

Politechnika Śląska  
Wydział Mechaniczny Technologiczny  
Katedra Podstaw Konstrukcji Maszyn

Sebastian Ryzdzik

# Identyfikacja stanu w układach rozproszonych

Gliwice 2007

*Recenzenci*

prof. dr hab. inż. Stanisław Radkowski - Politechnika Warszawska  
prof. dr hab. Wojciech Moczulski - Politechnika Śląska

*Redaktor zeszytów*

Wojciech Cholewa

*Redaktor techniczny*

Marek Wyleźoł

*Projekt okładki*

Wojciech Cholewa, Marek Wyleźoł

**ISBN 978-83-60759-03-5**

*Wydawca*

Katedra Podstaw Konstrukcji Maszyn  
Wydział Mechaniczny Technologiczny  
Politechnika Śląska  
ul. Konarskiego 18a, 44-100 Gliwice  
tel. (032) 237-14-67, fax (032) 237-13-60  
<https://kpk.m.polsl.pl>

---

Druk i oprawa (z dostarczonych materiałów)

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

---

Od autora

---

Zeszyt opracowałem na podstawie mojej rozprawy doktorskiej, której promotorem był prof. dr hab. inż. Wojciech Cholewa. Publiczna obrona rozprawy odbyła się 18 września 2007 roku przed Komisją powołaną przez Radę Wydziału Mechanicznego Technologicznego. W opracowaniu zostały uwzględnione uwagi recenzentów rozprawy doktorskiej: prof. dra hab. inż. Stanisława Radkowskiego i prof. dra hab. Wojciecha Moczulskiego.

Niniejszą książkę dedykuję Rodzinie dziękując za nieustanne wsparcie. Składam serdeczne podziękowania Koleżankom i Kolegom z Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej za okazaną mi pomoc i życzliwość w czasie realizacji pracy. Szczególnie zaś dziękuję prof. dr hab. inż. Wojciechowi Cholewie za wszelką pomoc oraz cenne uwagi krytyczne.

*Gliwice, listopad 2007*

*Sebastian Rzydzik*

Część pracy finansowano ze środków budżetowych na naukę w latach 2005-2008, jako fragment projektu badawczego.



---

## Spis treści

---

<b>Od autora</b>	<b>ii</b>
<b>Wykaz ważniejszych oznaczeń</b>	<b>1</b>
<b>1. Wprowadzenie</b>	<b>3</b>
1.1. Cel rozprawy . . . . .	4
1.2. Tezy rozprawy . . . . .	5
<b>2. Przedmiot badań</b>	<b>7</b>
2.1. Podstawowe pojęcia . . . . .	8
2.2. Modele diagnostyczne . . . . .	11
2.3. Doskonalenie modeli . . . . .	15
2.4. Dekompozycja obiektu . . . . .	16
2.5. Czas w diagnostyce . . . . .	18
2.6. Wyznaczanie wartości cech sygnałów diagnostycznych . . . . .	19
2.7. Metody wyboru cech sygnałów diagnostycznych . . . . .	20
2.7.1. Wybór zbioru cech sygnałów diagnostycznych z użyciem wiedzy specjalistów . . . . .	21
2.7.2. Wybór zbioru cech sygnałów diagnostycznych z użyciem algorytmów obliczeniowych . . . . .	22
2.8. Warunki działania obiektu . . . . .	25
2.9. Charakterystyka wybranych klasyfikatorów . . . . .	26
2.9.1. Układy wnioskujące systemów doradczych . . . . .	26
2.9.2. Tablice decyzyjne . . . . .	33
2.9.3. Metody klasyfikacji i grupowania . . . . .	34
2.9.4. Sieci neuronalne . . . . .	38
2.10. Wybrane metody uzgadniania opinii . . . . .	41
2.10.1. Agregacja opinii . . . . .	41
2.10.2. Automaty komórkowe . . . . .	43

2.10.3. Metody oparte na logice matematycznej i teorii zbiorów . . . . .	44
<b>3. Opis proponowanej metody</b>	<b>47</b>
3.1. Opis koncepcji . . . . .	47
3.2. Komunikacja pomiędzy modułami . . . . .	51
3.2.1. Metody komunikacji . . . . .	51
3.2.2. Synchronizacja czasu . . . . .	53
3.2.3. Uzgadnianie wyników identyfikacji warunków działania . . . . .	55
3.3. Synteza modelu globalnego . . . . .	62
3.3.1. Łączenie modeli lokalnych . . . . .	63
3.3.2. Identyfikacja Modułu D . . . . .	65
3.4. Identyfikacja modeli lokalnych . . . . .	67
3.4.1. Budowa modelu lokalnego . . . . .	67
3.4.2. Identyfikacja Modułu C . . . . .	68
3.4.3. Identyfikacja Modułu B . . . . .	71
3.4.4. Identyfikacja Modułu A . . . . .	74
3.5. Podsumowanie identyfikacji modułów . . . . .	76
<b>4. Wstępna weryfikacja metody</b>	<b>79</b>
4.1. Obiekt badań . . . . .	79
4.1.1. Charakterystyka obiektu . . . . .	79
4.1.2. Warunki działania i stany obiektu . . . . .	80
4.1.3. Dane symulacyjne . . . . .	81
4.2. Plan badań . . . . .	82
4.2.1. Opracowane oprogramowanie . . . . .	82
4.3. Model obiektu . . . . .	83
4.3.1. Dekompozycja obiektu na fragmenty . . . . .	83
4.3.2. Identyfikacja modeli lokalnych . . . . .	83
4.3.3. Identyfikacja modeli globalnych . . . . .	94
4.4. Przebieg badań . . . . .	98
4.5. Wyniki eksperymentu . . . . .	99
4.6. Wnioski . . . . .	100
<b>5. Weryfikacja metody /1/</b>	<b>107</b>
5.1. Obiekt badań . . . . .	108
5.1.1. Charakterystyka obiektu . . . . .	108
5.1.2. Warunki działania i stany obiektu . . . . .	108
5.1.3. Dane symulacyjne . . . . .	110
5.2. Plan badań . . . . .	110
5.2.1. Opracowane oprogramowanie . . . . .	111
5.3. Model obiektu . . . . .	111
5.3.1. Dekompozycja obiektu na fragmenty . . . . .	111
5.3.2. Identyfikacja modeli lokalnych . . . . .	112
5.3.3. Identyfikacja modeli globalnych . . . . .	119

---

5.4. Przebieg badań . . . . .	122
5.5. Wyniki eksperymentu . . . . .	123
5.6. Wnioski . . . . .	127
<b>6. Weryfikacja metody /2/</b>	<b>131</b>
6.1. Obiekt badań . . . . .	131
6.1.1. Charakterystyka obiektu . . . . .	131
6.1.2. Dane symulacyjne . . . . .	131
6.1.3. Warunki działania i stany obiektu . . . . .	132
6.2. Plan badań . . . . .	136
6.2.1. Opracowane oprogramowanie . . . . .	137
6.3. Model obiektu . . . . .	137
6.3.1. Dekompozycja obiektu na fragmenty . . . . .	137
6.3.2. Identyfikacja modeli lokalnych . . . . .	138
6.4. Przebieg badań . . . . .	141
6.5. Wyniki eksperymentu . . . . .	142
6.5.1. Weryfikacja metod rozpoznawania warunków działania obiektu . . . . .	142
6.5.2. Weryfikacja metod rozpoznawania stanu obiektu . . . . .	143
6.6. Wnioski . . . . .	144
<b>7. Podsumowanie i wnioski</b>	<b>147</b>
7.1. Podsumowanie . . . . .	147
7.2. Wnioski wynikające z pracy . . . . .	148
7.3. Kierunki dalszych badań . . . . .	149
<b>Bibliografia</b>	<b>151</b>
<b>Streszczenie</b>	<b>163</b>





---

## Wykaz ważniejszych oznaczeń

---

Poniżej znajduje się wykaz ważniejszych oznaczeń pojawiających się w rozprawie:

- $1X$  - składowa podstawowa w widmie amplitudowym sygnału diagnostycznego;
- $b(.)$  - ocena stopnia prawdziwości stwierdzenia lub reguły;
- $C_{sg}$  - współczynnik szczytu sygnału diagnostycznego;
- $d(x,y)$  - funkcja odległości pomiędzy elementami  $x$  i  $y$ ;
- $DT$  - zbiór danych testujących;
- $DU$  - zbiór danych uczących;
- $f_a(sg)_{max}$  - częstotliwość maksymalnej wartości w widmie amplitudowym sygnału diagnostycznego;
- $F$  - fakt;
- $h(x,y)$  - funkcja podobieństwa elementów  $x$  i  $y$ ;
- $I_{sg}$  - współczynnik impulsowości sygnału diagnostycznego;
- $K_{sg}$  - współczynnik kształtu sygnału diagnostycznego;
- $Ku_{sg}$  - współczynnik skupienia (koncentracji, kurtoza) sygnału diagnostycznego;
- $m^L$  - model lokalny;
- $m^G$  - model globalny;
- $n_{obr}$  - prędkość obrotowa;
- $O$  - zbiór fragmentów obiektu;

$R$  - reguła;

$s, s^k$  - stan elementarny (podstawowy), stan elementarny (podstawowy)  $k$ -tego modelu lokalnego;

$S$  - zbiór stanów (przestrzeń stanów);

$SG, sg$  - zbiór sygnałów diagnostycznych, sygnał diagnostyczny;

$S_{sg}$  - współczynnik asymetrii (skośność) sygnału diagnostycznego;

$sg_{AVE}$  - wartość średnia sygnału diagnostycznego;

$sg_{P-P}$  - wartość międzyszczytowa sygnału diagnostycznego;

$sg_{PEAK}$  - wartość szczytowa sygnału diagnostycznego;

$sg_{RMS}$  - wartość skuteczna sygnału diagnostycznego;

$t, \tau$  - czas 'makro', czas 'mikro';

$W, w$  - zbiór klas warunków działania fragmentu obiektu, klasa warunków działania fragmentu obiektu;

$W^O, w^O$  - zbiór klas warunków działania całego obiektu, klasa warunków działania całego obiektu;

$z \text{ lub } x, y, p, q$  - stwierdzenie;

$F$  - zbiór funkcji przetwarzających sygnały diagnostyczne;

$\Gamma$  - zbiór stanów pojedynczej komórki automatu komórkowego;

$\Lambda$  - zbiór sąsiadów pojedynczej komórki automatu komórkowego;

$\Lambda^B$  - zbiór sąsiadów bliskich pojedynczej komórki automatu komórkowego;

$\Lambda^D$  - zbiór sąsiadów dalekich komórki automatu komórkowego;

$\mu_A(x)$  - funkcja przynależności elementu  $x$  do zbioru  $A$ .

# ROZDZIAŁ 1

---

## Wprowadzenie

---

Rozprawa dotyczy diagnostyki technicznej. Celem diagnostyki technicznej jest określenie stanu technicznego obiektów technicznych za pomocą obiektywnych metod i środków [18, 92]. Należy zaznaczyć, że w tej pracy przyjęto nazywać szeroko rozumiane urządzenia (mechaniczne, elektryczne, elektroniczne, linie technologiczne, procesy technologiczne itp.) obiektami technicznymi lub w skrócie obiektami. W przypadku złożonych megaukładów (definicja megaukładu znajduje się w [60]) rozpatruje się fragmenty obiektów, przy czym:

1. Fragment obiektu może dotyczyć przestrzennego (terytorialnego) wyodrębnienia pewnej części obiektu.
2. Fragment obiektu może dotyczyć funkcjonalnego wyodrębnienia pewnej części obiektu.
3. Fragment obiektu może dotyczyć przestrzennego i funkcjonalnego wyodrębnienia pewnej części obiektu.

Każdy obiekt techniczny (fragment obiektu) w danej chwili czasu  $t$  znajduje się w pewnym stanie technicznym  $s_i$  należącym do, zwykle skończonego, zbioru możliwych stanów  $S$  przyporządkowanego temu obiektowi. Najprostszym możliwym zbiorem stanów  $S$  jest zbiór składający się z dwóch stanów (klas stanów):  $s_0$  – *zdatny* i  $s_1$  – *niezdatny*. Określenie stanu (klasy stanu) technicznego obiektu polega na bezpośrednich badaniach jego własności i/lub na pośrednich badaniach cech, tzw. procesów resztkowych, towarzyszących działającemu obiektowi technicznemu [18]. Zwykle dla danej klasy stanu definiuje się zbiór reprezentujących ją wzorcowych wartości obserwowanych cech, a następnie tworzy się model (funkcję klasyfikującą) zwany klasyfikatorem. Wynikiem działania klasyfikatora jest określenie, na przykład poprzez porównanie wartości obserwowanych cech ze wzorcami tych wartości, aktualnego stanu technicznego  $s$  rozpatrywanego obiektu lub fragmentu obiektu. Proces ten nosi miano wnioskowania diagnostycznego [110]. Ze

względu na dostępne dane wejściowe, pochodzące z działającego obiektu, klasyfikatory można podzielić na:

- klasyfikator mający dostęp do wszystkich możliwych danych związanych z całym rozpatrywanym obiektem (klasyfikator globalny),
- klasyfikator mający dostęp tylko do wybranych danych związanych z fragmentem obiektu (klasyfikator lokalny),
- klasyfikator mający dostęp tylko do wybranych danych związanych z fragmentem obiektu i pośrednio do danych pochodzących z innych fragmentów obiektu.

Jeżeli nie podejmować problemu wpływu liczby cech na jakość działania klasyfikatora [34], to jakość działania klasyfikatora globalnego powinna być najlepsza, natomiast jakość działania klasyfikatora lokalnego może być gorsza (ze względu na ograniczony dostęp do informacji pochodzących tylko z fragmentu obiektu). Trzeci z wymienionych klasyfikatorów będzie posiadał cechy zarówno klasyfikatora lokalnego jak i częściowo klasyfikatora globalnego, zatem jakość jego działania będzie zawarta pomiędzy jakościami działania tych klasyfikatorów. Klasyfikator ten wymaga użycia „pośrednika”, który będzie dostarczał dla klasyfikatora lokalnego informacje pochodzące z lokalnego otoczenia [136] rozpatrywanego fragmentu obiektu. Najważniejszą informacją pochodzącą z otoczenia będzie informacja o warunkach działania całego obiektu.

Określenia klasyfikator globalny i klasyfikator lokalny mają ścisły związek z modelami diagnostycznymi globalnymi i lokalnymi. W szczególnym przypadku modelem diagnostycznym jest klasyfikator. W ogólnym przypadku klasyfikator jest jednym z elementów modelu diagnostycznego.

Zastosowane do badań weryfikacyjnych obiekty techniczne (p. 4, p. 5 i p. 6) mogą sugerować, że opracowana metoda dotyczy rozpoznawania wyłącznie stanów technicznych. Niemniej jednak przedstawiona metoda może być użyta do identyfikacji stanu nie tylko obiektów technicznych, np. kondycji obszarów leśnych.

## 1.1. Cel rozprawy

Celem rozprawy jest analiza wybranych metod klasyfikacji informacji diagnostycznej, metod agregacji i uzgadniania wiedzy diagnostycznej oraz sposobów dekompozycji obiektów technicznych i syntezy globalnych modeli diagnostycznych. Wybrane metody i algorytmy znajdą zastosowanie w systemie wnioskującym o stanie technicznym wybranego obiektu rzeczywistego. Nadrzędnym celem rozprawy jest pokazanie metodyki tworzenia systemów diagnostycznych zbudowanych ze zbioru modeli lokalnych, związanych z fragmentami danego obiektu traktowanego jako układ rozproszony, które ostatecznie będą łączone ze sobą w model globalny całego obiektu. Pośrednim celem jest pokazanie, że identyfikacja poszczególnych modeli lokalnych może być prowadzona niezależnie od siebie.

## 1.2. Tezy rozprawy

Sformułowano dwie tezy pracy:

**Teza 1** Możliwe jest zbudowanie modelu globalnego występującego w postaci sieci modeli lokalnych, charakteryzujących się tym, iż modele te nie mają bezpośredniego dostępu do informacji diagnostycznych dotyczących wszystkich fragmentów obiektu, a dostęp pośredni ograniczony jest do danych o uzgodnionych przez te modele klas warunków działania i autonomicznie wyznaczanych przez nie klas stanów.

**Teza 2** Możliwa jest indywidualna (niezależna) identyfikacja modeli lokalnych będących elementami sieci określającej model globalny, bez potrzeby identyfikacji całego modelu globalnego.



## ROZDZIAŁ 2

---

### Przedmiot badań

---

Stosowane w diagnostyce technicznej pojęcia nie zawsze są pojęciami ogólnie przyjętymi. W związku z tym, w celu uniknięcia nieporozumień, zestawiono słownik podstawowych pojęć (p. 2.1) jakie są używane w tej rozprawie. Dalsze punkty zawierają opis modeli diagnostycznych (w tym modeli lokalnych i globalnych, p.2.2), zasad dekompozycji obiektów technicznych z punktu widzenia diagnostyki (p. 2.4) oraz rozróżnienie dwóch klas czasu, który jest wygodny w zależności od tego czy rozpatrujemy chwilowe wartości cech sygnałów diagnostycznych, czy stan eksploatacyjny obiektu (p. 2.5).

Ogólnie przedstawiono zagadnienie wyznaczania wartości cech sygnałów diagnostycznych (p. 2.6) oraz wybrane metody wyboru cech diagnostycznych, z uwzględnieniem wiedzy specjalistów jak i specjalnych algorytmów obliczeniowych (p. 2.7).

Ważnym zagadnieniem jest problem określania warunków działania badanego obiektu (p. 2.8). Określenie zbioru możliwych warunków działania pokazano na przykładzie.

Kolejny punkt zawiera charakterystykę wybranych klasyfikatorów (p. 2.9). Przede wszystkim skupiono się na klasyfikatorach bazujących na aparacie logiki matematycznej: dwuwartościowej (klasycznej), wielowartościowej oraz najbardziej ogólnej postaci logiki rozmytej. Pozostałe opisane metody - tablice decyzyjne, grupowanie i klasyfikacja oraz sieci neuronalne, zwykle na jednym z etapów swojego działania używają aparatu logiki matematycznej. Należy wyraźnie podkreślić, że metody te, w tej rozprawie, są zastosowane w charakterze klasyfikatorów.

W ostatnim punkcie tego rozdziału przedstawiono wybrane metody uzgadniania opinii (p. 2.10). Opisane trzy grupy metod znalazły zastosowanie w procesie wypracowywania wspólnej opinii dla przypadku identyfikacji warunków działania całego badanego obiektu.

## 2.1. Podstawowe pojęcia

W diagnostyce technicznej urządzeń i procesów nie ma ujednoczonego aparatu pojęciowego. Nieoficjalnie przyjmuje się, że definicje najważniejszych pojęć, takich jak *niezdatność*, *uszkodzenie* i *niesprawność*, znajdują się w wykazie terminów zaakceptowanych przez Komitet Techniczny SAFEPROCESS międzynarodowej organizacji IFAC [79]. W licznych przypadkach terminy są zgodne z definicjami zawartymi w normie PN-93/N-50191 [118] która jest tłumaczeniem angielskiej wersji normy międzynarodowej IEC-50 (191) [77]. Poniżej przytoczono definicje wybranych pojęć.

Ważną cechą każdego obiektu technicznego jest jego *niezawodność eksploatacyjna* [82, 11], którą można zdefiniować następująco:

***Niezawodność eksploatacyjna*** [82, 11]: *Prawdopodobieństwo poprawnego działania obiektu w określonym czasie i w zidentyfikowanych warunkach.*

***Niezdatność*** [79]: *Stan obiektu charakteryzujący się niezdolnością do wypełniania wymaganych funkcji. Inaczej, niezdatność jest to niedopuszczalne odchylenie przynajmniej jednej własności lub parametru systemu z obszaru dopuszczalnych (zazwyczaj) warunków nominalnych.*

***Uszkodzenie*** [118]: *Utrata zdolności obiektu do wypełniania wymaganych funkcji. Po uszkodzeniu obiektu występuje jego niezdatność. „Uszkodzenie” jest zdarzeniem w odróżnieniu od „niezdatności”, która jest stanem.*

***Niesprawność*** [82]: (a) *Jako stan techniczny: stan obiektu, w którym nie spełnia on chociażby jednego z wymagań dokumentacji technicznej, jest jednak zdolny do wykonywania z ograniczeniem wyznaczanych mu funkcji.* (b) *Jako zdarzenie: zdarzenie polegające na niekorzystnej zmianie wartości parametru obiektu osłabiającej jego zdolność do wypełniania zadanych funkcji zgodnie z wymaganiami pracy systemu.*

Proces zużywania się maszyn i urządzeń ma związek z procesami drganiowymi i wibroakustycznymi [19], które są podstawowym źródłem informacji diagnostycznej.

***Zużycie*** [19, 5, 7, 10]: *Zużycie jest to stopniowa utrata własności funkcjonalnych (użytkowych) obiektu. Zużycie można podzielić na: zmęczeniowe, tarciove, zużywanie się przez pełzanie i zużycie erozyjne.*

Przebieg badania diagnostycznego związany jest z realizacją następujących zadań [19, 125]:

***Diagnozowanie***: *Realizacja działań, których celem jest rozpoznanie aktualnego stanu technicznego diagnozowanego obiektu.*



**Genezowanie:** *Rozpoznawanie przeszłych stanów technicznych diagnozowanego obiektu.*

**Prognozowanie:** *Przewidywanie przyszłych stanów obiektu diagnozowania.*

Proces badania diagnostycznego jest ciągiem pewnych operacji. W skrócie można go przedstawić następująco: zwykle w pierwszym kroku wyznacza się zbiór *stanów elementarnych* tworzących *przestrzeń stanów*; następnym etapem jest pozyskanie *sygnałów* i przekształcenie ich w *sygnały diagnostyczne* o określonych *wartościach cech*; niektóre wartości cech sygnałów diagnostycznych stają się *symptomami* diagnostycznymi; ostatecznie, na podstawie *symptomów* i *wzorców wartości cech sygnałów* pewna funkcja klasyfikująca przypisuje aktualny *stan techniczny* obiektu do wybranej *klasy stanów*. Uzyskana w ten sposób informacja o stanie obiektu jest diagnozą. Diagnoza jest potrzebna operatorowi obiektu przy podejmowaniu decyzji o sposobie i zakresie sterowania obiektem oraz decydentowi systemu przy podejmowaniu decyzji o rodzaju i zakresie zadań eksploatacyjnych realizowanych przez system [11, 57].

**Cecha:** *Dowolny abstrakt lub konkret mogą być opisywane za pomocą zbioru atrybutów. Atrybuty mogą mieć charakter jakościowy lub ilościowy. Atrybut, przysługujący danemu obiektowi, nazywa się cechą. Cecha jest zapisywana jako para <nazwa, wartość> [34]. Inaczej, cecha jest to właściwość wyróżniająca interesujący nas obiekt z otaczającej rzeczywistości [169].*

**Sygnał:** *Sygnał jest to przebieg dowolnej wielkości fizycznej w czasie, będącej nośnikiem informacji (tu: o stanie obiektu) [18, 147]. Znane wartości cech sygnałów określane są jako **zmienne procesowe**. Zmienne procesowe są zatem bezpośrednio mierzone lub wyliczane na podstawie wartości innych mierzonych sygnałów lub też wypracowywane przez system automatyki jako sygnały sterujące [89].*

**Sygnał diagnostyczny [147]:** *Sygnał diagnostyczny jest to przebieg dowolnej wielkości fizycznej w czasie, będącej nośnikiem informacji pozwalającej na orzeczenie o stanie technicznym obiektu.*

**Wzorzec wartości cech sygnałów [27]:** *Obiekt obserwowany jest za pośrednictwem sygnałów, które opisywane są za pomocą wartości ich cech. Wzorcem wartości cech sygnałów nazywa się wyróżnioną wartość, przedział wartości lub wartość funkcyjną wyróżnioną na zbiorze wszystkich wartości cech sygnałów. Wzorzec wartości cechy sygnałów może być prosty (dotyczy jednej wartości jednej cechy jednego sygnału) lub złożony (dotyczy wielu wartości cech sygnałów rozpatrywanych łącznie). Wartość cechy sygnałów może być całkowicie zgodna ze wzorcem lub zgodna z pewnym stopniem zgodności.*

**Symptom:** Symptom jest to zmiana (odchylenie) wartości obserwowanej wielkości od wartości uznawanej za prawidłową [79]. Symptodem określonej klasy stanów jest zgodność chwilowych wartości cech sygnałów diagnostycznych z odpowiadającym tej klasie wzorcem wartości cech sygnałów [27].

**Cechy stanu, stan obiektu:** Własności obiektu opisane są jego cechami nazywanymi cechami stanu. Aktualny stan obiektu jest wektorem wartości jego cech stanu. W przypadku rozpatrywania niedokładnych wartości cech stanu aktualny stan obiektu należy do pewnej klasy stanu [27]. Na stan obiektu mają wpływ czynniki związane z działaniem obiektu, oddziaływaniami występującymi wewnątrz obiektu oraz pomiędzy rozpatrywanym obiektem i innymi obiektami znajdującymi się w jego otoczeniu [120]. W badaniach diagnostycznych obserwuje się chwilowy stan obiektu (określony przez cechy „wewnętrzne” tego obiektu) za pośrednictwem chwilowych wartości cech efektów „zewnętrznych” [34].

**Stan elementarny (podstawowy) [34]:** Stan elementarny jest to zbiór rozłącznych i różnych elementów, którego podzbiór opisuje stan obiektu. Każdy stan elementarny jest opisany przez uporządkowany zbiór odpowiednich cech elementarnych, przy czym podstawą dla utworzenia takiego zbioru mogą być różne aspekty, związane z badaniami urządzeń mechanicznych, np.: niewyważenie, nieosiowość, nadmierne luzy, itd.

**Stan złożony:** Stan techniczny nie będący stanem prostym jest stanem złożonym [109]. Stan złożony może być definiowany jako podzbiór stanów elementarnych określany na zbiorze wszystkich stanów elementarnych.

**Przestrzeń stanów [34]:** Przestrzeń stanów jest to zbiór wszystkich stanów elementarnych.

**Klasy stanów [34]:** Klasy stanów są to wyodrębnione w przestrzeni stanów pewne podobszary, które mają być rozpoznane w danym eksperymencie diagnostycznym. Wybór kryterium (kryteriów) grupowania stanów w klasy, a także kryteria określenia liczby rozpoznawanych klas stanów zależą przede wszystkim od celu prowadzonego eksperymentu diagnostycznego. W najprostszym przypadku będą to dwie klasy: sprawny i niesprawny.

**Proces propagacji stanów [120]:** Stan złożonego obiektu może być określany, między innymi, na podstawie stanów jego elementów składowych. Stany poszczególnych elementów często nie powinny być rozpatrywane jako stany niezależne, ponieważ stan każdego z nich może zależeć od stanu (jednego lub kilku) pozostałych elementów, jak również jego stan może wpływać na stan innych elementów. Takie oddziaływania stanów nazywa się procesem propagacji stanów.

### Układ rozproszony

W źródłach dotyczących zagadnień diagnostyki nie znaleziono definicji pojęcia układu rozproszonego odniesionego do urządzeń technicznych. W literaturze informatycznej (np. [54, 160, 80, 66]) pojawia się definicja pojęcia systemu rozproszonego mówiąca, że jest to zbiór niezależnych zasobów sprzętowych i programowych połączonych ze sobą w celu wymiany komunikatów i tworzących jedną całość. Na podstawie tej definicji zaproponowano, że:

*Pewne wyróżnione elementy (fragmenty) dowolnego obiektu technicznego rozpatrywane jako elementy (fragmenty) współdziałające ze sobą (oddziaływujące na siebie) będą nazywane **układem rozproszonym**.*


Należy dodać, że pojęcie **układ** zarezerwowano dla konkretów, a pojęcie **system** dla abstraktów [60]. Patrząc „z zewnątrz”, układ rozproszony będzie stanowił jedną całość i może być utożsamiany z całym obiektem (w informatyce mówi się, że system rozproszony jest transparentny). „Od środka” układ rozproszony będzie widziany jako zbiór niezależnych elementów (fragmentów) połączonych i wchodzących ze sobą w relacje (zarówno czynne jak i bierne).

