura uzgadniania wyjść modeli składowych powinna uwzględniać odpowiednie kryterium optymalizacji, na przykład w postaci warunku (5.4).

$$\sum_{i=1}^N r_i^2 \rightarrow \min \quad (5.4)$$

Metody uzgadniania są często stosowane w zagadnieniach podejmowania decyzji i planowania strategii negocjacyjnych w różnych dziedzinach. Przykłady różnych metod opisano w [8, 14, 76, 77, 83, 147].

5.2. Agregacja wyjść modeli składowych

Metody agregacji, stosowane do wyznaczenia wyjścia wielomodelu, polegają na wyznaczeniu jednej wartości wyjściowej wielomodelu na podstawie zbioru wartości wyjść modeli składowych. Ideę modelu wielowarstwowego agregującego wyjścia modeli składowych pokazano na rysunku 4.3.

Agregacja polega na zastąpieniu zbioru elementów pewnej przestrzeni przez jeden element tej samej przestrzeni reprezentujący ten zbiór [31]. Należy wyraźnie zaznaczyć, że w metodach agregacji, w odróżnieniu od metod uzgadniania, raz uzyskane wyjścia modeli składowych nie są modyfikowane, czyli nie ma pętli sprzężenia zwrotnego modyfikującego wyjścia modeli składowych. Agregacja wyjść modeli składowych wymaga jednak zdefiniowania operatora agregacji czyli algorytmu numerycznego umożliwiającego wyznaczenie jednego wspólnego wyjścia wielomodelu.

W badaniach opisywanych w niniejszej rozprawie wyjścia modeli składowych opisywały wartości cech stanu obiektu w przestrzeni obrazów tych cech. Ocena stanu technicznego obiektu z zastosowaniem jednego z modeli składowych wielomodelu była więc zbiorem liczb z przedziału $[0,1]$, opisujących stopnie przekonania o przynależności wartości wybranej cechy do jednej z klas. W rozpatrywanym przypadku, agregację można prowadzić niezależnie dla każdej klasy, definiując operator agregacji zgodnie z zależnością (5.5) [82].

$$\bigoplus : \bigcup_{n \in N} [0, 1]^n \longrightarrow [0, 1] \quad (5.5)$$

Prezentowana definicja operatora agregacji ma charakter ogólny. Przykłady operatorów agregacji opisano w rozdziale 5.2.2. Wszystkie operatory charakteryzują się pewnymi własnościami.

5.2.1. Własności operatorów agregacji

Opisane poniżej własności operatorów agregacji stanowią wytyczne przy definiowaniu nowych operatorów [31].

- Warunki brzegowe (*ang. boundary conditions*):

$$\bigoplus(0, 0, \dots, 0) = 0 \quad (5.6)$$

$$\bigoplus(1, 1, \dots, 1) = 1 \quad (5.7)$$

- Monotoniczność (*ang. monotonicity*):

$$y_i \geq x_i \Rightarrow \bigoplus(x_1, \dots, y_i, \dots, x_n) \geq \bigoplus(x_1, \dots, x_i, \dots, x_n) \quad (5.8)$$

Z (5.6), (5.7) i 5.8 wynika, że wynik agregacji będzie zawsze mieścił się w zakresie agregowanych wartości (między wartością minimalną i maksymalną).

- Ciągłość (*ang. continuity*):

Operator agregacji powinien być ciągły względem wszystkich agregowanych zmiennych. Pozwala to na zapewnienie pewnego rodzaju odporności (*ang. robustness*) na zachowania chaotyczne operatora [31].

- Łączność (*ang. associativity*):

$$\bigoplus(x_1, x_2, x_3) = \bigoplus(\bigoplus(x_1, x_2), x_3) = \bigoplus(x_1, \bigoplus(x_2, x_3)) \quad (5.9)$$

- Symetria (*ang. symmetry*):

Symetria oznacza, że kolejność zmiennych podczas agregacji nie ma wpływu na wynik.

$$\bigoplus(x_1, x_2, x_3) = \bigoplus(x_2, x_1, x_3) = \bigoplus(x_2, x_3, x_1) \quad (5.10)$$

- Zgodność (*ang. idempotence*):

Agregacja n wartości wynoszących x jest również równa x .

$$\bigoplus(x, x, \dots, x) = x \quad (5.11)$$

- Kompensacyjność (*ang. compensation*):

$$\min_{i=1}^n(x_i) \leq \bigoplus(x_1, x_2, \dots, x_n) \leq \max_{i=1}^n(x_i) \quad (5.12)$$

- Stabilność przy przekształceniu liniowym:

$$\bigoplus(r \cdot x_1 + t, r \cdot x_2 + t, \dots, r \cdot x_n + t) = r \cdot \bigoplus(x_1, x_2, \dots, x_n) + t \quad (5.13)$$

5.2.2. Operatory agregacji

Przedstawione własności operatorów agregacji z matematycznego punktu widzenia charakteryzują pewne cechy algorytmów agregacji, nie rozstrzygając przy tym, jakie przekształcenia matematyczne należy wykonać podczas agregacji. Rozwinięto szereg różnych operatorów agregacji, które posiadają wszystkie lub wybrane własności.

Operatory podstawowe, to operatory dobrze znane ze statystyki. Należą do nich:

- średnia arytmetyczna,
- średnia ważona,
- mediana,
- wartość maksymalna i/lub minimalna,
- ważona wartość maksymalna i/lub minimalna.

Wartości średnia, maksymalna i minimalna są charakterystycznymi cechami punktowymi zbioru liczb. Mediana jest wartością środkową zbioru uszeregowanego od wartości najmniejszej do największej. Analogicznie do mediany można zdefiniować inny operator agregacji nazywany statystyką *k*-tego rzędu (*ang. k-order statistic*). Agregacja z zastosowaniem tego operatora polega na wyborze *k*-tego elementu w uszeregowanym zbiorze.

Średnia ważona jest modyfikacją średniej arytmetycznej uwzględniającą „ważność” danych. W ogólnym przypadku wyrażana jest zależnością (5.14).

$$\bar{x} = \frac{\sum_{i=1}^N x_i w_i}{\sum_{i=1}^N w_i} \quad (5.14)$$

Operatory agregacji bazujące na ważonej wartości maksymalnej i/lub minimalnej nie są już zdefiniowane w tak jednoznaczny sposób jak średnia ważona. W różnych pracach ich autorzy definiowali te operatory na różne sposoby. Przykłady definicji tego typu operatorów opisano w [36, 43, 144].

Inne operatory agregacji są na ogół uogólnieniami zaprezentowanych operatorów podstawowych. Operatory średniej quasi-arytmetycznej są rozwinięciem operatora uśredniającego. Przykładami operatorów tej klasy mogą być średnia geometryczna i/lub harmoniczna.

Szczególną grupę operatorów stanowią operatory OWA (*ang. Ordered Weighted Averaging*) [145]. Operatory te bazują na średniej ważonej w postaci przedstawionej w (5.14) przy założeniu, że wagi są nieujemne a ich suma wynosi 1. Różnica polega na tym, że elementy agregowanego zbioru liczb są uporządkowane od wartości najmniejszej do największej. Operatory OWA mogą pełnić różne funkcje w zależności od sposobu zdefiniowania wag w (5.14). Wykorzystuje się w tym przypadku fakt uporządkowania agregowanych wielkości według wartości. Jeżeli zdefiniujemy wagi zgodnie z (5.15) to proponowany operator będzie w istocie wyznaczał wartość maksymalną, jeżeli (5.16), to będzie wyznaczał wartość minimalną. W przypadku (5.17) mamy do czynienia ze średnią arytmetyczną.

$$w_i = \{0, \dots, 0, 1\} \quad (5.15)$$

$$w_i = \{1, 0, \dots, 0\} \quad (5.16)$$

$$w_i = \frac{1}{N} \quad (5.17)$$

Operatory OWA są przydatne do łączenia wyjść modeli składowych, ponieważ są to operatory kompensacyjne, monotoniczne, zgodne oraz stabilne w przypadku przekształcenia liniowego.

5.3. Metody głosowania

Szczególnym przykładem metod agregacji mogą być metody bazujące na głosowaniu. Wyjątkowość tego sposobu agregacji polega na tym, że jej wynikiem nie jest wartość wyznaczona w wyniku przekształceń lub w wyniku wyboru jednej, wybranej wartości ze zbioru wartości wyjściowych wielomodelu. Wynikiem agregacji poprzez głosowanie jest ta wartość, która została wskazana przez większość modeli składowych. Metody głosowania są rozwijane przede wszystkim w teorii podejmowania decyzji.

Agregację wyjść modeli składowych metodami głosowania można prowadzić wtedy, gdy liczba możliwych wartości wyjść modelu jest mała. Zbiór tych wartości często bywa zbiorem wartości lingwistycznych (np. {„TAK”, „NIE”}).

Można wyróżnić pięć podstawowych metod głosowania [111]:

- proste głosowanie większościowe (*ang. majority voting*),
- głosowanie większościowe wazone,
- ograniczone głosowanie,
- rozszerzone głosowanie większościowe,
- rangowe głosowanie większościowe.

Metody prostego głosowania większościowego mogą być bardzo efektywne. Jednak lista możliwych wartości wyjść modeli składowych nie może być zbyt długa. W przeciwnym razie wynik głosowania w dużej mierze będzie przypadkowy.

Metody głosowania wazonego są rozwinięciem metod prostych. Modyfikacja polega na przypisaniu wagi każdemu modelowi składowemu, która jest oceną stopnia trafności diagnozy, uzyskanej na podstawie tego modelu.

Głosowanie ograniczone polega na ograniczeniu zbioru modeli składowych do tych, które w zaistniałej sytuacji są najodpowiedniejsze i wyznaczeniu wspólnego wyjścia na podstawie głosowania wybranych modeli.

Głosowanie rozszerzone jest przykładem metod uzgadniania wyjść modeli składowych. Polega na uzgadnianiu wartości wyjściowych pomiędzy k modelami, których wyjścia są najbardziej do siebie zbliżone. Wynik tego uzgadniania jest przyjmowany, jako wspólne wyjście wielomodelu reprezentatywne dla wszystkich modeli składowych.

Głosowanie rangowe bazuje na koncepcji uporządkowanych list preferowanych rozwiązań. W przypadku wyjść modeli składowych może to być uporządkowanie klas wartości cech stanu od klasy preferowanej najbardziej do klasy preferowanej najmniej. Pozwala to na agregację wyjść poprzez ustalenie globalnego porządku klas [57].

Przykłady metod głosowania oraz przykłady zastosowań opisano między innymi w [47, 73, 74, 99, 116].

5.4. Metody zaawansowane

Przedstawione w poprzednich rozdziałach podstawowe operatory agregacji oraz różne odmiany metod głosowania nie wyczerpują oczywiście wszystkich możliwości łączenia

wyjść modeli składowych. Metody bardziej zaawansowane bazują na metodach i technikach sztucznej inteligencji. Podstawą jest wówczas zidentyfikowany model agregujący wyjścia modeli składowych w jedno wyjście wielomodelu. Stosowana jest przy tym często koncepcja „czarnej skrzynki” opisana w rozdziale 3. Identyfikowany operator agregujący jest modelem typu MISO (*ang. Multiple Input Single Output*). Wejściami takiego modelu są wyjścia poszczególnych modeli składowych. Uzyskane wyjście jest wyjściem wielomodelu. Do identyfikacji takich operatorów mogą posłużyć różne metody identyfikacji modeli diagnostycznych, opisane również w rozdziale 3. Przykłady zastosowań różnych metod agregacji przedstawiono między innymi w [16, 44, 48, 112, 118, 119, 146].

Rozdział 6

Przykład metody definiowania i identyfikowania wielomodelu

W poprzednich rozdziałach przedstawiono modele stosowane w diagnostyce technicznej. Zdefiniowano również pojęcie wielomodelu. W niniejszym rozdziale opisano metodę identyfikowania wielomodelu do określenia stanu technicznego maszyny wirnikowej. Maszyny wirnikowe są szczególną klasą maszyn, od których wymaga się wysokiej niezawodności, eksploatując je równocześnie w warunkach ekstremalnych. Dlatego maszyny te są tematem licznych prac naukowo-badawczych z zakresu diagnostyki technicznej, których celem jest opracowanie metod diagnozowania i prognozowania ich stanu technicznego [4, 7, 32, 59, 103, 110, 131, 132, 143]. Wiele prac poświęcono głównie turbinom [1, 2, 40, 51, 67, 93, 149].

Złożoność działania maszyn wirnikowych sprawia, że autorzy wielu prac naukowo-badawczych ograniczają zakres swoich badań do wybranych wąskich dziedzin takich, jak na przykład obserwowanie maszyny w zmiennych warunkach działania [132], czy też obserwowanie i analizowanie trajektorii ruchu środka czopa [143].


W pracy [67] opisano badania, których celem było opracowanie metody klasyfikacji kinetostatycznej linii wałów maszyny wirnikowej. Zaprezentowana metoda bazowała na indukcyjnym pozyskiwaniu relacji umożliwiających klasyfikację położenia podpór łożyskowych. Podstawą badań były liczne zbiory danych uczących pochodzące z eksperymentu numerycznego i czynnego.

W przypadku badań opisywanych w niniejszej pracy, zaproponowano odmienne podejście ze względu na ograniczony zbiór danych uczących. Rozpoznawanie stanu technicznego turbozespołu ograniczono do określenia klas przemieszczeń podpór łożyskowych. W pracy opisano sposób identyfikowania wielomodelu stanowiącego fragment większego wielomodelu diagnostycznego.

6.1. Obiekt badań

Obiektem badań był turbogenerator o mocy 215 MW składający się z turbiny 13K215 i generatora. Schemat tego turbozespołu pokazano na rysunku 6.1. Jest to maszyna wir-

nikowa posiadająca część wysoko- (WP), średnio- (ŚP) i niskoprężną (NP) oraz generator (GEN). Wał maszyny posadowiony jest w siedmiu łożyskach (Ł1 - Ł7).



Rys. 6.1. Schemat turbogeneratorski - obiekt badań

Najczęściej występujące niesprawności maszyn wirnikowych są związane z uszkodzeniami wirnika i układów łożyskowych. Zaliczyć do nich można między innymi [12]:

- niewyrównoważenie,
- wygięcie wału,
- uszkodzenie elementów wirnika (np. łopatek),
- przycieranie wirnika o korpus (w tym przycieranie o uszczelnienia)
- itp.

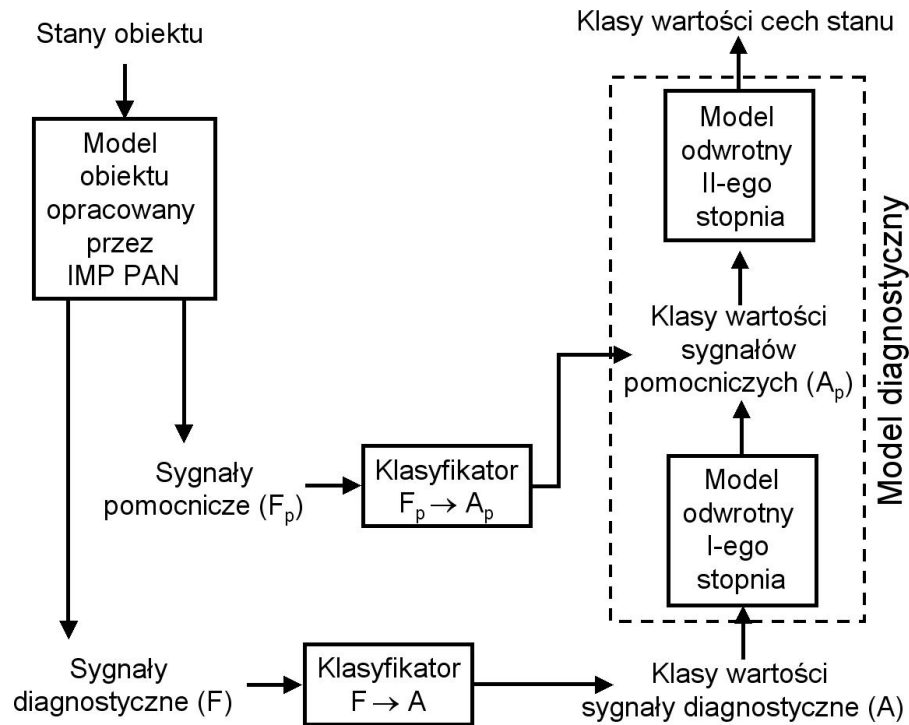
W przypadku wałów osadzonych w łożyskach hydrodynamicznych dodatkowo pojawiają się przypadki niestabilnego działania tych łożysk w wyniku drgań warstwy olejowej (wiry i bicie olejowe). Ważnym też czynnikiem warunkującym prawidłowe działanie turboszespołu jest poprawne wyosiowanie wirnika. Niewielkie przemieszczenie jednej lub kilku podpór może doprowadzić do wystąpienia szeregu groźnych niesprawności takich, jak przeciążenie, przycieranie wirnika o korpus i/lub uszczelnienia, niestabilne działanie łożysk hydrodynamicznych i in. Prawidłowe ustalenie położenia podpór łożyskowych zapewnia w trakcie działania maszyny zachowanie odpowiedniej kinetostatycznej linii wałów, co przyczynia się do stabilnego działania maszyny.

6.2. Model wielostopniowy

Koncepcja modeli wielostopniowych została zaproponowana w [19] w odniesieniu do odwrotnych modeli diagnostycznych. Ideę modelu wielostopniowego opisano już w rozdziale 4.4. Koncepcję modelu wielostopniowego, którego fragment jest opisany w tej pracy pokazano rysunku na 6.2.

Dwustopniowy model diagnostyczny został opracowany z zastosowaniem danych uczących. Dane te były wynikiem badań symulacyjnych wykonanych przez Instytut Maszyn Przepływowych Polskiej Akademii Nauk (IMP PAN) w Gdańsku. W badaniach symulacyjnych stosowany był model obiektu również opracowany przez IMP PAN. Opis tych badań zamieszczono w [60, 109, 117].