## 2.2. Modele diagnostyczne

W diagnostyce technicznej przyjęto, że **model obiektu** jest to uproszczone odwzorowanie właściwości obiektu wybranych ze względu na możliwość oceny jego zdolności do wykonania stawianych mu zadań [169]. Uproszczenie polega na ograniczeniu zbioru właściwości uwzględnianych w opisie. Rozróżnia się następujące modele ogólne [158]:

1. Model matematyczny - przybliżony (wyidealizowany) opis jakiejś klasy zjawisk wyrażony przy użyciu aparatu matematycznego;
2. Model nominalny - system założeń przyjmowanych w danej nauce w celu ułatwienia (lub umożliwienia) rozwiązania pewnego problemu badawczego;
3. Model realny - przedmiot lub układ przedmiotów (zdarzeń, sytuacji) spełniających założenia danej teorii, lub dostatecznie podobny do układu badanego, ale prostszy i łatwiej dostępny badaniom;
4. Model teoretyczny - konstrukcja hipotetyczna odwzorowująca dany rodzaj rzeczywistości w sposób uproszczony, sprowadzający jej cechy do związków najistotniejszych, budowana w celach heurystycznych;
5. Model semantyczny - logiczne odwzorowanie, czyli interpretacja danej teorii w postaci układu (dziedziny) przedmiotów opisywanego prawdziwie przez tę teorię.

Na potrzeby badań diagnostycznych tworzy się **modele diagnostyczne** [19, 18, 27, 84, 121, 168] (rys. 2.1). Model diagnostyczny przekształca dane o



Rys. 2.1. Model diagnostyczny [34]

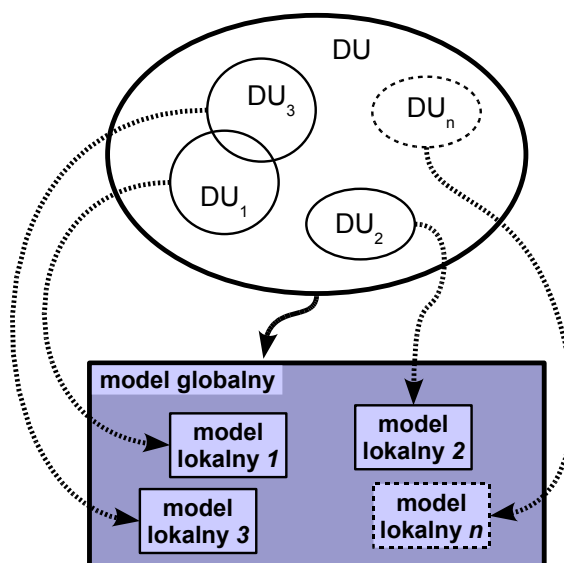
oddziaływaniu otoczenia na obiekt (poprzez wejścia  $X$ ) i obiektu na otoczenie (poprzez wyjścia  $Y$ ) w stan obiektu  $S$  [27]. Inaczej, jest to relacja pomiędzy cechami stanu obiektu a cechami sygnałów diagnostycznych [34, 35]. Tworzone są modele indywidualne, które opisują właściwości pojedynczego obiektu lub grupowe, opisujące wspólne właściwości pewnej klasy obiektów [34]. Modele diagnostyczne mogą być **modelami ilościowymi**, gdzie dane zapisane są w postaci liczb lub **modelami jakościowymi**, gdzie dane reprezentowane są w sposób przybliżony lub z zastosowaniem logiki wielowartościowej [27]. W dużej liczbie przypadków modele diagnostyczne tworzą klasyfikatory. **Klasyfikatory** umożliwiają wyznaczenie danych wyjściowych reprezentowanych w postaci zbiorów, grup (skupień) lub klas [27]. Klasyfikatory są używane w procesie klasyfikacji, czyli przyporządkowywaniu obiektów do wybranych klas na podstawie opisujących je cech.

W diagnostyce technicznej wyróżnia się dwie podstawowe formy eksperymentów diagnostycznych, na podstawie których identyfikuje się model obiektu, eksperyment czynny i eksperyment bierny [36]. **Eksperyment czynny** polega na obserwacji sygnałów diagnostycznych po uprzednim ustaleniu wartości parametrów wejściowych obiektu rzeczywistego (wartości cech stanu, wartości cech określających warunki działania i cech niezmiennych diagnozowanego obiektu). Natomiast, **eksperyment bierny** polega na obserwacji sygnałów diagnostycznych i parametrów wejściowych obiektu rzeczywistego bez ingerencji w wartości tych parametrów. Spośród wielu metod identyfikacji modelu diagnostycznego można wymienić:

- metodę regresyjną [19],
- metodę eksploatacyjnej analizy modalnej [149],
- metodę z zastosowaniem modelu odwrotnego [36],
- metody wykorzystujące opis obiektu w przestrzeni stanów [9],
- metody wykorzystujące sieci neuronalne [91],
- logikę rozmytą [88].

Niezależnie od przyjętej metodyki tworzenia modeli diagnostycznych, głównym problemem jest właściwa identyfikacja modelu. W diagnostyce technicznej identyfikacji podlega

wejście zarówno modelu jak i modelowanego obiektu. Zazwyczaj nie można obserwować wszystkich wejść obiektu lub z pewnych względów należy pominąć niektóre wejścia. Wiąże się to ze zredukowaniem rzędu modelu, a nawet jego linearyzacją. W związku z tym model diagnostyczny nie może w pełni odwzorowywać zachowania obiektu. W tym celu tworząc model diagnostyczny należy przewidzieć możliwość dostrajania go poprzez zmianę wybranych parametrów konfiguracyjnych takiego modelu.



Rys. 2.2. Model globalny i model lokalny.  $DU$  - zbiór danych uczących,  $DU_n$  - podzbiór danych uczących

W badaniach diagnostycznych opartych na modelach, wyróżnia się **klasę modeli globalnych** i **klasę modeli lokalnych** (rys. 2.2). Model globalny opisuje dane uczące w pełnej przestrzeni ich wartości [87]. W związku z tym podczas identyfikacji modeli globalnych pojawiają się dwa skrajne problemy związane z nadmiarem danych uczących oraz ich brakiem. Zwykle wprowadzane uproszczenia pogarszają jakość ich działania. Z drugiej strony wystarcza jeden model do identyfikacji stanu całego obiektu. Natomiast model lokalny jest to model, który reprezentuje dane uczące tylko w wybranym obszarze przestrzeni wartości. W [36, 37, 45] pokazano, że zastosowanie modeli lokalnych jest rozwiązaniem bardziej korzystnym, niż zastosowanie modeli globalnych. Głównym argumentem są tutaj koszty identyfikacji modelu globalnego. Wśród innych zalet tworzenia modeli lokalnych, w odniesieniu do modeli globalnych, wymienia się:

- łatwiejszą identyfikację (związaną m.in. z mniejszą liczbą obserwowanych wejść i mniejszą liczbą wyznaczanych parametrów),
- zwykle wyższą dokładność.

Wadami modeli lokalnych jest to, że nie zawsze jest możliwość:

- reprezentowania obiektu we wszystkich warunkach działania,

- uwzględnienia wszystkich stanów obiektu.

Powyższe wady wiążą się z ich lokalnym charakterem. Rozwiązaniem tych problemów jest utworzenie zbioru modeli lokalnych, których wypadkową będzie możliwie zupełna reprezentacja warunków działania całego obiektu oraz możliwie zupełna reprezentacja stanów całego obiektu. Modele lokalne mogą być identyfikowane osobno, przy czym należy uwzględnić na wejściu identyfikowanego modelu wszystkie cechy sygnałów diagnostycznych całego obiektu, które mogą przyjmować formę dodatkowych wejść z danymi pochodzącymi od innych modeli lokalnych. Wynika z tego pewna trudność polegająca na tym, że nie zawsze będzie możliwa dokładna identyfikacja modelu. W związku z tym, jak wspomniano powyżej, należy przewidzieć możliwość strojenia modelu lokalnego.

Powyżej opisana koncepcja stanowi osobną klasę modeli, tzw. **wielowarstwowych modeli diagnostycznych**. Modele takie stosuje się, gdy występuje nadmierna liczba możliwych do wyznaczenia cech sygnałów diagnostycznych i/lub występuje duża liczba cech stanu na podstawie których identyfikowana jest klasa stanu [27].

Inną klasą modeli są **wielomodele** [157]. W tej klasie model diagnostyczny pokazany na rys. 2.1 zastępuje się zbiorem modeli diagnostycznych. Przy czym modele w tym zbiorze połączone są ze sobą w układzie równoległym. W związku z tym każdy model posiada taką samą porcję informacji na wejściu. Natomiast wyjściem wielomodelu jest wyjście pojedynczego modelu najlepiej reprezentującego stan badanej maszyny w rozpatrywanej chwili czasu. Wybór modelu następuje poprzez oszacowanie ilości informacji o stanie technicznym obiektu dostarczanej przez poszczególne modele. Zaletą wielomodeli jest to, że zastosowane modele mogą uzupełniać się nawzajem, polepszając tym samym skuteczność działania modelu diagnostycznego. Natomiast wadą jest to, że każdy model dostaje tę samą porcję informacji oraz to, że nie ma szczegółowych wytycznych wspomagających dobór parametrów mechanizmu wybierającego model najlepiej reprezentujący stan obiektu (problem oceny informacji o stanie). W celu uniknięcia tych niedogodności stosuje się dekompozycję (por. p. 2.4) jednego modelu globalnego na zbiór modeli lokalnych związanych z fragmentami obiektu. Podział rozpatrywanego obiektu na fragmenty nie musi być podziałem rozłącznym. Jest to możliwe w przypadku jeżeli przewidziano odpowiednie agregowanie lub uzgadnianie wyjść modeli lokalnych [157].

Na zakończenie tego punktu należy jeszcze wspomnieć o kilku ważnych klasach modeli używanych w diagnostyce technicznej:

**Model funkcyjny:** Model funkcyjny opisuje związki pomiędzy danymi za pomocą funkcji matematycznych (np. funkcja liniowa, funkcja wykładnicza itp.) [110, 154].

**Model statystyczny:** W modelu statystycznym dane reprezentowane są w postaci łącznych rozkładów gęstości prawdopodobieństw ich wartości [27].

**Model przekonania:** W modelu przekonania dane reprezentowane są w postaci rozkładów

przekonań o ich wartościach, gdzie modele przekonań są odpowiednikami modeli statystycznych, w których miary prawdopodobieństwa zastąpiono miarami subiektywnych przekonań [27].

**Model odwrotny:** Model odwrotny przekształca, za pomocą relacji diagnostycznych, symptomy diagnostyczne w klasy stanów technicznych [27]. Jest otrzymywany w wyniku odwracania znanego modelu matematycznego rozpatrywanego obiektu [87].

**Model logiczny:** Model logiczny jest budowany w oparciu o aparat logiki matematycznej. Obejmuje stwierdzenia, orzekające o własnościach i właściwościach modelowanego obiektu oraz wnioski, dotyczące stanu obiektu, które na ich podstawie można wyciągnąć, a dotyczące własności i zachowania się modelowanego układu [110, 120].

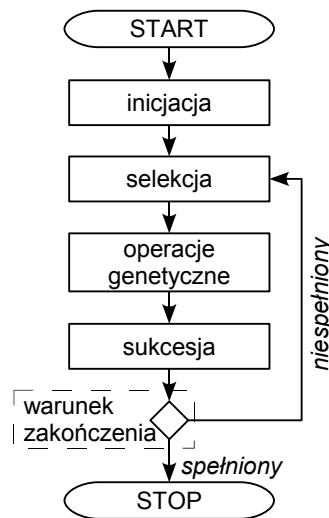
## 2.3. Doskonalenie modeli

Celem doskonalenia modeli, zarówno globalnych jak i lokalnych, jest poprawa jakości ich działania. Wynikiem działania modeli diagnostycznych jest wskazanie jednego lub zbioru stanów diagnozowanego obiektu. Zatem doskonalenie modeli powinno prowadzić do poprawy jakości stawianych diagnoz. Modele można doskonalic przez zmianę:

- struktury modelu (jego postaci),
- rodzaju parametrów modelu i ich wartości,
- liczby i rodzaju cech na wejściu modelu,
- zbioru przykładów uczących.

Ostatnia z wymienionych możliwości doskonalenia modeli może pośrednio wpływać na strukturę modelu oraz wartości parametrów modelu. Jak napisano w p. 2.2 identyfikowanie modeli globalnych jest dużo kosztowniejsze, niż identyfikowanie modeli lokalnych. Również doskonalenie modeli globalnych jest trudne i nie zawsze uzasadnione. Powodem jest przeszukiwanie wielowymiarowych przestrzeni, co wiąże się z przeprowadzeniem dużej liczby obliczeń.

W niniejszej pracy model globalny jest reprezentowany przez zbiór modeli lokalnych identyfikowanych oddzielnie. Modele lokalne związane są z określonym podzbiorem zawartym w zbiorze cech sygnałów diagnostycznych  $SG$  oraz z podzbiorem zawartym w zbiorze stanów obiektu  $S$ . W związku z tym postanowiono, że procesowi doskonalenia poddane zostaną modele lokalne. Zatem również przeprowadzona optymalizacja będzie optymalizacją lokalną. Wynika to z faktu, że optymalny zbiór danych otrzymany w wyniku doskonalenia jednego modelu lokalnego nie musi być optymalny dla innego modelu lokalnego, a tym bardziej dla modelu globalnego.



Rys. 2.3. Schemat algorytmu ewolucyjnego (na podstawie [71, 150])

Jedną z metod jest doskonalenie ewolucyjne z zastosowaniem algorytmu przedstawionego na rys. 2.3. Zastosowanie algorytmu ewolucyjnego wymaga określenia [4]:

- sposobu kodowania fenotypu w genotypie (sposobu reprezentacji potencjalnych rozwiązań),
- sposobu tworzenia populacji początkowej,
- funkcji oceniającej (funkcji przystosowania),
- sposobu selekcji i sukcesji osobników,
- sposobu prowadzenia operacji genetycznych,
- warunku (warunków) zakończenia działania algorytmu,
- wartości różnych parametrów używanych w algorytmie (rozmiaru populacji, prawdopodobieństwa użycia operatorów genetycznych itp.).

Bardzo ważnym elementem jest funkcja oceniająca, która ma decydujący wpływ na skuteczność działania algorytmu ewolucyjnego. Pomimo jej dużego znaczenia nie ma wytycznych na opracowanie jej postaci. Najczęściej funkcję oceniającą dobiera się indywidualnie na potrzeby rozpatrywanego zadania. Pozostałe elementy można dobrać zgodnie z wytycznymi zawartymi w literaturze (np. [4, 105]).

## 2.4. Dekompozycja obiektu

Dla potrzeb tworzenia modeli diagnostycznych obiektów technicznych przeprowadzana jest ich dekompozycja strukturalna (przestrzenna), związana z budową obiektu, i



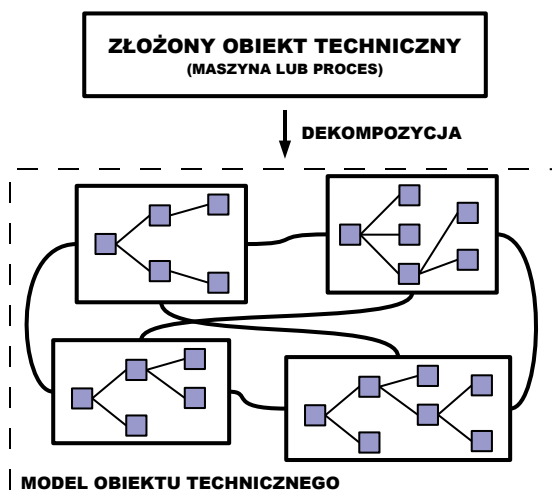
funkcjonalna, związana z działaniem obiektu [27, 92, 86, 89]. W wyniku dekompozycji otrzymujemy zbiór fragmentów obiektu  $o_i$ :

$$O = \{o_1, o_2, \dots, o_I\} \quad (2.1)$$

W przypadku maszyn, fragmentem obiektu może być podukład, zespół, element lub część. Dwa różne fragmenty obiektu, w zależności od przyjętego stopnia szczegółowości, mogą mieć na przykład wspólne elementy lub części. Ważne jest, żeby połączenie wszystkich fragmentów obiektu  $o_i$  w wyniku dało cały obiekt  $O$ :

$$O = \bigcup_{i=1}^I o_i \quad (2.2)$$

Pierwszy etap dekompozycji obiektów złożonych może zakończyć się utworzeniem struktury o charakterze rozproszonym. Dany fragment obiektu często można znów poddać dekompozycji. W ten sposób można tworzyć dalsze struktury rozproszone lub lokalne struktury hierarchiczne (rys. 2.4).



Rys. 2.4. Dekompozycja złożonego obiektu technicznego [133]

Dekompozycję złożonego obiektu prowadzi się do momentu, w którym dalszy podział nie wnosi nowych informacji mających wpływ na ocenę stanu modelowanego obiektu. Przykładem struktury rozproszonej może być zbiór maszyn na hali produkcyjnej, natomiast przykładem struktury hierarchicznej może być porządek: podukład, zespół, element i część, określony dla każdej z maszyn hali produkcyjnej. Należy zaznaczyć, że dekompozycja obiektu dla różnych poziomów szczegółowości może przyjmować raz formę dekompozycji strukturalnej, a raz formę dekompozycji funkcjonalnej.

**Przykład.** Przeprowadzając dekompozycję wybranego układu chłodzenia najlepszą formą będzie dekompozycja funkcjonalna. W pierwszym kroku należy wyróżnić bloki

funkcjonalne mające przydzielone zadania, np.: układ obiegu czynnika chłodzącego, którego zadaniem jest m.in. wymuszenie ruchu czynnika chłodzącego. Następnie, na drugim poziomie dekompozycji, można wyróżnić obiekty, które pełnią specjalne funkcje w układzie obiegu czynnika chłodzącego, np.: pompa (wymuszenie obiegu czynnika chłodzącego), zbiornik (gromadzenie zapasu/nadmiaru czynnika chłodzącego), przewody (doprowadzenie czynnika chłodzącego z jednego obiektu do drugiego obiektu), zawory (sterowanie parametrami przepływu czynnika chłodzącego), itd. Kolejny poziom dekompozycji może obejmować poszczególne zespoły/podzespoły funkcjonalne wchodzące w skład obiektów poziomu drugiego. W ten sposób można wyróżnić fragmenty obiektu pełniące określone funkcje, np.: łożysko toczne, którego zadaniem będzie zapewnienie ruchu obrotowego wirnika pompy. W przypadku wybrania dekompozycji strukturalnej należałoby uwzględnić odległości występujące pomiędzy obiektami, co doprowadziłoby do trudnej analizy tak reprezentowanego układu rzeczywistego. Z drugiej strony jeżeli rozpatrywanym obiektem będzie np. wirnik turbosespołu, to najwygodniej przeprowadzić wstępną dekompozycję strukturalną określając, m.in. położenie podpór łożyskowych, po to żeby wyróżnić zbiór fragmentów mających największy wpływ na rozpatrywany obiekt (tutaj przemieszczenie w rozpatrywanej podporze łożyskowej jest zależne od przemieszczeń w podporach sąsiednich).

Dekompozycja złożonego obiektu pociąga za sobą rzutowanie zbioru stanów  $S$  obiektu [89]. Do każdego fragmentu obiektu  $o_i$  przypisany jest podzbiór stanów  $s_i \subset S$ . Jeden stan elementarny może być przypisany do kilku fragmentów obiektu.

Ważne jest, żeby nie dzielić zbioru sygnałów diagnostycznych  $SG$ . Na podstawie wyróżnionego fragmentu obiektu tworzy się diagnostyczny model lokalny (p. 2.2). W trakcie identyfikacji takiego modelu wymagane jest, żeby na wejściu pojawił się możliwie liczny zbiór sygnałów diagnostycznych pochodzących z całego obiektu. Pewien podzbiór sygnałów diagnostycznych będzie pełnił rolę dodatkowych sygnałów niezbędnych do poprawy jakości identyfikowanego modelu lokalnego. Zatem podzbiory sygnałów diagnostycznych mogą mieć części wspólne. Powyższe założenia dotyczące podawania pełnego zbioru sygnałów diagnostycznych na wejście identyfikowanego modelu lokalnego oraz podawania sygnałów dodatkowych reprezentujących wzajemne oddziaływania fragmentów obiektu pozwala na indywidualne identyfikowanie modeli lokalnych z użyciem metod identyfikacji modeli globalnych.

## 2.5. Czas w diagnostyce

W diagnostyce technicznej rozróżnia się dwie klasy czasu [34, 39]:

- czas *mikro* ( $\tau$ ),
- czas *makro* ( $t$ ).

Czasem *mikro* przyjęto nazywać czas, w którym wyznaczone są chwilowe wartości cech sygnałów. Natomiast w czasie *makro* obserwowane są zmiany stanu diagnozowanego

obiektu. Zatem czas mikro jest czasem „znacznie krótszym” od czasu makro, a obydwa rodzaje czasów mogą należeć do dziedziny czasu *rzeczywistego* ( $\vartheta$ ) i mogą być rozpatrywane na wspólnej osi czasu.

## 2.6. Wyznaczanie wartości cech sygnałów diagnostycznych

Sygnały diagnostyczne, występujące w postaci przebiegu jakiejś wielkości fizycznej, są materialnymi nośnikami informacji o stanie obiektu [26, 5, 7]. W celu pozyskania informacji zawartej w sygnale, niezbędne jest jego odpowiednie opisanie. Wystarczającym opisem sygnału mogą być zbiory wartości cech, wyznaczanych na podstawie jego analizy w dziedzinie czasu, dziedzinie częstotliwości lub w dziedzinie modalnej, przy czym dziedziny te są sobie równoważne [39]. Dla potrzeb diagnostyki najbardziej pożądane są sygnały zdeterminowane, tzn. takie które można jednoznacznie opisać za pomocą zależności matematycznych, nie zawierających jakichkolwiek wielkości losowych lub sygnały losowe ergodyczne, tzn. sygnały losowe dla których potrafimy wyznaczyć cechy mając tylko jedną realizację takiego sygnału [39]. W rzeczywistych warunkach zawsze mamy doczynienia zarówno z sygnałami zdeterminowanymi jak i z sygnałami losowymi, które są opisywane za pomocą zbioru funkcji losowych lub zbioru zmiennych losowych (wartości sygnału losowego) [38, 5]. Sygnały zdeterminowane i losowe sygnały ergodyczne są opisywane za pomocą pewnych liczbowych cech punktowych (np. wartość skuteczna  $x_{RMS}$ ) lub funkcyjnych (np. rozkład gęstości mocy widma  $G_{xx}(f)$ ), natomiast dla sygnałów losowych wyznacza się oceny (estymatory  $\hat{x}$ ) tego sygnału (np. wartość oczekiwana wybranej cechy  $E\{x\}$ ). Sygnał losowy powinno się analizować na podstawie wszystkich realizacji takiego sygnału ( $N \rightarrow +\infty$ ). W praktyce jest to niemożliwe. Dlatego sygnały losowe opisuje się estymatorami, które są wyznaczane dla skończonej liczby realizacji tego sygnału ( $N < +\infty$ ).

Sygnały można analizować pod kątem zmian parametrów statystycznych oraz zmian parametrów przebiegu funkcji gęstości widmowej mocy sygnału. Najczęściej wyznaczanymi parametrami statystycznymi są [39, 89, 5, 7]:

- wartość średnia

$$\bar{x} = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x_{\alpha}(t) dt \quad (2.3)$$

- wariancja (odchylenie wartości zmiennej  $x$  od wartości średniej  $\bar{x}$ )

$$s^2(x) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T [x(t) - \bar{x}]^2 dt \quad (2.4)$$

- wartość średniokwadratowa (miara energii sygnału), której pierwiastkiem jest wartość skuteczna  $x_{RMS}$

$$\Psi_x^2 = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x^2(t) dt \quad (2.5)$$

Widmową gęstość mocy wyznacza się z funkcji autokorelacji określonej na analizowanym sygnale

$$R_{xx}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{t-T}^{t+T} x_\alpha(u) x_\alpha(u + \tau) du \quad (2.6)$$

gdzie:  $\tau$  - wartość opóźnienia

dokonując transformaty Fouriera

$$S_{xx}(f) = \int_{-\infty}^{+\infty} R_{xx}(\tau) e^{-j2\pi f\tau} d\tau \quad (2.7)$$

gdzie:  $\tau$  - wartość opóźnienia

Ponadto stosuje się bardziej zaawansowane metody analizy, jak [38]: analiza widmowa wyższych rzędów [122], analiza z zastosowaniem przekształcenia falkowego [147], analiza czasowo-częstotliwościowa [147], czy analiza z zastosowaniem przekształcenia Wignera-Ville'a.

Omówione powyżej cechy dotyczyły pojedynczego sygnału. Przeprowadza się również analizę z użyciem dwóch i więcej sygnałów, np. analizę korelacji wzajemnej  $R_{xy}(\tau)$ , kowariancję  $C_{xy}(\tau)$  lub wzajemną gęstość widmową  $G_{xy}(f)$ .

## 2.7. Metody wyboru cech sygnałów diagnostycznych

Niejednokrotnie rozpatrywany zbiór cech sygnałów diagnostycznych jest zbiorem bardzo licznym. Dlatego należy określić pewien zbiór cech sygnałów diagnostycznych, które będą związane z badanym obiektem lub wybranym aspektem działania tego obiektu. Ponadto, wybrane cechy powinny zawierać istotne informacje pozwalające jak najlepiej określić stan techniczny badanego obiektu. Inaczej mówiąc należy wskazać cechy relewantne, czyli cechy odpowiednie ze względu na rozpatrywany cel [28]. Zbiór cech relewantnych można wyznaczyć na dwa sposoby:

1. Z użyciem wiedzy specjalistów,
2. Z użyciem algorytmów obliczeniowych.

W literaturze można znaleźć wytyczne co do określania zbioru cech sygnałów diagnostycznych. W zależności od celu, któremu informacja zawarta w sygnałach ma służyć, wyodrębniamy [137]:

- informację użyteczną, na podstawie której może zostać postawiona diagnoza lub podjęte określone działanie,
- informację nadmiarową, po pominięciu której nie traci się nic na jakości diagnozy,
- informację bezużyteczną w interesującym nas kontekście, mogącą znaleźć zastosowanie w realizacji innych zadań,
- szum informacyjny utrudniający wyodrębnienie informacji użytecznej.

Zazwyczaj najmniejszą ilościowo grupę w stosunku do całości stanowi informacja użyteczna. W [19] zwraca się uwagę, że liczba symptomów (uwzględnianych cech) musi być nie mniejsza od liczby nadzorowanych uszkodzeń. Ponadto, symptomy te powinny być w miarę niezależne. Dzięki temu założeniu uzyskuje się dobrą rozróżnialność (selektywność) diagnozowanych uszkodzeń. Z drugiej strony liczba uwzględnianych cech nie może być zbyt duża [34]. W badaniach diagnostycznych, ze względu na rozpatrywanie skończonego zbioru obiektów, uwzględnienie nieodpowiednich cech powoduje pogorszenie rozróżnialności diagnozowanych uszkodzeń lub diagnozowanie błędnych uszkodzeń. Inaczej mówiąc wzrasta poziom szumu informacyjnego.

Na optymalizację zbioru uwzględnianych cech mają wpływ następujące czynniki [34]:

- informacja, która będzie stanowiła podstawę wyboru (*Co chcemy/powinniśmy wiedzieć?*),
- rodzaj wybieranych cech (*Czy wziąć cechy ze zbioru dostępnych cech lub czy na podstawie dostępnych cech utworzyć zbiór nowych cech?*),
- zależność między cechami (*Czy cechy są niezależne od siebie?*).

### **2.7.1. Wybór zbioru cech sygnałów diagnostycznych z użyciem wiedzy specjalistów**

Wiedza ekspertów specjalizujących się w diagnozowaniu maszyn jest bardzo cenna. Z drugiej strony nabyte doświadczenie niejednokrotnie trudno jest przedstawić w sformalizowanej postaci. Wiedza specjalistów bazuje przede wszystkim na doświadczeniu i intuicji. Pojawia się zatem problem zapisu wiedzy pochodzącej od specjalistów. W [110] opisano szereg metod opisu wiedzy deklaratywnej i proceduralnej. Najczęstszą formą pozyskiwania wiedzy od ekspertów są formularze (papierowe i/lub elektroniczne) oraz wszelkiego rodzaju analizy materiałów zarejestrowanych podczas działań specjalisty, np. obrazy wideo, fotografie, nagrania fonograficzne.

W [20] można znaleźć obszerne opracowanie metod diagnozowania stanu technicznego podstawowych elementów konstrukcyjnych oraz całych maszyn. Z przeprowadzonej analizy wynika, że podstawową wielkością niosącą najwięcej informacji o stanie technicznym obiektu jest temperatura. W wielu maszynach i urządzeniach pojawiające się

niesprawności znajdują odzwierciedlenie w zmianie wartości i/lub rozkładzie temperatury. Temperaturę można mierzyć kontaktowo (np. czujniki półprzewodnikowe) lub bezkontaktowo (np. pirometry, termografy). Analizując obrazy termalne (termograficzne), ukazujące promieniowanie podczerwone wysyłane przez diagnozowany obiekt, można zlokalizować miejsca wystąpienia niesprawności [64].

Działanie maszyny zwykle przejawia się w wykonywaniu ruchu pewnych jej elementów. Często jest to ruch obrotowy. Obok omówionej powyżej temperatury, ważnymi wielkościami są sygnały wibroakustyczne, a w tym przyspieszenia i prędkości drgań. Analizując cechy tych sygnałów w dziedzinie czasu i/lub częstotliwości można wskazać przyczyny uszkodzeń. Dla wielu maszyn, np.: wirnikowych maszyn przepływowych (sprężarki i pompy), turbozespołów, silników spalinowych wysokoprężnych i gaźnikowych, silników elektrycznych i obrabiarek, przekładni zębatych [6], sygnały wibroakustyczne są nośnikiem wielu symptomów i obok temperatury stanowią ważne źródło cech sygnałów diagnostycznych [20, 5, 5, 7]. Innych źródeł cech sygnałów diagnostycznych, w przypadku urządzeń posiadających w swojej strukturze elementy wirujące, dostarczają pomiary prędkości obrotowych, przesunięć (np. przemieszczeń promieniowych i wzdłużnych osi wałów) oraz mocy.

Kolejną grupę maszyn stanowią maszyny przepływowe. Tutaj, oprócz temperatury i drgań, ważnymi wielkościami są ciśnienia, przepływy, wydajności objętościowe, sprawności, moce elementów wykonawczych, czasy reakcji układu i trwania ruchów roboczych, a także poziomy cieczy w zbiornikach. Ponadto wykonuje się również analizę medium roboczego, np. badanie stanu oleju metodą ferrograficzną.

Ze względu na przeznaczenie, ważną klasą urządzeń poddawanych badaniom diagnostycznym są obrabiarki. W tej klasie urządzeń można wyróżnić wiele źródeł cech sygnałów diagnostycznych. Pomijając wielkości temperatur i sygnałów wibroakustycznych są to przede wszystkim: wielkości odkształceń korpusu, moce pobierane przez napędy, pozycjonowanie i siła mocowania przedmiotu oraz stan narzędzia i powierzchni obrabianej.

Inną klasę badań diagnostycznych wykonuje się w przypadku diagnozowania agregatów wielomaszynowych. Do takich badań należy m.in. ocena względnej osiowości korpusów zespołów maszyn [20].

### **2.7.2. Wybór zbioru cech sygnałów diagnostycznych z użyciem algorytmów obliczeniowych**

W przypadku, gdy nie posiadamy dostępu do źródła wiedzy dziedzinowej na temat badanego obiektu lub posiadany zbiór cech sygnałów diagnostycznych nie pozwala na skuteczne diagnozowanie uszkodzeń, należy użyć jednej z wielu metod automatycznego poszukiwania optymalnego zbioru cech sygnałów diagnostycznych. Metody te zwykle bazują na aparacie statystyki matematycznej. Często używa się takich przekształceń jak:

korelacja wzajemna, analiza wariancji (polegająca na wyznaczeniu statystyki testowej  $F$ -Snedecora i weryfikacji hipotezy zerowej o równości grup), użycie metod rangowych (polegających np. na wykonaniu testu Kruskalla–Wallisa oraz przeprowadzeniu weryfikacji hipotezy zerowej o równości grup), porównania wielokrotne średnich w grupach, testy Bonferroniego lub Tukeya–Scheff'ego itp.

W [138] zaproponowano metodę opartą na badaniu wrażliwości cech sygnałów diagnostycznych. Najbardziej ogólną definicją wrażliwości, uwzględniającą specyfikę diagnostyki i mającą na uwadze sugerowane klasy stanów jest definicja zaproponowana poniżej [138]:

*Wrażliwością*  $s_i^j$  wartości cech sygnałów  $W^j$ , na zmianę klasy stanu z  $B_i$  na inną, nazywamy względną zmianę wartości cech sygnałów  $W^j$  wynikającą ze zmiany tej klasy stanu.

Powyższej definicji odpowiada wzór [138]:

$$s_i^j = \frac{V(W^j|B_i)}{V(W^j|B)} \quad (2.8)$$

gdzie:

$B$  - zbiór wszystkich stanów;

$B_i$  - rozpatrywana klasa stanu do której może należeć jeden lub więcej stanów;

$W^j$  - zbiór wartości  $j$ -tej cechy sygnału;

$V(W^j|B_i)$  - wartość miary zmienności  $V$  cechy sygnału  $W^j$  wynikająca ze zmiany klasy stanu z  $B_i$  na inną i uwzględniającą cechy sygnału  $W^j$ ;

$V(W^j|B)$  - wartość miary zmienności  $V$  uwzględniająca cechy sygnału  $W^j$ .

Celem badań wrażliwości jest określenie w jakim stopniu zmienność wartości cech sygnałów jest zależna od klas stanu dla której ją wyznaczono, a w jaki stopniu zmienność ta jest przypadkowa. W tym celu wyznacza się pewne wzorce, które uznawane są za stany bazowe, a następnie służą one jako odniesienie do wyznaczania zmienności wartości badanych cech sygnałów.

Inną metodykę selekcji zbiorów cech istotnych przedstawiono w [94]. Sformułowana metoda redukcji liczby cech, składa się z następujących etapów:

**Etap 1** Przeprowadzenie testu występowania statystycznej istotności zmian wartości cechy, obliczanych dla realizacji sygnałów diagnostycznych pozyskiwanych w kolejnych punktach eksperymentu diagnostycznego,

**Etap 2** Przeprowadzenie badania wartości współczynnika korelacji pomiędzy parami cech,

**Etap 3** Przeprowadzenie badania występowania zależności ilościowych (funkcyjnych) pomiędzy cechami sygnałów a cechą decyzyjną, opisującą przynależność przykładów do klas stanu.

W przypadku, gdy dysponujemy sygnałami w dziedzinie częstotliwości badanie statystycznej istotności cech polega na tym, że testuje się charakterystyczne częstotliwości widma amplitudowego lub gęstości widmowej na tle całej realizacji badanego widma sygnału. Jeżeli wartość badanej cechy punktowej istotnie wyróżnia się na tle innych, to uznaje się ją za cechę, która może mieć wpływ na skuteczność rozpoznawania stanu technicznego [94].

Inna metoda statystyczna opiera się na badaniu funkcji korelacji pomiędzy wartościami cech. W metodzie tej analizuje się macierz współczynników korelacji. W przypadku pojawienia się cech skorelowanych usuwa się jedną z nich. Najczęściej do tego celu wyznacza się wartość średnią każdej z cech, a następnie, w trakcie porównania, usuwa się cechę o niższej wartości średniej, tzn. statystycznie mniej różniącą się od tła szumowego [94].

W kolejnej metodzie redukcję liczby cech uzyskuje się poprzez wyznaczenie zależności funkcyjnych występujących pomiędzy badanymi cechami [87]. Ten sposób wywodzi się z dziedziny odkryć wiedzy w bazach danych. Użycie tej metody polega na tym, że w pierwszym etapie definiuje się miarę  $V$  Cramera, określającą moc predykcji tablicy kontyngencji. Tablica taka jest budowana na podstawie wektorów wartości dwóch cech. W przypadku występowania zależności funkcyjnej miara  $V$  przyjmuje wartości bliskie 1, w przeciwnym przypadku wartość miary  $V$  jest bliska 0.

Zależności funkcyjnych pomiędzy badanymi cechami można poszukiwać metodą *BACON* – 3 [99, 98]. W tym celu definiuje się reguły heurystyczne oraz sytuacje ich użycia. W wyniku działania systemu otrzymujemy gotowe zależności funkcyjne pomiędzy zamiennymi wejściowymi. W tej metodzie jakość zdefiniowanych heurystyk bezpośrednio wpływa na skuteczność działania systemu.

Interesującą propozycją poszukiwania zbioru cech relewantnych jest metoda skalowania wielowymiarowego (ang. Multidimensional Scaling), która pozwala m.in. na przeprowadzenie wstępnej analizy licznego zbioru danych przedstawionych w postaci wykresu dwuwymiarowego [140]. Metoda ta realizuje odwzorowanie topograficzne  $n$ -wymiarowego zbioru danych w przestrzeń dwuwymiarową. Na powstałym obrazie zachowane są odpowiednie odległości pomiędzy wielkościami, odzwierciedlające różnice w pierwotnym zbiorze danych. Odwzorowanie topograficzne można przeprowadzić za pomocą m.in.: samoorganizującej się mapy cech Kohonena (ang. Kohonen Self-Organising Feature), metody GTM (ang. Generative Topographic Mapping), mapowania Sammon'a (ang. Sammon Mapping), metody NLM (ang. Non-Linear Mapping) lub niezależnej analizy składowych (ang. Independent Components Analysis).

Ostatnia opisana metoda automatycznego poszukiwania zbioru cech relewantnych wywodzi się z metod sztucznej inteligencji. Optymalizacja ewolucyjna [43], bo o niej mowa, polega na zastosowaniu algorytmu genetycznego [71, 4], który iteracyjnie doskonali jakość zbioru cech relewantnych poprzez faworyzowanie najlepszych cech za



pomocą pewnej funkcji oceny (patrz p. 2.3).

Należy zaznaczyć, że omówione metody nie wyczerpują tematu. Celem powyższej analizy jest pokazanie jak trudnym problemem, pomimo istnienia wielu rozwiązań, jest wskazanie zbioru cech sygnałów diagnostycznych przeznaczonych do diagnozowania uszkodzeń wybranego obiektu.

## 2.8. Warunki działania obiektu

Obiekt zawsze działa w określonych warunkach. Warunki działania obiektu są uzależnione przede wszystkim od jego sterowania i oddziaływania otoczenia, np.: sposób działania innych obiektów znajdujących się w sąsiedztwie, warunki posadowienia obiektu i warunki atmosferyczne [147, 8]. Zatem warunki działania  $w_i \in W$  opisuje pewien zbiór wartości cech, będących czynnikami zewnętrznymi, które mogą być związane ze strumieniami: zasilania, sterowania i zakłóceń (patrz: model maszyny jako systemu działającego w [19]). Zmiany warunków działania mają wpływ na wartości cech sygnałów diagnostycznych [123].

Ze względu na cel badań, obiekt techniczny można obserwować w nominalnych i przejściowych warunkach działania [20]. Przez nominalne warunki działania rozumiane są: stała prędkość obrotowa, stałe obciążenie (np. wydajność), stabilne temperatury wszystkich zespołów, stałe wielkości oddziaływań zewnętrznych (np. temperatura otoczenia, wilgotność) itp. Natomiast przejściowe warunki działania obiektu technicznego, umożliwiające obserwację odpowiedzi obiektu na różne, często niestacjonarne oddziaływania zewnętrzne i/lub wewnętrzne to przede wszystkim działanie obiektu w warunkach rozruchu i wybiegu [107], a także odpowiedź wywołana przez skokową zmianę jakiegoś czynnika, np. obciążenia. W przypadku maszyn wirnikowych, w warunkach rozruchu i wybiegu różne są stany i procesy obciążenia jej elementów, różne są skutki oddziaływania tłumienia (mechanicznego) elementów obserwowanej maszyny, różne czasy trwania tych operacji, z czym wiążą się różne wartości opóźnień/przyspieszeń ruchu obrotowego.

Określając warunki działania należy utworzyć zbiór możliwych warunków pracy badanego obiektu. Przykładowo dla turboszespołu można wyróżnić następujący zbiór warunków działania wraz z odpowiadającymi im przykładowymi symptomami:

- stan spoczynku turbiny, symptom: brak ruchu obrotowego - prędkość wirowania jest równa zero  $n = 0$ ,
- rozruch turbiny, symptom: wzrost prędkości wirowania  $n \rightarrow N$ ,
- praca nominalna turbiny, symptom: prędkość wirowania jest stała z niewielką tolerancją  $n = N \pm \delta N$ ,

- wybieg turbiny, symptom: spadek prędkości wirowania do zera  $n \rightarrow 0$ .

Identyfikując warunki działania obiektu musimy rozstrzygnąć, na podstawie cech, w jakich (aktualnie) warunkach działania (wyróżnionych w zbiorze możliwych warunków działania) działa badany obiekt, np.: *Czy turbina jest w fazie rozruchu?*, *Czy turbina jest w fazie wybiegu?*, *Czy turbina pracuje w warunkach nominalnych?*, itd. Żeby móc przeprowadzić proces identyfikacji warunków działania należy najpierw określić zbiór cech sygnałów diagnostycznych (symptomów). W przykładzie powyżej wskazano proste symptomy, które pozwalają na dokonanie identyfikacji podstawowych warunków działania turbozespołu. Na przykład analizując bieżącą wartość prędkości wirowania i jej wartości historyczne z przedziału czasu mikro można określić czy turbozespół jest w fazie rozruchu, w fazie wybiegu lub pracuje w warunkach nominalnych.

## 2.9. Charakterystyka wybranych klasyfikatorów

### 2.9.1. Układy wnioskujące systemów doradczych

#### Wstęp

System doradczy jest to program komputerowy przeznaczony do wykonywania specjalistycznych zadań, które wymagają profesjonalnej wiedzy i doświadczenia w stosowaniu tej wiedzy [40, 33, 32]. System doradczy składa się przynajmniej z:

- bazy wiedzy,
- bazy danych,
- układu wnioskującego,
- układu objaśniającego,
- układu sterującego dialogiem.

Baza wiedzy zawiera dane uzyskane w wyniku przeprowadzenia procesu pozyskiwania wiedzy. Metody pozyskiwania wiedzy diagnostycznej dzielą się na metody pozyskiwania wiedzy proceduralnej i wiedzy deklaratywnej [109, 108]. Wiedza proceduralna, określona najczęściej za pomocą procedur [159], jest pozyskiwana przede wszystkim od specjalistów w sposób bezpośredni lub pośredni (np.: przez analizę ich publikacji). Wiedza deklaratywna, dotycząca faktów, obiektów, relacji zachodzących pomiędzy obiektami itp., może być pozyskana zarówno od specjalistów jak i z baz danych (metody uczenia maszynowego lub metody automatycznego odkrywania wiedzy).

Więcej informacji na temat baz danych, układu objaśniającego i układu sterującego dialogiem w systemach doradczych można znaleźć w [40, 29, 111]. Szerszego omówienia wymaga układ wnioskujący, który często działa na podstawie reguł zgodnie z zasadami aparatu logiki klasycznej lub logiki wielowartościowej.

### Fakt

Fakt jest obiektem naszych obserwacji. Fakt w języku naturalnym przyjmuje formę zdania orzekającego opisującego pewną obserwację, np.:

fakt: *niski poziom cieczy w zbiorniku*

Fakt w postaci sformalizowanej zapisuje się jako trójkę:

$$\langle o, a, v \rangle \quad (2.9)$$

gdzie:  $o, a, v$  - obiekt (przedmiot obserwacji), atrybut, wartość.

Zatem, powyższy przykład faktu będzie zapisany następująco:

fakt:  $\langle o = \text{zbiornik}, a = \text{poziom cieczy}, v = \text{niski} \rangle$

Fakty opisują cechy charakterystyczne dziedziny problemu, istotne z punktu widzenia jego rozwiązania.

### Stwierdzenie

Stwierdzenie jest informacją o uznaniu wypowiedzi orzekającej o obserwowanych faktach lub reprezentującej określoną opinię [33]. Stwierdzenie składa się z treści oraz z wartości będącej miarą przekonania o prawdziwości tej treści. Treścią stwierdzenia jest fakt. Stwierdzenie zapisywane jest najczęściej jako czwórka uporządkowana:

$$\langle o, a, v, b \rangle \quad (2.10)$$

lub w formie rozwiniętej jako szóstka uporządkowana:

$$\langle o, a, v, w, t, b \rangle, \quad (2.11)$$

gdzie:  $o, a, v$  - obiekt, atrybut, wartość,  $t$  - czas, w którym jest rozpatrywany obiekt  $o$  (chwila lub odcinek czasu),  $b$  - ocena stopnia prawdziwości stwierdzenia,  $w$  - waga stwierdzenia, która może posłużyć jako podstawa porządkowania komunikatów wysyłanych do użytkownika systemu doradczego.

Ocena stopnia prawdziwości stwierdzenia  $b(x)$  lub inaczej ocena stwierdzenia jest to miara akceptacji wypowiedzi  $x$ . Najprostszą formą oceny stwierdzenia jest przyjęcie skali dwuwartościowej:

$$b(x) \in \{\text{TAK}, \text{NIE}\} \quad (2.12)$$

Innym sposobem jest ocena bazująca na rachunku prawdopodobieństwa lub modelu Bayesa (p. 3.3.1). Przyjmuje się umownie, że wartością stwierdzenia będzie prawdopodobieństwo  $p(x)$  prawdziwości wypowiedzi  $x$  stanowiącej treść stwierdzenia [25]:

$$b(x) = p[\langle o(x), a(x), v(x) \rangle] \in [0, 1] \quad (2.13)$$

Rozwinięciem powyższej oceny stopnia prawdziwości stwierdzenia jest wprowadzenie operatorów modalnych: *możliwe* ( $\Pi(x)$ ) i *konieczne* ( $N(x)$ ) [34].

Kolejnym sposobem wprowadzenia miar stopnia prawdziwości dla stwierdzeń jest wprowadzenie współczynnika pewności  $CF$  (ang. Certainty Factor) [34, 112]. Stopień pewności hipotezy  $y$  wyznaczany dla znanych warunków  $x$  jest równy

$$CF(y,x) = MB(y,x) - MD(y,x) \quad (2.14)$$

Miara  $MB(y,x)$  oznacza wzrost przekonania o prawdziwości hipotezy  $y$  na podstawie warunków  $x$ , natomiast miara  $MD(y,x)$  oznacza wzrost braku przekonania o prawdziwości stwierdzenia  $y$  na podstawie warunków  $x$ . Pomiędzy miarami  $MB(y,x)$  i  $MD(y,x)$  zachodzi relacja

$$MB(\neg y,x) = MD(y,x) \quad (2.15)$$

Na stwierdzeniach dopuszczalne jest wykonywanie operacji logicznych [25]: koniunkcji ( $\wedge$ , AND), alternatywy ( $\vee$ , OR), zaprzeczenia ( $\neg$ , NOT), a także agregacji [24] (p. 2.10.1) i akumulacji [29].

### Reguła

Regułą nazywa się pewną postać zapisu faktów. Reguła składa się z *przesłanek* i *konkluzji*. Przesłankami jak i konkluzjami są fakty lub stwierdzenia. Zatem reguła przyjmuje następującą postać:

$$\text{jeżeli } \textit{przesłanka} \text{ to } \textit{konkluzja} \quad (2.16)$$

Przesłanka może przyjmować formy bardziej rozbudowane składające się z kilku stwierdzeń połączonych spójnikami logicznymi (np. koniunkcji  $\wedge$ , alternatywy  $\vee$ ). Konkluzje składają się zwykle z jednego stwierdzenia.

### Wnioskowanie

Wnioskowanie jest to jedna z podstawowych odmian rozumowania obok sprawdzania, dowodzenia i wyjaśniania [156]. Wnioskować znaczy tyle co na podstawie uprzednio uznanych stwierdzeń (zdań, sądów) dochodzić do uznania nowego (dotąd nie uznawanego) stwierdzenia (zdania, sądu), lub wzmacniać pewność z jaką nowe stwierdzenie uznajemy [3]. Stwierdzenia na podstawie których dochodzimy do uznania lub wzmocnienia pewności nowego stwierdzenia nazywane są przesłankami, zaś stwierdzenie na ich podstawie uznane nazywany jest wnioskiem (konkluzją) (por. Reguła). Pomiędzy przesłankami a konkluzją nie musi zachodzić jakiś szczególny stosunek, a zwłaszcza jedno z nich nie musi być racją dla drugiego – wnioskowanie może być:

- a) pewne albo prawdopodobne,
- b) poprawne albo niepoprawne.

W logice klasycznej (dwuwartościowej) wnioskowanie związane jest z operatorem implikacji ( $\rightarrow$ ) [34]. Dla znanych stwierdzeń  $p$  i  $q$  implikacja tylko wówczas jest fałszywa, gdy  $p$  jest prawdziwe i  $q$  jest fałszywe. Implikację często zapisuje się w postaci reguły:

$$\text{jeżeli } p \text{ to } q \quad (2.17)$$

Należy podkreślić, że implikacja ( $p \rightarrow q$ ) nie oznacza wynikania jednego stwierdzenia ( $q$ ) z drugiego stwierdzenia ( $p$ ).

Logika klasyczna stosuje dwa podstawowe schematy wnioskowania [34]:

- *modus ponens* (sposób wnioskowania przez uznanie przesłanki): dla stwierdzeń  $p$  i  $q$ , jeżeli reguła  $p \rightarrow q$  jest prawdziwa i stwierdzenie  $p$  jest prawdziwe, to stwierdzenie  $q$  jest prawdziwe:

$$\frac{p \rightarrow q \quad \text{reguła} \\ p \quad \text{przesłanka}}{q \quad \text{wniosek}} \quad (2.18)$$

- *modus tollens* (sposób wnioskowania przez zaprzeczenie konkluzji): dla stwierdzeń  $p$  i  $q$ , jeżeli reguła  $p \rightarrow q$  jest prawdziwa i stwierdzenie  $q$  jest fałszywe, to stwierdzenie  $p$  jest fałszywe:

$$\frac{p \rightarrow q \quad \text{reguła} \\ \neg q \quad \text{przesłanka}}{\neg p \quad \text{wniosek}} \quad (2.19)$$

Powyższe schematy wnioskowań pozwalają na zastosowanie metody wnioskowania w przód (od znanych przesłanek) oraz wnioskowania wstecz (od znanych konkluzji, hipotez) [112]. Celem wnioskowania w przód jest wyznaczenie nieznanymi wartościami pewnych stwierdzeń, będących konkluzjami, na podstawie dostępnych wartości innych stwierdzeń, będących przesłankami, z użyciem dostępnych reguł z pewnego, zazwyczaj ograniczonego, zbioru reguł. Inaczej mówiąc, wnioskowanie w przód służy do diagnozowania [112].

Wnioskowanie wstecz polega na weryfikacji lub falsyfikacji znanego stwierdzenia, będącego konkluzją pewnej reguły, na podstawie weryfikacji prawdziwości stwierdzeń, będących przesłankami w tej regule. Inaczej mówiąc, wnioskowanie wstecz polega na weryfikowaniu prawdziwości hipotez.

### Wnioskowanie rozwinięte przybliżone

Wnioskowanie rozwinięte przybliżone charakteryzuje się tym, że [112]:

1. w regułach mogą wystąpić zanegowane stwierdzenia ( $b(x)$  i  $\neg b(x)$ ),
2. wartości stwierdzeń są wartościami przybliżonymi zapisanymi, np.: jako współczynniki pewności  $CF(x)$ ,

3. reguły mają przyporządkowane współczynniki pewności.

W trakcie procesu wnioskowania wyznaczane są współczynniki pewności dla konkluzji, jak i negacji konkluzji. Jeżeli wnioskowanie rozwinięte przybliżone będzie prowadzone dla dokładnych wartości stwierdzeń oraz zanegowane stwierdzenia nie będą dopuszczalne, to taki proces wnioskowania będzie nazywał się *wnioskowaniem elementarnym*. W przypadku, gdy konkluzja reguły ma wartość współczynnika pewności równą  $CF(x)$ , to konkluzja zanegowana  $\neg x$  będzie miała współczynnik pewności równy (przy założeniu, że  $CF(x) \in [0, 1]$ )

$$CF(\neg x) = 1 - CF(x) \quad (2.20)$$

Do celów wnioskowania rozwiniętego przybliżonego zalicza się [112]:

1. Wyznaczenie współczynników pewności konkluzji (stwierdzeń) wszystkich reguł dla początkowych warunków (stwierdzeń) o znanych współczynnikach pewności.
2. Wyznaczenie współczynnika wybranej hipotezy lub negacji tej hipotezy dla początkowych znanych wartości współczynników pewności warunków (stwierdzeń).

Współczynnik pewności reguły jest iloczynem współczynnika pewności samej reguły i współczynnika pewności koniunkcji lub alternatywy stwierdzeń (konkluzji) tej reguły

$$CF(z) = CF_{\text{reguły}} \cdot CF_{\text{konkluzji}} \quad (2.21)$$

W przypadku, gdy pojawią się dwie jednakowe konkluzje  $x$  i  $y$  o różnych współczynnikach pewności  $CF(x)$  i  $CF(y)$ , to wypadkowa wartość współczynnika pewności wynosi

$$CF(x, y) = CF(x) + CF(y) - CF(x)CF(y) \quad (2.22)$$

*Przykład*

Założmy, że mamy następujące fakty [120] (wzór 2.9):

**FAKT 1** ( $F_1$ )  $\langle$  łożysko, składowa podstawowa drgań, wzrost  $\rangle$

**FAKT 2** ( $F_2$ )  $\langle$  łożysko, amplituda składowej harmonicznej 0.5X, podwyższona  $\rangle$

**FAKT 3** ( $F_3$ )  $\langle$  łożysko, amplituda składowej harmonicznej 1.5X, podwyższona  $\rangle$

**FAKT 4** ( $F_4$ )  $\langle$  łożysko, amplituda składowej harmonicznej 2.5X, podwyższona  $\rangle$

**FAKT 5** ( $F_5$ )  $\langle$  wał, przycieranie, występuje  $\rangle$

Przypisując każdemu faktowi  $F_i$  stopień przekonania o jego prawdziwości  $b(x_i)$  otrzymamy zbiór pięciu stwierdzeń (wzór 2.10):

**STW. 1** ( $z_1$ )  $\langle$  łożysko, składowa podstawowa drgań, wzrost,  $b(x_1)$   $\rangle$

**STW. 2** ( $z_2$ )  $\langle$  łożysko, amplituda składowej harmonicznej 0.5X, podwyższona,  $b(x_2)$   $\rangle$

**STW. 3** ( $z_3$ )  $\langle$  łożysko, amplituda składowej harmonicznej  $1.5X$ , podwyższona,  $b(x_3)$   $\rangle$

**STW. 4** ( $z_4$ )  $\langle$  łożysko, amplituda składowej harmonicznej  $2.5X$ , podwyższona,  $b(x_4)$   $\rangle$

**STW. 5** ( $z_5$ )  $\langle$  wał, przycieranie, występuje,  $b(x_5)$   $\rangle$

Mając zbiór stwierdzeń możemy przedstawić związki pomiędzy nimi w postaci reguły (wzór 2.16):

**REGUŁA 1** ( $R_1$ ) jeżeli  $z_1 \wedge z_2 \wedge z_3 \wedge z_4$  to  $z_5$


Na podstawie wartości stopni przekonania stwierdzeń  $z_1, z_2, z_3, z_4$  będących przesłankami oraz przyjętej metody wnioskowania można wyznaczyć wartość stopnia przekonania o prawdziwości konkluzji reguły  $R_1$ , a tym samym całej reguły (wzór 2.21).

### Logika rozmyta

W 1965 roku Lotfi A. Zadeh opublikował pracę pt. „Fuzzy Sets” [165], w której zawarł opis teorii zbiorów rozmytych oraz logiki rozmytej. Jednym z podstawowych pojęć tej teorii jest pojęcie zbioru rozmytego. Jeśli  $X$  oznacza zbiór elementów, to zbiór rozmyty  $A$  można zdefiniować na elementach zbioru  $X$  jako parę:

$$A = \{x, \mu(x) | x \in X\} \quad (2.23)$$

gdzie:  $\mu_A(x)$  - jest funkcją przynależności elementów  $x$  do zbioru  $A$ .