Wejściem opisywanego dwustopniowego modelu diagnostycznego były klasy wartości sygnałów diagnostycznych, a wyjściem klasy wartości cech stanu. W celu powiązania



Rys. 6.2. Koncepcja diagnostycznego modelu wielostopniowego

obydwu stopni modelu zdefiniowano dodatkową przestrzeń klas wartości sygnałów pomocniczych. Przytaczając opisaną w rozdziale 3 ideę obrazów wartości cech, można powiedzieć, że opracowywany wielomodel będzie przekształcał przestrzeń obrazów cech sygnałów diagnostycznych w przestrzeń obrazów cech stanu. Przekształcenie będzie prowadzone dwuetapowo:

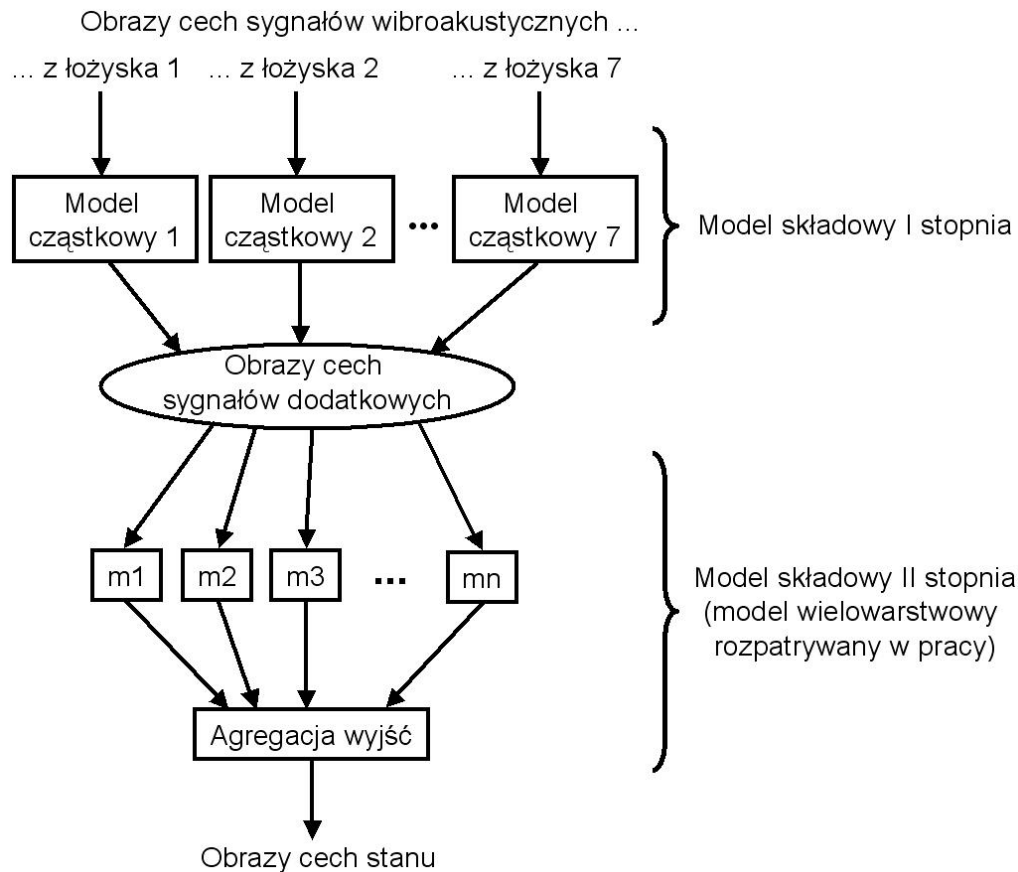
- Model I stopnia - przekształcający przestrzeń obrazów cech sygnałów diagnostycznych w przestrzeń obrazów cech sygnałów dodatkowych;
- Model II stopnia - przekształcający przestrzeń obrazów cech sygnałów dodatkowych w przestrzeń obrazów cech stanu technicznego;

Strukturę modelu wielostopniowego pokazano na rysunku 6.3.

Celem identyfikacji opisywanego modelu było rozpoznanie za jego pomocą stanu technicznego maszyny w zakresie przemieszczeń podpór łożyskowych. Poszukiwana była relacja *symptom - stan*. Jak już wcześniej napisano, rozpatrywane były przestrzenie obrazów cech. Cechami stanu były wartości przemieszczeń poszczególnych podpór w kierunku poziomym i pionowym.

Zbiór sygnałów możliwych do obserwacji obiektu jest bardzo szeroki. W przypadku maszyn wirnikowych mierzonych jest szereg parametrów procesowych (np. temperatury i ciśnienia medium roboczego, prędkość obrotowa), jak i szereg sygnałów wibroakustycznych. Systemy nadzoru maszyn wirnikowych najczęściej umożliwiają rejestracje sygnałów wibroakustycznych mierzonych na każdym łożysku w dwóch prostopadłych kierunkach. Dodatkowo, w zależności od konstrukcji turbiny mierzone mogą być:

- wartości przemieszczeń czopa wału względem panwi,



Rys. 6.3. Dwustopniowy model diagnostyczny z wyróżnionym wielomodelem (na podstawie [24])

- wartości bezwzględnych przemieszczeń panwi,
- wartości bezwzględnych przemieszczeń czopa (tylko w badaniach symulacyjnych)

Mnogość sygnałów wibroakustycznych oraz cech możliwych do oszacowania na ich podstawie powoduje, że trudno wskazać jest cechy sygnałów umożliwiające zidentyfikowanie modeli do diagnozowania przemieszczeń podpór. Oczywiście znane są metody poszukiwania cech relewantnych (por. roz. 2.2.2), jednak w rozpatrywanym przykładzie zdecydowano się na inne podejście.

Przeznaczeniem identyfikowanego modelu była klasyfikacja położenia podpór łożyskowych. Identyfikowanie klasyfikatora miało bazować na danych uczących. Niedogodnością takiego postępowania jest to, że oprócz informacji zawartej w danych uczących, nie ma możliwości uwzględnienia dodatkowej wiedzy o obiekcie przy opracowywaniu klasyfikatora. Rozwiązaniem tego problemu może być dekompozycja modelu na kilka modeli mniejszych z uwzględnieniem dodatkowych sygnałów diagnostycznych, których wartości wnoszą dodatkową informację o obiekcie. Stąd, zaproponowano do klasyfikacji położenia podpór model wielostopniowy, w którym przestrzeń sygnałów dodatkowych stanowiły klasy obciążenia łożysk [24].

Biorąc pod uwagę mechanizm powstawania drgań podczas działania maszyny można

zauważyć, że jedną z możliwych przyczyn ich występowania są siły działające w układzie. Układ sił, z kolei, można przekształcać i/lub redukować zgodnie z regułami mechaniki ogólnej. Zakładając więc, że układ sił działających na wał maszyny wirnikowej został zredukowany do układu sił, których punkty przyłożenia znajdują się w łożyskach, wówczas wał będzie w równowadze wtedy, gdy obciążenia maszyny zredukowane do łożysk będą równoważone przez reakcje podpór. Rozpatrując zagadnienie z drugiej strony można wykazać, że na wartości obciążeń poszczególnych łożysk mają między innymi wpływ przemieszczenie tych jak i sąsiednich podpór.

W pracy [133] została przedstawiona, bazująca na algorytmach ewolucyjnych, metoda identyfikowania modeli cząstkowych, które stanowiły model pierwszego stopnia modelu dwustopniowego pokazanego na rysunku 6.3. Zadaniem modeli cząstkowych było klasyfikowanie stanu obciążenia poszczególnych łożysk na podstawie cech sygnałów wibroakustycznych, będących wynikiem obserwacji poszczególnych łożysk. Modele cząstkowe są szczególną grupą modeli składowych, które nie reprezentują relacji dotyczących całego obiektu, lecz tylko wybranych łożysk.


Z uwagi na to, że łożyska w turbogeneratorze znacznie różnią się między sobą zarówno pod względem rozmiaru jak i wartości obciążeń w nich występujących zdecydowano, że wyjściem modeli cząstkowych będą stopnie przynależności obciążenia każdego z siedmiu łożysk do jednej z pięciu zdefiniowanych klas (por. rys. 6.4):

- Lq - koniec wektora obciążenia przesunięty w lewo;
- Dq - koniec wektora obciążenia przesunięty w dół;
- Pq - koniec wektora obciążenia przesunięty w prawo;
- Gq - koniec wektora obciążenia przesunięty w górę;
- Sq - nominalne obciążenia łożyska;

Stopnie przynależności obciążenia do poszczególnych klas, rozumiane jako stopnie przekonania o wystąpieniu obciążenia określonego rodzaju, pozwalają na rezygnację z uwzględniania dokładnych wartości obciążenia i rozpatrywanie ich w kategoriach podobieństwa do znanych wartości wzorcowych. Taki sposób rozpatrywania wartości cech polega na wyznaczeniu ich obrazów z punktu widzenia wartości wzorcowych (por. roz. 2.1.6). Reprezentacja cech przez ich obrazy została opisana w [18].

6.3. Model wielowarstwowy

Przedmiotem badań opisanych w niniejszej pracy był model wielowarstwowy stanowiący drugi stopień modelu wielostopniowego (rys. 6.3). W rozpatrywanym przypadku wielomodel jak i wszystkie jego modele składowe były klasyfikatorami stanu maszyny w zakresie przemieszczeń podpór. W proponowanym rozwiązaniu łączenie wyjść modeli składowych bazuje na metodach agregacji z zastosowaniem podstawowych operatorów (por. rozdz. 5).



Rys. 6.4. Zdefiniowane klasy obciążenia łożysk ze względu na położenie końca wektora wypadkowego obciążenia

6.4. Modele składowe

Przeznaczeniem identyfikowanego modelu wielowarstwowego było rozpoznanie klas położenia podpór łożyskowych na podstawie klas obciążenia łożysk. Rozpatrywano pięć następujących klas położenia każdej z siedmiu podpór:

- L - podpora przesunięta w lewo;
- D - podpora przesunięta w dół;
- P - podpora przesunięta w prawo;
- G - podpora przesunięta w górę;
- S - bazowe położenie podpory.

Każdy model składowy klasyfikował położenia podpór na podstawie klas obciążenia łożysk uzyskanych z modeli cząstkowych opisanych w [133]. Podczas identyfikowania modeli składowych poczyniono dwa założenia.

W pierwszym zakładano, że na rozpoznane przemieszczenie i -tej podpory łożyskowej mają wpływ wyłącznie obciążenia łożysk od $i-2$ do $i+2$ (por. Tab. 6.1).

Drugie założenie dotyczyło modeli, które klasyfikowały położenie podpór niezależnie w kierunku poziomym i pionowym. Wyjściem każdego modelu składowego był wektor pięciu liczb określających stopień przekonania o położeniu podpory łożyskowej w każdej z pięciu zdefiniowanych klas. Były to liczby z przedziału od 0 do 1.

Podczas identyfikowania niektórych modeli składowych zadanie określenia położenia podpory rozpatrywano niezależnie w kierunku pionowym i poziomym. W takim przypadku rozpatrywane były trzy klasy dla kierunku poziomego: „przemieszczenie w lewo” - „przemieszczenie w prawo” - „brak przemieszczenia w kierunku poziomym”, i trzy

Tab. 6.1. Założenia dotyczące wpływu obciążeń na przemieszczenia podpór łożyskowych

Nr podpory łożyskowej	Numery łożysk, których obciążenia są skutkiem przemieszczenia danej podpory
1	1,2,3
2	1,2,3,4
3	1,2,3,4,5
4	2,3,4,5,6
5	3,4,5,6,7
6	4,5,6,7
7	5,6,7

dla kierunku pionowego: „przemieszczenie w dół” - „przemieszczenie w górę” - „brak przemieszczenia w kierunku pionowym”. W celu uzyskania odpowiedzi dotyczącej jednej podpory należało dokonać złożenia odpowiedzi uzyskanych dla kierunku pionowego i poziomego. Złożenia dokonywano w następujący sposób:

- przynależność do klasy L =
przynależność do klasy „przemieszczenie w lewo”
- przynależność do klasy D =
przynależność do klasy „przemieszczenie w dół”
- przynależność do klasy P =
przynależność do klasy „przemieszczenie w prawo”
- przynależność do klasy G =
przynależność do klasy „przemieszczenie w górę”
- przynależność do klasy S =
mniejsza z przynależności do klas: „brak przemieszczenia w kierunku pionowym”
i „brak przemieszczenia w kierunku poziomym”

Powyższe dwa założenia zastosowano głównie w celu uproszczenia struktury modeli.

W rozpatrywanym wielomodelu zastosowano następujące modele składowe:

- m1 - liniowy model regresyjny;
- m2 - klasyfikator neuronalny;
- m3 - model interpolacyjny identyfikowany na podstawie algorytmu W11;
- m4 - model interpolacyjny identyfikowany na podstawie algorytmu W12;
- m5 - model interpolacyjny identyfikowany na podstawie algorytmu W13;
- m6 - model interpolacyjny identyfikowany na podstawie algorytmu W14;
- m7 - klasyfikator bayesowski;
- m8 - klasyfikator FkM (*Fuzzy k-Means*);

6.4.1. Liniowy model regresyjny - (m1)

Jak już wspomniano modele cząstkowe umożliwiają wyznaczenie klasy obciążenia na podstawie wartości cech sygnałów [133]. Znając klasy obciążeń poszczególnych łożysk należy określić klasy przemieszczeń poszczególnych podpór, rozpatrywanych w tym przypadku jako cechy stanu obiektu.

Należy w tym miejscu podkreślić, że pomimo tego, że w układzie liniowo-sprężystym, jakim jest wał w rozpatrywanym obiekcie, zakłada się liniową zależność pomiędzy siłami a przemieszczeniami [39], to rozpatrywana zależność pomiędzy klasami sił i klasami przemieszczeń jest nieliniowa.

Ideą stosowania wielomodeli jest jednak dążenie do możliwie największego uproszczenia identyfikowanych modeli. W związku z tym, pierwszy model składowy bazował na analizie regresji liniowej, ze względu na prostotę tej metody.

Zależność (6.1) przedstawia superpozycję stopni przynależności do klas sił q mających wpływ na wartość stopni przynależności do klas przemieszczeń u . Współczynniki a określają wielkość wpływu poszczególnych q na wartość u .

$$u_i = a_{i1}q_1 + a_{i2}q_2 + a_{i3}q_3 + \dots a_{iN}q_N \quad (6.1)$$

Ze względu na anizotropię własności fizycznych podpór łożyskowych występującą w turbogeneratorach założono, że zadanie należy rozpatrywać niezależnie w płaszczyźnie pionowej i poziomej. Dysponując zbiorem danych uczących w postaci wartości przynależności do klas sił i przemieszczeń podpór, można wyznaczyć model przybliżony poprzez dostrojenie wartości współczynników wpływu.

Jednym z najprostszych przypadków dostrajania jest zastosowanie metody najmniejszych kwadratów przedstawionej w zależnościach (6.2) oraz (6.3).

$$u_i = a_{i1}q_1 + a_{i2}q_2 + a_{i3}q_3 + \dots a_{iN}q_N + \epsilon_i \quad (6.2)$$

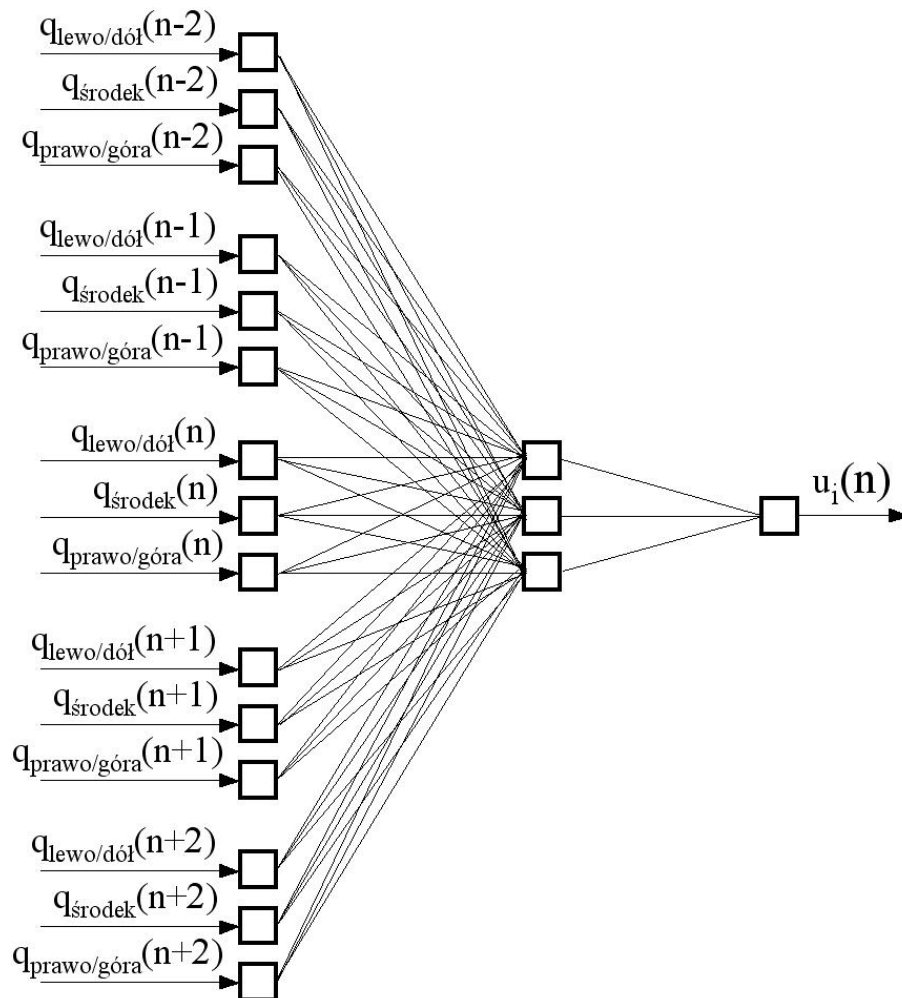
$$\sum \epsilon_i^2 \rightarrow \min \quad (6.3)$$

Współczynniki ϵ zawierają reszty modelu.