Rys. 2.5. Wykres funkcji sigmoidalnej (tangens hiperboliczny) [111]

Funkcja przynależności reprezentuje stopień przynależności elementu  $x \in X$  do zbioru  $A$ . W klasycznym przypadku wartość funkcji przynależności zawiera się w przedziale  $[0, 1]$ . Możliwe jest rozszerzenie tego przedziału do innych wartości, np.  $[-1, 1]$ . Jako funkcje przynależności stosuje się m.in. następujące postacie: singleton, trójkąt, trapez lub sigmoida. Singleton jest najprostszą funkcją przynależności i jest zdefiniowana następująco:

$$\mu_A(x) = \begin{cases} 1 & \text{dla } x \in A \\ 0 & \text{dla } x \notin A \end{cases} \quad (2.24)$$

Natomiast funkcja sigmoidalna (rys. 2.5), inaczej tangens hiperboliczny, ma bardziej rozwiniętą postać:

$$\mu_A(x) = \begin{cases} 0 & \text{dla } a \leq x \leq \alpha \\ 2 \left( \frac{x-\alpha}{\gamma-\alpha} \right) & \text{dla } \alpha \leq x \leq \beta \\ 1 - 2 \left( \frac{x-\gamma}{\gamma-\alpha} \right)^2 & \text{dla } \beta \leq x \leq \gamma \\ 1 & \text{dla } \gamma \leq x \leq b \end{cases} \quad (2.25)$$

gdzie:  $a, b, \alpha, \beta, \gamma$  są liczbami rzeczywistymi oraz  $a \leq \alpha \leq \gamma \leq b$  oraz  $\beta = \frac{\alpha+\gamma}{2}$ .

Zastosowanie logiki rozmytej w procesie wnioskowania składa się z trzech etapów [89, 23]:

**Etap 1** Rozmywanie (fuzyfikacja) wartości liczbowych - tworzenie wartości jakościowych.

**Etap 2** Wnioskowanie rozmyte.

**Etap 3** Zamiana zbioru rozmytego na wartość liczbową (defuzyfikacja).

Rozmywanie polega na przekształceniu wielkości z dziedziny ilościowej na wielkości z dziedziny jakościowej reprezentowanej przez zbiory na podstawie opisujących je funkcji przynależności. Wnioskowanie rozmyte polega na wyznaczaniu w dziedzinie jakościowej wartości wyjść na podstawie wejść za pomocą zbioru reguł rozmytych. Proces wnioskowania rozmytego jest rozszerzeniem wnioskowania rozwiniętego przybliżonego opisanego wcześniej.

Reguła rozmyta ma następującą postać:

$$\text{jeżeli } \{\text{przesłanka}, \mu(\text{przesłanka})\} \text{ to } \textit{konkluzja} \quad (2.26)$$

Reguła rozmyta może posiadać pewną progową wartość stopnia zapłonu, po przekroczeniu której *konkluzja* reguły jest spełniona (przyjmuje wartość równą 1). Progowa wartość zapłonu reguły jest ustalana empirycznie lub z pomocą eksperta. W innym przypadku wartość stopnia zapłonu reguły może być uznawana za stopień pewności spełnienia *konkluzji*. Wartość stopnia zapłonu jest obliczana na podstawie wartości stopni spełnienia *przesłanek*:

$$\mu(\{\textit{przesłanki}\}) = \mu(\textit{przesłanka}_1) \oplus \mu(\textit{przesłanka}_2) \oplus \dots \oplus \mu(\textit{przesłanka}_n) \quad (2.27)$$

Wartość wypadkową wszystkich *przesłanek* można wyznaczyć za pomocą operatorów t-normy (np. *PROD* - wyznacza iloczyn wartości stopni spełnienia *przesłanek* lub *MIN* - wyznacza minimalną wartość ze zbioru wartości stopni spełnienia *przesłanek*) [126, 89] lub za pomocą operatora średniej arytmetycznej (*MEAN*) (por. z metodami agregacji informacji opisanymi w p. 2.10.1).



## 2.9.2. Tablice decyzyjne

Tablica decyzyjna składa się z trzech obszarów: wierszy warunków (C), wierszy działań (A) i wierszy wyjść (E) [119, 40] (rys. 2.6).

<i>obszar opisów warunków</i>	obszar warunków C
<i>obszar opisów działań</i>	obszar działań A
<i>obszar opisów wyjść</i>	obszar wyjść E

Rys. 2.6. Ogólna postać tablicy decyzyjnej

Poszczególne kolumny tablicy są regułami decyzyjnymi posiadającymi własne wartości warunków (domyślnie połączonych ze sobą spójnikami koniunkcji  $\wedge$ ) (C), po spełnieniu których wykonywane jest przypisane działania (A) oraz wykonywana jest operacja związana z obsługą wyjścia (E), np. wywołanie innej tablicy decyzyjnej lub zakończenie działania. Reguły są testowane w kierunku „od lewej do prawej”. Liczba warunków (zmiennych zdaniowych) dla każdej reguły jest stała, przy czym dopuszcza się, że dany

Tab. 2.1. Przykład tablicy decyzyjnej [34, 31]

	TREŚĆ STWIERDZENIA	R1	R2	R3	R4	R5	R6	R7
C1	Występują drgania samowzbudne o częstotliwości równej około 50 % częstotliwości wirowania wału.	Y	N	-	N	N	Y	Y
C2	Temperatura oleju jest zbyt wysoka.	Y	Y	Y	N	-	-	N
C3	Temperatura oleju jest zbyt niska.	-	-	Y	N	Y	Y	N
C4	Panewka łożyska ma przekrój eliptyczny.	-	-	-	-	-	-	N
A1	Zmniejszyć luzy promieniowe.						X	
A2	Zwiększyć luzy promieniowe.		X					
A3	Zmniejszyć natężenie oleju przepływającego przez łożysko.					X		
A4	Przeprowadzić weryfikacyjne obliczenia cieplne łożyska.	X						
A5	Zastosować panewki o przekroju eliptycznym.							X
E1	Błąd.			X				
E2	Koniec.	X	X		X	X	X	X

warunek przyjmuje wartość *bez znaczenia*. Każdy warunek może przyjmować wartości z przypisanego mu skończonego zbioru wartości. W najprostszej postaci warunek będzie posiadał trzy wartości: *TAK*, *NIE*, *bez znaczenia*. Działanie, przypisane do danej reguły, może być wykonywane lub nie, przy czym działania są wykonywane w kolejności „z góry na dół”.

W tablicy decyzyjnej nie mogą pojawić się reguły sprzeczne (posiadające te same warunki, lecz różne działania) oraz reguły nadmiarowe (posiadające te same warunki i te same działania). Reguły można łączyć ze sobą zastępując je nowymi regułami. Warunkiem łączenia reguł jest, żeby łączone reguły posiadały ten sam ciąg działań i różniły się wartościami tylko w jednym warunku.

Przykładową postać tablicy pokazano w tab. 2.1. Tworzenie tablicy decyzyjnej jest poprzedzone procesem gromadzenia treści stwierdzeń dla wartości warunków (C) i działań (A). W drugim etapie budowane są reguły (R). W ostatniej fazie tablica powinna zostać zweryfikowana poprzez wyliczenie odpowiednich wskaźników. Dla tablic decyzyjnych wyznacza się szereg cech statystycznych, np.: ważoną liczbę odpowiedzi (WDC), określającą które warunki mają najczęściej wpływ na decyzję lub wykaz dominancji (DOM), który pokazuje, które warunki mają tendencję do dominowania nad pozostałymi. Można również zbadać mechaniczną doskonałość tablicy, czyli kompletność zbioru reguł, wg wzoru:

$$\sum_j CC_j = \prod_i M_i \quad (2.28)$$

gdzie:

$CC_j$  - liczba kolumnowa, która określa ile elementarnych reguł zawiera reguła złożona;  
 $M_i$  - liczba modułowa, która określa liczbę wartości przyjmowanych przez warunki.

Budowę tablicy, przede wszystkim w trakcie tworzenia zbioru reguł, można przyspieszyć dzięki użyciu metod pozyskiwania i odkrywania wiedzy [109, 108].

Korzystanie z gotowej tablicy decyzyjnej polega na ustaleniu wartości stwierdzeń warunków C i wykonaniu na ich podstawie działania A. Działanie A jest konkluzją koniunkcji warunków C w danej regule R. W celu ułatwienia tworzenia i używania tablic decyzyjnych można skorzystać z dedykowanego oprogramowania, np. programu CLIPS [51].

### 2.9.3. Metody klasyfikacji i grupowania

Metody klasyfikacji i grupowania są przeznaczone do rozpoznawania wzorców (ang. pattern recognition) [145]. Rozpoznawanie wzorców to proces określania postaci wzorca i klasyfikacji tego wzorca na podstawie cech charakterystycznych [89]. Metod klasyfikacji i grupowania używa się m.in. do sprawdzania zbiorów danych pod kątem występowania w nich określonych wzorców oraz redukcji liczby danych. Możliwe jest również określanie stopnia podobieństwa z jakim badany zbiór danych pasuje do danego wzorca. Umożliwia

to przeprowadzenie procesu przybliżonej klasyfikacji i grupowania.

Ze względu na przeznaczenie rozróżnia się [48, 151]:

- *Algorytmy grupowania*, gdzie grupowanie jest to podział zbioru elementów na podzbiory tak, by podobieństwo elementów należących do jednego podzbioru było największe, a elementów należących do różnych podzbiorów najmniejsze (otrzymane podzbiory zwykle nazywane są grupami lub klasami),
- *Algorytmy klasyfikacji*, gdzie klasyfikacja to dwuetapowy proces:

**Etap 1** Budowa klasyfikatora (np. zbiór reguł) opisującego wyróżnione, wspólne cechy wejściowego zbioru klas,

**Etap 2** Zastosowanie klasyfikatora w procesie przydzielenia nieznanym elementom do wcześniej zdefiniowanych klas na podstawie wartości pewnych cech charakterystycznych wspólnych dla wszystkich klas.

Zarówno wśród algorytmów klasyfikacji jak i metod grupowania można wymienić metody [145]:

- bazujące na miarach odległości (tzw. metody minimalno-odległościowe), np.: metoda najbliższego sąsiada [166], metoda  $k$  najbliższych sąsiadów, metoda drzewa minimalnego, algorytm MMD;
- bazujące na miarach podobieństwa, np.: procedury hierarchiczne z miarą podobieństwa (procedura aglomeracyjna, procedura dzielenia) i algorytm iteracyjny z miarą podobieństwa [141].

W [23] odległość pomiędzy elementami  $x$  i  $y$  w przestrzeni cech ilościowych  $V$  definiuje się jako wartość funkcji  $d(x,y)$  zwanej funkcją odległości, takiej że:

$$d : V \times V \rightarrow \{r \in R^1 : r \geq 0\}, \quad (2.29)$$

oraz spełniającej warunki

$$\begin{aligned} & \forall_{x,y \in V} [d(x,x) \leq d(x,y)] \\ & \forall_{x,y \in V} [d(x,y) = d(y,x)] \\ & \forall_{x,y,z \in V} [d(x,z) \leq d(x,y) + d(y,z)] \end{aligned}, \quad (2.30)$$

gdzie  $R^1$  jest zbiorem liczb rzeczywistych.

Najprostszą funkcją odległości jest odległość euklidesowa:

$$d^2(x,y) \stackrel{d}{=} (x-y)(x-y)^T \quad (2.31)$$

Inne funkcje odległości, to: odległości Hamminga (inaczej odległość Manhattan)  $d^1$ , odległość Canberra  $d^1$ , odległości Czebyszewa  $d^\infty$  oraz uogólniona miara odległości między dwoma punktami - odległość Minkowskiego:

$$d^m(x, y) = \left( \sum_{i=1}^n |x_i - y_i|^m \right)^{\frac{1}{m}} \quad (2.32)$$

Zmieniając wartość metryki  $m$  można przekształcić funkcję odległości Minkowskiego w inne postacie funkcji odległości wymienione powyżej. Na przykład, gdy  $m = 2$ , to otrzymujemy odległość euklidesową.

Podobieństwo elementów  $x, y \in V$  jest wartością funkcji  $h(x, y)$  nazywanej funkcją podobieństwa, takiej, że [34]:

$$h : V \times V \rightarrow \{r \in \mathbb{R}^1 : 0 \leq r \leq 1\}, \quad (2.33)$$

i spełniającej warunki:

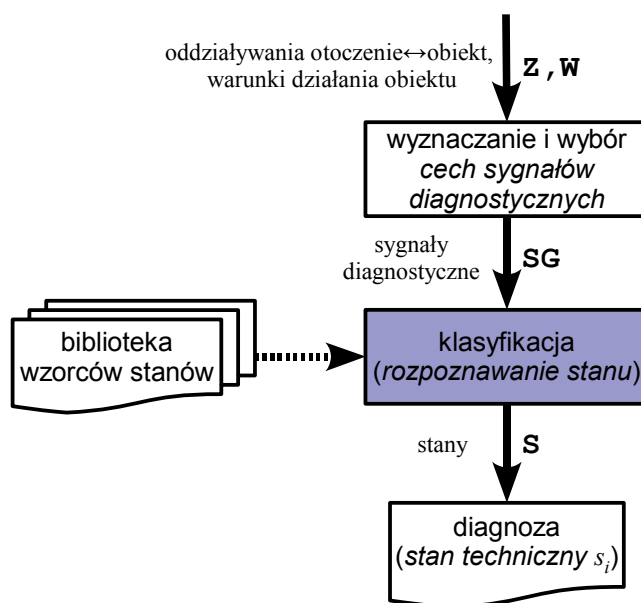
$$\begin{aligned} \forall_{x, y \in V} [h(x, y) \leq h(x, x)] \\ \forall_{x, y \in V} [h(x, y) = h(y, x)] \end{aligned} \quad (2.34)$$

Funkcję podobieństwa można określić z użyciem funkcji odległości, jako  $h(d)$  ( $d$  - jest wartością funkcji odległości). Przy czym dla  $d = 0$  funkcja ma wartość maksymalną (zwykle równą 1), czyli  $h(0) = 1$ . Bezpośrednio podobieństwo można wyznaczyć na przykład z funkcji cosinusa kąta między wektorami  $x$  i  $y$  w przestrzeni  $V$ :

$$h(x, y) = \frac{xy^T}{\sqrt{xx^T} \cdot \sqrt{yy^T}} \quad (2.35)$$

Jakość procesu grupowania sprawdza się za pomocą ilorazu średniej odległości elementów w grupie i średniej odległości grup lub za pomocą ilorazu sumy momentów bezwładności grup i momentu bezwładności wszystkich elementów. W procesie klasyfikacji ocenie jakości poddaje się klasyfikator. Na jakość klasyfikatora mają wpływ dane uczące na podstawie których taki klasyfikator się buduje oraz dane testujące, które służą do sprawdzenia poprawności klasyfikacji. Wyniki klasyfikacji porównuje się z wynikami grupowania i na tej podstawie ocenia się jakość klasyfikatora.

W [133] pokazano, że metody grupowania bazujące na miarach podobieństwa wspomagają dekompozycję obiektu na fragmenty (p. 2.2). Zbiór wejściowy zawierał oceny jakości informacji wymienianych pomiędzy prostymi systemami wnioskującymi, rozpoznającymi tylko jeden stan (rodzaj uszkodzenia), połączonymi w sieć. W wyniku przeprowadzonych badań pokazano, że użycie metod grupowania jest równie skuteczne jak podział obiektu na fragmenty dokonany przez eksperta.

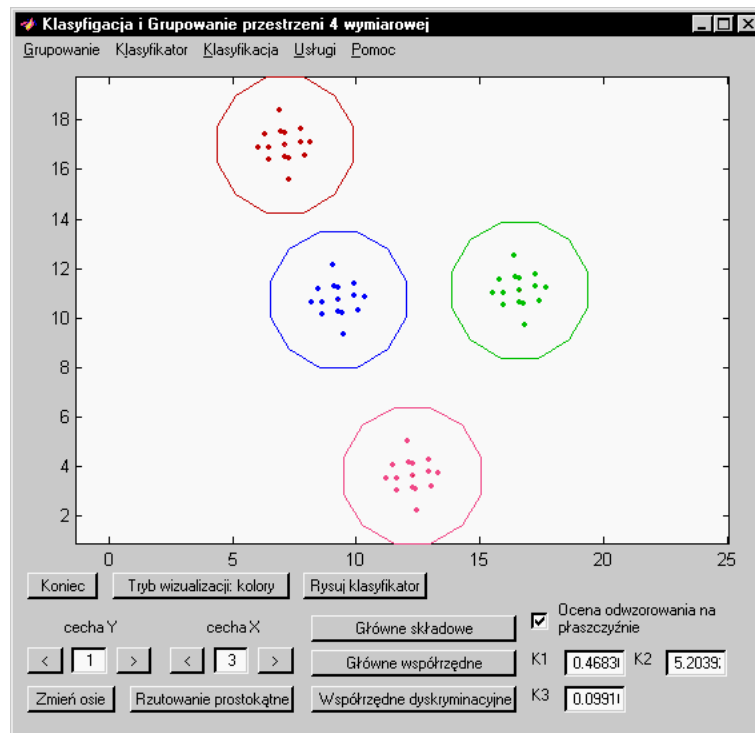


Rys. 2.7. Rozpoznawanie stanu metodami klasyfikacji (na podstawie [89])

Metod klasyfikacji i grupowania można również użyć do określania stanu technicznego lub warunków działania. Polega to na wykonaniu następujących kroków (rys. 2.7):

1. Zdefiniować zbiór  $S$  klas stanów technicznych  $s_i$  analizowanego obiektu.
2. Wybrać istotne (najbardziej wrażliwe) cechy obserwowanych sygnałów diagnostycznych oraz wskazać aktualne warunki działania obiektu.
3. Przeprowadzić grupowanie wartości wybranych cech sygnałów diagnostycznych na zadaną liczbę grup, która jest równa liczbie elementów zbioru  $S$  powiększonej o klasę „nie rozpoznano stanu”.
4. Utworzyć bibliotekę wzorców klas stanów (np. znaleźć przedstawicieli grup) i przyporządkować im nazwy elementów zbioru  $S$ .
5. Zbudować klasyfikator, który będzie zawierał reguły klasyfikacji.
6. Zweryfikować jakość klasyfikatora.

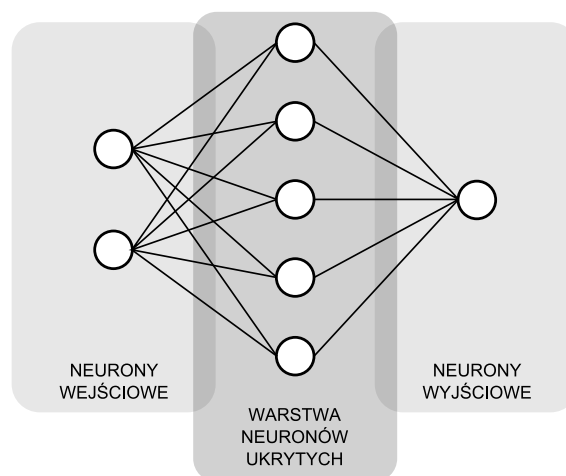
Wstępną ocenę zbioru danych można przeprowadzić z użyciem wyspecjalizowanych narzędzi, np. programu „Klasyfikacja i Grupowanie” [130], który jest dodatkiem do programu MATLAB [103]. Na rys. 2.8 pokazano główne okno programu, a w nim zbiór danych podzielony na cztery klasy (grupy).



Rys. 2.8. Przykład programu wspomagającego proces klasyfikacji i grupowania [130]

## 2.9.4. Sieci neuronalne

Sieci neuronalne należą do grupy układów nieliniowych, zdolnych do równoległego przetwarzania informacji [101]. Sieć neuronalna zbudowana jest z neuronów, jednostek przetwarzających informacje i połączeń pomiędzy neuronami (rys. 2.9) [144]. Każdy



Rys. 2.9. Ogólna postać sieci neuronalnej

neuron jest połączony z pewną liczbą innych neuronów. Sieci neuronalne przechowują informację dzięki możliwości wpływania na strukturę, poprzez zmianę wartości wag  $w_{ij}$  połączeń pomiędzy neuronami. Każdy neuron opisywany jest przez położenie w sieci, układ połączeń z innymi neuronami, funkcję przejścia (np.: funkcja liniowa, funkcja skoku, funkcja sigmoidalna (rys. 2.5) itp.) oraz stanami wewnętrznymi. Samą sieć możemy scharakteryzować przez strukturę rozmieszczenia neuronów i połączenia pomiędzy nimi, sposób przekazywania informacji oraz metodę trenowania. Wśród najczęściej stosowanych rodzajów sieci można spotkać perceptron wielowarstwowy, sieć Hopfielda i sieć Hamminga.

Działanie sieci polega na przekształceniu wartości atrybutów wejściowych  $x_i$  na wartości atrybutów wyjściowych  $y_j$ . Ogólnie można zapisać, że wartości wyjść są wyznaczone ze wzoru:

$$y_j = \sum_{i=1}^n w_{ij}x_i \quad (2.36)$$

Proces uczenia sieci, nazywany trenowaniem, polega na dobraniu wartości wag  $w_{ij}$  połączeń pomiędzy neuronami. Trenowanie sieci odbywa się z nauczycielem lub bez nauczyciela. W pierwszej metodzie nauczyciel wymusza postępy przez minimalizację błędu pomiędzy wartościami otrzymywanymi a wartościami wzorcowymi. Natomiast w drugiej metodzie sieć uczy się bezpośrednio na danych wejściowych.

Ze względu na przepływ informacji sieci neuronalne dzieli się na sieci [146]:

- jednokierunkowe, o stałym kierunku przepływu (ang. *feed forward networks*),
- rekurencyjne; sieci ze sprzężeniem zwrotnym,
- komórkowe, w których neurony są ustawione w wiersze i kolumny.

Najczęściej używane są sieci jednokierunkowe oraz sieci rekurencyjne. Przykład sieci jednokierunkowej pokazano na rys. 2.9. Sieć tego typu stosowano np. do poszukiwania cech sygnałów dodatkowych, tzn. cech oddziaływań wirtualnych lub ukrytych występujących pomiędzy modelami lokalnymi, pozwalających na rozprzęgnięcie tych modeli [150]. Warstwa wejściowa ma za zadanie przekazać wartości parametrów wejściowych do warstwy ukrytej lub, gdy nie ma takiej, bezpośrednio do warstwy wyjściowej. Każdy neuron warstwy  $l$  ukrytej i wyjściowej przekształca własne wartości wejściowe  $x_i$ , będące wartościami wyjściowymi warstwy poprzedniej  $l - 1$ , na własne wartości wyjściowe  $x_j$ , będące wartościami wejściowymi  $x_i$  warstwy następnej  $l + 1$  lub wartościami wyjściowymi  $y_j$  całej sieci neuronalnej, zgodnie ze wzorem:

$$x_{l,j} = \sum_{i=1}^n w_{l,ij}x_{l-1,i} \quad (2.37)$$

gdzie:

$x$  - wartość wejściowa lub wyjściowa neuronu,

$l$  - nr warstwy,  
 $n$  - liczba neuronów w warstwie  $l$ ,  
 $i$  - nr neuronu w warstwie  $l$ ,  
 $j$  - nr neuronu w warstwie  $l + 1$ .

W diagnostyce sieci neuronalne najczęściej są używane jako klasyfikatory. Stąd też bardzo dobrze nadają się do zastosowania w procesie identyfikacji stanu fragmentu obiektu lub jego warunków działania. W [153] można znaleźć przykład zastosowania sieci neuronalnej do detekcji zmian i rozpoznawania stanu manipulatora robota.

Identyfikacja stanu lub warunków działania za pomocą sieci neuronalnej wymaga podania na wejście cech sygnałów diagnostycznych. Proces trenowania sieci rozpoczyna się od utworzenia zbioru danych uczących  $DU$ , który zawiera wektory wartości cech sygnałów diagnostycznych i odpowiadające im stany techniczne obiektu (lub warunki działania). Następnie sieć jest trenowana według zadanej strategii, np. metodą propagacji błędu wstecz (ang. Back-propagation). Po przeprowadzeniu treningu, można przejść do testowania sieci za pomocą zbioru danych testujących  $DT$  i wyznaczenia parametrów jakościowych klasyfikacji. Należy pamiętać, że uzyskana struktura sieci i wartości wag połączeń pomiędzy neuronami nie odwzorowują żadnej ze struktur modelowanego obiektu.

Sieci neuronalne posiadają następujące zalety:

- zdolność tworzenia uogólnień, czyli aproksymacja dowolnych, ciągłych, nieliniowych zależności [114],
- przetwarzają niekompletne dane,
- wynikiem ich działania mogą być wartości przybliżone,
- równoległe przetwarzanie danych, które skraca czas klasyfikacji,
- zdolność do adaptacji.

Wśród wad można wymienić:

- złe dane uczące i źle przeprowadzony proces trenowania może doprowadzić do zbytńskiego dopasowania sieci do danych uczących, co powoduje zanikanie zdolności tworzenia uogólnień,
- brak algorytmów zastosowania sieci neuronalnych w zależności od rozpatrywanego problemu, jedynie wytyczne i uwagi praktyczne.



## 2.10. Wybrane metody uzgadniania opinii

### 2.10.1. Agregacja opinii

Agregacją opinii nazywa się proces prowadzący do wypracowania nowej, wypadkowej opinii (konkluzji, decyzji) na podstawie opinii wejściowych [24]. Agregację przeprowadza się za pomocą, tzw. *operatorów agregacji* ( $\oplus$ )

$$y = x_1 \oplus x_2 \oplus \cdots \oplus x_n \quad (2.38)$$

gdzie:

$x_i$  - agregowane opinie;

$y$  - rezultat agregacji.

W odróżnieniu do uzgadniania opinii, agregacja jest procesem jednokrotnym, tzn. agregowane opinie są argumentami operatora agregacji na podstawie których wyznaczana jest opinia wypadkowa. Natomiast uzgadnianie opinii jest procesem iteracyjnym, w wyniku którego opinia wypadkowa jest wypracowywana pomiędzy źródłami opinii.

Operator agregacji jest to funkcja matematyczna, która powinna spełniać niżej wymienione kryteria [104, 67, 72, 59].

Warunki brzegowe: Jeżeli przyjąć, że  $x \in [0, 1]$ , to wartość zwracana przez operator agregacji również musi zawierać się w przedziale  $[0, 1]$

$$\forall x \in [0, 1] : 0 \oplus 0 \oplus \cdots \oplus 0 = 0 \quad (2.39)$$

oraz

$$\forall x \in [0, 1] : 1 \oplus 1 \oplus \cdots \oplus 1 = 1 \quad (2.40)$$

Monotoniczność: W przypadku, gdy pewne zmienne  $x_i$  i  $y_i$  są związane relacją  $x_i \leq y_i$ , to

$$x_1 \oplus \cdots \oplus x_i \oplus \cdots \oplus x_n \leq x_1 \oplus \cdots \oplus y_i \oplus \cdots \oplus x_n \quad (2.41)$$

Ciągłość: Funkcja agregacji powinna być ciągła przynajmniej w granicach zmiennych  $x_i$ .

Łączność: Dla zmiennych  $x_1$ ,  $x_2$  i  $x_3$  łączny wynik powinien być niezależny od kolejności wyznaczanych agregacji cząstkowych

$$x_1 \oplus x_2 \oplus x_3 = (x_1 \oplus x_2) \oplus x_3 = x_1 \oplus (x_2 \oplus x_3) \quad (2.42)$$

Symetryczność: Ta własność jest niezbędna w przypadku, gdy agregacja jest przeprowadzana na zmiennych posiadających tę samą wagę, np.: w przypadku opinii pochodzących od nieznanymi ekspertów. Dla każdej permutacji  $\sigma$  zbioru  $\{1, 2, \dots, n\}$  mamy

$$x_{\sigma(1)} \oplus x_{\sigma(2)} \oplus \cdots \oplus x_{\sigma(n)} = x_1 \oplus x_2 \oplus \cdots \oplus x_n \quad (2.43)$$

Bi-symetryczność: W przypadku, gdy operator agregacji posiada  $n^2$  wejść, to

$$(x_{11} \oplus x_{12}) \oplus (x_{21} \oplus x_{22}) = (x_{11} \oplus x_{21}) \oplus (x_{12} \oplus x_{22}) \quad (2.44)$$

Absorbacja (pochłanianie): W przypadku, gdy operator agregacji posiada element absorbcyjny  $a$  (inaczej zwany anihilatorem), który spełnia rolę veta, to

$$x_1 \oplus \dots \oplus a \oplus \dots \oplus x_n = a \quad (2.45)$$

Neutralność: W przypadku, gdy operator agregacji posiada element neutralny  $e$ , to

$$x_1 \oplus \dots \oplus e \oplus \dots \oplus x_n = x_1 \oplus \dots \oplus x_n \quad (2.46)$$

Zgodność (idempotentność): W przypadku, gdy argumentami funkcji agregacji jest ten sam element, to

$$x \oplus x \oplus \dots \oplus x = x \quad (2.47)$$

Kompensacyjność: Dla znanych wartości argumentów operatora agregacji wypadkowa wartość powinna być zawarta w przedziale

$$\min_{i=1}^n (x_i) \leq x_1 \oplus x_2 \oplus \dots \oplus x_n \leq \max_{i=1}^n (x_i) \quad (2.48)$$

Liniowa stabilność: W przypadku, gdy argumenty są liniowo zmienne, to

$$(r \cdot x_1 + t) \oplus (r \cdot x_2 + t) \oplus \dots \oplus (r \cdot x_n + t) = r \cdot (x_1 \oplus x_2 \oplus \dots \oplus x_n) + t \quad (2.49)$$

Niezmienniczość: W przypadku, gdy argumenty reprezentują miary pewności kryteriów, to miary te powinny być przeliczone na oceny według pewnej funkcji  $f(\cdot)$ . W takim przypadku agregacja zmiennych poddanych transformacji za pomocą pewnej funkcji  $f(\cdot)$  powinna być równa

$$f(x_1) \oplus f(x_2) \oplus \dots \oplus f(x_n) = f(x_1 \oplus x_2 \oplus \dots \oplus x_n) \quad (2.50)$$

Operatory agregacji opinii można podzielić na następujące rodzaje:

1. Operatory podstawowe

- (a) Średnia arytmetyczna
- (b) Średnia ważona

- (c) Mediana [16]
  - (d) Maksimum i minimum
  - (e) Maksimum ważone i minimum ważone [162, 61]
2. Operatory średniej quasi-arytmetyczna [90, 2, 1, 62, 63]
  3. Operatory sumy symetrycznej [139]
  4. Operator OWA (ang. ordered weighted averaging) [163, 76]
  5. Operatory fuzji (ang. fusion operators) [68, 72]
    - (a) Model Bayesa
    - (b) Klasyczny rachunek prawdopodobieństwa
  6. Operatory t-norm i t-conorm [126]
  7. Operatory kompensacyjne (ang. compensatory operator) [167]
  8. Uninormy [164]

### 2.10.2. Automaty komórkowe

Teoria automatów komórkowych została opracowana przez Janosza von Neumanna i Stanisława Ulama. W literaturze [74, 95] automat komórkowy jest definiowany jako czwórka

$$\langle m, \Gamma, N, f \rangle \quad (2.51)$$

gdzie:

$m$  - wymiar przestrzeni, w której rozmieszczone są komórki;

$\Gamma$  - zbiór stanów w jakich może znaleźć się pojedyncza komórka;

$N$  - zbiór sąsiadów każdej komórki (lub promień  $r$  otoczenia, z którego wynika zbiór sąsiadów);

$f$  - funkcja przejścia przypisana komórce.


Działanie automatu komórkowego rozpoczyna się od ustalenia warunków początkowych. Po uruchomieniu, każda komórka przyjmuje określony stan w chwili czasu  $t + 1$  w zależności od stanu w chwili  $t$  tej komórki i komórek sąsiednich ze zbioru  $N$ . Stan ten wyznaczany jest za pomocą funkcji przejścia  $f$ . Określanie stanów każdej komórki jest procesem iteracyjnym.

Automaty komórkowe mogą być definiowane w przestrzeniach wielowymiarowych i nie wszystkie komórki muszą mieć ten sam zbiór stanów i przynależną im funkcję przejścia. Również otoczenie komórki nie musi być definiowane dla z góry przyjętej wartości promienia  $r$ . Wśród zalet tego narzędzia należy wymienić:

- możliwość dyskretyzacji „przestrzeni”;

- możliwość dyskretyzacji czasu;
- możliwość przypisania do każdej komórki innego zbioru stanów;
- możliwość przypisania do każdej komórki innej funkcji przejścia;
- możliwość zdefiniowania dla każdej komórki innego otoczenia lokalnego.

Na rysunku 2.10 pokazano przykład użycia automatu komórkowego do doskonalenia zbioru reguł sterujących minipojazdem poruszającym się w nieznanym środowisku [135]. Ciemne obszary są przeszkodami, natomiast 13 zgrupowanych komórek o różnych odcieniach szarości tworzy model minipojazdu zawierający: sterownik, napęd i czujniki zbliżeniowe. Każdy typ komórki posiada własny zbiór wartości stanów  $S$ , własne otoczenie  $N$  i własną funkcję przejścia  $f$ .



Rys. 2.10. Przykład użycia automatu komórkowego [131] (opis w tekście)

Automaty komórkowe mają jedną wadę - nie zawsze są zbieżne do stabilnego stanu. Dla pewnych parametrów (funkcji przejścia i warunków początkowych) wartości stanów poszczególnych komórek mogą oscylować wokół punktu równowagi. Z drugiej strony automaty komórkowe mogą być zbieżne do stanu ustalonego niezależnie od przyjętych warunków początkowych. Mówi się wówczas o tzw. automatach komórkowych zbieżnych. Komórki w tych automatach potrafią się same organizować dążąc jednocześnie do stanu ustalonego (o ile taki jest możliwy do osiągnięcia).

Automaty komórkowe znalazły zastosowanie do modelowania zjawisk fizycznych (w tym zagadnień nieliniowych), symulowania działania obiektów oddziaływujących na siebie w ciągu przyczynowo-skutkowym, przeprowadzania obliczeń równoległych itp.

### 2.10.3. Metody oparte na logice matematycznej i teorii zbiorów

Charakterystykę logiki klasycznej, wielowartościowej i rozmytej przedstawiono w p. 2.9.1. W klasycznym ujęciu pewien element  $x$  należy do zbioru  $X$  ( $x \in X$ ) lub nie należy

do zbioru  $X$  ( $x \notin X$ ). W teorii zbiorów przybliżonych [115] element  $x$  może należeć do zbioru  $X$ , może nie należeć do zbioru  $X$  lub może należeć do brzegu zbioru  $X$  ( $x \in BnX$ ). W przypadku zbiorów rozmytych [165] przynależność elementu  $x$  do zbioru  $X$  jest definiowana przez pewną funkcję, która przyporządkowuje elementowi  $x$  stopień przynależności z umownego przedziału wartości  $[0; 1]$  zgodnie ze wzorem 2.23.

W przypadku uzgadniania opinii (będących elementami zbiorów opinii) wypadkowa opinia może być iloczynem zbiorów. W takim przypadku powtarzająca się opinia w każdym ze zbiorów będzie opinią wypadkową. Problem pojawi się, gdy opinia nie będzie elementem jednego ze zbiorów - w wyniku operacji iloczynu zbiorów zostanie odrzucona. Rozwiązaniem tego problemu, może być założenie, że opinia zawarta w „wystarczającej liczbie zbiorów” jest opinią wypadkową. Przez określenie „wystarczająca liczba zbiorów” jest rozumiana pewna wartość empiryczna wyrażona w %.

Lepszym rozwiązaniem jest użycie zbiorów rozmytych, gdzie każdy element zbioru posiada funkcję przynależności reprezentującą stopień przynależności tego elementu do zbioru (p. 2.9.1). Dzięki użyciu zbiorów rozmytych, w wyniku procesu uzgadniania opinii, otrzymamy propozycję opinii wypadkowej z określonym stopniem przynależności, który można traktować jako stopień pewności. Proces tworzenia opinii wypadkowej można przeprowadzić tak jak proces wnioskowania rozmytego przy wyznaczaniu wartości przesłanek (p. 2.9.1), czyli na przykład za pomocą operatorów t-normy lub za pomocą operatora średniej arytmetycznej (por. p. 2.10.1).



### 3.1. Opis koncepcji

Zakłada się, że obiekt jest obserwowany za pośrednictwem sygnałów, których cechy określają oddziaływania pomiędzy obiektem i otoczeniem oraz oddziaływania pomiędzy elementami obiektu. Stan techniczny będzie opisywany zbiorem cech stanu [34]. Każda cecha stanu przyjmuje wartości ilościowe lub jakościowe. Dla potrzeb wnioskowania diagnostycznego niezbędne będą sygnały diagnostyczne, tzn. cechy sygnałów obserwowanych, cechy związane ze zmianami obserwowanych sygnałów oraz residua wyznaczone przez porównanie cech obserwowanych sygnałów z wartościami cech uzyskanych z eksperymentów numerycznych przeprowadzonych na odpowiednich modelach [92, 89].

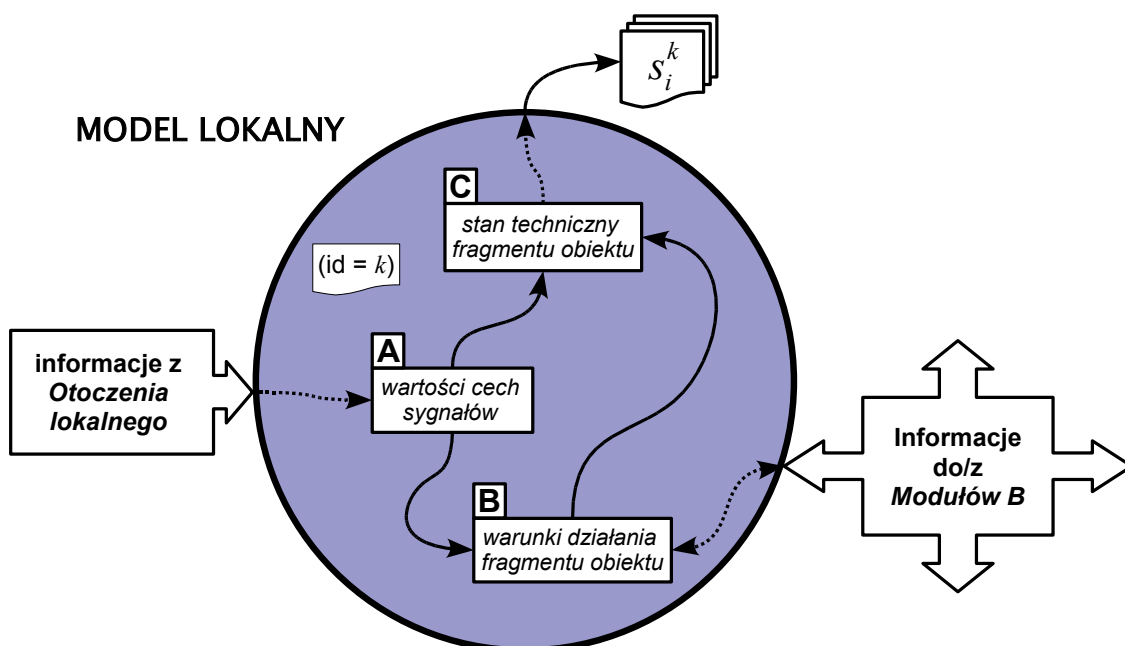
Zazwyczaj buduje się globalne modele diagnostyczne, w których identyfikuje się relacje diagnostyczne zachodzące pomiędzy cechami sygnałów diagnostycznych oraz cechami stanów [92]. Następnie, uzyskane relacje diagnostyczne poddaje się optymalizacji, których wynikiem jest optymalny zbiór cech sygnałów diagnostycznych oraz optymalna struktura modelu [138]. Identyfikacja modelu globalnego może być zadaniem złożonym. W wyniku poszukiwań optymalnej struktury modelu można uzyskać zbiór modeli prostych. Każdy model prosty obejmuje wyłącznie wybrane relacje diagnostyczne, czyli wybrane cechy sygnałów diagnostycznych i wybrane cechy stanu. Optymalizacja struktury modelu globalnego może być wspomagana poprzez wprowadzenie wielomodeli występujących w postaci modeli wielostopniowych i wielowarstwowych [44, 150, 157].

Alternatywnym sposobem jest rezygnacja z poszukiwania globalnego modelu diagnostycznego i zastąpienie go zbiorem modeli lokalnych, z których każdy pozwala na wyznaczenie (uwzględnienie) cech diagnostycznych dotyczących wyłącznie wybranego funkcjonalnego lub strukturalnego fragmentu obiektu [83]. Identyfikacja modeli lokalnych może odbywać się za pomocą metod stosowanych w identyfikacji modeli globalnych,

przy założeniu, że na wejściu modelu będą dostępne wszystkie cechy sygnałów diagnostycznych całego obiektu. W celu uproszczenia identyfikacji modelu diagnostycznego zaproponowano, żeby uwzględnić hierarchiczną strukturę obiektu technicznego (zgodnie z porządkiem podukład, zespół, element i część), która pozwoli na rozpatrywanie niezależnie identyfikowanych zagnieźdzonych modeli o różnym stopniu szczegółowości [120].

Model lokalny może być modelem lokalnym strukturalnie (przestrzennie, terytorialnie), jak np. model łożyska tocznego, lub modelem lokalnym funkcjonalnie (lecz o możliwym znacznym rozproszeniu terytorialnym), jak np. model układu chłodzenia. Zaproponowano, że każdy model lokalny zbudowany jest z trzech współdziałających ze sobą modułów (rys. 3.1):

- Modułu A, który będzie wyznaczał wartości cech sygnałów pozyskiwanych z fragmentu obiektu związanego z modelem lokalnym,
- Modułu B, który będzie rozpoznawał (klasyfikował) warunki działania fragmentu obiektu związanego z modelem lokalnym,
- Modułu C, który będzie identyfikował (klasyfikował) stan (techniczny) fragmentu obiektu związanego z modelem lokalnym.



Rys. 3.1. Postać diagnostycznego modelu lokalnego. A, B, C - moduły  $k$ -tego modelu lokalnego;  $s_i^k$  -  $i$ -ty stan  $k$ -tego fragmentu obiektu

Zadaniem Modułu A jest wyznaczanie wartości cech sygnałów diagnostycznych  $sg$  pozyskanych z fragmentu obiektu  $o_i$  związanego z modelem lokalnym  $m_i^L$ . W związku z



tym Moduł A będzie zawierał zbiór funkcji i procedur  $F$  wyznaczających wartości cech sygnałów diagnostycznych [108, 92]. Moduł A ma dostęp wyłącznie do cech sygnałów pozyskanych z fragmentu obiektu związanego z tym modelem. Nie są dla niego dostępne cechy sygnałów pochodzących z innych fragmentów obiektu. W [42, 46] przedstawiono przykłady cech, które można wyznaczyć z sygnałów drganiowych przeznaczonych do diagnozowania uszkodzeń turbosespołu. Wśród zbiorów potencjalnych cech relewantnych wyróżniono m.in.:

- Cechy punktowe własne sygnałów w dziedzinie czasu [39], np.: wartość średnia absolutna  $x_{AVE}$ , wartość skuteczna  $x_{RMS}$ , wartość szczytowa absolutna  $x_{PEAK}$ , współczynnik kształtu  $K$ , współczynnik szczytu  $C$ , współczynnik impulsowości  $I$ , współczynnik asymetrii (skośność)  $S$  [93], kurtozę  $Ku$  [93] itp.;
- Cechy punktowe wzajemne sygnałów w dziedzinie czasu, np.: stopień okresowości, maksymalna wartość części rzeczywistej znormalizowanej funkcji autokorelacji  $ReR_{zz}(\tau = T_1)$  [161], okres trajektorii  $T_1$  [161];
- Cechy punktowe własne sygnałów w dziedzinie częstotliwości, np.: wartości składowych widma amplitudowego sygnału o częstotliwościach  $0.25X, 0.33X, 0.5X, 1X, 2X, 3X, 4X, 0.38 \div 0.46X$ , fazy składowych widma amplitudowego o częstotliwościach  $1X, 2X, 3X, 4X$ ;
- Cechy punktowe trajektorii centralnych w dziedzinie czasu, np.: wartość średnia absolutna  $r_{AVE}$ , wartość skuteczna  $r_{RMS}$  itp., oraz maksymalne promieniowe przemieszczenie wału  $s_{max}$ , maksymalna podwójna amplituda promieniowych  $s_{maxP-P}$ , przy czym trajektoria centralna  $r$  jest wyznaczana według wzoru:

$$r(n) = \sqrt{x^2(n) + y^2(n)} \quad (3.1)$$

W ogólnym zbiorze cech można jeszcze uwzględnić zbiory cech sygnałów dodatkowych uzyskanych na drodze przekształceń numerycznych sygnałów pozyskanych bezpośrednio z obiektu, np.: cechy sygnałów prędkości i przemieszczeń [41].

Jakość wyznaczanych wartości cech sygnałów (ich przydatność) ma istotny wpływ na jakość działania pozostałych dwóch modułów. Przed przystąpieniem do wyznaczania konkretnych wartości należy sygnały poddać procesowi obróbki wstępnej polegającej m.in. na obniżeniu poziomu szumów [34]. Niewłaściwy zbiór cech może prowadzić do błędnych klasyfikacji warunków działania (Moduł B) i błędnej klasyfikacji stanu (Moduł C). W trakcie poszukiwania zbioru cech zdarza się, że wspólne uwzględnienie pewnych „przeciętnych” cech daje lepsze rezultaty w identyfikacji i działaniu klasyfikatora, niż uwzględnienie cech wskazanych, np. w literaturze specjalistycznej lub przez eksperta. Dlatego też należy zwrócić uwagę na metody poszukiwania zbioru cech relewantnych [150].

Zadaniem Modułu B jest rozpoznawanie warunków działania  $W$  fragmentu obiektu  $o_i$  związanego z modelem lokalnym  $m_i^L$  oraz uzgadnianie z innymi Modułami B

warunków działania całego obiektu. Zakłada się, że Moduł B ma dostęp do wyników działania Modułu A. Każdy Moduł B ma przypisany pewien zbiór warunków działania fragmentu obiektu związanego z modelem lokalnym oraz zbiór warunków działania całego obiektu. Działanie Modułu B polega na wykonaniu trzech kroków:

**Krok 1** Rozpoznawanie warunków działania fragmentu obiektu  $W$ .

**Krok 2** Rozpoznawanie warunków działania całego obiektu  $W^O$ .

**Krok 3** Uzgadnianie z innymi Modułami B warunków działania całego obiektu  $W^O$ .

W pierwszym kroku są rozpoznawane warunki działania dla fragmentu obiektu. Następnie stanowią one dane wejściowe do drugiego etapu - wyznaczania propozycji warunków działania całego obiektu. Ostatecznie, w procesie agregacji lub uzgadniania opinii Moduły B wypracowują wspólną opinię wskazując ostatecznie warunki działania całego obiektu.

Klasa rozpoznanych warunków działania całego obiektu stanowi jedno z wejść Modułu C. Zatem jakość działania Modułu B ma wpływ na jakość działania Modułu C, który na podstawie tej informacji identyfikuje stan obiektu. Z drugiej strony na jakość działania klasyfikatora warunków działania danego Modułu B ma wpływ jakość zbioru wartości cech sygnałów dostarczanych przez Moduł A. W związku z tym konieczne jest wyznaczenie zbioru cech relewantnych, przy czym muszą to być cechy niosące istotne informacje pozwalające na jak najlepsze rozpoznanie warunków działania obiektu.

Moduł C jest klasyfikatorem stanu. Jego zadaniem jest klasyfikacja (identyfikacja) stanu fragmentu obiektu  $o_i$  związanego z modelem lokalnym  $m_i^L$ . Każdy obiekt techniczny (fragment obiektu) w danej chwili czasu makro  $t$  znajduje się w pewnym stanie  $s_i$  należącym do, zwykle skończonego, zbioru możliwych stanów  $S$  przyporządkowanego temu obiektowi. Najprostszym możliwym zbiorem stanów jest zbiór stanów eksploatacyjnych składający się z dwóch klas stanów:

$$S = \begin{cases} s_0 & \text{zdatny} \\ s_1 & \text{niezdatny} \end{cases} \quad (3.2)$$

W diagnostyce maszyn zwykle powyższy zbiór stanów jest niewystarczający. Maszyny zużywają się w trakcie ich działania i w wielu przypadkach nagła utrata zdatności jest poprzedzona pojawieniem się pewnych niesprawności. W związku z tym rozszerza się zbiór stanów eksploatacyjnych  $S$  najczęściej do trzech lub czterech klas:

$$S = \begin{cases} s_0 & \text{zdatny} \\ s_1 & \text{dostatecznie zdatny} \\ s_2 & \text{dopuszczalnie zdantny} \\ s_3 & \text{niezdatny} \end{cases} \quad (3.3)$$

Zaproponowane zbiory stanów mogą odnosić się do każdego fragmentu dowolnego urządzenia technicznego. W celu bardziej precyzyjnego określenia miejsca i wielkości

niesprawności lokalizuje się uszkodzenie oraz jego wielkość. Wówczas zbiór  $S$  jest bardziej rozbudowany i jest tworzony specjalnie dla konkretnego urządzenia lub jego fragmentu.

W przypadku zastosowania bardziej rozbudowanych klasyfikatorów stanów zaproponowano następujący zbiór stanów [12]:

$$S = \begin{cases} s_0 & \text{zdatny} \\ s_1 & \text{niezdatny} \\ s_2 & \text{stan obiektu nie w pełni rozpoznany} \\ s_3 & \text{niezdatny inny fragment (układ) obiektu} \\ s_4 & \text{obiekt trwale niezdatny} \end{cases} \quad (3.4)$$

Zastosowanie takiego zbioru stanów pozwala odpowiedzieć na pytanie: "Który układ (fragment) obiektu jest niezdatny?", poprzez wskazanie uszkodzonego fragmentu lub zbioru fragmentów obiektu.

W celu przeprowadzenia procesu klasyfikacji stanu niezbędna jest znajomość wartości cech relewantnych oraz warunków działania w jakich znajduje się obiekt. Jak widać, na jakość działania Modułu C mają wpływ dwa pozostałe moduły. Wyznaczanie wartości cech dla sygnałów z dużym poziomem wartości szumów i podawanie ich na wejście Modułu C spowoduje znaczny wzrost liczby przypadków z błędnie sklasyfikowanymi stanami. Także błędne sklasyfikowanie warunków działania obiektu może doprowadzić do błędnego sklasyfikowania stanu obiektu. W związku z tym nie można przeprowadzić identyfikacji tego modułu całkowicie niezależnie od pozostałych.

W związku z powyższym, działanie modułów skupia się na realizacji następujących zadań:

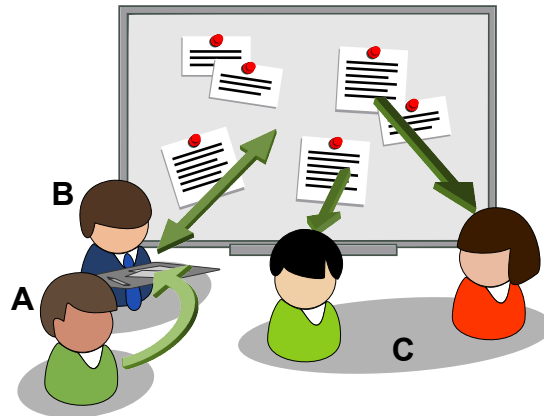
1. obserwacji lokalnego nośnika informacji o stanie fragmentu obiektu (sygnału diagnostycznego); w proponowanej metodzie jest to realizowane przez Moduł A,
2. wnioskowania o warunkach działania fragmentu obiektu i całego obiektu; w proponowanej metodzie jest to realizowane przez Moduł B,
3. wnioskowania o stanie technicznym obiektu na podstawie wyników obserwacji lokalnych nośników informacji oraz wyników identyfikacji i uzgadniania warunków działania całego obiektu; w proponowanej metodzie jest to realizowane przez Moduł C.

## 3.2. Komunikacja pomiędzy modułami

### 3.2.1. Metody komunikacji

Moduły B posiadają zdolność komunikowania się między sobą w celu uzgodnienia wspólnej decyzji w wyborze rodzaju warunków działania całego obiektu. Proces komu-

nikowania może odbywać się z pośrednikiem (np. za pomocą tablicy ogłoszeń (ang. blackboard) [49]) lub bezpośrednio z użyciem wybranego języka wymiany komunikatów.



Rys. 3.2. Tablica ogłoszeń (na podstawie [33]). A - źródło komunikatów, B - administrator, C - odbiorcy komunikatów

Tablica ogłoszeń (rys. 3.2) jest modelem wspólnej, dzielonej pamięci [75], przez którą Moduły B wymieniają informacje pomiędzy sobą. Moduły B mogą do niej zapisywać komunikaty i wyniki obliczeń oraz odczytywać potrzebne informacje zapisane przez inne Moduły B. W danej chwili Moduł B może być odbiorcą komunikatu (C) lub źródłem komunikatu (A). Nad prawidłowym działaniem tablicy ogłoszeń czuwa administrator (B), którego należy kojarzyć z programem nadzorującym. W bardziej rozbudowanych systemach można wprowadzić kilka tablic, które posłużą do lokalnej wymiany informacji dla grup Modułów B.

W przypadku bezpośredniej wymiany informacji pomiędzy Modułami B należy użyć wyspecjalizowanych narzędzi, np. szkieletowego systemu wieloagentowego. System taki zazwyczaj posiada wbudowany mechanizm wspomagający wymianę komunikatów pomiędzy jednostkami (tu agentami) za pomocą specjalnego języka, np. KQML, FBPA ACL lub FIPA ACL. Z szerokiego grona narzędzi do opracowywania i rozwijania systemów wieloagentowych, takich jak: FIPA-OS [148], ZEUS [52], BOND [102], czy Grasshopper [78], zwrócono uwagę na środowisko o nazwie JADE [96]. JADE (ang. Java Agent DEvelopment Framework) jest platformą w pełni zgodną ze specyfikacją opracowaną przez fundację FIPA (ang. The Foundation for Intelligent Physical Agents) [65], której celem jest opracowywanie standardów dla technologii agentowych.

Platforma JADE została napisana w języku programowania Java [143]. Dzięki temu możliwe jest uruchomienie środowiska agentowego na każdym urządzeniu komputerowym, na które napisano wirtualną maszynę Java (ang. Java Virtual Machine). Cała platforma jest zarządzana przez specjalnego agenta o nazwie *ams* (ang. Agent Management Service). Agent ten jest odpowiedzialny za obsługę serwisów uruchamianych w ramach działań podejmowanych przez agentów.

Biorąc pod uwagę cechy systemów wieloagentowych, takie jak [49]: ograniczony horyzont postrzegania środowiska i zadania przez agenta, brak scentralizowanego sterowania, rozproszenie (decentralizacja) danych, asynchroniczność działania, uznano, że to narzędzie dobrze będzie się sprawdzało w zadaniu opracowania i rozwijania opisywanych modułów oraz przeprowadzenia badań symulacyjnych działania zbioru modeli lokalnych.

W procesie bezpośredniej komunikacji niezbędne jest ustalenie zasady nadrzędności i podrzędności. Można w tym celu użyć, tzw. metody elekcji. Elekcja jest potrzebna do ustalenia hierarchii ważności w przypadku wzajemnego odpytywania się przez Moduły B [132]. W systemach komputerowych elekcja ma na celu wybranie spośród wielu „identycznych” procesów tego, który będzie pełnił rolę koordynatora. Algorytmy przeprowadzające elekcję próbują najczęściej zlokalizować proces, którego identyfikator jest największy i mianować go koordynatorem. W naszym przypadku Moduły B otrzymują kolejne numery  $ID^{MB}$  zgodnie z kolejnością uruchamiania modeli lokalnych (rys. 3.1). Elekcję można przeprowadzić za pomocą „algorytmu tyrana” (ang. bully algorithm). Jego przebieg, zaadoptowany dla potrzeb komunikacji pomiędzy Modułami B, ma następującą postać – Moduł B ( $B'$ ), który zauważył, że koordynator nie istnieje, rozpoczyna proces elekcji [69]:

1.  $B'$  wysyła komunikat ELEKCJA do wszystkich Modułów B z numerami większymi od jego własnego numeru  $ID^{MB'}$ ,
2. jeżeli nie uzyska żadnej odpowiedzi, to  $B'$  staje się koordynatorem,
3. jeżeli jakiś Moduł B o większym numerze  $ID^{MB}$  prześle odpowiedź, to on przejmuje kontrolę, a  $B'$  czeka na komunikat od zwycięzcy elekcji.