6.4.2. Sieć neuronalna - (m2)

Drugim modelem składowym był model klasyfikujący położenie podpór z zastosowaniem sieci neuronalnej. Podobnie jak w modelu identyfikowanym na podstawie metody najmniejszych kwadratów, podczas identyfikowania modelu neuronalnego również można rozpatrywać osobno zależności klas przemieszczeń i sił w kierunku pionowym i poziomym. Klasyfikator neuronalny może składać się z kilku prostych sieci, których zadaniem jest oszacowanie przynależności położenia podpory do jednej z wyróżnionych klas. Struktura tych sieci jest zależna od tego, dla którego łożyska jest identyfikowana. Zgodnie z założeniami z tabeli 6.1 na przemieszczenia łożysk 1 i 7 wpływ mają obciążenia z trzech łożysk, na przemieszczenia łożysk 2 i 6 wpływają obciążenia czterech łożysk, w

pozostałych przypadkach - pięciu łożysk. Na rysunku 6.5 pokazano strukturę sieci neuronalnej [15-3-1] do określenia przynależności położenia podpory w przypadku, gdy na to położenie wpływają obciążenia z pięciu łożysk. W przypadku łożysk 2 i 6 liczba wejść sieci wynosi 12, a w przypadku łożysk 1 i 7 liczba ta wynosi 9. Takie sieci ze względu na stosunkowo prostą strukturę mogą być trenowane algorytmem wstecznej propagacji błędów. Dla każdego łożyska identyfikowanych jest sześć takich sieci odpowiednio dla klas: *przesunięcie w lewo* - *położenie środkowe* - *przesunięcie w prawo* w kierunku poziomym oraz *przesunięcie w dół* - *położenie środkowe* - *przesunięcie w górę* w kierunku pionowym. Następnie sześć wartości określających przynależność do poszczególnych klas jest zamieniane na pięć wartości zgodnie z procedurą przedstawioną w 6.4



Rys. 6.5. Sztuczna sieć neuronalna o strukturze [15-3-1]

6.4.3. Interpolacyjne modele odwzorowań - (m3 - m6)

Kolejną grupę modeli stanowią modele interpolacyjne. W odróżnieniu od modeli aproksymacyjnych, modele interpolacyjne są rozpięte na danych a nie zastępują te dane z określoną dokładnością. Jedne z bardziej skutecznych metod identyfikowania ta-

kich modeli bazują na algorytmach wywodzących się z metod identyfikowania modeli odwrotnych [21, 22]. Algorytmy W11, W12, W13 oraz W14 bazują na poszukiwaniu powierzchni modelu w lokalnym otoczeniu rozpatrywanego punktu.

Algorytm W11

Poszukiwanie wartości stopni przynależności do klas położenia podpór w przypadku modelu interpolującego dane z zastosowaniem algorytmu W11 polega na wyznaczeniu wartości tych stopni jako średnich ważonych znanych wartości tych stopni z danych wzorcowych. Najważniejszym czynnikiem mającym wpływ na jakość modelu stosującego ten algorytm jest właściwy dobór wag. W prezentowanym przypadku jest to funkcja wagi opisana zależnością (6.4).

$$v(d(\mathbf{Q}, \mathbf{Q}_i)) = \exp(-d^2(\mathbf{Q}, \mathbf{Q}_i)) \quad (6.4)$$

gdzie:

\mathbf{Q}, \mathbf{Q}_i - wektory wartości q stopni przynależności do klas obciążenia (rozpatrywane jako punkty w wielowymiarowej przestrzeni);

$v(d(\mathbf{Q}, \mathbf{Q}_i))$ - wartość wagi i - tego znanego punktu \mathbf{Q} , dla którego poszukiwane są wartości stopnia przynależności do klasy przemieszczeń.

$d(\mathbf{Q}, \mathbf{Q}_i)$ - odległość między punktem \mathbf{Q} a znanym wektorem \mathbf{Q}_i .

Algorytm W12

Działanie algorytmu W12 polega na wyznaczeniu lokalnego modelu liniowego w najbliższym otoczeniu rozpatrywanego punktu. Model ten opisany jest zależnością (6.5).

$$\hat{u}(\mathbf{Q}) = (\mathbf{Q} - \mathbf{Q}_i) \cdot \mathbf{k} + u(\mathbf{Q}) \quad (6.5)$$

gdzie:

macierz \mathbf{k} jest macierzą opisującą model wyznaczoną z układu równań (6.6)

$$\mathbf{b} = \mathbf{K} \cdot \mathbf{k} + \delta \quad (6.6)$$

gdzie:

$$\mathbf{b} = \begin{bmatrix} u(\mathbf{Q}_1) - U(\mathbf{Q}) \\ \vdots \\ u(\mathbf{Q}_N) - U(\mathbf{Q}) \end{bmatrix} \quad (6.7)$$

$$\mathbf{K} = \begin{bmatrix} \mathbf{Q}_1 - \mathbf{Q} \\ \vdots \\ \mathbf{Q}_N - \mathbf{Q} \end{bmatrix} \quad (6.8)$$

Zadanie dostrajania modelu sprowadza się do zadania optymalizacji opisanego zależnością (6.9) przy założeniu (6.10).

$$\sum (\delta)^2 \rightarrow \min \quad (6.9)$$

$$\sum (\delta) = 0 \quad (6.10)$$

Algorytm W13

Algorytm W13 jest rozwinięciem koncepcji wyznaczania modelu interpolacyjnego zawartej w algorytmie W12. Dodatkowym elementem występującym w tym algorytmie jest funkcja oceniająca ważność danych. Jej zadaniem jest zwiększenie wpływu sąsiadów znajdujących się w bezpośrednim otoczeniu rozpatrywanego punktu. Ma to szczególne znaczenie w przypadku, gdy dane wzorcowe nie są rozmieszczone odpowiednio gęsto.

Algorytm W14

Algorytm W14 podobnie jak W13 również stanowi rozwinięcie koncepcji lokalnego modelu zawartej w W12. Modyfikacja w tym przypadku polega na wprowadzeniu nieliniowości.

Szczegółowy opis przedstawionych algorytmów zamieszczono w [21,22].

6.4.4. Sieć Bayesa - (m7)

Modele bazujące na sieciach Bayesa należą do grupy modeli probabilistycznych opisanych w 3.3.4 Koncepcja sieci przekonań bazuje na prawdopodobieństwie warunkowym Bayesa. Na rysunku 6.6 pokazano strukturę sieci Bayesa w rozpatrywanym przypadku. Wszystkie węzły są pięciostanowe. Węzły od $U1$ do $U7$ reprezentują przemieszczenia podpór, których stany reprezentują klasy tych przemieszczeń. Węzły od $Q1$ do $Q7$ reprezentują obciążenia łożysk, które również są podzielone na pięć klas. Gałęzie sieci biegną od węzłów U do Q , co odzwierciedla modelowaną relację przyczynowo-skutkową. Wnioskowanie o przemieszczeniach podpór odbywa się w drugą stronę tj. poprzez ustalenie stanów węzłów U na podstawie znanych stanów węzłów Q . Prawdopodobieństwa warunkowe zostały wyznaczone w wyniku trenowania sieci na podstawie danych uczących.


6.4.5. Klasyfikator FkM - (m8)

Klasyfikator FkM (*Fuzzy k-Means*) jest modelem bazującym na metodzie grupowania stosującej zbiory rozmyte. Algorytm *Fuzzy k-Means* jest algorytmem optymalizacji podziału zbioru N elementów na k grup rozmytych. Zadanie optymalizacji sprowadza się do minimalizacji funkcji celu w postaci (6.11) [52].

$$\sum_{j=1}^N \sum_{i=1}^K (\mu_{ij})^m \cdot d^2(x_j, V_i) \rightarrow \min \quad (6.11)$$

gdzie:

x_j - j -ty element zbioru X ,



Rys. 6.6. Struktura sieci Bayesa

X - zbiór punktów, których kolejne współrzędne określają przynależność do rozpatrywanych klas obciążenia.

V_i - reprezentant i -tej grupy,

μ_{ij} - oznacza wartość przynależności j -tego elementu zbioru X do i -tej grupy V .

$d(i)$ - jest miarą odległości j -tego elementu zbioru X do środka i -tej grupy V .

m - jest miarą rozmytości i powinien spełniać warunek $m > 1$. Najczęściej wynosi on 2.

Procedurę optymalizacji tego podziału można przedstawić w następujących etapach:

- Etap I - wybór prototypów środków grup;
- Etap II - wyznaczenie przynależności elementów dzielonego zbioru do wszystkich podzbiorów (grup);
- Etap III - wyznaczenie nowych środków grup;
- Etap IV - jeżeli żaden ze środków grup nie zmienił położenia to rozwiązanie jest optymalne. Jeżeli chociaż jeden środek zmienił położenie to powrót do etapu II.

Wartości przynależności w etapie II wyznaczane są z zależności (6.12).

$$\mu_{ij} = \frac{[\frac{1}{d^2(X_j, V_i)}]^{1/(m-1)}}{\sum_{k=1}^K [\frac{1}{d^2(X_j, V_k)}]^{1/(m-1)}} \quad (6.12)$$

Wyznaczenie nowych środków grup bazuje na średniej ważonej zdefiniowanej w zależności (6.13).

$$\hat{V}_i = \frac{\sum_{j=1}^N (\mu_{ij})^m \cdot X_j}{\sum_{j=1}^N (\mu_{ij})^m} \quad (6.13)$$

Procedura poszukiwania środków grup jest iteracyjna a kryterium jej zakończenia może być osiągnięcie w kolejnych iteracjach zmian wartości przynależności mniejszej od zadanego progu. Wynikiem iteracyjnego procesu poszukiwania kolejnych położzeń środków grup jest otrzymany podział optymalny, w którym reprezentantami grup są właśnie znalezione środki. Reprezentacja grup wraz z kryterium klasyfikacji rozmytej zdefiniowanym w zależności (6.12) stanowi klasyfikator FKM. W rozpatrywanym przypadku wybrano do identyfikowania modelu odległość euklidesową.

6.5. Wyznaczenie wyjścia wielomodelu

Wyjściami wszystkich modeli opisanych w poprzednim rozdziale są wektory wartości przynależności położenia podpór łożyskowych turbogenerators do wyróżnionych klas. Wektory uzyskane z zastosowaniem poszczególnych modeli stanowią rozmytą klasę stanu obiektu w zakresie przemieszczenia podpór. Stosując analogię do grupy ekspertów, przytoczoną w rozdziale 5 można stwierdzić, że jeden wspomniany wektor jest opinią eksperta (modelu) dotyczącą bieżącego stanu maszyny w ustalonym zakresie. Zastosowane różne metody identyfikowania modeli składowych mogą w różny sposób odzwierciedlać relacje pomiędzy klasami obciążeń a klasami przemieszczeń podpór. Oznacza to, że na podstawie różnych modeli można wysnuć różne wnioski o położeniu podpory. W celu wyznaczenia jednego wspólnego wyjścia wielomodelu zaproponowano metodę polegającą na agregacji wyjść modeli składowych bazującą na operatorze OWA opisanym w rozdziale 5.2.2.


Głównym problemem podczas definiowania operatora jest sposób określenia wag wyjść modeli składowych. W badaniach opisanych w niniejszej rozprawie stosowano dwa sposoby zdefiniowania wag.

6.5.1. Metoda I - wagi stałe

Jednym ze sposobów zdefiniowania wag modeli składowych jest przypisanie stałych ich wartości poszczególnym modelom. Podstawą określenia wartości poszczególnych wag mogą być na przykład wyniki badań weryfikacyjnych. Na podstawie oceny uzyskanych wyników klasyfikacji położenia podpór, można określić wartości wag rozpatrywanego modelu składowego na przykład w zależności od numeru podpory. W przypadku turbo-generatora posiadającego siedem łożysk wagi modeli składowych były wektorami siedmiu liczb.

6.5.2. Metoda II - wagi zmienne

W drugiej metodzie wagi były wyznaczane indywidualnie dla każdego rozpatrywanego przypadku na podstawie funkcji wagowej, pokazanej na rysunku 6.7 i zdefiniowanej w zależności (6.14).



Rys. 6.7. Funkcja wagi

$$w_{ij} = \exp \left[-\frac{(u_{ij} - \bar{u}_j)^2}{(\max(u_{ij}) - \min(u_{ij}))^2} \right] \quad (6.14)$$

gdzie:

w_{ij} - waga i -tego modelu składowego podczas wyznaczania wartości przynależności położenia podpory do j -tej klasy,

u_{ij} - wartość przynależności położenia podpory do j -tej klasy uzyskana na podstawie i -tego modelu składowego,

\bar{u}_j - wartość agregowana wyznaczana na podstawie (5.14).

Zdefiniowane w zależności (6.14) wartości wag uzależnione są od odległości wartości u_{ij} od wartości średniej, która w opisywanym przypadku jest poszukiwaną, nieznaną wartością wyjściową wielomodelu. W związku z tym, nie jest możliwe oddzielne wyznaczenie wartości wag, a następnie na ich podstawie wyznaczenie wyjścia wielomodelu. Zarówno wagi jak i poszukiwana wartość średnia muszą być wyznaczone jednocześnie. Dlatego w opisywanych badaniach zastosowano algorytm iteracyjny do wyznaczenia wyjścia wielomodelu. Algorytm poszukiwał rozwiązania następującej zależności:

$$\bar{u}_j - \frac{\sum_{i=1}^N u_{ij} w_{ij}}{\sum_{i=1}^N w_{ij}} = 0 \quad (6.15)$$

Rozdział 7

Badania weryfikacyjne

Metoda identyfikacji wielomodelu przedstawiona w rozdziale 6 została zweryfikowana w badaniach doświadczalnych. Zastosowane dane uczące pochodziły z badań symulacyjnych turbogenerators o mocy 215MW. Nieliniowy model numeryczny jak i eksperymenty symulacyjne zostały wykonane przez zespół profesora Jana Kicińskiego z Instytutu Maszyn Przepływowych (IMP) Polskiej Akademii Nauk (PAN) w Gdańsku i zostały udostępnione do badań Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej.

W badaniach prowadzonych w IMP PAN symulowano działanie obiektu będącego w następujących stanach technicznych [3, 79, 109, 117]:

- stan bez niesprawności (tzw. przypadek bazowy);
- przemieszczenia pojedynczych podpór łożyskowych;
- przemieszczenia równoczesne dwóch podpór (różne kombinacje przemieszczeń podpór łożysk 5 i 6);
- przekoszenia panwi względem czopa;
- pęknięcie wału.

Podczas prowadzonych symulacji rejestrowano trzy rodzaje sygnałów przemieszczeń:

- przemieszczenia czopa względem panwi;
- przemieszczenia bezwzględne panwi;
- przemieszczenia bezwzględne czopa.

Wyznaczono również wartości reakcji podpór we wszystkich siedmiu łożyskach.

7.1. Dane uczące

W badaniach opisanych w niniejszej pracy zastosowano dane uczące zawierające wyniki symulacji działania turbogenerators bez niesprawności oraz działania turbogenerators z przemieszczonymi podporami łożyskowymi. Zgodnie z opisem zamieszczonym w rozdziale 6.2 wielomodel, będący przedmiotem badań, stanowi część modelu wielostopniowego. W pracy [133] przedstawiono metodę identyfikowania modeli cząstkowych, umożliwiającą klasyfikację stanu obciążenia łożyska na podstawie wybranych cech sygnałów wibroakustycznych. Wynik klasyfikacji obciążenia łożysk był zbiorem rozmytym,

którego wartości funkcji przynależności określały stopień przekonania o wystąpieniu obciążenia z określonej klasy. Klasy przemieszczenia jak i obciążenia podpór zostały opisane w rozdziałach 6.2 oraz 6.4 Rozmyte klasy obciążenia i położenia podpór stanowiły dane uczące do identyfikacji wielomodelu diagnostycznego.

Spośród wszystkich przypadków rozpatrywanych w badaniach symulacyjnych prowadzonych przez IMP PAN do identyfikowania wielomodelu wybranych zostało 89 przypadków, w których wprowadzona niesprawność polegała na przemieszczeniu jednej lub dwóch podpór.

Dane te zawierały:

- przypadek bazowy;
- 28 przypadków przemieszczeń pojedynczych podpór na maksymalną dopuszczalną odległość w czterech kierunkach (przemieszczenia duże) - 7 łożysk · 4 kierunki;
- 28 przypadków przemieszczeń pojedynczych podpór, w których przemieszczenie podpory wynosiło około jednej trzeciej dopuszczalnej maksymalnej wartości przemieszczenia (przemieszczenia małe) - 7 łożysk · 4 kierunki;
- 32 przypadki równoczesnego przemieszczenia dwóch podpór (kombinacje przemieszczeń łożysk 5 i 6).

Szczegółowe informacje dotyczące przeprowadzonych eksperymentów symulacyjnych i sposobu generowania danych przedstawiono w [109] dla przypadku bazowego oraz w [117] dla przykładów przemieszczeń jednej i dwóch podpór. Każdy z powyższych stanów technicznych badany był tylko jeden raz, co oznacza, że zbiór danych uczących w opisywanych badaniach zawierał 89 przykładów.

Przykłady uczące zawierały dwa wektory liczb. Pierwszy, zawierał wartości stopni przynależności obciążenia poszczególnych łożysk do zdefiniowanych w rozdziale 6 pięciu klas. Wartości te zostały uzyskane na podstawie modeli cząstkowych opisanych w [133]. Drugi wektor zawierał wartości przynależności położenia podpór do zdefiniowanych klas. Wszystkie wartości przynależności w tym wektorze wynosiły 0 lub 1. Wartość 1 była przypisana tym klasom położenia podpory, w których znajdowała się ona podczas badań symulacyjnych wykonanych przez IMP PAN.

7.2. Testowanie modeli składowych

Przedstawione w rozdziale 6.4 modele zostały zweryfikowane pod kątem prawidłowej klasyfikacji przemieszczeń podpór. Wyniki testów były podstawą przy wyborze modeli do wielomodelu. Na potrzeby testów zbiór danych uczących został podzielony na dwa podzbiory:

- zbiór danych trenujących - zawierający 28 przykładów przemieszczeń dużych, 28 przemieszczeń małych i przypadek bazowy (razem 57 przykładów). Zbiór ten był też zbiorem testowym w przypadku 1 (TEST 1);
- zbiór danych testujących - zawierający 32 przykłady równoczesnych przemieszczeń podpór 5 i 6.

Ze względu na małą liczbę przykładów uczących zrezygnowano z większej liczby testów ze zmianą zbiorów trenujących i testujących. Spowodowane było to faktem, iż w zbiorze danych trenujących występują co najwyżej dwa przykłady określonego stanu technicznego, lecz w dwóch różnych stopniach zaawansowania. W przypadku testowania modeli na przykład metodą *leave-one-out* usunięcie jednego z tych przypadków ze zbioru danych trenujących mogłoby spowodować, że model mógłby źle identyfikować te stany, gdyż w zbiorze danych trenujących byłoby zbyt mało przykładów stanów podobnych do tego wybranego. Należy zwrócić uwagę, że przykłady ze zbioru testującego pochodzą z badań symulacyjnych z zastosowaniem modelu obiektu będącego w złożonym stanie technicznym, który wynika ze złożenia dwóch stanów elementarnych (przemieszczenia dwóch podpór).