Każdy Moduł B w dowolnej chwili może otrzymać komunikat ELEKCJA od Modułów B o mniejszym numerze  $ID^{MB}$ . Musi wtedy przesłać komunikat zwrotny OK w celu poinformowania, że jest aktywny i przejmuje sterowanie, a następnie przeprowadzić elekcję (o ile tego jeszcze nie zrobił). Ostatecznie wszystkie Moduły B poza jednym rezygnują z elekcji. Ten wysyła do wszystkich komunikat KOORDYNATOR.

W czasie bezpośredniej wymiany informacji Moduły B, poprzez analogię do topologii sieci komputerowych, mogą tworzyć strukturę gwiazdy, krążącego żetonu (pierścień) [132] lub połączenie każdy z każdym (sieć).

### 3.2.2. Synchronizacja czasu

W systemach, w których występuje wymiana komunikatów pomiędzy elementami tego systemu należy rozwiązać problem synchronizacji czasu. Znajomość aktualnego czasu jest niezbędna w zachowaniu spójności danych i ustalaniu kolejności niezależnie obserwowanych zdarzeń (*zdarzenie* rozumiane jest jako działanie zaobserwowane w punkcie czasu). Czas można mierzyć z zadaną dokładnością, która determinuje czy czas będzie

rozumiany jako punkt na osi czasu, czy jako przedział. W większości przypadków wystarczy dokładność na poziomie niezbędnym do ustalenia kolejności wystąpienia zdarzeń [54].



Rys. 3.3. Logiczne znaczniki czasu (na podstawie [54]).  $m_1^L, m_2^L, m_3^L$  - modele lokalne; a, b, c, d, e, f - zdarzenia; 1, 2, 3, 4, 5 - kolejność wystąpienia zdarzeń;  $k_1, k_2$  - komunikaty

W celu ustalenia kolejności zachodzących zdarzeń, należy każdemu modelowi lokalnemu  $m_i^L$  przyporządkować *znacznik czasu*, będący wartością punktu czasu w którym dane zdarzenie zaszło. Na przykład, w systemach komputerowych Unix przyjęto, że pewna data (tu 1 stycznia 1970) będzie odniesieniem (tzw. *początkiem epoki*) i począwszy od tej daty wszystkie następne będą mierzone w postaci całkowitej liczby sekund. Zatem przyjmując pewien punkt „zero” można każde zdarzenie opisać znacznikiem czasu i dzięki temu porównać czas jego wystąpienia w odniesieniu do innych zdarzeń. Wadą takiego podejścia jest to, że taki znacznik obowiązuje w obszarze działania danego zegara fizycznego - w obszarze grupy modeli lokalnych. W związku z tym pojawia się potencjalny problem synchronizacji czasu pomiędzy zegarami różnych systemów zawierających grupy modeli lokalnych. Istnieje kilka metod pozwalających rozwiązać ten problem [54]:

- uniwersalny czas skoordynowany (UTC),
- metoda Cristiana [55],
- algorytm Gusella i Zatti, [73],
- protokół czasu sieciowego (NTP) [106].

Jak już napisano, w większości przypadków nie jest potrzebna dokładna wartość czasu wystąpienia zdarzenia, a jedynie ich kolejność. Uporządkowanie zdarzeń opiera się na dwóch regułach [54]:

**Reguła 1** Jeżeli dwa zdarzenia wystąpią w tej samej grupie modeli lokalnych, to ich kolejność odpowiada kolejności ich zaobserwowania.

**Reguła 2** Jeżeli jest wysyłany komunikat z jednego modelu lokalnego do drugiego modelu lokalnego, to zdarzenie wysłania poprzedza zdarzenie odebrania tego komunikatu.

Takie uporządkowanie nazywa się *relacją uprzedniości zdarzeń* [97].

Na potrzeby porządkowania zdarzeń wprowadzono, tzw. *zegar logiczny*, którego wartość jest monotonicznie rosnącym licznikiem programowym zazwyczaj niezależnym od zegara fizycznego. W trakcie działania systemu, modele lokalne uaktualniają swoje zegary logiczne  $Z_i$  i przesyłają te wartości w komunikatach według zasad [54] (rys. 3.3):

1.  $Z_1$  jest zwiększany, gdy zajdzie zdarzenie w  $m_1^L : Z_1 = Z_1 + 1$ .
2. (a)  $m_1^L$  wysłała komunikat  $k$  i znacznik  $t = Z_1$ .  
(b) Po odebraniu komunikatu  $k$  i wartości  $t$  model  $m_2^L$  oblicza  $Z_2 = \max(Z_2, t)$ , zwiększa wartość zegara logicznego  $Z_2$  (patrz Reguła 1) i przyjmuje komunikat  $k$ .

Zatem pomiędzy dwoma dowolnymi zdarzeniami  $a$  i  $b$  zachodzi związek [54]:

$$a \rightarrow b \Rightarrow Z_a < Z_b \quad (3.5)$$

### 3.2.3. Uzgadnianie wyników identyfikacji warunków działania

Moduł B posiada dostęp do zbioru możliwych warunków działania całego obiektu. Znając możliwe warunki działania obiektu, identyfikuje je poprzez wymianę informacji (łącznie z własną opinią) z innymi Modułami B, w tym informacji dodatkowych dostępnych w innych Modułach A, dostępnych pośrednio poprzez Moduły B innych modeli lokalnych. Wynikiem tej identyfikacji jest rozpoznanie warunków działania całego obiektu przedstawiane przez dany Moduł B.

Warunki działania całego obiektu tworzą zbiór  $W^O$  rozmytych warunków działania:

$$W^O = \{w_1^O, w_2^O, \dots, w_n^O\} \quad (3.6)$$

gdzie:

$w$  - jest wartością stopnia prawdziwości z przedziału  $[0; 1]$ ;  
 $1, 2, \dots, n$  - jest identyfikatorem warunku działania obiektu.

Każdy element tego zbioru posiada identyfikator oraz wartość, która jest traktowana jako stopień prawdziwości wystąpienia danego warunku działania. W danej chwili czasu eksploatacji obiektu, wartości stopni prawdziwości o wystąpieniu danych warunków działania całego obiektu mogą być wyznaczane za pomocą:

- metod agregacji opinii (p. 2.10.1),
- automatu komórkowego (p. 2.10.2),
- metod opartych na logice matematycznej i teorii zbiorów (p. 2.10.3),

W celu wymiany informacji pomiędzy Modułami B uznano, że każdy Moduł B posiada własną oś czasu makro  $t$ , która porządkuje występowanie określonych warunków działania [110].

### Agregacja opinii

Uzgadnianie wspólnej opinii o warunkach działania całego obiektu przez poszczególne Moduły B z użyciem metod agregacji opinii polega na tym, że każdy Moduł B wyznacza wartości stopni prawdziwości każdego warunku działania obiektu ( $w_{j,i}^O \in W^O$ ):

$$\begin{aligned} \text{moduł } B_1 : W_1^O &= \{w_{11}^O, w_{12}^O, \dots, w_{1n}^O\} \\ \text{moduł } B_2 : W_2^O &= \{w_{21}^O, w_{22}^O, \dots, w_{2n}^O\} \\ &\vdots \\ \text{moduł } B_m : W_m^O &= \{w_{m1}^O, w_{m2}^O, \dots, w_{mn}^O\} \end{aligned} \quad (3.7)$$

gdzie:

$W_j^O$  - macierz wartości stopni przekonania proponowanych przez dany Moduł B,  
 $w_{j,i}^O$  - wartość stopnia prawdziwości wystąpienia danego warunku działania proponowana przez dany Moduł B,  
 $i$  - identyfikator warunku działania całego obiektu,  
 $j$  - identyfikator Modułu B.

W kolejnym kroku przeprowadzana jest agregacja wartości stopni prawdziwości wyznaczanych przez Moduły B:

$$\begin{aligned} \hat{w}_1^O &= w_{11}^O \oplus w_{21}^O \oplus \dots \oplus w_{m1}^O \\ \hat{w}_2^O &= w_{12}^O \oplus w_{22}^O \oplus \dots \oplus w_{m2}^O \\ &\vdots \\ \hat{w}_n^O &= w_{1n}^O \oplus w_{2n}^O \oplus \dots \oplus w_{mn}^O \end{aligned} \quad (3.8)$$

Otrzymujemy nowy zbiór:

$$\hat{W}^O = \{\hat{w}_1^O, \hat{w}_2^O, \dots, \hat{w}_n^O\} \quad (3.9)$$

Ostatecznie wybierane są tylko te propozycje warunków działania całego obiektu, które posiadają największe wartości stopni prawdziwości:

$$W'^O = \max(\hat{W}^O) \quad (3.10)$$

Zbiór  $W'^O$  może być zbiorem jednoelementowym lub zbiorem wieloelementowym, w przypadku, gdy maksymalne wartości stopni prawdziwości ze zbioru  $W^O$  są sobie równe.

Na potrzeby realizacji zadania przyjęto następujące dwa operatory agregacji:


1. operator średniej quasi-arytmetycznej,
2. operator t-conorm.



### Operator średniej quasi-arytmetycznej

Spośród operatorów agregacji średniej quasi-arytmetycznej zwrócono uwagę na operatory z rodziny funkcji  $f : x \rightarrow x^\alpha$  [62, 63]


$$x_1 \oplus x_2 \oplus \dots \oplus x_n = \sqrt[\alpha]{\frac{1}{n} \sum_{i=1}^n x_i^\alpha} = \sqrt[\alpha]{\sum_{i=1}^n \left(\frac{1}{n} \cdot x_i^\alpha\right)} \quad (3.11)$$



Rys. 3.4. Wykres rodziny funkcji  $f(x,y) = \sqrt[\alpha]{\frac{x^\alpha + y^\alpha}{2}}$  dla  $\alpha = -10$

Dużą zaletą tej funkcji jest to, że wartości przez nią zwracane można modyfikować zmieniając wartość parametru  $\alpha$  [59]:

- jeżeli  $\alpha = 1$ , to funkcja wyznacza średnią arytmetyczną,
- jeżeli  $\alpha = 2$ , to funkcja wyznacza średnią Euklidesową,
- jeżeli  $\alpha = -1$ , to funkcja wyznacza średnią harmoniczną,
- jeżeli  $\alpha \rightarrow -\infty$ , to funkcja dąży do najmniejszej wartości spośród jej argumentów (rys. 3.4),
- jeżeli  $\alpha \rightarrow \infty$ , to funkcja dąży do największej wartości spośród jej argumentów (rys. 3.5),



Rys. 3.5. Wykres rodziny funkcji  $f(x,y) = \sqrt[\alpha]{\frac{x^\alpha + y^\alpha}{2}}$  dla  $\alpha = 10$

- jeżeli  $\alpha \rightarrow 0$ , to funkcja dąży do wartości średniej geometrycznej,
- jeżeli  $\alpha = 0$ , to funkcja jest nieoznaczona.

W związku z tym zaproponowano, żeby wyznaczać stopień prawdziwości według zależności

$$T(x_1, x_2, \dots, x_n) = x_1 \oplus x_2 \oplus \dots \oplus x_n = \sqrt[\alpha]{\frac{1}{n} \sum_{i=1}^n T(x_i)^\alpha} \quad (3.12)$$

W przypadku dwóch elementów o różnych stopniach prawdziwości i  $\alpha = 2$  wzór 3.12 upraszcza się do wzoru na średnią kwadratową

$$T(x, y) = x \oplus y = \sqrt{\frac{T(x)^2 + T(y)^2}{2}} \quad (3.13)$$

Należy uważać w przypadku stosowania dużych wartości parametru  $\alpha$  (przypadek, gdy  $\alpha \rightarrow \infty$ ). Na przykład

(1) jeżeli  $T(x) = 1$  i  $T(y) = 0$ , to  $T(x, y) \approx 0.933$

(2) jeżeli  $T(x) = 1$  i  $T(y) = 0.9$ , to  $T(x, y) \approx 0.961$

Widać, że dla  $T(x) = 1$  wynik agregacji  $T(x, y)$  będzie zawsze bliższy większej wartości ze zbioru  $\{T(x), T(y)\}$  (rys. 3.5). W przypadku, gdy dwa elementy mają tę samą wartość (np.:  $T(x) = T(y) = 0.7$ ) to wypadkowy stopień prawdziwości również posiada tę samą


wartość. Pomimo, że funkcja spełnia warunek *identyczności* (2.47), to uważa się [24], że jest to wada, ponieważ dwa elementy o tych samych wartościach stopni prawdziwości powinny dać wypadkową o wyższej wartości stopnia prawdziwości. Tej „wady” pozbawiony jest operator t-conorm.

#### Operator t-conorm

Ogólnie mówiąc, operator t-conorm w logice spełnia rolę spójnika sumy ( $\vee$ , OR) (w przeciwieństwie do operatora t-norm będącego spójnikiem koniunkcji ( $\wedge$ , AND)) [126]. Rodzinę funkcji t-conorm zadaną wzorem

$$f(x, y) = x + y - xy \quad (3.14)$$

pokazano na rysunku 3.6.



Rys. 3.6. Wykres rodziny funkcji  $f(x, y) = x + y - xy$

Jeżeli uznać, że niespełnienie warunku *identyczności* jest „zaletą”, to operator agregacji może być użyty w procesie agregacji opinii zgodnie z zależnością

$$T(x, y) = x \oplus y = T(x) + T(y) - T(x)T(y), \quad (3.15)$$

ale tylko dla przypadku tych samych wartości stopnia prawdziwości, np.:

$$\text{dla } T(x) = T(y) = 0.7 \text{ otrzymujemy } T(x, y) = 0.91.$$

Jeżeli przyjąć, że:

$$(1) \quad T(x) = 1 \quad \text{ i } \quad T(y) = 0, \quad \text{ to } \quad T(x, y) = 1 + 0 - 1 \cdot 0 = 1$$

$$(2) T(x) = 1 \quad \text{i} \quad T(y) = 0.9, \quad \text{to} \quad T(x,y) = 1 + 0.9 - 1 \cdot 0.9 = 1$$

Jak widać, dla  $T(x) = 1$  niezależnie od wartości  $T(y)$ ,  $T(x,y)$  zawsze będzie równe 1 (rys. 3.6). Jest to szczególnie niebezpieczne, gdy  $T(y) = 0$ , ponieważ uznanie nieprawdziwego warunku działania obiektu za prawdziwy, w przypadku zestawienia go z warunkiem działania uznanym za prawdziwy, może prowadzić do sytuacji konfliktowych w trakcie oceny stanu technicznego obiektu.

### Automaty komórkowe

Jeżeli założyć, że:

1. modele lokalne  $m^L$  dyskretyzują model globalny  $m^G$ ,
2. model lokalny  $m^L$  posiada skończoną liczbę stanów  $\Gamma$  (tutaj stany są to warunki działania fragmentu obiektu  $W$  i całego obiektu  $W^O$  generowane przez Moduły B),
3. każdy model lokalny  $m^L$  posiada własny zbiór sąsiadów  $\Lambda$  interpretowany jako *otoczenie lokalne*,
4. każdy model lokalny  $m^L$  posiada własną funkcję przejścia interpretowaną jako *lokalny widok otoczenia*, której argumentami są wartości pochodzące od innych modeli lokalnych z *otoczenia lokalnego*,

to do uzgadniania wyników identyfikacji warunków działania można użyć automatu komórkowego.

Należy wyjaśnić, że przez *lokalny widok otoczenia* rozumiany jest widok modelu globalnego zrealizowany przez model lokalny, którego wiedza o sąsiednich modelach lokalnych zmniejsza się wraz ze wzrostem „odległości” (spadkiem podobieństwa) od nich [136]. Zastosowanie metody lokalnego widoku otoczenia wymaga sformalizowania zależności zakresu i jakości dostępnej wiedzy od odległości. Można to zrealizować zakładając, że rozpatrujemy odległość w jakiejś wielowymiarowej przestrzeni metrycznej, która może być obserwowana wyłącznie za pośrednictwem dostępnych nam rzutów reprezentujących różne aspekty funkcjonowania badanego obiektu.

Prostym i skutecznym sposobem jest podzielenie zbioru sąsiadów  $\{\Lambda\}$  przypisanego do danego modelu lokalnego  $m^L$  na trzy podzbiory:

$\Lambda^B$  - podzbiór sąsiadów *bliskich*,

$\Lambda^D$  - podzbiór sąsiadów *dalekich*,

$\Lambda^\infty$  - podzbiór bardzo dalekich sąsiadów, czyli pozostałych sąsiadów  $(1 - (\Lambda^B \cup \Lambda^D))$ .

Mając ustalone podzbiory sąsiadów można zbudować funkcję przejścia  $f$  ustalającą propozycję warunków działania całego obiektu w czasie  $t + 1$ . Wówczas, modele lokalne z podzbioru  $\Lambda^B$  będą miały największy wpływ na tę propozycję, modele z podzbioru  $\Lambda^D$

będą miały mniejszy wpływ, a modele z  $\Lambda^\infty$  będą miały najmniejszy wpływ. To jak wielki wpływ będzie miało otoczenie lokalne na propozycję generowaną przez dany model  $m^L$  można ustalać wprowadzając wagi  $\omega$  przypisane do poszczególnych podzbiorów. Nie można zapomnieć o aktualnej (w czasie  $t$ ) propozycji danego modelu lokalnego  $m^L$ . Ta propozycja powinna mieć największą wagę.

Warunkami początkowymi są wstępne propozycje warunków działania całego obiektu wypracowane przez poszczególne Moduły B modeli lokalnych. Proces uzgadniania wiedzy przebiega iteracyjnie. Zakończenie działania automatu komórkowego następuje w momencie, gdy wszystkie lub pewien założony odsetek modeli lokalnych zaproponuje ten sam warunek działania całego obiektu  $w^O$ .

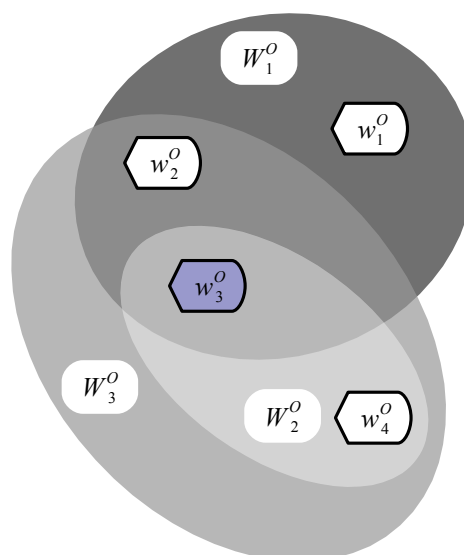
### Metody oparte na logice matematycznej i teorii zbiorów

Każdy moduł B generuje zbiór proponowanych warunków działania całego obiektu (wzór 3.7). Zbiory te mogą zostać porównane ze sobą. Proponuje się użyć jednego z dwóch sposobów:

1. iloczyn zbiorów,
2. suma zbiorów ze zliczaniem powtarzających się elementów.

#### *Iloczyn zbiorów*

Jest to najprostsza metoda spośród wymienionych. W wyniku operacji iloczynu zbiorów  $W_i^O$  otrzymujemy wypadkowy zbiór  $W'^O$ , w którym znajdują się warunki




Rys. 3.7. Iloczyn zbiorów warunków działania.  $W_1^O, W_2^O, W_3^O$  - zbiory warunków działania wygenerowane przez Moduły B;  $w_1^O, w_2^O, w_3^O, w_4^O$  - propozycje warunków działania całego obiektu

działania  $w_i^O$  wspólne dla wszystkich proponowanych zbiorów  $W_i^O$  przez Moduły B. Dla przypadku zamieszczonego na rys. 3.7 wypadkowy zbiór zawiera tylko jeden element:

$$W^O = \{w_3^O\}$$

*Suma zbiorów ze zliczaniem powtarzających się elementów*

W trakcie tego porównania powtarzające się warunki są zliczane (rys. 3.8). Ostatecznie



Rys. 3.8. Zliczanie elementów zbiorów warunków działania.  $W_1^O, W_2^O, W_3^O$  - zbiory warunków działania wygenerowane przez Moduły B;  $w_1^O, w_2^O, w_3^O, w_4^O$  - propozycje warunków działania całego obiektu;  $\Sigma$  - liczba powtórzeń warunku działania we wszystkich zbiorach

najczęściej powtarzający się warunek będzie traktowany jako najbardziej prawdopodobny warunek działania całego obiektu. Może się zdarzyć, że w wyniku opisanych działań uzyskany rezultat nie będzie rozstrzygał o warunkach działania całego obiektu. W związku z tym przewiduje się wprowadzenie wartości progowej dla liczby powtarzających się tych samych propozycji warunków działania całego obiektu powyżej której dana propozycja będzie uznawana za ostateczną. Wartości progowe będą ustalane dynamicznie jako procent liczby Modułów B biorących udział w uzgadnianiu warunków działania całego obiektu. W przypadku nie uzyskania wartości progowej przez żadną z propozycji uznaje się, że Moduły B nie potrafią ustalić warunków działania całego obiektu. Może się również zdarzyć, że wynikiem będą dwie lub więcej propozycji, które uzyskały te same liczby powtórzeń. Wówczas przyjmuje się, że takie propozycje są propozycjami *warunkowo ostatecznymi*.

### 3.3. Synteza modelu globalnego

Syntezę całego układu wnioskującego pokazano na rys. 3.9. Z diagnozowanego obiektu pozyskiwane są sygnały, które trafiają na wejścia modeli lokalnych związanych z frag-



pojawiają w przypadku dekompozycji przestrzennej, a inne w przypadku dekompozycji funkcjonalnej. Wynikiem działania każdego modelu lokalnego  $m_k^L$  jest rozpoznany stan  $s_i$  fragmentu obiektu  $s_i^k$  (rys. 3.1). Zakłada się, że dany stan  $s_i^k$  będzie reprezentowany przez stwierdzenie  $z_{k,i}$ . Struktury hierarchiczne pozwalają na określanie stanu obiektu w różnych stopniach szczegółowości z zachowaniem porządku od ogółu do szczegółu. Powoduje to, że zbiory stwierdzeń tworzące strukturę hierarchiczną mogą zostać zastąpione jednym stwierdzeniem, za którym ukryty jest fragment drzewa stwierdzeń. Takie podejście nie ogranicza dokładności stawianych diagnoz [40].

Struktury sieciowe pozwalają na równorzędną syntezę stwierdzeń  $z_{k,i}$  o stanie technicznym  $s_i^k$  obiektu generowanych przez modele lokalne  $m_k^L$ . Do tego celu można użyć, tzw. sieci stwierdzeń.

### Zagadnienie Bayesa

W 1763 pośmiertnie opublikowano znane z rachunku prawdopodobieństwa zagadnienie Thomasa Bayesa (1702-1761). Zagadnienie to można przedstawić następująco [70]:

*Dany jest układ zupełny zdarzeń  $A_1, A_2, \dots, A_n$  ( $n$  skończone lub przeliczalne) oraz zdarzenie  $B$  określone w tej samej przestrzeni  $I$ .*

*Zdarzenie  $B$  zaszło. Interesuje nas w tym przypadku prawdopodobieństwo zdarzenia  $A_k$  ( $k \in [1; n]$ ) obliczane na podstawie otrzymanej już informacji o zajściu zdarzenia  $B$ , tzn. prawdopodobieństwo warunkowe*

$$P(A_k|B) \tag{3.16}$$

Zatem chcemy się dowiedzieć jakie jest prawdopodobieństwo zajścia zdarzenia  $A_k$ , gdy zaszło już zdarzenie  $B$ . Jeżeli znamy prawdopodobieństwa  $P(A_k)$  i  $P(B|A_k)$ , to

$$P(A_k|B) = \frac{P(A_k) \cdot P(B|A_k)}{\sum_{i=1}^n P(A_i) \cdot P(B|A_i)} = \frac{P(A_k) \cdot P(B|A_k)}{P(B)} \tag{3.17}$$


### Sieć stwierdzeń

Poniżej zamieszczono definicję sieci stwierdzeń [33]:

**Sieć stwierdzeń** (inaczej przekonań, Bayesa) jest to acykliczny graf skierowany, którego węzłom przypisane są zestawy stwierdzeń i wektory ich wartości, a gałęziom skierowanym przyporządkowane są tablice zawierające wartości prawdopodobieństw warunkowych dla wszystkich elementów iloczynu kartezyjskiego zestawów stwierdzeń przypisanych do węzłów.

Przykładową sieć stwierdzeń pokazano na rysunku 3.10. Węzłom i gałęziom mogą być





Rys. 3.10. Sieć stwierdzeń (na podstawie [25]). Oznaczenia:  $a(\cdot)$  - oddziaływania otoczenia,  $b(\cdot)$  - do obserwatora,  $x(\cdot)$  - stwierdzenia

przypisane wagi określające np. stopnie przekonania o słuszności tych stwierdzeń [33]. Duże trudności w stosowaniu sieci stwierdzeń napotka się w momencie ustalania wartości prawdopodobieństw warunkowych [120]. Trudności biorą się stąd, że dla ich ustalenia potrzebne są dobrej jakości przykłady uczące lub „dobra” wiedza eksperta (dopuszcza się również taki przypadek). Szczególnie, gdy wartość węzła zależy od wartości dużej liczby innych węzłów. Działanie sieci polega na poszukiwaniu stanu jej równowagi. W efekcie ustalone są prawdopodobieństwa wszystkich węzłów w sieci. Należy zaznaczyć, że prawdopodobieństwa w sieciach stwierdzeń są interpretowane jako prawdopodobieństwa subiektywne lub miary stopni przekonania.

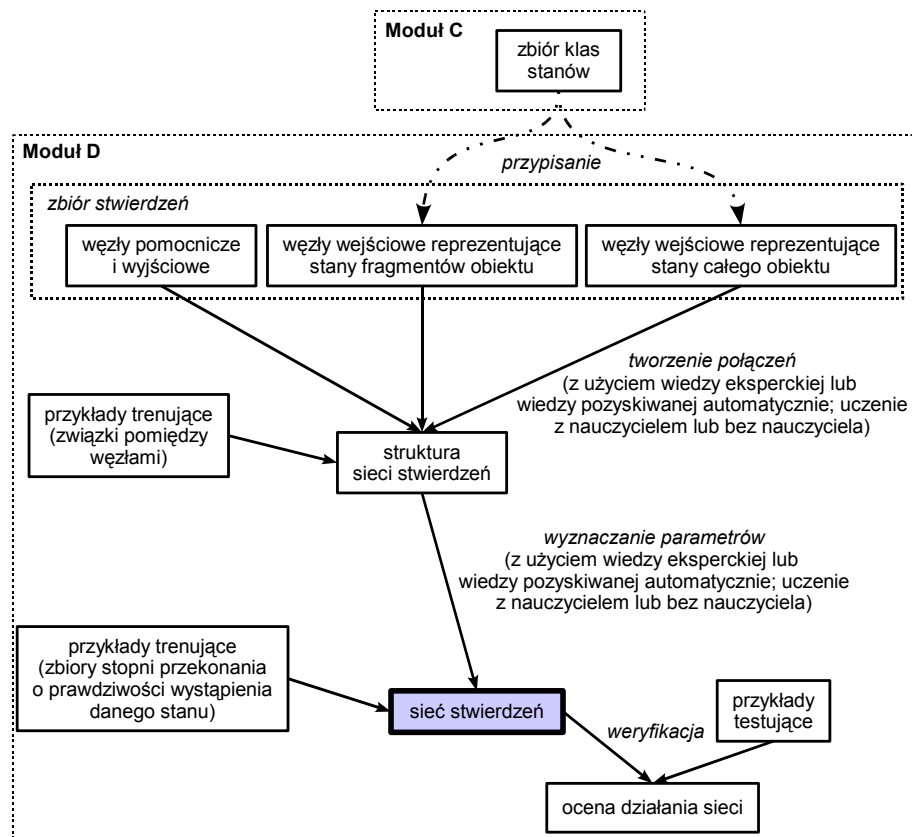
### 3.3.2. Identyfikacja Modułu D

Moduł D jest warstwą nadrzędną, mającą za zadanie wyznaczenie stanu całego obiektu na podstawie informacji o stanach fragmentów obiektów generowanych przez Moduły C. W tym celu użyto sieci stwierdzeń. Na rysunku 3.11 pokazano schemat procesu identyfikacji tego modułu.