Wyniki były weryfikowane subiektywnie. Ocena polegała na sprawdzeniu do jakiego wniosku można dojść obserwując wyznaczone wartości przynależności położenia podpór do zdefiniowanych klas. W tym celu opracowany został graficzny sposób prezentacji wyników pokazany na rysunku 7.1. W trakcie oceny rozpatrywane były trzy rodzaje błędów:

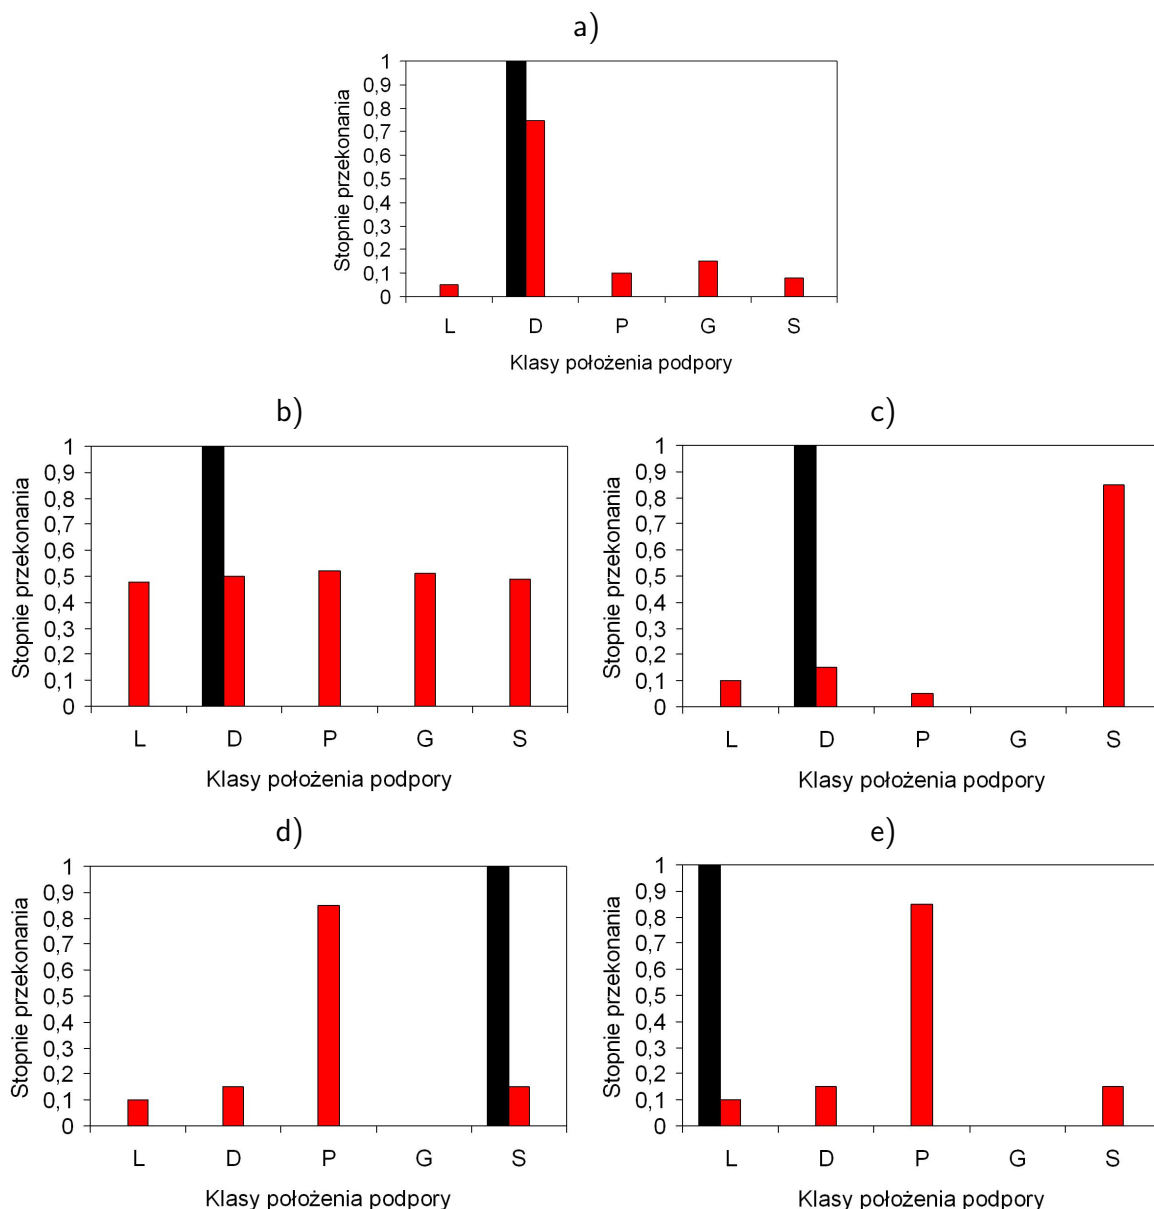
- błąd rodzaju I - niewykrycie zaistniałego przemieszczenia podpory (rys. 7.1c);
- błąd rodzaju II - wykrycie nieistniejącego przemieszczenia podpory (rys. 7.1d);
- błąd rodzaju III - wykrycie istniejącego przemieszczenia podpory, ale w niewłaściwym kierunku (rys. 7.1e).

Błędy te można utożsamiać z dwoma zadaniami jakie są stawiane systemom diagnozującym. Pierwszym zadaniem jest wykrywanie niesprawności (błąd rodzaju I). W przypadku, gdy określony model ma być zastosowany w systemie diagnozującym, ważne jest również, żeby system nie zgłaszał fałszywych alarmów. Stąd, podjęta w pracy ocena błędów rodzaju II. Bardzo istotna jest też prawidłowa klasyfikacja stanu, czyli w rozpatrywanym zadaniu właściwe rozpoznanie kierunku, w którym nastąpiło przemieszczenie podpory. Określenie błędów rodzaju III pozwala na ocenę skuteczności wykrywania tych kierunków.

Należy zwrócić uwagę, że koszty rozpatrywanych błędów są różne. Najbardziej kosztownym błędem jest błąd I rodzaju, gdyż niewykrycie przemieszczenia podpory może doprowadzić do poważnego uszkodzenia a nawet zniszczenia maszyny. Błędy II rodzaju pociągają za sobą koszty fałszywych alarmów. Są to przede wszystkim koszty ekonomiczne wynikające z nieuzasadnionego wyłączenia maszyny. Najmniej „szkodliwe” jest wystąpienie błędów III rodzaju, ponieważ sam fakt wykrycia przemieszczenia którejś podpory skutkuje wyłączeniem maszyny i rozpoczęciem badań mających na celu dokładne rozpoznanie stanu, co może przyczynić się do wykrycia tego błędu i odpowiedniego skorygowania kierunku przemieszczenia podpory.

W dalszych rozważaniach zamiast błędów klasyfikacji przedstawiona jest skuteczność klasyfikacji. Skuteczność klasyfikacji wyznaczano odejmując od 100 % udziały błędów poszczególnych rodzajów również wyrażone w procentach.

Pierwszym czynnikiem jaki był rozpatrywany podczas oceny modeli była ich selektywność, czyli zdolność rozróżniania rozpatrywanych stanów. Selektywność wyjścia modelu rozumiana jest jako maksymalna różnica wartości stopni przekonania o położeniu podpory. Na rysunku 7.1 przedstawiono przykład wyjścia modelu o odpowiedniej (rys. 7.1a) i nieodpowiedniej (rys. 7.1b) selektywności. Nietrudno zauważyć, że w przypadku przedstawionym na rysunku 7.1a model dość jednoznacznie i poprawnie sklasyfikował położenie podpory. W przypadku przedstawionym na rysunku 7.1b trudno jest stwierdzić, w której klasie położenia znajduje się podpora.



Rys. 7.1. Przykłady odpowiedzi modeli - poprawnej (a), o nieodpowiedniej selektywności (b), błąd I-ego rodzaju (c), błąd II-ego rodzaju (d) oraz błąd III-ego rodzaju (e) - wartości oczekiwane oznaczono kolorem czarnym, oszacowane na podstawie modelu kolorem szarym

Modele były testowane w trzech testach:

- TEST 1 - zbiór danych trenujących był zarazem zbiorem testowym (56 przypadków przemieszczenia jednej podpory i stan bazowy);
- TEST 2 - zbiorem trenującym było 56 przypadków przemieszczenia pojedynczych podpór i stan bazowy, a zbiorem testowym były 32 przypadki równoczesnego przemieszczenia dwóch podpór. Wyjście wielomodelu wyznaczano na podstawie metody II - wagi zmienne (por. rozdz. 6.5);
- TEST 3 - zbiory trenujący i testowy były takie same jak w teście drugim. Wyjście wielomodelu wyznaczano na podstawie metody I - wagi stałe (por. rozdz. 6.5).

W teście pierwszym oceniano stopień dopasowania modeli do danych trenujących. Test ten mógł być stosowany w przypadku modeli: liniowego (m1), neuronalnego (m2), sieci Bayesa (m7) oraz klasyfikatora FkM (m8). W przypadku modeli interpolacyjnych (m3-m6) wyniki wskazywały na idealne dopasowanie do danych. Wynikało to z faktu, że w przypadku tych modeli zbiór danych trenujących jest zarazem zbiorem danych wzorcowych, które są integralną częścią tych modeli. Ze względu na to, że model jest rozpięty na tych danych wzorcowych, błąd interpolacji w ich przypadku wynosi 0. Z tego też powodu modele te nie były w tym teście oceniane.

W teście tym oceniano dopasowanie modeli do danych uczących w tzw. wariancie optymistycznym. Negatywny wynik tego testu miał oznaczać, że model nie nadaje się do klasyfikacji położenia podpór na podstawie dostępnych danych i w efekcie nie powinien być brany pod uwagę w dalszych testach wielomodelu.

W przypadku testu drugiego i trzeciego sprawdzano, jak modele identyfikowane na podstawie danych trenujących obejmujących przykłady stanów z przemieszczeniami pojedynczych podpór będą klasyfikowały stany złożone, występujące jako równoczesne przemieszczenie dwóch podpór. Ze względu na dostępne dane uczące, test ten pozwalał na weryfikację błędów I i III rodzaju dla podpór 5 i 6 oraz II rodzaju dla pozostałych podpór.

Wagi występujące w modelu statycznym w teście trzecim zostały wyznaczone doświadczalnie. Dla każdego z modeli przeprowadzono dwa dodatkowe testy, w których zbiór zawierający przypadki przemieszczeń pojedynczych podpór i stan bazowy podzielono w następujący sposób:

- przypadek A - przemieszczenia małe i stan bazowy stanowiły dane trenujące, a przemieszczenia duże dane testujące;
- przypadek B - przemieszczenia duże i stan bazowy stanowiły dane trenujące, a przemieszczenia małe dane testujące;

W każdym z tych testów dla każdego łożyska osobno sprawdzono udziały błędów I i II rodzaju. Następnie wyniki z obydwu przypadków uśredniono odpowiednio dla każdego łożyska. Na ich podstawie wyznaczono wartości skuteczności klasyfikacji, które w tym przypadku pełniły rolę wag rozpatrywanego modelu, podczas agregacji wyjść modeli składowych. Wartości te zestawiono w tabeli 7.12

7.2.1. Wyniki testów - TEST 1

W teście pierwszym oceniano stopień dopasowania modeli do danych trenujących. Ocenie poddano wszystkie modele z wyjątkiem interpolacyjnych modeli odwzorowań.

W wyniku przeprowadzonych badań stwierdzono, że model liniowy (m1) we wszystkich testach i dla wszystkich łożysk wykazuje bardzo małą selektywność. Nie można było na podstawie wyjścia tego modelu określić położenia podpór, gdyż wszystkie stopnie przekonania dla danego łożyska były w przybliżeniu równe. Model ten został w związku z tym wyłączony z dalszych rozważań.

Wyniki testowania sieci neuronalnej (m2) wskazywały na 100% skuteczności klasyfikacji przemieszczeń podpór wszystkich łożysk. Jak już wspomniano wcześniej, modele od (m3) do (m6) nie były badane w tym teście.

Wyniki testowania modelu 7 (sieć Bayesa) przedstawiono w tabeli 7.1. Model ten wykazuje 100 % skuteczności klasyfikacji w przypadku błędów rodzaju II i III. Nieco gorsze wyniki uzyskano dla błędów I-ego rodzaju. Model ten charakteryzuje się mniejszą wrażliwością na przemieszczenia podpór (szczególnie łożyska 6). Jeżeli jednak już wyniki wskazują na przemieszczenie to można ze 100 % pewnością stwierdzić, że takie przemieszczenie naprawdę istnieje i jest w tym kierunku, który wynika z uzyskanych wartości przynależności.

Tab. 7.1. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (sieć Bayesa - TEST 1)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	100,00	100,00	100,00
2	87,50	100,00	100,00
3	62,50	100,00	100,00
4	75,00	100,00	100,00
5	37,50	100,00	100,00
6	12,50	100,00	100,00
7	50,00	100,00	100,00

Kolejnym modelem był klasyfikator FkM (m8). Wyniki jego testów przedstawiono w tabeli 7.2. Wyniki uzyskane w przypadku tego modelu są znacznie lepsze od wyników uzyskanych na podstawie sieci Bayesa, w szczególności pod względem wykrywania przemieszczeń podpór. Jednak w przypadku łożysk 3, 4, 5 pewność tego, że podpora jest faktycznie przemieszczona jest bardzo mała. Nie lepiej jest w przypadku łożysk 6 oraz 7. Dobrze natomiast klasyfikowany jest kierunek wystąpienia przemieszczeń.

Tab. 7.2. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (klasyfikator FkM - TEST 1)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	100,00	67,35	87,50
2	100,00	44,90	100,00
3	100,00	14,29	100,00
4	100,00	12,24	100,00
5	75,00	22,45	100,00
6	87,50	36,73	100,00
7	87,50	38,78	85,71

7.2.2. Wyniki testów - TEST 2

Test drugi został przeprowadzony celem sprawdzenia na ile skuteczne są modele trenowane na przykładach prostych niesprawności wtedy, gdy stosowane są do rozpoznawania stanów złożonych. Dane testowe zawierały różne kombinacje przemieszczeń podpór łożyskowych 5 i 6. Dlatego w testach nie oceniano błędów II-ego rodzaju dla tych łożysk, gdyż podpory te zawsze były przesunięte oraz błędów I-ego i III-ego rodzaju dla pozostałych łożysk, gdyż te łożyska w każdym teście były w położeniu bazowym. Wyniki testu drugiego przedstawiono w załączniku A, natomiast zestawienie skuteczności klasyfikacji dla poszczególnych modeli w tabelach 7.3 - 7.9.

Zadowolające wyniki uzyskano w przypadku sieci neuronalnej w rozpoznawaniu stanu bazowego łożysk 1 - 4 (tab. 7.3). Gorsze wyniki uzyskane dla łożyska 7 mogą być spowodowane położeniem tego łożyska na końcu wału za generatorem. Zadowolająca jest również skuteczność sieci przy klasyfikowaniu kierunku przemieszczenia, jednak wykrywanie przemieszczeń jest na niższym poziomie. Porównując wartości skuteczności klasyfikacji w przypadku błędów rodzaju I z wynikami innych modeli zawartymi w tabelach 7.4 - 7.8 można zauważyć, że sieć neuronalna nie odbiega zbytnio od pozostałych modeli. Porównując udziały błędów I rodzaju dla podpór 5 i 6 rozpatrywanych osobno można zauważyć, że skuteczność klasyfikacji tych podpór jest przeciętna. Jeżeli rozpatrywane będzie wystąpienie przemieszczenia na 5 lub 6 podporze to wynik jest znacznie lepszy. Podobnie w przypadku pozostałych modeli, łączne rozpatrywanie podpór 5 i 6 daje znacznie lepsze wyniki, gdyż w dużej liczbie testów położenie jednego z łożysk jest klasyfikowane prawidłowo. Może to być spowodowane tym, że łożyska 5 i 6 sąsiadują ze sobą i duże przesunięcie jednego z nich przy równoczesnym niewielkim przesunięciu drugiego, może spowodować, że to niewielkie przesunięcie będzie nierozpoznawalne.

Wyniki testowania modelu interpolacyjnego bazującego na algorytmie W11 przed-

Tab. 7.3. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (sieć neuronalna - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	96,88	-
2	-	84,38	-
3	-	87,50	-
4	-	78,13	-
5	40,63	-	84,62
6	62,50	-	75,00
7	-	53,13	-
5 lub 6	78,57	-	86,36

stawione w tabeli 7.4 wskazują na lepsze wykrywanie stanu bazowego podpór 1 - 4 a szczególnie łożyska 7 w porównaniu z siecią neuronalną. Lepsza jest również skuteczność rozpoznawania kierunku przemieszczeń łożysk 5 i 6, jednak wyniki wykrywania przemieszczeń są gorsze.

Tab. 7.4. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (model interpolacyjny (W11) - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	100,00	-
2	-	100,00	-
3	-	100,00	-
4	-	96,88	-
5	25,00	-	100,00
6	37,50	-	75,00
7	-	87,50	-
5 lub 6	60,71	-	82,35

Model interpolacyjny bazujący na algorytmie W12 również może być stosowany do klasyfikowania położenia podpór 1-4 oraz 7 (tab. 7.5). Dobre wyniki uzyskano też w przypadku identyfikowania kierunku przemieszczeń podpór 5 i 6, a wyniki wykrywania tych

przemieszczeń są lepsze niż w przy zastosowaniu modelu m3. Reasumując, ze względu na skuteczności rozpoznawania stanu technicznego turbogeneratora, model ten można umieścić pomiędzy modelami m2 i m3.

Tab. 7.5. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (model interpolacyjny (W12) - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	96,88	-
2	-	96,88	-
3	-	96,88	-
4	-	96,88	-
5	34,38	-	90,91
6	53,13	-	64,71
7	-	75,00	-
5 lub 6	75,00	-	80,95

Wyniki interpolacyjnego modelu stosującego algorytm W13 przedstawiono w tabeli 7.6. Model ten stanowi modyfikację modelu m4 polegającą na wprowadzeniu oceny ważności danych będących w najbliższym otoczeniu rozpatrywanego punktu. Wyniki uzyskane dla łożysk 1 - 6 są identyczne lub nieznacznie gorsze w porównaniu do wyników uzyskanych z zastosowaniem modelu m4. Duża natomiast różnica na niekorzyść modelu m5 wystąpiła dla łożyska 7.

Model 6 również jest modyfikacją modelu stosującego algorytm W12. Wyniki testowania tego modelu przedstawiono w tabeli 7.7. Wyniki klasyfikacji łożysk 1,3,4 oraz 7 są nieznacznie gorsze niż w poprzednich przypadkach. Znacznej poprawie jednak uległo wykrywanie przemieszczeń, które w przypadku łożyska 6 są na zadowalającym poziomie. Nieco gorzej model ten sprawdza się w przypadku klasyfikacji kierunku przemieszczeń.

Sieć Bayesa jest jakościowo zupełnie innym modelem niż poprzednio opisane, gdyż jest to model probabilistyczny. W związku z tym, jego identyfikowanie nie polega na poszukiwaniu odwzorowania przestrzeni klas obciążeń w przestrzeń klas przemieszczeń podpór tylko na ocenie prawdopodobieństwa wystąpienia określonych stanów podpór. Wyniki testowania tego modelu przedstawiono w tabeli 7.8. Wyniki rozpoznawania położenia bazowych podpór 1 - 4 oraz 7 są znacznie lepsze w porównaniu z pozostałymi modelami. Jednak wykrywanie przemieszczeń podpór 5 a zwłaszcza 6 jest na dość niskim poziomie.

Klasyfikator FkM jest jedynym modelem, zastosowanie którego powoduje wzorowe wykrywanie przemieszczeń podpór 5 oraz 6 (tab. 7.9). Okupione jest to jednak zupełnym brakiem skuteczności przy określaniu położenia podpór sąsiednich do 5 i 6 tj. łożysk 3,4

Tab. 7.6. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (model interpolacyjny (W13) - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	96,88	-
2	-	96,88	-
3	-	87,50	-
4	-	93,75	-
5	34,38	-	90,91
6	46,88	-	80,00
7	-	43,75	-
5 lub 6	71,43	-	80,00

Tab. 7.7. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (model interpolacyjny (W14) - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	50,00	-
2	-	93,75	-
3	-	71,88	-
4	-	56,25	-
5	53,13	-	76,47
6	78,13	-	56,00
7	-	50,00	-
5 lub 6	82,14	-	82,61

oraz 7. Sytuacja jest nieco lepsza w przypadku łożyska 2, a w przypadku łożyska 1 można stwierdzić, że wynik jest zadowalający.

7.3. Wyniki testowania wielomodelu

Wyniki uzyskane na podstawie wielomodelu zostały przedstawione w tabelach 7.10 w przypadku testu pierwszego, w 7.11 dla testu drugiego oraz w 7.13 dla testu trzeciego.

Tab. 7.8. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (sieć Bayesa - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	96,88	-
2	-	100,00	-
3	-	100,00	-
4	-	100,00	-
5	34,38	-	72,73
6	15,63	-	80,00
7	-	93,75	-
5 lub 6	53,57	-	73,33

Tab. 7.9. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (klasyfikator FkM - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	75,00	-
2	-	34,38	-
3	-	0,00	-
4	-	0,00	-
5	100,00	-	62,50
6	100,00	-	59,38
7	-	6,25	-
5 lub 6	100,00	-	92,86

7.3.1. Wyniki testów - TEST 1

W przypadku testu pierwszego dopasowanie wielomodelu do danych uczących jest wzorowe. Dla wszystkich łożysk uzyskano 100 % skuteczność klasyfikacji. Test ten wykonano stosując dane testujące równe danym trenującym. Większą jednak rolę odgrywa test drugi, w którym dane testowe nie występowały w zbiorze trenującym i zawierały dodatkowo złożony stan techniczny.

Tab. 7.10. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (wielomodel - TEST 1)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	100,00	100,00	100,00
2	100,00	100,00	100,00
3	100,00	100,00	100,00
4	100,00	100,00	100,00
5	100,00	100,00	100,00
6	100,00	100,00	100,00
7	100,00	100,00	100,00

7.3.2. Wyniki testów - TEST 2

Porównując wyniki uzyskane na podstawie wielomodelu dla drugiego testu (tab. 7.11) z wynikami testów modeli składowych (tab. od 7.3 do 7.9) można stwierdzić, że zastosowanie wielomodelu znacznie poprawia wyniki klasyfikacji położenia podpór łożyskowych w porównaniu z modelami składowymi. W przypadku łożysk od 1 do 4, skuteczność identyfikacji stanu bazowego podpór jest bardzo wysoka. Bardzo dobry wynik uzyskano również dla łożyska 7. Wyniki uzyskane dla tego łożyska z zastosowaniem niektórych modeli składowych były znacznie gorsze. Wykrywanie kierunków przemieszczeń podpory 5 jest na zadowalającym poziomie. Wyniki uzyskane dla podpory 6 są gorsze. Wyniki wykrywania przemieszczeń tych podpór można uznać za przeciętne i znacznie gorsze na przykład od wyników uzyskanych z zastosowaniem klasyfikatora FkM. Jednak stosując klasyfikator FkM nie można było rozpoznać stanu podpór sąsiednich do wspomnianych 5 i 6.

7.3.3. Wyniki testów - TEST 3

W tabeli 7.12 pokazano wagi wielomodelu wyznaczone doświadczalnie. Wagi te zostały wyznaczone na podstawie wyników klasyfikacji uzyskanych w badaniach wstępnych. Procedura prowadzenia badań wstępnych została opisana w rozdziale 7.2. Wartości w poszczególnych kolumnach odpowiadają kolejnym modelom składowym. W wierszach przedstawiono kolejne łożyska. W przypadku modeli od (m2) do (m5) wartości uzyskane dla wszystkich łożysk zawierają się w przedziale od 0.5 do 0.8. Wagi modelu (m6) są stosunkowo niskie od 0.3 do 0.5. Bardzo wysokie wagi uzyskano dla modelu (m7) - od 0.84 do 0.96. W przypadku modelu (m8) można zauważyć duże zróżnicowanie wartości wag od 0.23 dla łożyska 2 do 0.71 dla łożyska 1.

Tab. 7.11. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (wielomodel - TEST 2)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	96,88	-
2	-	100,00	-
3	-	96,88	-
4	-	100,00	-
5	43,75	-	92,86
6	53,13	-	64,71
7	-	81,25	-
5 lub 6	78,57	-	86,36

Tab. 7.12. Wagi modeli składowych uzyskane na podstawie badań

Numer łożyska	Wagi modeli składowych						
	m2	m3	m4	m5	m6	m7	m8
1	0,768	0,696	0,768	0,679	0,500	0,964	0,714
2	0,732	0,732	0,696	0,732	0,482	0,857	0,232
3	0,554	0,643	0,554	0,607	0,625	0,857	0,446
4	0,589	0,786	0,661	0,768	0,518	0,875	0,357
5	0,554	0,750	0,732	0,786	0,339	0,857	0,464
6	0,500	0,768	0,625	0,536	0,393	0,839	0,625
7	0,429	0,786	0,768	0,643	0,446	0,911	0,482

W tabeli 7.13 pokazano wyniki testowania wielomodelu. Porównując uzyskane wyniki z wynikami z testu drugiego można zauważyć niewielkie zmiany w skuteczności klasyfikacji stanu bazowego podpór od 1 do 4 (por. tab. 7.11). Stan bazowy podpory 7 rozpoznawany jest nieznacznie lepiej. Wyniki uzyskane dla podpory 5 są identyczne. W przypadku podpory 6 nastąpił spadek skuteczności wykrywania przemieszczeń tej podpory. Wzrosła natomiast skuteczność wykrywania kierunku przemieszczenia.

Tab. 7.13. Zestawienie skuteczności klasyfikacji dla poszczególnych łożysk (wielomodel - TEST 3)

Numer łożyska	Skuteczność klasyfikacji		
	I [%]	II [%]	III [%]
1	-	96,88	-
2	-	100,00	-
3	-	100,00	-
4	-	96,88	-
5	43,75	-	92,86
6	50,00	-	81,25
7	-	84,38	-
5 lub 6	78,57	-	86,36

Rozdział 8

Podsumowanie i wnioski

8.1. Podsumowanie

W pracy przedstawiono wady i zalety wielomodeli diagnostycznych. Omówiono modele stosowane zarówno do reprezentowania zachowania obiektów technicznych, jak i modele diagnostyczne służące detekcji i klasyfikacji niesprawności. Autor wprowadził definicję wielomodeli diagnostycznych i podział tych wielomodeli ze względu na zastosowanie i sposób wyznaczania wyjścia na podstawie wyjść modeli wchodzących w ich skład. Wyróżniono modele wielowarstwowe oraz wielostopniowe. Opisano modele wieloaspektowe i sekwencyjne jako szczególne przypadki modeli wielowarstwowych. Przedstawiono również podział metod wyznaczania wyjścia wielomodelu na metody agregacji i uzgadniania wyjść modeli składowych. Omówione zostały metody agregacji z zastosowaniem operatorów podstawowych, a także metody głosowania i zaawansowane metody agregacji stosujące algorytmy i techniki sztucznej inteligencji.

Przedstawiono przykład definiowania i identyfikowania wielomodelu służącego do rozpoznawania stanu technicznego maszyny wirnikowej w zakresie klasyfikacji położenia podpór łożyskowych, na podstawie przybliżonej informacji o stanie obciążenia tych podpór. Opisano modele składowe oraz sposób agregacji wyjść modeli składowych w jedno wspólne wyjście wielomodelu z zastosowaniem operatora *OWA*. Opisano dwie metody wyznaczenia wag modeli składowych. Przedstawiono również wyniki badań weryfikacyjnych wielomodelu z zastosowaniem danych uczących, będących rezultatem badań symulacyjnych prowadzonych przez Instytut Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku. Na podstawie wyników badań weryfikacyjnych sformułowano wnioski.

8.2. Wnioski

8.2.1. Wniosek ogólny

Na podstawie wyników uzyskanych w trakcie badań wykazano słuszność postawionych tez. Stwierdzono, że zastosowanie wielomodelu diagnostycznego pozwala na uzyskanie lepszych wyników rozpoznawania stanu technicznego maszyny wirnikowej niż nie-

zależne stosowanie modeli składowych wielomodelu. Ponadto stwierdzono, że dekompozycja modelu na kilka prostszych modeli składowych wielomodelu, pozwala na ich identyfikację nawet w przypadku małej liczby danych uczących, dla której identyfikacja jednego złożonego modelu jest utrudniona

Należy zdawać sobie oczywiście sprawę z tego, że przeprowadzone badania weryfikacyjne miały ograniczony zakres, co powoduje, że podany wniosek ogólny ma z formalnego punktu widzenia również ograniczony zakres ważności.

8.2.2. Wnioski szczegółowe

- 1 Przedstawiony wielomodel był częścią modelu wielostopniowego, w którym wyodrębniono dwa stopnie połączone przez wyznaczony zbiór cech sygnałów pomocniczych. Zastosowanie takiego rozwiązania znacznie uprościło struktury modeli składowych i metody ich identyfikacji.
- 2 Wielomodel opracowany w niniejszej pracy jako układ drugiego stopnia dwustopniowego klasyfikatora stanu technicznego maszyny wirnikowej posiadał strukturę modelu wielowarstwowego. Równoległe zastosowanie kilku modeli składowych pozwoliło na poprawę wyników rozpoznawania stanu w zakresie klasyfikacji przemieszczeń podpór.
- 3 Zastosowanie klas obciążeń łożysk jako zbioru cech sygnałów pomocniczych pozwoliło na uwzględnienie wpływu stanu określonego łożyska, jak i łożysk sąsiednich. Pozwoliło również na uwzględnienie dodatkowej wiedzy o modelowanych relacjach i modelowanym obiekcie w identyfikowanym klasyfikatorze stanu.
- 4 Bardzo mała selektywność modelu liniowego (m1) przy zadowalającej jakości sieci neuronalnej (m2) wskazuje na to, że modelowana zależność klas obciążenia i klas przemieszczenia podpór ma charakter nieliniowy. Wniosek ten jest zgodny z oczekiwaniami.
- 5 Interpolacyjne modele odwzorowań bazujące na algorytmach W11-W14 pomimo tego, że należą do jednej klasy modeli, w różny sposób klasyfikują położenie podpór, co pozwala stwierdzić, że wydobywają one różną informację o stanie obiektu z danych wzorcowych.
- 6 Wyniki uzyskane na podstawie modelu (m8) wskazują na wzorowe wykrywanie dużych przemieszczeń podpór. Model ten jednak źle rozpoznaje bazowe położenie podpór 1-4. Przyczyną tego mogą być przemieszczenia podpór 5 oraz 6, czyli łożysk, które są największe i najbardziej obciążone, co powoduje, że ich stan ma dominujący wpływ na stan pozostałych, mniejszych łożysk.
- 7 Wyniki uzyskane na podstawie agregacji wyjść modeli składowych z zastosowaniem metody I wskazują na nieznacznie lepsze rozpoznawanie stanu bazowego podpory 7 w porównaniu do metody II. Równocześnie skuteczność wykrywania przemieszczenia podpory 6 jest niższa. Stany pozostałych podpór rozpoznawane są podobnie w przypadku obydwu metod agregacji.

- 8 Przeciętne wyniki klasyfikacji położenia podpór łożysk 5 i 6 rozpatrywanych osobno, mogą być spowodowane wzajemnym oddziaływaniem tych łożysk. Wskazują na to znacznie lepsze rezultaty, gdy rozpoznawane jest przemieszczenie podpory 5 lub 6.

8.3. Kierunki dalszych badań

Przedstawiona w pracy koncepcja modelowania złożonych relacji diagnostycznych z zastosowaniem wielomodelu, a także zadowalające wyniki badań weryfikacyjnych opisanego wielomodelu bazującego na powszechnie znanych algorytmach identyfikacji modeli diagnostycznych i dobrze rozpoznanych operatorach agregacji, otwierają szerokie możliwości badań nad rozwijaniem w szczególności metod agregacji i uzgadniania wyjść modeli składowych, sformalizowanych metod dekompozycji zadań modelowania złożonych relacji i analizy odporności (*ang. robustness*) metod rozpoznawania stanu bazujących na wielomodelach w porównaniu z modelami globalnymi.

Dodatek A

Wyniki testowania modeli składowych

A.1. objaśnienia

A.1.1. Oznaczenia klas położenia podpór łożyskowych

- L - podpora przesunięta w lewo
- D - podpora przesunięta w dół
- P - podpora przesunięta w prawo
- G - podpora przesunięta w górę
- S - położenie bazowe podpory

A.1.2. Identyfikatory przykładów testowych

Każdy przykład testowy udostępniony przez IMP PAN posiadał identyfikator w postaci ósmioznakowej kombinacji liter i cyfr [61]:

L N XX L N XX

gdzie:

L - litera określająca kierunek przemieszczenia łożyska zgodny z rozpatrywanymi klasami (l-lewo, d-dół, p-prawo, g-góra).

N - numer przemieszczanego łożyska.

XX - identyfikator wartości przemieszczenia. Wartość liczbowa wynikała z numeru iteracji, po której zakończono eksperyment symulacyjny (szczegółowy opis zamieszczono w [60]).

Pierwsze cztery znaki dotyczą pierwszego przemieszczanego łożyska, a drugie cztery znaki drugiego z przemieszczanych łożysk. Jeżeli pierwsze cztery znaki są zerami (**0000**), to w danym przykładzie przemieszczane było tylko jedno łożysko.

A.1.3. Interpretacja wykresów słupkowych

W każdym przypadku testowym wyniki otrzymane z zastosowaniem modelu korelowano ze znaną klasą przemieszczenia. Położenia słupków związanych ze znaną, zadaną klasą przemieszczenia (oznaczone kolorem ■) wskazują kierunek przemieszczenia rozpatrywanej podpory.

Wysokości słupków reprezentujących odpowiedzi modeli (oznaczone kolorem ■) oznaczają wartość z przedziału [0,1] stopnia przekonania o położeniu łożyska w jednej z rozpatrywanych klas.

A.2. Wyniki testowania modelu 2 - sieć neuronalna

W tabeli A.1 pokazano wyniki testowania modelu składowego (m2). Na podstawie uzyskanych wyników można stwierdzić poprawne klasyfikowanie położenia bazowego podpory 1. W przypadku łożyska 2, w trzech testach nie można wskazać klasy, w której znajduje się podpora (testy: d602l520, g502p620, l602g520). Przynależność położenia podpory do każdej klasy była rozpatrywana niezależnie od pozostałych. Wynik tych trzech testów świadczy o tym, że w rozpatrywanym łożysku zaistniała niesprawność, jednak na podstawie zdefiniowanych klas nie można jej zidentyfikować. Pozostałe wyniki uzyskane dla łożyska 2 są poprawne. Wyniki klasyfikacji położenia podpór łożyskowych 3 i 4 nie są już tak dobre jak łożysk 1 i 2. Przyczyną tego może być mniejsza odległość tych łożysk od łożysk 5 i 6, które były przemieszczone. Położenie podpory 3 jest błędnie sklasyfikowane w testach: d502l618 oraz g602p518, natomiast położenie podpory 4 w testach: d502l618, d502l620, d602p518, g602g520, g602l520 i p502l618. Położenie podpory 7, podobnie jak w przypadku podpór 3 i 4, w kilku testach zostało błędnie rozpoznane. Są to testy: d502d620, d502g620, g502d620, g602d520, l602l520.

Najsłabiej wypada klasyfikacja położenia podpór 5 i 6, czyli tych, które były przemieszczane w rozpatrywanych testach. Łączne rozpatrywanie obydwu łożysk wskazuje, że niemal w każdym przypadku przynajmniej jedna z podpór była rozpoznawana prawidłowo. Może to być spowodowane faktem, że w rozpatrywanych testach przemieszczenie jednej podpory było często znacznie większe od przemieszczenia drugiej podpory (tzw. duże i małe przemieszczenia - por. rozdz. 7.2).