Przed rozpoczęciem procesu identyfikacji należy utworzyć zbiór klas stanów  $S$  obiektu i jego fragmentów oraz zbiory stwierdzeń:

1. wejściowych,
2. pomocniczych,
3. wyjściowych.

Każdy element tych zbiorów przyjmuje wartości z przedziału  $[0; 1]$  i są to wartości stopnia prawdziwości wystąpienia danego stanu. Każdy stan obiektu jest związany z wybranym stwierdzeniem wejściowym. Część węzłów reprezentuje stany fragmentów obiektu, a część stany całego obiektu. Oprócz stwierdzeń wejściowych są jeszcze stwierdzenia pomocnicze (np. spełniające rolę stwierdzeń grupujących stwierdzenia związane ze stanami wybranego fragmentu obiektu) oraz stwierdzenia wyjściowe.



Rys. 3.11. Schemat procesu identyfikacji Modułu D (opis w tekście). Strzałki oznaczają działania, opisy w ramkach prostokątnych oznaczają wyniki przeprowadzanych działań, wyróżniona ramka prostokątna z opisem oznacza cel prowadzonych działań.

W pierwszym kroku identyfikacji sieci stwierdzeń należy wyznaczyć jej strukturę poprzez połączenie ze sobą wybranych stwierdzeń (węzłów sieci). W większości przypadków struktura sieci jest tworzona przez ekspertów lub z użyciem ich wiedzy. Istnieją również metody numerycznego generowania połączeń na podstawie danych. Automatyczne generowanie struktury sieci przeprowadza się badając warunkową niezależność stwierdzeń lub stosuje się optymalizację struktury grafu oceniając stopień jego dopasowania do struktury wzajemnych zależności pomiędzy rzeczywistymi danymi [13, 100]. Wśród metod automatycznego generowania struktury sieci należy wymienić:

1. *Algorytm Chow-Liu* [47]. Wynikiem zastosowania algorytmu jest drzewo o ścieżkach przypadkowo zorientowanych. Metoda ta najlepiej nadaje się dla sieci mających rozkład drzewa, w innym przypadku tworzone jest najlepiej dopasowane drzewo.
2. *Algorytm Pearla* [116]. Algorytm ten jest zmodyfikowanym algorytmem Chow-Liu. Struktura sieci Bayesa zwracana przez algorytm Pearla ma postać polidrzewa, tzn. otrzymana struktura jest drzewem, w którym dowolne dwa wierzchołki po-

łączone są co najwyżej jedną ścieżką. W odróżnieniu do algorytmu Chow-Liu, w drzewie dopuszcza się występowanie węzłów zbiegających się.

3. *Algorytm PC* [142]. Zastosowanie algorytmu prowadzi do utworzenia grafu skierowanego. Działanie rozpoczyna się od zbudowania grafu o gałęziach nieskierowanych, który następnie jest iteracyjnie modyfikowany poprzez testowanie warunkowej niezależności pomiędzy węzłami. Odmianą algorytmu PC jest algorytm BN-PC-B [21].
4. *Algorytm K2* [53]. W wyniku otrzymywany jest graf skierowany. Działanie z zastosowaniem algorytmu K2 polega na dodawaniu do węzła rodziców. Podstawą oceny jest funkcja heurystyczna wykorzystująca miarę bayesowską. Funkcja ta wyznacza stopień dopasowania konfiguracji rodziców danego węzła do rzeczywistego rozkładu.

Drugi krok identyfikacji Modułu D polega na wyznaczeniu tablic wartości prawdopodobieństw warunkowych. Proces budowy takich tablic przeprowadza się z użyciem wiedzy specjalistów lub z użyciem wiedzy pozyskanej z baz danych [110]. Jedną z metod automatycznego generowania tablic jest *metoda gradientowa*. W metodzie gradientowej uczenia się wartości prawdopodobieństw [48] celem jest znalezienie hipotezy  $h$ , która jest w maksymalnym stopniu zgodna z danymi trenującymi  $T$ , czyli maksymalizuje prawdopodobieństwo  $Pr(T|h)$ . Hipoteza jest określana przez tablice prawdopodobieństw warunkowych, które docelowo mają zawierać jak najlepsze przybliżenie prawdziwych prawdopodobieństw warunkowych wartości atrybutów [48].

Inna metoda została zastosowana w programie Netica [113]. Podczas uczenia sieci zakłada się warunkową niezależność wartości prawdopodobieństw warunkowych węzła w stosunku do jego rodziców. Wyznaczanie wartości tablic polega na zliczaniu liczby przypadków dla różnych warunków (kombinacji stanów rozpatrywanego węzła i jego rodziców).

W [15] proponuje się inne podejście. Przeprowadza się spotkanie grup ekspertów i osób zainteresowanych problemem w wyniku którego opracowywane są tablice prawdopodobieństw warunkowych. Następnie otrzymane wartości są uśredniane i interpolowane. Na podstawie wyznaczonych parametrów interpolacyjnych wyznaczone są ostateczne wartości prawdopodobieństw.

## 3.4. Identyfikacja modeli lokalnych

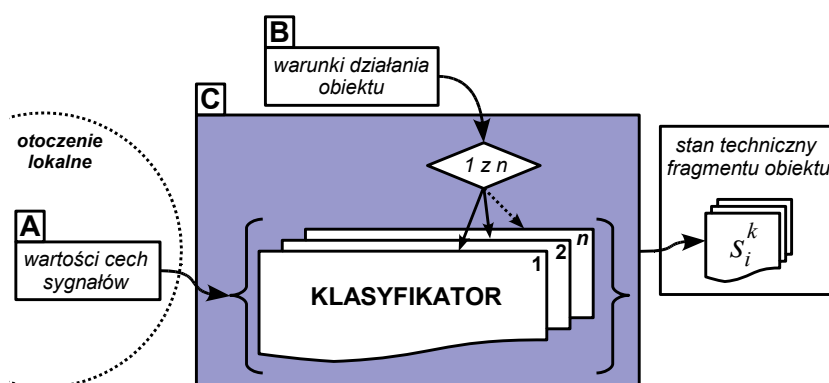
### 3.4.1. Budowa modelu lokalnego

Model lokalny reprezentuje fragmenty obiektu (strukturalne i/lub funkcjonalne) [30, 133]. Każdy model lokalny jest zbudowany z trzech, ściśle współpracujących Modułów A, B i C. Zwykle budowanie modelu diagnostycznego rozpoczyna się od ustalenia zbioru stanów technicznych i zbioru możliwych warunków działania. Mając określone te dwa zbiory

można przejść do wyboru sygnałów diagnostycznych i ich cech, w przypadku gdy dysponujemy wiedzą dziedzinową, lub pozyskania jak największej liczby cech sygnałów diagnostycznych i na podstawie metod redukcji liczby cech wybrać zbiór cech relewantnych. Dlatego też w dalszej części tego rozdziału przedstawiono metody identyfikacji modułów zaczynając od Modułu C, następnie opisano identyfikację Modułu B i Modułu A. W przypadku Modułu B skupiono się wyłącznie na metodach identyfikacji warunków działania. Metody komunikacji pomiędzy Modułami B opisano w punkcie 3.2.

### 3.4.2. Identyfikacja Modułu C

Zakłada się, że Moduł C zbudowany jest z szeregu klasyfikatorów połączonych ze sobą równolegle (rys. 3.12), przy czym wybierany jest jeden klasyfikator w zależności od rozpoznanej klasy warunków działania całego obiektu. Zatem zachodzi konieczność identyfikowania szeregu klasyfikatorów z użyciem zbiorów danych uczących pozyskanych z obiektu znajdującego się w danej klasie warunków jego działania.



Rys. 3.12. Schemat budowy Modułu C

Schemat procesu identyfikacji Modułu C pokazano na rysunku 3.13. W celu identyfikacji Modułu C należy dysponować następującymi zbiorami danych:

- zbiór klas warunków działania  $W$ ,
- zbiór danych uczących  $DU$  zawarty w zbiorze wartości cech sygnałów diagnostycznych  $SG$ ,
- zbiór danych testujących  $DT$  zawarty w zbiorze wartości cech sygnałów diagnostycznych  $SG$ .

Powyżej wymienione zbiory powinny być określone na drodze analizy badanego obiektu lub jego fragmentu.

Jeżeli dysponujemy gotowym zbiorem klas stanów  $S$  wówczas nie trzeba przeprowadzać identyfikacji tego zbioru. W przeciwnym razie należy poddać analizie procesy



- określić interesujące, ze względów diagnostycznych, klasy stanu  $S^k$  i klasy warunków działania  $W^k$ ;
- przyporządkować rozpatrywane stany poszczególnym klasom stanu, a warunki działania danym klasom warunków działania;
- określić zbiór rozpatrywanych cech sygnałów  $SG_i$  związany z modelem lokalnym  $m_i^L$ .

Następnie należy użyć jednego z opisanych w p. 2.7 algorytmów.

Identyfikację pojedynczego klasyfikatora stanu przeprowadza się na podstawie danych zawartych w:

- zbiorze klas warunków działania,
- zbiorze klas stanów,
- zbiorze cech relewantnych.

Do budowy klasyfikatora stanu można użyć jednej z metod opisanych w p. 2.9, tj.:

- systemu ekspertowego (wnioskowanie z użyciem logiki klasycznej, wielowartościowej i rozmytej),
- tablicy decyzyjnej,
- klasyfikacji i grupowania z użyciem miar odległości,
- sieci neuronalnej.

Identyfikacja klasyfikatora może być przeprowadzana z nauczycielem lub bez nauczyciela. Najczęściej jest dostępny zbiór przykładów trenujących, w związku z tym budowa klasyfikatora jest przeprowadzana z nauczycielem. Sprawność otrzymanego klasyfikatora ocenia się na podstawie jego weryfikacji z użyciem danych testujących  $DT$  zawartych w zbiorze cech sygnałów diagnostycznych  $SG$ .

Przy wyborze metody z użyciem której będzie przeprowadzane rozpoznawanie stanu obiektu należy kierować się następującymi kryteriami:

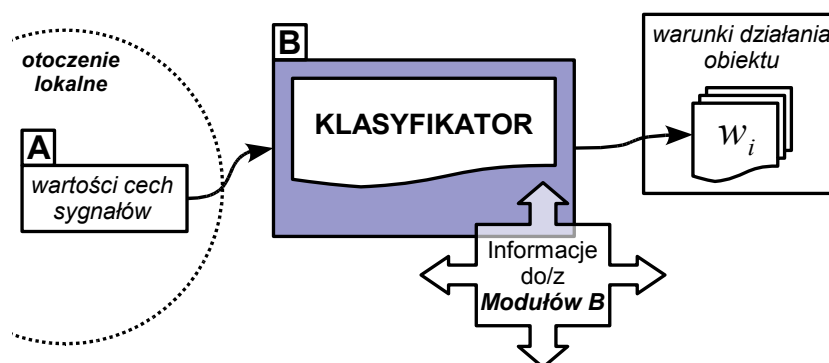
- liczbą klas stanów,
- liczbą klas warunków działania,
- liczbą cech relewantnych,
- kosztem identyfikacji klasyfikatora (modelu),
- kosztem użytkowania klasyfikatora (modelu),

- kosztem późniejszej aktualizacji klasyfikatora.

W przypadku małej liczby klas stanów i małej liczby cech relewantnych można użyć metod wnioskowania z użyciem logiki matematycznej i tablicę decyzyjną. Mała liczba przesłanek i mała liczba konkluzji pozwala na „ręczne” zbudowanie zbioru reguł, który będzie na wystarczającym poziomie ogólności. Pomimo posiadania wiedzy, że jedna z metod daje lepsze wyniki od innych nie zawsze jest uzasadnione jej użycie. Koszt identyfikacji klasyfikatora: czas identyfikacji, potrzebne zasoby programowe i sprzętowe oraz liczba parametrów konfiguracyjnych, powoduje, że nie zawsze racjonalne jest zastosowanie danej metody. Budując klasyfikator należy rozpatrzyć jego użytkowanie i późniejszą aktualizację (mogą pojawić się nowe cechy relewantne lub może pojawić się potrzeba rozszerzenia rozpoznawanych klas stanów). Wówczas należy zastosować metody, które pozwalają na późniejszą łatwą aktualizację klasyfikatora.

### 3.4.3. Identyfikacja Modułu B

Moduł B posiada jeden klasyfikator, który na podstawie danych zawartych w zbiorze cech relewantnych określa warunki działania obiektu lub jego fragmentu (rys. 3.14). Schemat procesu identyfikacji klasyfikatora warunków działania Modułu B przedstawiono na rys. 3.15.

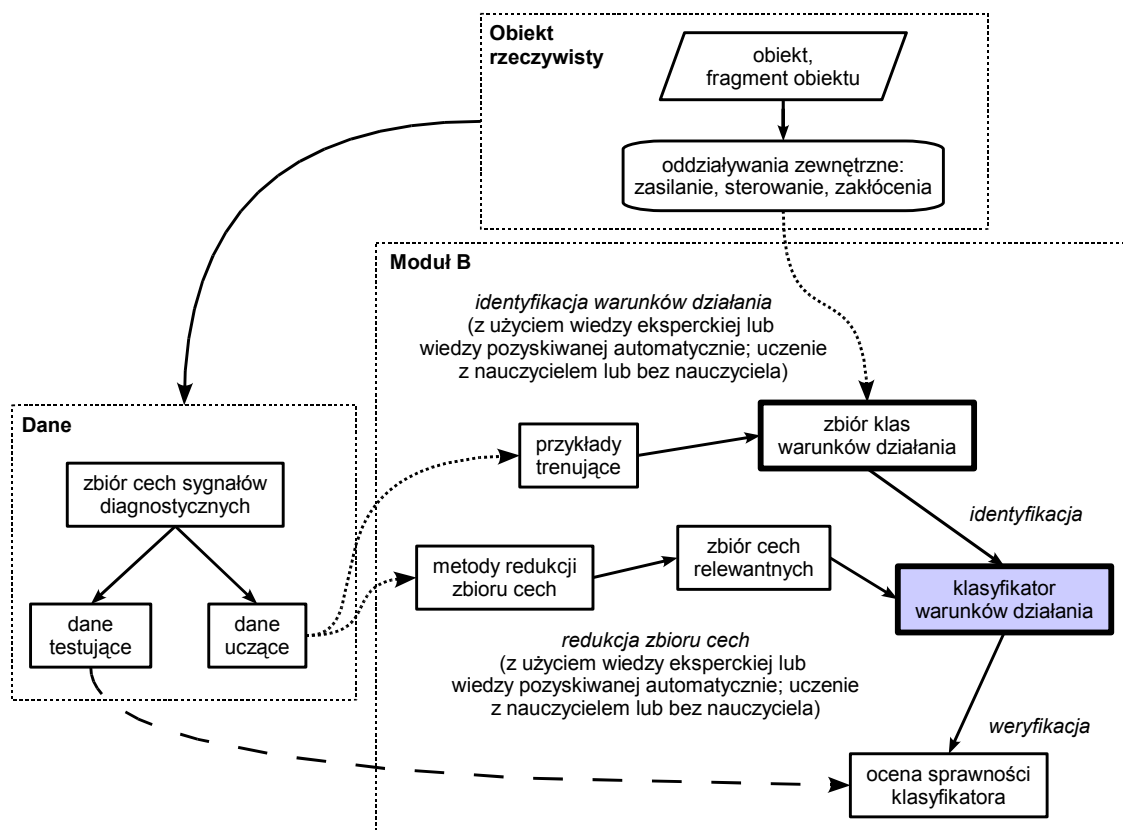


Rys. 3.14. Schemat budowy Modułu B

Identyfikację można przeprowadzić podobnie jak proces identyfikacji Modułu C. Przy czym wcześniej wystarczy zgromadzić następujące zbiory danych:

- zbiór danych uczących  $DU$  zawarty w zbiorze wartości cech sygnałów diagnostycznych  $SG$ ,
- zbiór danych testujących  $DT$  zawarty w zbiorze wartości cech sygnałów diagnostycznych  $SG$ .

Wymienione zbiory powinny być określone na drodze analizy badanego obiektu lub jego fragmentu.



Rys. 3.15. Schemat procesu identyfikacji Modułu B - klasyfikatora warunków działania (opis w tekście). Strzałki oznaczają działania, opisy w ramkach prostokątnych oznaczają wyniki przeprowadzanych działań, wyróżnione ramki prostokątne z opisami oznaczają ważniejsze cele prowadzonych działań.

Jeżeli dysponujemy gotowym zbiorem klas warunków działania  $W$  wówczas nie trzeba przeprowadzać identyfikacji tego zbioru. W przeciwnym razie należy poddać analizie oddziaływania zewnętrzne badanego obiektu. Użyteczna informacja pozwalająca zgromadzić zbiór warunków działania znajduje się przede wszystkim w oddziaływaniach zewnętrznych badanego obiektu (p. 2.8). Zastosowanie wiedzy eksperckiej lub wiedzy pozyskiwanej ze zbiorów danych pozwala na zdefiniowanie zbioru klas warunków działania  $W$ . Podobnie jak przy identyfikacji zbioru klas stanów, także i tutaj jako metod pozyskiwania wiedzy przeznaczonej do poszukiwania zbioru klas warunków działania można użyć metod grupowania (p. 2.9.3).

Kolejny krok identyfikacji Modułu B polega na przeprowadzeniu operacji redukcji liczby cech sygnałów diagnostycznych (p. 2.7). Przy czym uwzględniane cechy powinny być najlepsze ze względu na skuteczność rozpoznawania warunków działania.

Identyfikację klasyfikatora warunków działania obiektu lub jego fragmentu przeprowadza się na podstawie danych zawartych w:



- zbiorze klas warunków działania,
- zbiorze cech relewantnych.

Tak jak w procesie identyfikacji Modułu C, również tutaj identyfikację klasyfikatora można przeprowadzić z użyciem następujących narzędzi (p. 2.9):

- systemu ekspertowego (wnioskowanie z użyciem logiki klasycznej, wielowartościowej i rozmytej),
- tablicy decyzyjnej,
- metod klasyfikacji i grupowania z użyciem miar odległości,
- sieci neuronalnej.

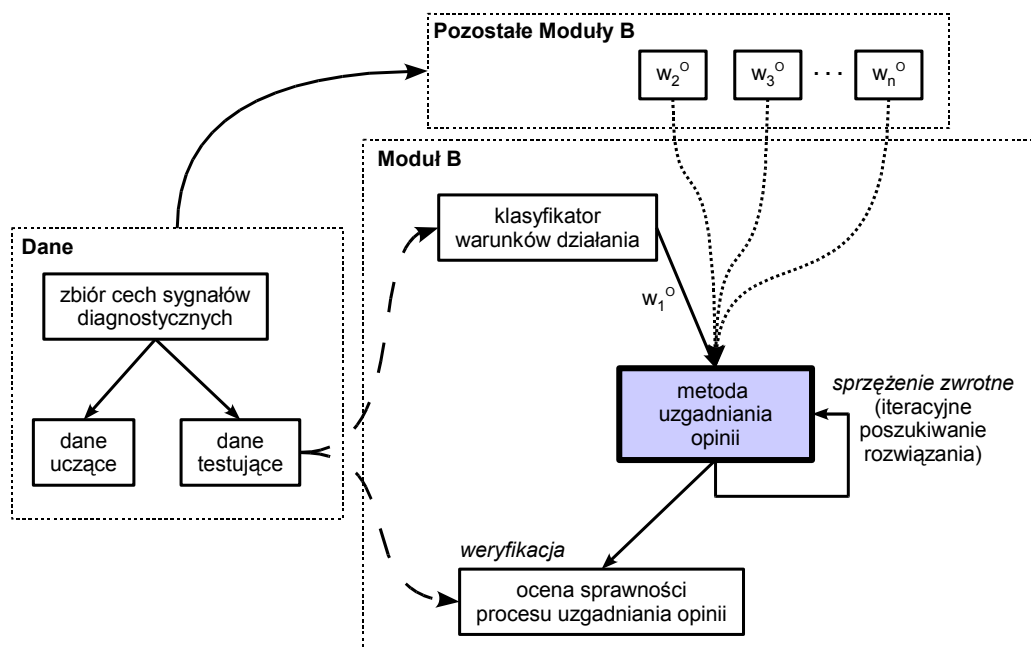
Jedyna różnica polega na tym, że w wyniku działania klasyfikatora, zamiast stanów  $s$ , otrzymujemy warunki działania  $w$ . Również identyfikacja klasyfikatora może być przeprowadzana z nauczycielem lub bez nauczyciela. Zazwyczaj dostępne zbiory danych trenujących pozwalają na użycie metody identyfikacji klasyfikatora z nauczycielem. Sprawność otrzymanego klasyfikatora można ocenić przeprowadzając jego weryfikację z użyciem danych testujących  $DT$  zawartych w zbiorze cech sygnałów diagnostycznych  $SG$ .

Przy wyborze metody z użyciem której będzie przeprowadzane rozpoznawanie warunków działania fragmentu i całego obiektu należy kierować się następującymi kryteriami (patrz p. 3.4.2):

- liczbą klas warunków działania fragmentu obiektu,
- liczbą cech relewantnych,
- kosztem identyfikacji klasyfikatora (modelu),
- kosztem użytkowania klasyfikatora (modelu),
- kosztem późniejszej aktualizacji klasyfikatora.

Zazwyczaj liczba rozpoznawanych klas warunków działania obiektu jest mniejsza od liczby klas stanów w jakich może znaleźć się obiekt. Często zdarza się, że występuje tylko jedna cecha relewantna. Także liczba rozpoznawanych klas warunków działania jest zazwyczaj stała i nie jest wymagane późniejsze rozszerzenie tego zbioru. W związku z tym klasyfikatory warunków działania będą prostsze w budowie i łatwiejsze w ich identyfikacji od klasyfikatorów stanów.

Po zbudowaniu klasyfikatorów warunków działania obiektu lub jego fragmentu należy przystąpić do drugiego etapu identyfikacji Modułu B - wyboru i zastosowania metody uzgadniania opinii. Na rysunku 3.16 pokazano ogólny schemat identyfikacji metody uzgadniania opinii.




Rys. 3.16. Schemat procesu identyfikacji Modułu B - uzgadnianie opinii (opis w tekście). Strzałki oznaczają działania, opisy w ramkach prostokątnych oznaczają wyniki przeprowadzanych działań, wyróżniona ramka prostokątna oznacza cel prowadzonych działań.

Danymi wejściowymi dla wybranej metody uzgadniania opinii są opinie o warunkach działania obiektu lub jego fragmentu wypracowane przez klasyfikator identyfikowanego Modułu B (opinia  $w_1^O$ ) oraz klasyfikatory pozostałych Modułów B (opinie  $w_2^O$ ,  $w_3^O$  i  $w_n^O$ ) na podstawie zbioru danych testujących  $DT$ . W zależności od wybranej metody (p. 3.2), należy ustalić parametry procesu uzgadniania opinii. Sprawność przyjętej metody można ocenić weryfikując rezultaty jej działania z danymi testującymi  $DT$ .

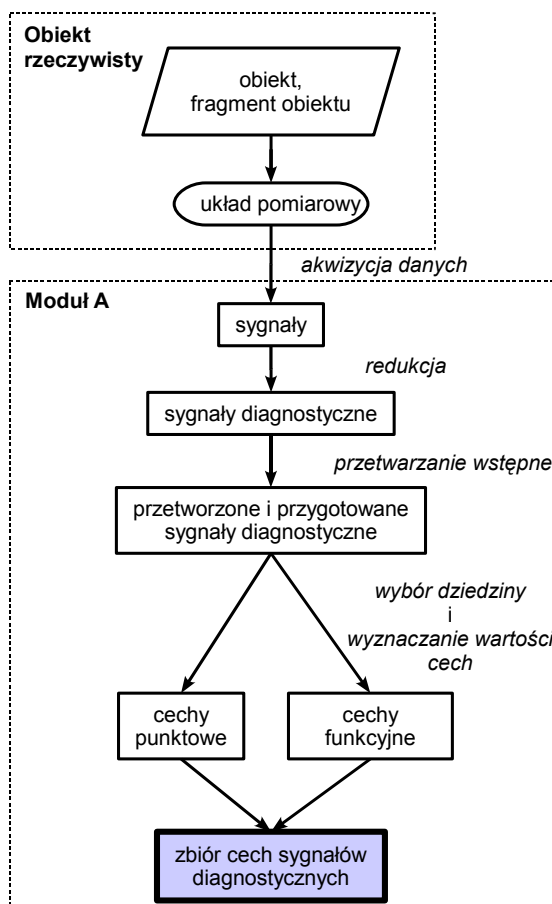
### 3.4.4. Identyfikacja Modułu A

Zadaniem Modułu A jest dostarczanie zbioru wartości cech sygnałów diagnostycznych (rys. 3.17). Schemat procesu identyfikacji Modułu A pokazano na rys. 3.18.

Badanie diagnostyczne rozpoczyna się od przeprowadzenia pomiarów sygnałów [11]. Zanim przystąpimy do wyznaczania konkretnych wartości cech sygnałów musimy określić pewien zbiór sygnałów diagnostycznych  $SG$ , czyli sygnałów będących nośnikami informacji pozwalających na orzeczenie o stanie technicznym obiektu oraz o jego warunkach działania. Sygnały diagnostyczne mogą być niekompletne lub obciążone błędami wynikającymi przede wszystkim z przyjętej metody pomiarowej, oprzyrządowania (czujniki, tory pomiarowe itp.) oraz od warunków w jakich wykonywany był pomiar [57]. Oddziaływania zewnętrzne otoczenia mają nie tylko wpływ na badany obiekt (p. 2.8 i



Rys. 3.17. Schemat budowy Modułu A



Rys. 3.18. Schemat procesu identyfikacji Modułu A (opis w tekście). Strzałki oznaczają działania, opisy w ramkach prostokątnych oznaczają wyniki przeprowadzanych działań, wyróżniona ramka prostokątna oznacza cel prowadzonych działań.

p. 3.4.3), ale również na układ pomiarowy. W związku z tym, wyselekcjonowany zbiór sygnałów diagnostycznych należy poddać procesowi przetwarzania wstępnego polegającego m.in. na usunięciu szumów i normalizacji. Następnie sygnały są przedstawiane w różnych dziedzinach i analizowane przy użyciu różnych funkcji  $F$  w celu wyznaczenia wartości cech punktowych lub funkcyjnych (p. 2.6). Ostatecznie zbiory wartości cech

sygnałów diagnostycznych są zapisywane, przechowywane i udostępniane (np. przy użyciu baz danych).

### 3.5. Podsumowanie identyfikacji modułów

Ogólny schemat zawierający identyfikację poszczególnych modułów pokazano na rysunku 3.19. Dla potrzeb identyfikacji Modułów A, B i C niezbędne jest pozyskanie sygnałów z obiektu. Potrzebne sygnały mogą pochodzić z oddziaływań zewnętrznych, pozwalających na rozpoznawanie warunków działania i procesów resztkowych (np. wibroakustycznych, cieplnych itp.), pozwalających przede wszystkim na identyfikację stanu obiektu. Na podstawie sygnałów wyznaczane są zbiory wartości cech sygnałów diagnostycznych, które następnie są dzielone na dwa podzbiory: danych uczących *DU* i danych testujących *DT* (Moduły A). Dane uczące i wyznaczony na podstawie oddziaływań zewnętrznych zbiór możliwych warunków działania obiektu pozwalają na identyfikację klasyfikatorów warunków działania (Moduły B). Dane uczące, zbiór możliwych warunków działania obiektu i wyznaczony zbiór możliwych stanów fragmentów obiektu pozwalają na identyfikację zestawu klasyfikatorów stanów fragmentów obiektu lub w szczególnym przypadku klasyfikatorów stanów całego obiektu (Moduły C). Na podstawie zbioru danych testujących *DT* wyznaczone klasyfikatory Modułów B i Modułów C są weryfikowane. W wyniku tej weryfikacji powstaje ocena sprawności danego klasyfikatora.