Tab. A.1: Wyniki testowania modelu 2 - TEST 2

Stan	Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń						
	Łoż. 1 LDPGS	Łoż. 2 LDPGS	Łoż. 3 LDPGS	Łoż. 4 LDPGS	Łoż. 5 LDPGS	Łoż. 6 LDPGS	Łoż. 7 LDPGS
d502d620	■	■	■	■	■	■	■
d502g620	■	■	■	■	■	■	■
d502l618	■	■	■	■	■	■	■
d502p620	■	■	■	■	■	■	■
d602d520	■	■	■	■	■	■	■
d602g520	■	■	■	■	■	■	■
d602l520	■	■	■	■	■	■	■
d602p518	■	■	■	■	■	■	■
g502d620	■	■	■	■	■	■	■
g502g620	■	■	■	■	■	■	■
g502l620	■	■	■	■	■	■	■
g502p620	■	■	■	■	■	■	■
g602d520	■	■	■	■	■	■	■

Tab. A.1: Wyniki testowania modelu 2 - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
g602g520	■	■	■	■	■	■	■
g602l520	■	■	■	■	■	■	■
g602p518	■	■	■	■	■	■	■
l502d620	■	■	■	■	■	■	■
l502g620	■	■	■	■	■	■	■
l502l618	■	■	■	■	■	■	■
l502p620	■	■	■	■	■	■	■
l602d520	■	■	■	■	■	■	■
l602g520	■	■	■	■	■	■	■
l602l520	■	■	■	■	■	■	■
l602p518	■	■	■	■	■	■	■
p502d620	■	■	■	■	■	■	■
p502g620	■	■	■	■	■	■	■
p502l618	■	■	■	■	■	■	■
p502p620	■	■	■	■	■	■	■
p602d520	■	■	■	■	■	■	■
p602g520	■	■	■	■	■	■	■
p602l520	■	■	■	■	■	■	■
p602p518	■	■	■	■	■	■	■

A.3. Wyniki testowania modelu 3 - interpolacyjny model bazujący na algorytmie W11

W tabeli A.2 pokazano wyniki testowania modelu składowego (m3). Na podstawie wyników nie stwierdzono wystąpienia błędów II rodzaju w klasyfikacji położenia podpór od 1 do 4. W przypadku łożyska 7, w trzech testach (d502g620, g502d620 i g602d520) stwierdzono błędne rozpoznanie położenia bazowego podpory.

W przypadku podpór 5 i 6 wyniki należy analizować łącznie, podobnie jak to miało miejsce podczas analizy wyników testów modelu (m2). W przypadku modelu (m3) wyniki również nie są zadowalające. W dużej liczbie przypadków położenia obydwu podpór są błędnie sklasyfikowane. Są to na ogół błędy I rodzaju, co oznacza niewykrycie zaistniałego przemieszczenia. W dwóch przypadkach (g602g520 i g602l520) wyniki wskazują na przemieszczenie podpory 6, jednak kierunek tego przesunięcia jest niepoprawny.

Tab. A.2: Wyniki testowania modelu 3 - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620	■	■	■	■	■	■	■
d502g620	■	■	■	■	■	■	■
d502l618	■	■	■	■	■	■	■
d502p620	■	■	■	■	■	■	■
d602d520	■	■	■	■	■	■	■
d602g520	■	■	■	■	■	■	■
d602l520	■	■	■	■	■	■	■
d602p518	■	■	■	■	■	■	■
g502d620	■	■	■	■	■	■	■
g502g620	■	■	■	■	■	■	■
g502l620	■	■	■	■	■	■	■
g502p620	■	■	■	■	■	■	■
g602d520	■	■	■	■	■	■	■
g602g520	■	■	■	■	■	■	■
g602l520	■	■	■	■	■	■	■
g602p518	■	■	■	■	■	■	■
l502d620	■	■	■	■	■	■	■
l502g620	■	■	■	■	■	■	■
l502l618	■	■	■	■	■	■	■
l502p620	■	■	■	■	■	■	■
l602d520	■	■	■	■	■	■	■
l602g520	■	■	■	■	■	■	■
l602l520	■	■	■	■	■	■	■
l602p518	■	■	■	■	■	■	■
p502d620	■	■	■	■	■	■	■
p502g620	■	■	■	■	■	■	■
p502l618	■	■	■	■	■	■	■
p502p620	■	■	■	■	■	■	■
p602d520	■	■	■	■	■	■	■
p602g520	■	■	■	■	■	■	■
p602l520	■	■	■	■	■	■	■
p602p518	■	■	■	■	■	■	■

A.4. Wyniki testowania modelu 4 - interpolacyjny model bazujący na algorytmie W12

W tabeli A.3 pokazano wyniki testowania modelu składowego (m4). Na podstawie uzyskanych wyników nie stwierdzono błędów II rodzaju w przypadku podpór od 1 do 3. Położenie podpory 4 zostało błędnie rozpoznane w teście d502l618. W siedmiu przypadkach zostało błędnie sklasyfikowane położenie podpory 7 (testy: d502g620, d602l520, g502d620, g502l620, g602d520, l602l520 i l602p518).

Podobnie, jak w przypadku zastosowania modeli (m2) i (m3), słabo było rozpoznawane położenie podpór 5 i 6. Dominującym błędem było niewykrycie przemieszczenia (błąd I rodzaju). W jednym przypadku wykryto przemieszczenie podpory 5 w złym kierunku (l602g520). W przypadku podpory 6 sytuacja taka wystąpiła pięć razy (d602p518, g602g520, g602l520, l502d620 i p602p518).

Tab. A.3: Wyniki testowania modelu 4 - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620	■	■	■	■	■	■	■
d502g620	■	■	■	■	■	■	■
d502l618	■	■	■	■	■	■	■
d502p620	■	■	■	■	■	■	■
d602d520	■	■	■	■	■	■	■
d602g520	■	■	■	■	■	■	■
d602l520	■	■	■	■	■	■	■
d602p518	■	■	■	■	■	■	■
g502d620	■	■	■	■	■	■	■
g502g620	■	■	■	■	■	■	■
g502l620	■	■	■	■	■	■	■
g502p620	■	■	■	■	■	■	■
g602d520	■	■	■	■	■	■	■
g602g520	■	■	■	■	■	■	■
g602l520	■	■	■	■	■	■	■
g602p518	■	■	■	■	■	■	■
l502d620	■	■	■	■	■	■	■
l502g620	■	■	■	■	■	■	■
l502l618	■	■	■	■	■	■	■
l502p620	■	■	■	■	■	■	■
l602d520	■	■	■	■	■	■	■

Tab. A.3: Wyniki testowania modelu 4 - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
l602g520	■	■	■	■	■	■	■
l602l520	■	■	■	■	■	■	■
l602p518	■	■	■	■	■	■	■
p502d620	■	■	■	■	■	■	■
p502g620	■	■	■	■	■	■	■
p502l618	■	■	■	■	■	■	■
p502p620	■	■	■	■	■	■	■
p602d520	■	■	■	■	■	■	■
p602g520	■	■	■	■	■	■	■
p602l520	■	■	■	■	■	■	■
p602p518	■	■	■	■	■	■	■

A.5. Wyniki testowania modelu 5 - interpolacyjny model bazujący na algorytmie W13

W tabeli A.4 pokazano wyniki testowania modelu składowego (m5). Na podstawie uzyskanych wyników nie stwierdzono błędów II rodzaju w rozpoznawaniu położenia bazowego podpór od 1 do 3. Położenie podpory 4 błędnie sklasyfikowano w testach l602d520 i p502g620, a podporę 7 w testach d502g620, d602l520, g502d620, g502l620, g602d520, l602l520 i l602p518. Bardzo duża jest liczba testów, w których na podstawie rozpatrywanego modelu nie można stwierdzić, w której klasie znajduje się podpora 7.

W przypadkach rozpoznawania położenia podpór 5 i 6 w wielu testach nie było rozpoznawane przemieszczenie żadnej z nich. Błędy klasyfikacji położenia podpory 5 były na ogół I rodzaju z wyjątkiem testu p602g520, w który przemieszczenie rozpoznano w złym kierunku. W przypadku podpory 6, również najczęstszym błędem był błąd I rodzaju. W testach: d602p518, g502p620, g602g520 i p602p518 przemieszczenie zostało rozpoznane w złym kierunku.

Tab. A.4: Wyniki testowania modelu 5 - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620	■	■	■	■	■	■	■
d502g620	■	■	■	■	■	■	■

Tab. A.4: Wyniki testowania modelu 5 - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502l618	■	■	■	■	■	■	■
d502p620	■	■	■	■	■	■	■
d602d520	■	■	■	■	■	■	■
d602g520	■	■	■	■	■	■	■
d602l520	■	■	■	■	■	■	■
d602p518	■	■	■	■	■	■	■
g502d620	■	■	■	■	■	■	■
g502g620	■	■	■	■	■	■	■
g502l620	■	■	■	■	■	■	■
g502p620	■	■	■	■	■	■	■
g602d520	■	■	■	■	■	■	■
g602g520	■	■	■	■	■	■	■
g602l520	■	■	■	■	■	■	■
g602p518	■	■	■	■	■	■	■
l502d620	■	■	■	■	■	■	■
l502g620	■	■	■	■	■	■	■
l502l618	■	■	■	■	■	■	■
l502p620	■	■	■	■	■	■	■
l602d520	■	■	■	■	■	■	■
l602g520	■	■	■	■	■	■	■
l602l520	■	■	■	■	■	■	■
l602p518	■	■	■	■	■	■	■
p502d620	■	■	■	■	■	■	■
p502g620	■	■	■	■	■	■	■
p502l618	■	■	■	■	■	■	■
p502p620	■	■	■	■	■	■	■
p602d520	■	■	■	■	■	■	■
p602g520	■	■	■	■	■	■	■
p602l520	■	■	■	■	■	■	■
p602p518	■	■	■	■	■	■	■

A.6. Wyniki testowania modelu 6 - interpolacyjny model bazujący na algorytmie W14

W tabeli A.5 pokazano wyniki testowania modelu składowego (m6). Rozpoznanie położenia bazowego podpór od 1 do 4 i podpory 7 jest gorsze niż ma to miejsce w przypadku modeli (m2)-(m5). Położenie podpory 1 błędnie sklasyfikowano w 5 przypadkach (testy d502p620, d602p518, g502l620, l602l520 i p602p518). W przypadku podpory 2 błędy wystąpiły w testach g602l520, g602p518 i l602d520. Znaczna liczba błędów została zaobserwowana w przypadku podpór 3 (8 błędów), 4 (14 błędów) oraz 7 (14 błędów).

Rozpoznanie położenia podpór 5 i 6 można uznać za nieznacznie lepsze niż modeli (m2)-(m5). Wystąpiła mniejsza liczba przypadków, w których nie rozpoznano położenia żadnej z rozpatrywanych podpór. Pomimo lepszego rozpoznania przemieszczenia podpór 5 i 6, w wielu przypadkach kierunek przemieszczenia identyfikowany był błędnie. Błędy III rodzaju w przypadku klasyfikacji położenia podpory 5 wystąpiły w testach g502p620 i p602g520, natomiast w przypadku podpory 6 w testach: d602p518, g502d620, g602g520, g602l520, p502d620, p502g620 i p602p518.

Tab. A.5: Wyniki testowania modelu 6 - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620	■	■	■	■	■	■	■
d502g620	■	■	■	■	■	■	■
d502l618	■	■	■	■	■	■	■
d502p620	■	■	■	■	■	■	■
d602d520	■	■	■	■	■	■	■
d602g520	■	■	■	■	■	■	■
d602l520	■	■	■	■	■	■	■
d602p518	■	■	■	■	■	■	■
g502d620	■	■	■	■	■	■	■
g502g620	■	■	■	■	■	■	■
g502l620	■	■	■	■	■	■	■
g502p620	■	■	■	■	■	■	■
g602d520	■	■	■	■	■	■	■
g602g520	■	■	■	■	■	■	■
g602l520	■	■	■	■	■	■	■
g602p518	■	■	■	■	■	■	■
l502d620	■	■	■	■	■	■	■
l502g620	■	■	■	■	■	■	■

Tab. A.5: Wyniki testowania modelu 6 - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
I502I618							
I502p620							
I602d520							
I602g520							
I602I520							
I602p518							
p502d620							
p502g620							
p502I618							
p502p620							
p602d520							
p602g520							
p602I520							
p602p518							

A.7. Wyniki testowania modelu 7 - sieć Bayesa

W tabeli A.6 pokazano wyniki testowania modelu składowego (m7). Wyniki rozpoznawania położenia bazowego podpór od 1 do 4 i podpory 7 są bardzo dobre. W przypadku podpór od 2 do 4 nie stwierdzono występowania błędów II rodzaju, a w przypadku podpory 1 tylko jeden błąd w teście g602p518. Błędne rozpoznanie klasy położenia podpory 7 nastąpiło w dwóch przypadkach (testy: d502d620 i p502d620), co jest wynikiem znacznie lepszym niż wyniki uzyskane w przypadku modeli od (m2) do (m6).

Rozpoznawanie położenia podpór 5 i 6 jest jednak słabe. W większości przypadków nie są wykrywane przemieszczenia żadnej z podpór. Błędy III rodzaju wystąpiły w testach g502I620, I502I618, p502g620 i p602g520 w przypadku podpory 5 oraz w testach: g502p620, I602g520 i I602I520 w przypadku podpory 6.

Tab. A.6: Wyniki testowania modelu 7 - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620							
d502g620							

Tab. A.6: Wyniki testowania modelu 7 - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502l618							
d502p620							
d602d520							
d602g520							
d602l520							
d602p518							
g502d620							
g502g620							
g502l620							
g502p620							
g602d520							
g602g520							
g602l520							
g602p518							
l502d620							
l502g620							
l502l618							
l502p620							
l602d520							
l602g520							
l602l520							
l602p518							
p502d620							
p502g620							
p502l618							
p502p620							
p602d520							
p602g520							
p602l520							
p602p518							

A.8. Wyniki testowania modelu 8 - klasyfikator FkM

W tabeli A.7 pokazano wyniki testowania modelu składowego (m8). Na podstawie uzyskanych wyników stwierdzono bardzo słabe rozpoznawanie położenia bazowego podpór od 1 do 4 oraz podpory 7. W przypadku podpory 1 wystąpiło 8 błędów, a podpory 2 - 24 błędy. Położenia podpór 3 i 4 w żadnym teście nie zostało sklasyfikowane poprawnie, a położenie podpory 7 tylko w dwóch (testy: d602I520 i I602g520).

Bardzo dobrze wykrywane są przemieszczenia podpór 5 i 6. Błędy pierwszego rodzaju wystąpiły dla obydwu podpór tylko jeden raz (test d502d620 w przypadku podpory 5 i test d602I520 w przypadku podpory 6). W pozostałych przypadkach przemieszczenia zostały wykryte, jednak kierunki przemieszczeń były rozpoznawane znacznie gorzej (11 błędów III rodzaju w przypadku podpory 5 i 12 błędów w przypadku podpory 6).

Tab. A.7: Wyniki testowania modelu 8 - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620							
d502g620							
d502I618							
d502p620							
d602d520							
d602g520							
d602I520							
d602p518							
g502d620							
g502g620							
g502I620							
g502p620							
g602d520							
g602g520							
g602I520							
g602p518							
I502d620							
I502g620							
I502I618							
I502p620							
I602d520							
I602g520							
I602I520							

Tab. A.7: Wyniki testowania modelu 8 - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
l602p518							
p502d620							
p502g620							
p502l618							
p502p620							
p602d520							
p602g520							
p602l520							
p602p518							

Dodatek B

Wyniki testowania wielomodelu

B.1. Objasnienia

Objasnienia zawartości tabel z wynikami zamieszczono w załączniku A.

B.2. Wyniki testowania wielomodelu - TEST 1

W tabeli B.1 pokazano wyniki testowania wielomodelu uzyskane w teście pierwszym (TEST 1). Na podstawie uzyskanych wyników stwierdzono 100 % skuteczność rozpoznawania klas położenia podpór. Niektóre wartości stopni przynależności są niskie jednak wartość maksymalna zawsze przypada na klasę oczekiwaną w danym teście.

Tab. B.1: Wyniki testowania wielomodelu - TEST 1

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
0000d111	■		■	■	■	■	■
0000d120	■		■	■	■	■	■
0000d211		■	■	■	■	■	■
0000d220		■	■	■	■	■	■
0000d311		■	■	■	■	■	■
0000d320		■	■	■	■	■	■
0000d411		■	■	■	■	■	■
0000d420		■	■	■	■	■	■
0000d511		■	■	■	■	■	■
0000d520		■	■	■	■	■	■
0000d611		■	■	■	■	■	■
0000d620		■	■	■	■	■	■
0000d711		■	■	■	■	■	■
0000d720		■	■	■	■	■	■
0000g111	■		■	■	■	■	■
0000g120	■		■	■	■	■	■
0000g211		■	■	■	■	■	■
0000g220		■	■	■	■	■	■
0000g311		■	■	■	■	■	■
0000g320		■	■	■	■	■	■
0000g411		■	■	■	■	■	■
0000g420		■	■	■	■	■	■
0000g511		■	■	■	■	■	■
0000g520		■	■	■	■	■	■

Tab. B.1: Wyniki testowania wielomodelu - TEST 1 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
0000g611	■	■	■	■	■	■	■
0000g620	■	■	■	■	■	■	■
0000g711	■	■	■	■	■	■	■
0000g720	■	■	■	■	■	■	■
0000l111	■	■	■	■	■	■	■
0000l120	■	■	■	■	■	■	■
0000l211	■	■	■	■	■	■	■
0000l220	■	■	■	■	■	■	■
0000l311	■	■	■	■	■	■	■
0000l320	■	■	■	■	■	■	■
0000l411	■	■	■	■	■	■	■
0000l420	■	■	■	■	■	■	■
0000l511	■	■	■	■	■	■	■
0000l520	■	■	■	■	■	■	■
0000l611	■	■	■	■	■	■	■
0000l618	■	■	■	■	■	■	■
0000l711	■	■	■	■	■	■	■
0000l720	■	■	■	■	■	■	■
0000p111	■	■	■	■	■	■	■
0000p120	■	■	■	■	■	■	■
0000p211	■	■	■	■	■	■	■
0000p220	■	■	■	■	■	■	■
0000p311	■	■	■	■	■	■	■
0000p320	■	■	■	■	■	■	■
0000p411	■	■	■	■	■	■	■
0000p420	■	■	■	■	■	■	■
0000p511	■	■	■	■	■	■	■
0000p518	■	■	■	■	■	■	■
0000p611	■	■	■	■	■	■	■
0000p620	■	■	■	■	■	■	■
0000p711	■	■	■	■	■	■	■
0000p720	■	■	■	■	■	■	■
pbartmax	■	■	■	■	■	■	■

B.3. Wyniki testowania wielomodelu - TEST 2

W tabeli B.2 pokazano wyniki testowania wielomodelu uzyskane w teście drugim (TEST 2). Na podstawie uzyskanych wyników stwierdzono bardzo dobre rozpoznawanie położenia bazowego podpór od 1 do 4. Położenia podpór 2 i 4 zawsze były rozpoznane prawidłowo. W przypadku podpór 1 i 3 w teście g602p518 nie można było stwierdzić, w której klasie znajduje się podpora. Cztery błędy rozpoznania położenia bazowego podpory 7 również można uznać za wynik zadowalający w porównaniu z modelami składowymi (por. z załącznikiem A).

Rozpoznawanie przemieszczeń podpór 5 i 6 można uznać za wynik słaby, nieco tylko lepszy niż wyniki uzyskane na podstawie modeli składowych. W przypadku podpory 5 wystąpiło 18 błędów I rodzaju i 1 III rodzaju, natomiast w przypadku podpory 6 wystąpiło 15 błędów I rodzaju i 6 błędów III rodzaju.

Tab. B.2: Wyniki testowania wielomodelu - TEST 2

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620							
d502g620							
d502l618							
d502p620							
d602d520							
d602g520							
d602l520							
d602p518							
g502d620							
g502g620							
g502l620							
g502p620							
g602d520							
g602g520							
g602l520							
g602p518							
l502d620							
l502g620							
l502l618							
l502p620							
l602d520							
l602g520							

Tab. B.2: Wyniki testowania wielomodelu - TEST 2 (c.d.)

Oczekiwane (kolor ■) oraz oszacowane (kolor ■) klasy przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
l602l520							
l602p518							
p502d620							
p502g620							
p502l618							
p502p620							
p602d520							
p602g520							
p602l520							
p602p518							

B.4. Wyniki testowania wielomodelu - TEST 3

W tabeli B.3 pokazano wyniki testowania wielomodelu uzyskane w teście trzecim (TEST 3). Uzyskane wyniki wskazują na bardzo dobre rozpoznawanie stanu bazowego podpór od 1 do 4. W przypadku podpory 7 w testach d502g620, g502d620, g602d520, l602l520 oraz l602p518 wystąpiły błędy.

Rozpoznawanie położenia podpór 5 i 6, podobnie jak w poprzednich przypadkach, jest słabe. W przypadku podpory 5 wystąpiło 18 błędów I rodzaju i jeden III rodzaju. W przypadku podpory 6 zaobserwowano 16 błędów I rodzaju i 3 błędy III rodzaju. Należy jednak podkreślić, że niemal w każdym teście wykrywane jest przemieszczenie jednej z podpór.

Tab. B.3: Wyniki testowania wielomodelu - TEST 3

Oczekiwane ■ oraz oszacowane ■ wartości przemieszczeń							
Stan	Łoż. 1	Łoż. 2	Łoż. 3	Łoż. 4	Łoż. 5	Łoż. 6	Łoż. 7
	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS	LDPGS
d502d620							
d502g620							
d502l618							
d502p620							
d602d520							
d602g520							
d602l520							

Tab. B.3: Wyniki testowania wielomodelu - TEST 3 (c.d.)

Oczekiwane ■ oraz oszacowane ■ wartości przemieszczeń							
Stan	Łoż. 1 LDPGS	Łoż. 2 LDPGS	Łoż. 3 LDPGS	Łoż. 4 LDPGS	Łoż. 5 LDPGS	Łoż. 6 LDPGS	Łoż. 7 LDPGS
d602p518							
g502d620							
g502g620							
g502l620							
g502p620							
g602d520							
g602g520							
g602l520							
g602p518							
l502d620							
l502g620							
l502l618							
l502p620							
l602d520							
l602g520							
l602l520							
l602p518							
p502d620							
p502g620							
p502l618							
p502p620							
p602d520							
p602g520							
p602l520							
p602p518							
pbartmax							

Bibliografia

- [1] Bachschmid N., Pennacchi P., Tanzi E., Vania A.: *Cracks in rotating shafts: experimental behaviour, modelling and identification*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [2] Bachschmid N., Pennacchi P., Vania A.: *Malfunction identification in rotor systems at normal operating speed*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [3] Banaszek S.: *Pęknięcia wirnika*. Kiciński J. (red.). *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbospołach energetycznych*, rozdz. 22.3, str. 1080–1116. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [4] Barszcz T., Czop P., Uhl T.: *Nieparametryczna metoda estymacji w diagnostyce członów wykonawczych systemu sterowania turbiną*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 435–440, Władysławowo, wrzesień 2003.
- [5] Bielawski P.: *Diagnozowanie z wykorzystaniem przebiegów procesów roboczych maszyn tłokowych*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 371–376, Władysławowo, wrzesień 2003.
- [6] Boukhris A., Giuliani S., Mourot G.: *Rainfall-rainoff multi-modelling for sensor fault diagnosis*. *Control Engineering Practice*, 9(6):659–671, czerwiec 2001.
- [7] Bucher I., Shomer O.: *Active, model based diagnostics of rotating machinery*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [8] Buffa F., Marzano G., Norese M.: *MACRAME: A Modelling Methodology in Multiactor Contexts*. *Decision Support Systems*, 17:331–343, 1996.
- [9] Cameron B.: *CH46 Gearbox Rig Test Plan Contract N 000 14-92-C-0106*. Westland Helicopters Ltd., Mechanical Research Note MRN 389, styczeń 1993.
- [10] Campbell S., Horton K., Nikoukhah R.: *Auxiliary signal design for rapid multi-model identification using optimization*. *Automatica*, 38(8):1313–1325, sierpień 2002.

- [11] Carmel D., Marcovitch S.: *Pruning algorithm for multi-model adversary search*. Artificial Intelligence, 99(2):325–355, marzec 1998.
- [12] Cempel C.: *Podstawy wibroakustycznej diagnostyki maszyn*. WNT, Warszawa 1982.
- [13] Cempel C.: *Wibroakustyczna diagnostyka maszyn*. PWN, Warszawa 1989.
- [14] Chan C.-L., Chang C.-C.: *A Method Combining MAU and Fuzzy Logic for Co-operative Decision Making*. Computers in Engineering, 35:291–294, 1998.
- [15] Cholewa W.: *Metody diagnozowania maszyn z zastosowaniem zbiorów rozmytych*. Zeszyty Naukowe Politechniki Śląskiej, Mechanika z. 79, Gliwice, 1983.
- [16] Cholewa W.: *Aggregation of Fuzzy Options - An Axiomatic Approach*. Fuzzy Sets and Systems, 17:249–258, North-Holland 1985.
- [17] Cholewa W.: *Doskonalenie sieci bayesowskich dla potrzeb diagnostyki technicznej*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 363–366, Władysławowo, wrzesień 2003.
- [18] Cholewa W.: *Modele odwrotne i modelowanie diagnostyczne*. Diagnostyka, 30(1):111–114, wrzesień 2004.
- [19] Cholewa W.: *Odwrotne modele diagnostyczne*. Kiciński J. (red.). *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbozespołach energetycznych*, rozdz. 27.4, str. 1311–1314. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [20] Cholewa W., Kaźmierczak J.: *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów*. Skrypt Politechniki Śląskiej Nr 1904, Gliwice 1995.
- [21] Cholewa W., Kiciński J. (red.): *Diagnostyka techniczna. Odwrotne modele diagnostyczne*. Wydawnictwo Politechniki Śląskiej, Gliwice, 1997.
- [22] Cholewa W., Kiciński J. (red.): *Diagnostyka techniczna. Metody odwracania nieliniowych modeli obiektów*. Zeszyty Katedry Podstaw Konstrukcji Maszyn, z. 120, Gliwice, 2001.
- [23] Cholewa W., Moczulski W.: *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów*. Skrypt Politechniki Śląskiej Nr 1758, Gliwice, 1993.
- [24] Cholewa W., Urbanek G., Wojtusik J.: *Modele wielostopniowe. Przykład*. Kiciński J. (red.). *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbozespołach energetycznych*, rozdz. 27.5, str. 1314–1321. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [25] Cholewa W., White M.: *Application of neural networks for inversing of vibration models*. Zeszyty Naukowe Politechniki Śląskiej, Mechanika z. 116, Gliwice, 1994.
- [26] Ciupke K.: *Metody selekcji i redukcji informacji w diagnostyce technicznej*. Zeszyty Katedry Podstaw Konstrukcji Maszyn, z. 118, Gliwice, 2001.

- [27] Conversano C., Siciliano R., Mola F.: *Generalized additive multi-mixture model for data mining*. Computational Statistics and Data Analysis, 38(4):487–500, luty 2002.
- [28] Czop P.: *Wielomodele w diagnostyce technicznej*. II Międzynarodowy Kongres Diagnostyki Technicznej, Diagnostyka 2000, Warszawa, 2000.
- [29] Delmotte F., Dubois L., Borne P.: *A general scheme for multi-model controller using trust*. Mathematics and Computers in Simulation, 41(1-2):173–186, czerwiec 1996.
- [30] Dembski J., Jędruch W.: *Automatyczne konstruowanie ekstraktora cech sygnałów wibroakustycznych na podstawie podobnych zadań diagnostycznych*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 509–514, Władysławowo, wrzesień 2003.
- [31] Detyniecki M. *Fundamentals on Aggregation Operators*. <http://www.cd.berkeley.edu/marcin/agop.pdf>, 2001.
- [32] Djebili O., Laimeche R.: *Predictive maintaince approach for optimal operation of rotating machines*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [33] Doll C., Le Gorrec Y., Ferreres G., Magni J.: *A robust self-scheduled missile autopilot: design by multi-model eigenstructure assignment*. Control Engineering Practice, 9(10):1067–1078, październik 2001.
- [34] Druzovec M., Welzer T., Colnaric M., Gyorkos J.: *Diagnostics and a qualitative model*. International Journal of Medical Informatics, 63:51–60, 2001.
- [35] Duan J., Chung F.: *Multilevel fuzzy relation systems: structure and identification*. Soft Computing, 6:71–86, Springer-Verlag, 2002.
- [36] Dubois D., Prade H.: *Weighted minimum and maximum operators in fuzzy set theory*. Hollnagel E. (red.), The Reliability of Expert Systems, str. 64–118, Chichester, 1986. Ellis Horwood Limited.
- [37] Duvall M., Riggs J., Lee P.: *Multi-model decoupled Generic Model Control*. Control Engineering Practice, 9(5):471–481, maj 2001.
- [38] Dybała J., Radkowski S.: *Wykorzystanie sieci neuronowych w rozpoznawaniu czasowo-częstotliwościowych obrazów wczesnych faz uszkodzeń*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 503–508, Władysławowo, wrzesień 2003.
- [39] Dyląg Z., Jakubowicz A., Orłoś Z.: *Wytrzymałość materiałów, tom 1*. WNT, Warszawa, 1996.
- [40] Dzięcioł E., Szczepanowski A.: *Zastosowanie mikrofalowego czujnika ruchu w diagnozowaniu łopatek turbin*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 401–404, Łągów Lubuski, wrzesień 2001.

- [41] Dziopa P., Gentil S.: *Multi-model-based Operation Support System*. Engineering Application of Artificial Intelligence, 10(2):117–127, kwiecień 1997.
- [42] Dziubich T.: *Analiza efektywności wybranych metod uczenia sieci neuronowych w diagnostyce systemów rozproszonych*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 137–140, Łagów Lubuski, wrzesień 2001.
- [43] Fagin R., Wimmers E.: *A formula for incorporating weights into scoring rules*. Theoretical Computer, 239:309–338, 2000.
- [44] Fernandez Salido J., Murakami S.: *Extending Yager's orness concept for the OWA aggregators to other mean operators*. Fuzzy Sets and Systems, str. 121–137, luty 2001.
- [45] Fidali M.: *Metody łącznej analizy sygnałów w wielokanałowych układach diagnostujących maszyny wirnikowych*. Zeszyty Katedry Podstaw Konstrukcji Maszyn, z. 123, Gliwice, 2003.
- [46] Gambier A., Badreddin E.: *Application of hybrid modeling and control techniques to desalination plants*. Desalination, 152(1-3):175–184, luty 2003.
- [47] Gang J., Woo T., Sung I.: *Recognition of printed and handwritten numerals using multiple features and modularized neural networks*. Korean Inst. of Telematics, 32B(10):101–111, 1995.
- [48] Geslin S., Salles M., Ziad A.: *Fuzzy aggregation in economic environments I. Quantitative fuzziness, public goods and monotonicity assumptions*. Mathematical Social Science, 45(2):155–166, kwiecień 2003.
- [49] Gibiec M.: *Identyfikacja obciążeń eksploatacyjnych w oparciu o metody sztucznej inteligencji*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 195–198, Łagów Lubuski, wrzesień 2001.
- [50] Gryboś R.: *Dynamika maszyn wirnikowych*. PWN, 1994.
- [51] Głuch J., Krzyżanowski J.: *Oszacowanie dokładności diagnostyki ustabilizowanych i niestabilizowanych ciepłnie obiegów z turbinami parowymi*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 453–458, Łagów Lubuski, wrzesień 2001.
- [52] Hammah R. E., Curran J. H.: *On Distance Measures for the Fuzzy k-Means Algorithm for Joint Data*. Rock Mechanics and Rock Engineering, 32(1), 1999.
- [53] Huang Y., Chan K., Zhang Z.: *Texture Classification by multi-model feature integration using Bayesian networks*. Pattern Recognition Letters, 24(1-3):393–401, styczeń 2003.
- [54] Janczak A.: *Modele neuronowe Wienera w diagnostyce podzespołów procesów*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 123–126, Łagów Lubuski, wrzesień 2001.

- [55] Jensen F.: *An Introduction to Bayesian Networks*. UCL Press and Springer Verlag, 1996.
- [56] Johansen T., Murray-Smith R.: *Multiple Model Approaches to Modelling and Control*. Francis&Taylor, 1997.
- [57] Kacprzyk J.: *Zbiory rozmyte w analizie systemowej*. PWN, Warszawa, 1986.
- [58] Khuu S., Rodriguez J., Romagnolio J., Ngian K.: *Optimisation and control of an industrial surfactant reactor*. *Computers & Chemical Engineering*, 24(2-7):863–870, lipiec 2000.
- [59] Kiciński J.: *Numerical modelling of selected defects in rotating machinery*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [60] Kiciński J. (red.): *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbozespołach energetycznych*. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [61] Kiciński J. (red.): *Symulacja defektów i budowa relacji diagnostycznych modelu numerycznego*. *Zeszyty Katedry Podstaw Konstrukcji Maszyn*, z. 125, Gliwice, 2005.
- [62] Klemiata M., Duda J.: *Analiza falkowa w diagnostyce układów regulacji*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 373–376, Łągów Lubuski, wrzesień 2001.
- [63] Klimek A.: *Metody doskonalenia odwrotnych modeli diagnostycznych*. *Zeszyty Naukowe Politechniki Śląskiej, Mecahnika* z. 134, Gliwice, 1999.
- [64] Kohut P.: *Zastosowanie analizy obrazu do pomiaru przemieszczeń*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 519–524, Władysławowo, wrzesień 2003.
- [65] Kolavennu S., Palanki S., Cockburn J.: *Robust control I/O linearizable systems via multi model H_2/H_∞ synthesis*. *Chemical Engineering Science*, 55(9):1583–1589, maj 2000.
- [66] Korbicz J., Kościelny J., Kowalczuk Z., Cholewa W. (red.): *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*. WNT, Warszawa 2002.
- [67] Kostka P.: *Metody klasyfikacji postaci kinetostatycznych linii wałów maszyn wirnikowych*. *Zeszyty Katedry Podstaw Konstrukcji Maszyn*, z. 121, Gliwice, 2001.
- [68] Kościelny J. M.: *Diagnostyka zautomatyzowanych procesów przemysłowych*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2001.
- [69] Kościelny J. M.: *Bezwarunkowa i warunkowa rozróżnialność uszkodzeń*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 55–60, Władysławowo, wrzesień 2003.

- [70] Kowalczyk Z., Suchomski P.: *Analityczne metody diagnostyki obiektów dynamicznych: filtracja Kalmana jako podstawa odpornej detekcji*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 33–38, Łagów Lubuski, wrzesień 2001.
- [71] Kowalczyk W., Królikowski A.: *Diagnostyka uszkodzeń systemu z wykorzystaniem metod częstotliwościowych*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 169–172, Władysławowo, wrzesień 2003.
- [72] Kuś J., Korbicz J.: *Diagnostyka parametrów częstotliwościowych systemów dynamicznych przy pomocy harmonicznycy sieci neuronowych GMDH*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 141–144, Łagów Lubuski, wrzesień 2001.
- [73] Lam L., Suen C. Y.: *A theoretical-analysis of the application of majority voting to pattern-recognition*. 12th IAPR Int. Conf. on Pattern Recognition, 2:418–420, 1994.
- [74] Lam L., Suen C. Y.: *Application of majority voting to pattern recognition: an analysis of its behavior and preference*. IEEE Transaction on Pattern Analysis and Machine Intelligence, 27(5):553–568, 1997.
- [75] Lucifredi A., Silvestri P.: *Experiences on innovative trends in the field of rotating machinery condition monitoring and diagnostics*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [76] Luo X., Jennings N., Shadbolt N., Leung H., J.H. L.: *A Fuzzy Constraint Based Model for Biteral, Multi-Issue Negotiations in Semi-Competitive Environments*. Artificial Intelligence, 148:53–102, 2003.
- [77] Luo X., Zhang C., Leung H.: *Information Sharing Between Heterogeneous Uncertain Reasoning Models in a Multi-Agent Environment: A Case Study*. International Journal of Approximate Reasoning, 27:27–59, 2001.
- [78] Ławryńczuk M., Tatjewski P.: *Obszarowe modele neuronowe procesów dynamicznych - struktura algorytmu identyfikacji*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 145–148, Łagów Lubuski, wrzesień 2001.
- [79] Łuczak M.: *Nierównoległość osi panwi czopa*. Kiciński J. (red.). *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbozespołach energetycznych*, rozdz. 22.4, str. 1117–1157. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [80] Mangiameli P., West D., Rampal R.: *Model selection for medical diagnosis decision support systems*. Decision Support Systems, 36:247–259, 2004.

- [81] Marques J., Lemos J.: *Optimal and suboptimal shape tracking based on the multi-model partitioning theory*. Image and Vision Computing, 19(8):539–550, maj 2001.
- [82] Mesiar K., Komornikova M.: *Aggregation Operators*. Herceg D., Surla K. (red.), Proceedings of the XI Conference on Applied Mathematics (PRIM'96), str. 193–211, Novi Sad, 1997.
- [83] Mikhailov L., Tsvetinov P.: *Evaluation of services using a fuzzy analytic hierarchy process*. Applied Soft Computing, 5:23–33, 2004.
- [84] Moczulski W.: *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*. Zeszyty Naukowe Politechniki Śląskiej, Mechanika z. 130, Gliwice, 1997.
- [85] Moczulski W.: *Metodyka heurystycznego modelowania obiektów i procesów dla potrzeb diagnostyki i sterowania*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 195–200, Władysławowo, wrzesień 2003.
- [86] Moczulski W.: *Heuristic Models of Objects and Processes for Their Diagnostics and Control*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [87] Moczulski W., Szulim R.: *Zastosowanie heurystycznych metod modelowania w diagnostyce złożonego procesu przemysłowego*. Konf. XXX Jubileuszowe Ogólnopolskie Sympozjum. Diagnostyka Maszyn, Katowice, 2003. (publikacja CD).
- [88] Morrison F.: *Sztuka modelowania układów dynamicznych. Deterministycznych, chaotycznych, stochastycznych*. WNT, 1996.
- [89] Mrugalski M., Korbicz J.: *Dobór struktury modelu neuronowego w układzie detekcji uszkodzeń obiektów dynamicznych*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 275–280, Władysławowo, wrzesień 2003.
- [90] Nascimento J. C., Marques J. S.: *Improving the robustness of parametric shape tracking with switched multiple models*. Pattern Recognition, 35(12):2711–2718, grudzień 2002.
- [91] Niola V., Oliviero R., Quaremba G.: *Fuzzy logic for the classification of a complex signal analyzed by wavelets*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [92] Nowicki R., Rutkowski L.: *Przybliżone zbiory rozmyte w diagnostyce*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 67–72, Władysławowo, wrzesień 2003.
- [93] Orłowski Z.: *Diagnostyka w życiu turbin parowych*. WNT, Warszawa, 2001.

- [94] Ozkan L., Kothare M., Georgakis C.: *Control of a solution copolymerization reactor using multi-model predictive control*. Chemical Engineering Science, 58(7):1207–1221, kwiecień 2003.
- [95] Ören T. I.: *Model Update: A Model Specification Formalism with a Generalized View of Discontinuity*. Proceedings of the Summer Computer Simulation Conference, str. 689–694, Montreal, Quebec, Kanada, 27-30 lipiec 1987.
- [96] Ören T. I.: *Dynamic Templates and Semantic Rules for Simulation Advisors and Certifiers*. Fishwick P., Modjeski R. (red.), Knowledge-Based Simulation: Methodology and Application, str. 53–76, Berlin, Heidelberg, New York, Tokyo, 1991. Springer-Verlag.
- [97] Ören T. I., Yilmaz L.: *Dynamic Model Updating in Simulation with Multimodels: A Taxonomy and a Generic Agent-Based Architecture*. Proceedings of the Summer Computer Simulation Conference, San Jose, California, USA, 24-29 lipiec 2004.
- [98] Padovese L., Vicente S.: *A study of the effects of errors in frequency response functions on the characterisation of vibrating systems*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [99] Parker J.: *Voting methods for multiple autonomus agents*. 3rd Australian and New Zealand Conf. on Intelligent Information Systems, str. 128–133, Perth, Australia, 1995.
- [100] Patan K.: *Sieci neuronowe w detekcji i lokalizacji uszkodzeń w stacji wyparnej*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 281–286, Władysławowo, wrzesień 2003.
- [101] Patan M., Patan K.: *Kalibracja modeli diagnostycznych dla układu dwóch zbiorników przy użyciu optymalnego planowania eksperymentu*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 189–194, Władysławowo, wrzesień 2003.
- [102] Pedrycz W.: *Fuzzy multimodels*. IEEE Transactions on Fuzzy Systems, 4(2):139–148, 1996.
- [103] Pennacchi P., Vania A.: *Validation of rotating machine models by means of the analysis of the shape and orientation of the shaft orbits*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [104] Petridis V., Kehagias A.: *A Multi-Model Algorithm for Parameter Estimation of Time-varying Nonlinear Systems*. Automatica, 34(4):469–475, kwiecień 1998.
- [105] Pieczyński A.: *Rozmyty klasyfikator w diagnostyce procesów przemysłowych*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 185–188, Łągów Lubuski, wrzesień 2001.

- [106] Piegat A.: *Modelowanie i sterowanie rozmyte*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2003.
- [107] Porfirio C., Almeida Neto E., Odloak D.: *Multi-model predictive control of an industrial C3/C4 splitter*. *Control Engineering Practice*, 11(7):765–779, lipiec 2003.
- [108] Portier C., Sherman C., Kopp-Schneider A.: *Multistage, stochastic models of the cancer process: A general theory of calculating tumor incidence*. *Stochastic Environmental Research and Risk Assessments*, 14:173–179, Springer-Verlag, 2000.
- [109] Prońska A., Kiciński J., Banaszek S.: *Procedura strojenia modelu - przypadek bazowy*. Kiciński J. (red.). *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbozespołach energetycznych*, rozdz. 21, str. 989–1021. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [110] Radkowski S.: *Wykorzystanie sygnału wibroakustycznego w diagnozowaniu wczesnych faz uszkodzeń*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 33–42, Władysławowo, wrzesień 2003.
- [111] Rahman A., Fairhurst M.: *Multiple classifier decision combination strategies for character recognition: A review*. *International Journal on Document Analysis and Recognition*, 5:166–194, 2003.
- [112] Ralescu A., Ralescu D.: *Extensions of fuzzy aggregation*. *Fuzzy Sets and Systems*, 86(3):321–330, 1997.
- [113] Ravindranathan M., Leitch R.: *Model switching in intelligent control systems*. *Artificial Intelligence in Engineering*, 13(2):175–187, kwiecień 1999.
- [114] Rodrigues M., Odloak D.: *MPC for stable linear systems with model uncertainty*. *Automatica*, 39(4):569–583, kwiecień 2003.
- [115] Rosenblatt F.: *The Perceptron: a probabilistic model for information storage & organization in the brain*. *Psychological Review*, 65:386–408, 1958.
- [116] Rovatti R., Ragazzoni R., Kovacs Z., Guerrieri R.: *Voting rules for k-nearest neighbors classifiers*. *Neural Computations*, 7(3):594–605, 1995.
- [117] Rybczyński J.: *Rozosiowania linii wirników*. Kiciński J. (red.). *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbozespołach energetycznych*, rozdz. 22.2, str. 1024–1079. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [118] Sasikala K., Petrou M.: *Generalised fuzzy aggregation in estimating the risk of desertification of a burned forest*. *Fuzzy Sets and Systems*, 118(1):121–137, luty 2001.
- [119] Sasikala K., Petrou M.: *Properties of the generalised fuzzy aggregation operators*. *Pattern Recognition Letters*, 22(1):15–24, styczeń 2001.
- [120] Sławik D.: *Wrażliwość diagnostyczna cech sygnałów wibroakustycznych w dziedzinie częstotliwości*. Cholewa W., Burczyński T. (red.), *Artificial Intelligence in*

- Mechanics and Mechanical Engineering (AI-Mech), str. 315–319, Gliwice, listopad 2000.
- [121] Sławik D., Wachla D., Wojtusik J.: *Wrażliwość diagnostyczna cech sygnałów wibroakustycznych*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 439–442, Łagów Lubuski, wrzesień 2001.
- [122] Sławik D., Wojtusik J.: *Kryterium wyboru cech sygnałów wibroakustycznych dla potrzeb odwracania modeli diagnostycznych*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 393–396, Łagów Lubuski, wrzesień 2001.
- [123] See L., Abraham R.: *Multi-model data fusion for hydrological forecasting*. Computers & Geosciences, 27(8):987–994, październik 2001.
- [124] Slupphaug O., Bjarne A.: *Nonlinear robust constrained control of partially uncontrollable and open-loop unstable systems*. Journal of Process Control, 10(2-3):269–274, kwiecień 2000.
- [125] Smets I., Haegebaert J., Carrette R., Van Impe J.: *Linearization of the activated sludge model ASM1 for fast and reliable predictions*. Water Research, 37(8):1831–1851, kwiecień 2003.
- [126] Sobczak W., Malina W.: *Metody selekcji i redukcji informacji*. WNT, Warszawa, 1985.
- [127] Syfert M.: *Zaawansowana struktura rozmytej sieci neuronowej dla potrzeb lokalizacji uszkodzeń*. Korbicz J., Pieczyński A. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 205–210, Łagów Lubuski, wrzesień 2001.
- [128] Śmierzchalski R.: *Model okrętowego silnika głównego do współpracy z rzeczywistym systemem sterowania i kontroli*. Kowalczyk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 175–180, Władysławowo, wrzesień 2003.
- [129] Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1995.
- [130] Teodorescu H., Chelaru M., Kandel A., Tofan I., Irimia M.: *Fuzzy method in tremor assessments prediction and rehabilitation*. Artificial Intelligence in Medicine, 21:107–130, 2001.
- [131] Thiry C., Yan A., Golinval J.: *Damage detection in rotating machinery using statistical methods: PCA analysis and autocorrelation matrix*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [132] Timofiejczuk A.: *Metoda badania maszyn wirnikowych w warunkach rozruchu, rozbiegu i wybiegu*. Zeszyty Naukowe Politechniki Śląskiej, Mechanika z. 133. Gliwice 1999.

- [133] Urbanek G.: *Ewolucyjne metody identyfikacji odwrotnych modeli diagnostycznych*. Udostępniona robocza wersja rozprawy doktorskiej opracowanej pod kierunkiem profesora W. Cholewy.
- [134] Van Zante-de Fokkert J. I., de Kok T. G.: *The mixed and multi model line balancing problem: a comparison*. European Journal of Operational Research, 100(3):399–412, sierpień 1997.
- [135] Venkat A., Vijaysai P., Guidi R.: *Indentification of complex nonlinear processes based on fuzzy decomposition of the steady state space*. Journal of Process Control, 13(6):473–478, wrzesień 2003.
- [136] Volaufová J.: *Some estimation problems in multistage linear models*. Linear Algebra and Its Application, 388:389–397, 2004.
- [137] Wachla D.: *Badanie wrażliwości diagnostycznej cech sygnałów wibroakustycznych przekładni zębatych w dziedzinie czasu*. Cholewa W., Burczyński T. (red.), Artificial Intelligence in Mechanics and Mechanical Engineering (AI-Mech), str. 345–349, Gliwice, listopad 2000.
- [138] Wachla D.: *Discovering dynamics of a sample mechanical system using context-free grammars*. Cholewa W., Burczyński T., Moczulski W. (red.), Symposium on Artificial Intelligence Methods (AI-Meth), str. 141–142, Gliwice, listopad 2003.
- [139] Witczak M.: *Obserwatory stanu i programowanie genetyczne w detekcji uszkodzeń symulatora zaworu*. Kowalczuk Z. (red.), V Krajowa Konferencja Naukowo-Techniczna Diagnostyka Procesów Przemysłowych (DPP'2001), str. 127–132, Władysławowo, wrzesień 2003.
- [140] Wojtusik J.: *Wrażliwość diagnostyczna wzajemnych cech par sygnałów wibroakustycznych w ujęciu metod klasyfikacji i grupowania*. Cholewa W., Burczyński T. (red.), Artificial Intelligence in Mechanics and Mechanical Engineering (AI-Mech), str. 363–367, Gliwice, listopad 2000.
- [141] Wojtusik J.: *Multi-Models of Technical Objects. General Concept*. Cholewa W., Burczyński T. (red.), Symposium on Artificial Intelligence Methods (AI-Meth), str. 433–436, Gliwice, listopad 2002.
- [142] Wojtusik J.: *Pros and Cons of Joined Local Models in the Technical Diagnostics*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [143] Wysogład B.: *Metody reprezentacji drgań wałów maszyn wirnikowych w diagnostycznych bazach danych*. Zeszyty Naukowe Politechniki Śląskiej, Mechanika z. 126. Gliwice 1996.
- [144] Yager R.: *A new methodology for ordinal multi aspect decisions based on fuzzy sets*. Decision Science, 12:589–600, 1981.
- [145] Yager R.: *On ordered weighted averaging operators in multi-criteria decision making*. IEEE Transactions on Systems, Man and Cybernetics, 18:183–190, 1988.

- [146] Yager R., Kelman A.: *Fusion of Fuzzy Information with Considerations for Compatibility, Partial Aggregation and Reinforcement*. International Journal of Approximate Reasoning, 15:93–122, sierpień 1996.
- [147] Yen J., Bui T.: *The negotiable alternatives identifier for group negotiation support*. Applied Mathematics and Computation, 104:259–276, 1999.
- [148] Zadeh L.: *Fuzzy sets*. Inf. and Control, Volume 8:338–353, 1965.
- [149] Zhao G., Jiang D., Diao J., Qian L.: *Application of wavelets time-frequency analysis on fault diagnosis for steam turbine*. 5th International Conference „Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques”, Senlis, Francja, 11-13 październik 2004. (publikacja CD).
- [150] Zong-Mu Y., Kuei-Hisiang L.: *A systematic approach for designing multistage fuzzy control systems*. Fuzzy Sets and Systems, 143:251–273, 2004.

Wielomodele diagnostyczne maszyn wirnikowych

Streszczenie

W pracy przedstawiono wady i zalety wielomodeli diagnostycznych. Omówiono takie pojęcia, jak: cecha, sygnał diagnostyczny, cecha sygnału diagnostycznego, stan techniczny, cecha stanu technicznego, czas 'makro', czas 'mikro', klasa stanu technicznego, obrazy cech. Dokonano przeglądu i systematyki modeli stosowanych w diagnostyce technicznej wraz z omówieniem koncepcji rozpatrywania obiektu w diagnostyce technicznej w postaci tzw. „czarnej skrzynki”. Wprowadzono definicję wielomodeli. Wyróżniono, ze względu na ich strukturę, dwie podstawowe klasy wielomodeli: modele wielowarstwowe i modele wielostopniowe. Ponadto, w grupie modeli wielowarstwowych przedstawiono dwa przypadki szczególne: modele sekwencyjne i modele wieloaspektowe. Przedstawiono również pole możliwych rozwiązań metod wyznaczenia jednego wyjścia modeli wielowarstwowych na podstawie wyjść modeli składowych. Omówiono metody agregacji i uzgadniania wyjść. Pokazano różne rozwiązania operatorów agregacji oraz metody głosowania jako szczególną grupę metod agregacji.

Zaprezentowano przykład metody identyfikacji wielomodelu diagnostycznego do rozpoznawania stanu technicznego maszyny wirnikowej w zakresie przemieszczeń podpór łożyskowych. Wielomodel, będący fragmentem większego wielomodelu, służył do rozpoznawania klasy położenia podpór łożyskowych na podstawie klas obciążenia łożysk. Stanowił drugi stopień modelu dwustopniowego, w którym w odróżnieniu od jednostopniowych klasyfikatorów uwzględniono dodatkową informację o obiekcie badań poprzez zdefiniowanie przestrzeni klas obciążenia łożysk, spinającą obydwie stopnie modelu. W opisywanych badaniach zastosowano model wielowarstwowy, w którym wyjście było wynikiem agregacji wyjść modeli składowych. Modelami składowymi były klasyfikatory bazujące na sieci neuronalnej, interpolacyjnych modelach odwrotnych, sieci Bayesa oraz metodzie *fuzzy k-means*. Metodę tą zweryfikowano na podstawie danych uczących pochodzących z symulacji udostępnionych przez Instytut Maszyn Przepływowych Polskiej Akademii Nauk (IMP PAN) w Gdańsku.

Modele trenowane były na podstawie przykładów uczących, dotyczących zachowania obiektu w warunkach przemieszczenia jednej, wybranej podpory. Testowanie modeli i wielomodelu przeprowadzono na podstawie przykładów stanów złożonych, w których przemieszczane były dwie podpory jednocześnie. Na podstawie przeprowadzonych badań stwierdzono, że rozpoznawanie klas położenia podpór z zastosowaniem wielomodelu daje lepsze wyniki niż osobne stosowanie modeli składowych tego wielomodelu jako modeli globalnych.

Słowa i zwroty kluczowe: diagnostyka techniczna, diagnostyka maszyn i urządzeń, model diagnostyczny, model wielostopniowy, wielomodel, klasyfikacja stanu

Dziedziny: budowa i eksploatacja maszyn, diagnostyka techniczna

Diagnostic Multi-Models of Rotating Machineries

Summary

Pros and cons of diagnostic multi-model were considered in the thesis. There are such terms as feature, diagnostic signal, diagnostic signal feature, technical state, technical state feature, 'macro' time, 'micro' time, class of technical state, feature patterns explained. A review and systematics of models applied in the technical diagnostics are discussed with the object consideration concept in the form of so-called "black-box". The multi-models definition was introduced. Two elementary classes of multi-models: multistage models and multilayer models, were distinguished from their structure point of view. Moreover, two particular cases of multilayer models: sequence models and multiaspect models, were presented. A field of possible solutions of one output evaluation of multilayer models based on component model outputs was considered. Aggregation and negotiation methods were discussed. Several different aggregation operators were shown and voting methods considered as a special case of aggregation methods were presented.

An example of identification method of diagnostic multi-model to technical state recognition of rotor machinery scoped on bearings displacements was presented. Multi-model, being a part of bigger multi-model, was applied to class recognition of bearing locations based on classes of bearing loads. It was the second stage of two-stage model in which contrary to one-stage classifiers the extra knowledge about considered object was introduced by definition of the space of bearing loads classes, coupling both model stages. In the described research, multilayer model the output of which was the result of aggregation of component model outputs was applied. Classifiers basing on neural networks, interpolation inverse models, Bayesian networks and fuzzy k-means method were the component models. The method was verified on the base of learning data received from simulation which were enabled by Institute of Fluid-Flow Machinery of Polish Academy of Sciences (IFFM PAS) in Gdańsk. Models were trained on the base of learning examples considering object behavior in the case of one selected bearing displacement. Test of component models and multi-model were based on examples of complex technical states in which simultaneous displacements of two bearing were introduced. Based on the received results, it was stated that consideration of bearing location classes with the application of multi-model deliver better results than separate application of component models of this multi-model as global ones.

Keywords: Technical diagnostics, diagnostics of machinery and devices, diagnostic model, multi-layer model, multi-model, state classification

Domains: design and maintenance of machinery, technical diagnostics