Kolejnym etapem jest wybór i zastosowanie metody uzgadniania opinii o warunkach działania obiektu. Do tego celu potrzebne są opinie innych Modułów B. W zależności od przyjętej metody będzie przeprowadzana agregacja opinii lub uzgadnianie opinii w pętli sprzężenia zwrotnego, tzn. rozwiązanie będzie poszukiwane iteracyjnie. Ostatecznie przyjętą metodę należy zweryfikować za pomocą zbioru testującego *DT*.

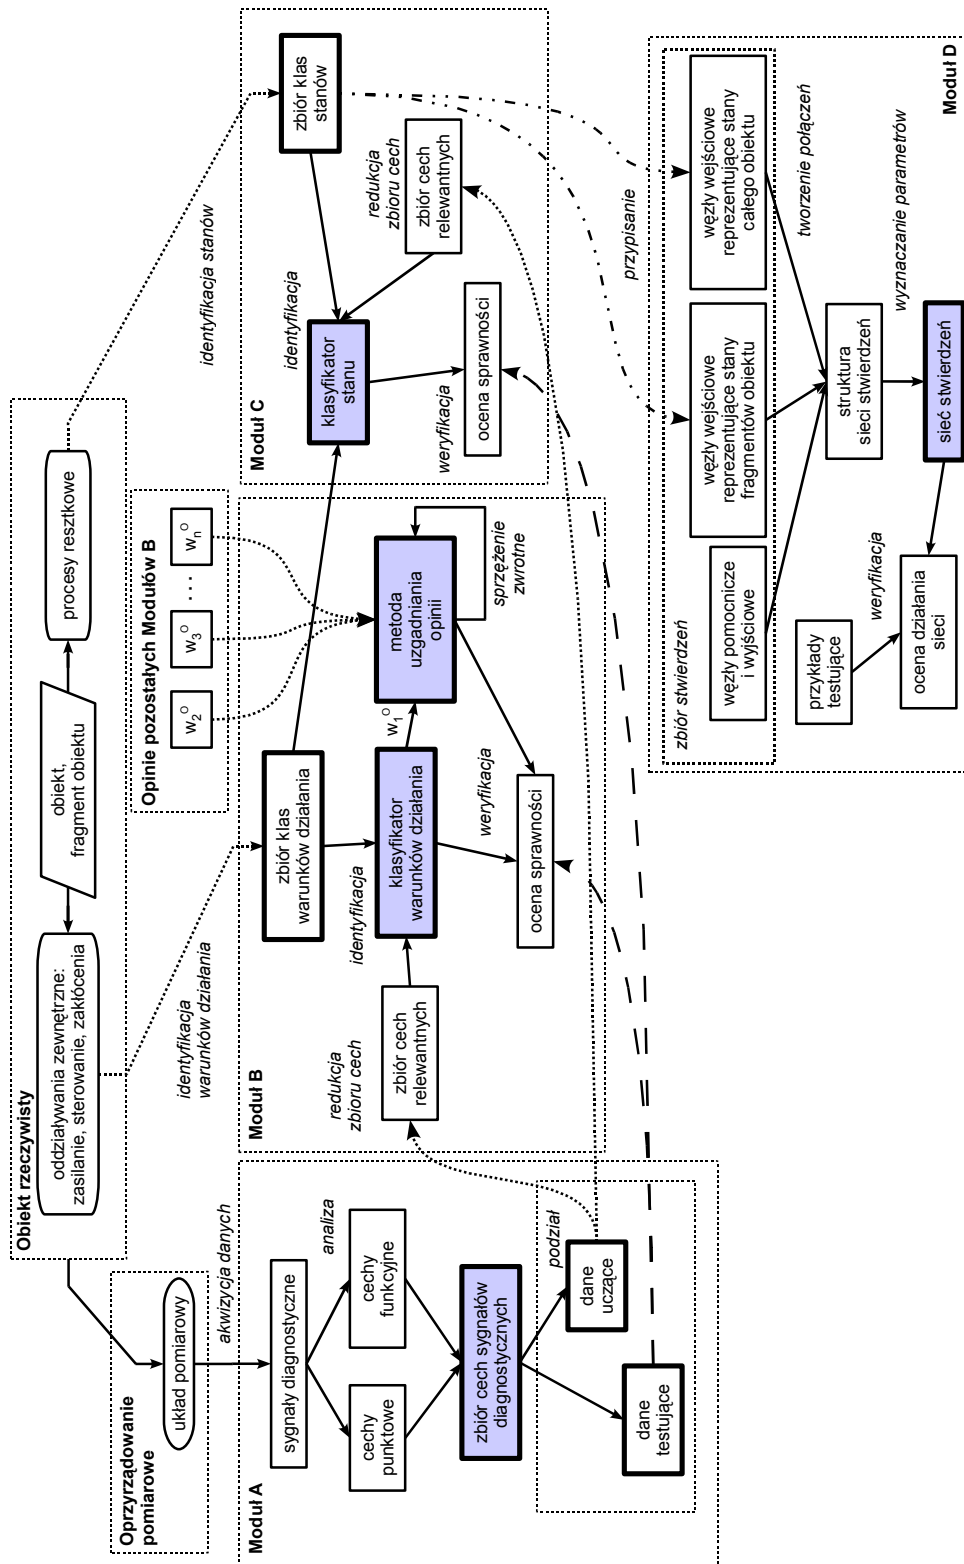
W celu przeprowadzenia identyfikacji Modułu D potrzebny jest zbiór klas stanów obiektu i jego fragmentów oraz zbiór stwierdzeń. Poszczególne stany są reprezentowane przez węzły tworzonej sieci stwierdzeń. Proces identyfikacji składa się z dwóch kroków:

**Krok 1** Tworzenie połączeń pomiędzy węzłami, w wyniku czego nadajemy sieci odpowiednią strukturę.

**Krok 2** Wyznaczanie parametrów sieci, w wyniku czego otrzymujemy tablice prawdopodobieństw warunkowych.

W ostatnim etapie przeprowadzana jest weryfikacja mająca na celu sprawdzenie poprawności działania sieci.

W p. 3.1 zwrócono uwagę, że jakość działania jednych modułów ma wpływ na jakość działania innych. Moduł D potrzebuje danych wypracowywanych przez Moduł C. Moduł C potrzebuje danych wynikających z działania Modułu A i Modułu B. Natomiast Moduł B jest identyfikowany na podstawie danych otrzymywanych z Modułu A.



Rys. 3.19. Ogólny schemat procesu identyfikacji modelu lokalnego (opis w tekście). Strzałki oznaczają działania, opisy w ramkach prostokątnych oznaczają wyniki przeprowadzanych działań, wyróżnione ramki prostokątne z opisami oznaczają ważniejsze cele prowadzonych działań.

W związku z tym jakość działania modelu lokalnego zależy od jakości działania poszczególnych modułów.

Z powodu silnych powiązań pomiędzy modułami doskonalenie proponowanej postaci modelu lokalnego polega na iteracyjnym doskonaleniu modułów. Optymalizacja jednego modułu pociąga za sobą optymalizację pozostałych. W przypadku Modułu A jakość zbioru cech sygnałów diagnostycznych zależy od jakości sygnałów pochodzących z obiektu lub jego fragmentu (rys. 3.18). Dlatego należy przeprowadzić wstępne przetwarzanie sygnałów diagnostycznych mające na celu uzyskanie sygnałów o lepszej jakości. Należy również, w miarę możliwości, zwiększać liczbę wyznaczanych cech sygnałów. Duża liczba zróżnicowanych cech zwiększa szanse, że metody redukcji zbioru cech znajdą lepsze zbiory cech relewantnych.

Ze względu na podobieństwo w działaniu Modułów B i C, można je optymalizować w podobny sposób (rys. 3.15 i rys. 3.13). Optymalizacji można poddać proces redukcji zbioru cech oraz proces rozpoznawania klas warunków działania lub klas stanów badanego obiektu. Dla obu przypadków można zastosować wybrane metody bazujące na [50]:

- miarach podobieństwa,
- sieciach neuronalnych,
- algorytmach ewolucyjnych,
- zbiorach rozmytych i przybliżonych,
- wykorzystujących kryterium minimum entropii.

Wymienione metody można stosować z zalecanymi parametrami lub optymalizować te parametry dążąc do poprawy jakości otrzymanego zbioru cech relewantnych.

W sieci stwierżeń (Moduł D, rys. 3.11) przeprowadza się optymalizację struktury sieci oraz jej parametrów. Optymalizację struktury przeprowadza się w dwóch etapach [13]:

**Etap 1** Wprowadza się dodatkowe gałęzie pomiędzy wybranymi węzłami, w celu poprawy jakości wnioskowania.

**Etap 2** Zmniejsza się liczbę parametrów sieci, poprzez usunięcie gałęzi i/lub węzłów, które nie wpływają na jakość wnioskowania.

Jednym ze sposobów optymalizacji parametrów sieci stwierżeń jest analiza wrażliwości, która pozwala ocenić jakość parametrów sieci, a przede wszystkim wartości prawdopodobieństw warunkowych.

---

## Wstępna weryfikacja metody


---

W rozdziale przeprowadzono weryfikację metody modelowania obiektów technicznych opisanej w rozdziale 3. Do weryfikacji wykorzystano dane pochodzące z symulatora maszyny wirnikowej. Celem badań weryfikacyjnych jest pokazanie przydatności proponowanej metody przedstawiania modelu obiektu w postaci zbioru modeli lokalnych.

### 4.1. Obiekt badań

#### 4.1.1. Charakterystyka obiektu

Do celów badań weryfikacyjnych wybrano model teoretyczny maszyny wirującej składającej się z wału osadzonego w dwóch podporach oraz z dwóch tarcz osadzonych na wale (rys. 4.1). Tarcze osadzone są w ten sposób, że dzielą wał na trzy równe długości.



Rys. 4.1. Wirnik dwupodporowy z dwiema tarczami. Oznaczenia: A, B - podpory łożyskowe; 1, 2 - tarcze

Modelem podstawowym do budowy symulatora był tzw. model Jeffcott'a (lub inaczej wirnik de Laval lub wirnik Föple'a) [124]. Model Jeffcott'a/Föple'a jest modelem z

jedną tarczą osadzoną na bezmasowym, lepkosprężystym (giętkim) wale w połowie odległości pomiędzy podporami tego wału [155]. Na potrzeby opracowanego symulatora rozbudowano ten model o jeszcze jedną tarczę. Jako modele podpór zastosowano sprężysto-tłumiący układ Kelvina-Voigt'a, który reprezentuje podatność i własności tłumiące łożysk oraz podpór [56].

W opracowanym modelu uwzględniono m.in. [124]:

- podatność i własności tłumiące łożysk oraz podpór,
- dodatkowe masy, które reprezentują inercję podpór i łożysk,
- anizotropię zewnętrzną układu związaną z jego posadowieniem (większa sztywność układu występuje dla kierunku pionowego, co ma miejsce w przypadku rzeczywistych układów),
- luz łożyskowy związany z promieniowym przemieszczeniem się czopa wału w panwi łożyska.

Przedstawiony model maszyny wirującej jest modelem nieliniowym uwzględniającym dwanaście stopni swobody.

#### 4.1.2. Warunki działania i stany obiektu

Zmieniając wartości parametrów konfiguracyjnych symulatora uzyskano możliwość obserwacji modelu maszyny wirującej w trzech warunkach działania:

$w_1 = w_1^0$  : rozruch ( $n\_obr = 0 \div 3600[obr/min]$ ),

$w_2 = w_2^0$  : praca ustalona ( $n\_obr = 3600[obr/min]$ ),

$w_3 = w_3^0$  : wybieg ( $n\_obr = 3600 \div 0[obr/min]$ ).

Dodatkowo wprowadzono trzy stany techniczne:

$s_1$  : nadmierny luz promieniowy w łożysku A,

$s_2$  : nadmierne niewyrównoważenie tarczy 1,

$s_3$  : nadmierne niewyrównoważenie tarczy 2.

Niewyrównoważenia były niewyrównoważeniami momentowymi. Obiekt uważano za zdatny, gdy były spełnione wszystkie poniższe warunki:

1. wartość luzu promieniowego w łożysku A  $\delta_A < 1.5[mm]$
2. wartość mimośrodów położenia tarczy 1  $e_1 < 15[mm]$
3. wartość mimośrodów położenia tarczy 2  $e_2 < 15[mm]$



Każdy stan był zadawany z różnymi wartościami luzu i mimośrodków:

$$s_0 : \quad (1) \delta_A = 0, e_1 = 0, e_2 = 0; \quad (2) \delta_A = 0.5[mm], e_1 = 5[mm], e_2 = 5[mm];$$

$$s_1 : \quad (1) \delta_A = 1.5[mm], e_1 = 5[mm], e_2 = 5[mm]; \quad (2) \delta_A = 3[mm], e_1 = 5[mm], e_2 = 5[mm];$$

$$s_2 : \quad (1) \delta_A = 0.5[mm], e_1 = 15[mm], e_2 = 5[mm]; \quad (2) \delta_A = 0.5[mm], e_1 = 30[mm], e_2 = 5[mm];$$

$$s_3 : \quad (1) \delta_A = 0.5[mm], e_1 = 5[mm], e_2 = 15[mm]; \quad (2) \delta_A = 0.5[mm], e_1 = 5[mm], e_2 = 30[mm].$$

Zatem każdy warunek działania  $w_i$  obserwowano w stanie pełnej zdatności ( $s_0$ ) oraz w trzech stanach reprezentujących różne niezdatności.

### 4.1.3. Dane symulacyjne

Symulator pozwalał na obserwację składowych  $x$  i  $y$  sygnałów przemieszczeń promieniowych w dwóch wzajemnie prostopadłych kierunkach każdej tarczy i podpory. Dodatkowo rejestrowano bieżącą prędkość obrotową wału  $n\_obr$ . Z racji tego, że prędkość obrotowa jest najlepszą cechą pozwalającą rozpoznać zaproponowane warunki działania  $w_i$ , będzie ona wykorzystywana w różnym zakresie w trakcie prowadzonych badań.

Wszystkie sygnały rejestrowano w przedziale czasu równym 10 [s] z częstotliwością próbkowania równą 1024 [Hz]. Na podstawie przeprowadzonych symulacji uzyskano w sumie 168 przykładów:

$$w_1 : s_0 \cdot 20 \text{ przykładów} + s_1 \cdot 20 \text{ przykładów} + s_2 \cdot 20 \text{ przykładów} + s_3 \cdot 20 \text{ przypadków} \\ = 80 \text{ przykładów}$$

$$w_2 : s_0 \cdot 2 \text{ przykłady} + s_1 \cdot 2 \text{ przykłady} + s_2 \cdot 2 \text{ przykłady} + s_3 \cdot 2 \text{ przykłady} = 8 \text{ przy-} \\ \text{kładów}$$

$$w_3 : s_0 \cdot 20 \text{ przykładów} + s_1 \cdot 20 \text{ przykładów} + s_2 \cdot 20 \text{ przykładów} + s_3 \cdot 20 \text{ przykładów} \\ = 80 \text{ przykładów}$$

W przypadku warunków  $w_1$  i  $w_3$ , dla każdego stanu z określonymi wartościami parametrów wyznaczano 10 przykładów. Przy czym przykłady te związane były z obserwacją obiektu w różnych zakresach zmian prędkości obrotowej wału w trakcie rozruchu i wybiegu - przedział zmian prędkości wirowania wału  $n\_obr$  został podzielony na 10 podprzedziałów. W przypadku stałej prędkości wirowania wału (warunek działania  $w_2$ ) wyznaczono po jednym przykładzie dla każdego stanu z określonymi wartościami luzu i mimośrodków.

## 4.2. Plan badań

Badania weryfikacyjne przeprowadzono według następujących kroków:

1. Przeprowadzono dekompozycję przestrzenną obiektu na fragmenty.
2. Przeprowadzono identyfikację modeli lokalnych. Dla każdego modelu lokalnego przeprowadzono:
  - (a) identyfikację Modułu A - wybrano i zastosowano funkcje wyznaczające wartości cech sygnałów;
  - (b) identyfikację Modułu B - z dostępnych danych trenujących wyznaczono zbiór cech relewantnych, które posłużyły wraz ze zbiorem możliwych warunków działania do budowy klasyfikatora warunków działania oraz wybrano metody uzgadniania opinii generowanych przez Moduły B;
  - (c) identyfikację Modułu C - z dostępnych danych trenujących wyznaczono zbiór cech relewantnych, które posłużyły wraz ze zbiorem możliwych stanów obiektu do budowy klasyfikatora stanów.
3. Zidentyfikowano Moduł D - określono zbiór stwierdzeń, utworzono strukturę sieci stwierdzeń oraz dobrano jej parametry.
4. Przeprowadzono identyfikację modeli globalnych - zbudowano klasyfikator warunków działania i klasyfikator stanów.
5. Dla zidentyfikowanych modeli lokalnych i modelu globalnego przeprowadzono badania porównawcze:
  - (a) Sprawdzone sprawności klasyfikatorów warunków działania.
  - (b) Sprawdzone skuteczność procesu uzgadniania opinii o warunkach działania całego obiektu.
  - (c) Sprawdzone sprawności klasyfikatorów stanów.
  - (d) Sprawdzone poprawność działania sieci stwierdzeń.

### 4.2.1. Opracowane oprogramowanie

Identyfikację Modułów A, B i C oraz badania weryfikacyjne przeprowadzono z użyciem programu MATLAB [103]. W tym celu utworzono pakiet funkcji przeznaczonych do:

- wyznaczania wartości cech sygnałów diagnostycznych,
- tworzenia zbiorów cech relewantnych,
- budowy klasyfikatorów warunków działania i klasyfikatorów stanów,
- przeprowadzania procesu agregacji i uzgadniania opinii.

Moduł D identyfikowano w programie Netica [113]. W tym celu użyto klas udostępnianych poprzez API JNetica. Utworzone oprogramowanie zostało napisane w języku Java [143]. Opracowane metody pozwoliły na wprowadzanie nowych wartości wybranych stwierdzeń i automatyczne uaktualnianie pozostałych.

## 4.3. Model obiektu

### 4.3.1. Dekompozycja obiektu na fragmenty

Dla przedstawionego na rysunku 4.1 obiektu zdecydowano się zastosować dekompozycję przestrzenną. W związku z tym badany obiekt  $O$  podzielono na cztery fragmenty:

$o_1 \in$  tarcza 1,

$o_2 \in$  tarcza 2,

$o_3 \in$  węzeł łożyskowy A,

$o_4 \in$  węzeł łożyskowy B.

Wszystkie wyróżnione fragmenty, tarcze i węzły łożyskowe, są związane ze sobą wałem, który pełni rolę „nośnika oddziaływań”. Każdy fragment  $o_i$  ma przyporządkowane sygnały dwóch składowych przemieszczeń  $x_{(\cdot)}$  i  $y_{(\cdot)}$  oraz sygnał prędkości obrotowej wału  $n\_obr$ .

### 4.3.2. Identyfikacja modeli lokalnych

Dla każdego fragmentu obiektu został zidentyfikowany jeden model lokalny:

$o_1 \rightarrow m_1^L$ ,  $o_2 \rightarrow m_2^L$ ,  $o_3 \rightarrow m_3^L$ ,  $o_4 \rightarrow m_4^L$ ,

zbudowany z Modułu A, Modułu B i Modułu C. Identyfikację modułów opisano w dalszej części tego punktu.

#### Moduł A

Na podstawie pozyskanych sygnałów przeprowadzono identyfikację Modułów A dla każdego z czterech modeli lokalnych  $m_i^L$ . Docelowo Moduł A powinien działać w czasie rzeczywistym, na bieżąco przetwarzając zarejestrowane sygnały na chwilowe wartości ich cech. Zakłada się, że są to wyłącznie cechy punktowe. W opisywanym przypadku zarejestrowane sygnały tworzą zbiór 168 par sygnałów  $x$  i  $y$  (każdy przykład jest realizacją dwóch sygnałów). Dla każdego testu wybierano zbiór sygnałów związany z danym warunkiem działania i danym stanem obiektu, a następnie wybierano 2 przykłady kolejno występujące po sobie. Powodem jest to, że w warunkach rozbiegu lub wybiegu zmienia się częstotliwość wymuszenia (w wyniku zmiany prędkości obrotowej wału). Zatem rozpatrywanie zbioru cech punktowych pojedynczej, chwilowej realizacji sygnału prowadzi do błędnej klasyfikacji warunków działania jako ustalone warunki pracy.

Identyfikowane Moduły A na wejściu posiadały sygnały składowych przemieszczeń  $x_{(.)}$  i  $y_{(.)}$  związane z rozpatrywanym fragmentem obiektu oraz sygnał aktualnej prędkości obrotowej wału  $n\_obr$ . Dla składowych przemieszczeń wyznaczone były cechy punktowe własne w dziedzinie czasu i dziedzinie częstotliwości oraz cechy punktowe wzajemne w dziedzinie czasu [42]. Wśród zbioru tych cech można wymienić:

- aktualną wartość prędkości obrotowej ( $n\_obr$ ),
- wartość średnią ( $(.)_{AVE}$ ; symbol  $(.)$  oznacza, że cecha jest wyznaczana dla składowej  $x$ ,  $y$  i trajektorii  $r$  liczonej wg wzoru 3.1),
- wartość skuteczną ( $(.)_{RMS}$ ),
- wartość szczytową ( $(.)_{PEAK}$ ),
- wartość międzyszczytową ( $(.)_{P-P}$ ),
- współczynnik kształtu ( $K_{(.)}$ ),
- współczynnik szczytu ( $C_{(.)}$ ),
- współczynnik impulsowości ( $I_{(.)}$ ),
- kurtozę ( $Ku_{(.)}$ ),
- skośność ( $S_{(.)}$ ),
- częstotliwość maksymalnej wartości widma amplitudowego ( $f\_a(.)_{max}$ ),
- wartości amplitud składowych o częstotliwościach  $0.33X$ ,  $0.4X$ ,  $0.5X$ ,  $1X$ ,  $2X$ ,  $3X$  i  $4X$  ( $a_{(.)}$ ),
- przesunięcia fazowe dla składowych o częstotliwościach  $1X$ ,  $2X$ ,  $3X$  i  $4X$  ( $\varphi_{(.)}$ ),
- współrzędne biegunowe środka trajektorii niecentralnej ( $r0$ ,  $\varphi0$ ),
- stopień okresowości ( $ReR_{zz}$ ) i okres trajektorii ( $T_1$ ).

Cały zbiór 74 cech punktowych ma następującą postać:

$$\begin{aligned}
 & n\_obr; \\
 & x_{AVE}; x_{RMS}; x_{PEAK}; x_{PEAK+}; x_{PEAK-}; x_{P-P}; K_x; C_x; I_x; Ku_x; S_x; \\
 & f\_ax_{max}; a_{x033}; a_{x04}; a_{x05}; a_{x1}; a_{x2}; a_{x3}; a_{x4}; \varphi_{x1}; \varphi_{x2}; \varphi_{x3}; \varphi_{x4}; \\
 & y_{AVE}; y_{RMS}; y_{PEAK}; y_{PEAK+}; y_{PEAK-}; y_{P-P}; K_y; C_y; I_y; Ku_y; S_y; \\
 & f\_ay_{max}; a_{y033}; a_{y04}; a_{y05}; a_{y1}; a_{y2}; a_{y3}; a_{y4}; \varphi_{y1}; \varphi_{y2}; \varphi_{y3}; \varphi_{y4}; \\
 & r_{AVE}; r_{RMS}; r_{PEAK}; r_{PEAK+}; r_{PEAK-}; r_{P-P}; K_r; C_r; I_r; Ku_r; S_r; \\
 & f\_ar_{max}; a_{r033}; a_{r04}; a_{r05}; a_{r1}; a_{r2}; a_{r3}; a_{r4}; \varphi_{r1}; \varphi_{r2}; \varphi_{r3}; \varphi_{r4}; \\
 & r0; \varphi0; ReR_{zz}; T_1
 \end{aligned} \tag{4.1}$$

Badany model obiektu jest modelem zdeterminowanym, do sygnałów składowych  $x$  i  $y$  nie był dodawany szum. Jak napisano w p. 4.1.1 model jest modelem nieliniowym. Głównym źródłem nieliniowości jest wprowadzany luz. Ważne jest, żeby opracowywany zbiór cech sygnałów był zbiorem możliwie licznym. Wówczas istnieje większa szansa znalezienia „dobrego” zbioru cech relewantnych. Ponadto, dwie cechy, które pozwalają na zbudowanie skutecznych klasyfikatorów, nie muszą pozwalać na budowę jednego, jeszcze lepiej działającego klasyfikatora. Zdarza się, że dwie „przeciętne” cechy mogą pozwolić na budowę klasyfikatora charakteryzującego się dużą sprawnością.

### **Moduł B**

Wyznaczone przez Moduły A wektory wartości cech sygnałów stanowią dane wejściowe pozwalające na identyfikację Modułów B. Moduł B realizuje dwie funkcje:

1. rozpoznaje klasę warunków działania - jest klasyfikatorem warunków działania,
2. bierze udział w procesie uzgadniania opinii wraz z pozostałymi Modułami B.

W procesie klasyfikacji użyto dwóch metod:

1. klasyfikacji z użyciem miar odległości,
2. klasyfikacji z użyciem sieci neuronalnej.

W przypadku metody klasyfikacji z użyciem miar odległości zastosowano kryterium najbliższego sąsiada z funkcją odległości w postaci miary euklidesowej. Liczba rozpoznawanych klas była równa 3. Natomiast jako sieć neuronalną zastosowano sieć typu feed-forward zbudowaną z jednej warstwy ukrytej zawierającej 5 neuronów z sigmoidalną funkcją przejścia oraz jednej warstwy wyjściowej zawierającej 3 neurony z liniową funkcją przejścia. Sieci neuronalne zostały poddane optymalizacji z użyciem algorytmu ewolucyjnego (p. 2.3). Kierując się wytycznymi zawartymi m.in. w [150] przyjęto, że:

- genotyp osobnika  $p$  jest chromosomem zbudowanym z rzeczywistoliczbowego ciągu o długości odpowiadającej liczbie rozpatrywanych cech punktowych (każda cecha posiada własny identyfikator);
- fenotyp osobnika  $p$  stanowi rozkład przykładów trenujących w przestrzeni cech relewantnych (dla danego osobnika);
- populacje początkowe są generowane losowo;
- selekcja jest przeprowadzana metodą selekcji proporcjonalnej;
- sukcesja jest przeprowadzana według modelu elitarnego;
- krzyżowanie osobników jest przeprowadzane jako jednopunktowe;
- wartości parametrów algorytmu są następujące:

- liczba osobników  $p$  (stała) = 30,
- liczba rozpatrywanych cech =  $max$  7,
- liczba pokoleń = 50,
- współczynnik krzyżowania = 30 [%],
- współczynnik mutacji = 1 [%].

Z racji charakteru rozpoznawanych warunków działania, najlepszą cechą jest prędkość obrotowa wału  $n_{obr}$ . Ścisłej mówiąc nie jej wartość, a zmiana wartości w stosunku do poprzednio zarejestrowanej. Stąd wymagane jest uprzednie wyznaczenie gradientów wartości kolejnych prędkości obrotowych wału. Na tak przygotowanych danych przeprowadzono testy klasyfikatorów. Połowa danych stanowiła dane uczące, a druga połowa dane testujące. Wynik klasyfikacji wyniósł 100 [%] poprawnie rozpoznanych przykładów.

Biorąc pod uwagę tylko prędkość obrotową wału  $n_{obr}$ , zamiast omówionych wyżej klasyfikatorów wystarczy użyć prostej tablicy decyzyjnej (tab. 4.1). Wówczas zadanie klasyfikacji uprości się do analizy czterech reguł z dwiema przesłankami.

Tab. 4.1. Tablica decyzyjna wspomagająca rozpoznawanie klas warunków działania obiektu

	TREŚĆ STWIERDZENIA	R1	R2	R3	R4
C1	Prędkość wirowania wału rośnie	Y	N	N	Y
C2	Prędkość wirowania wału maleje	N	Y	N	Y
A1	Rozbieg ( $w_1$ )	X			
A2	Praca ustalona ( $w_2$ )			X	
A3	Wybieg ( $w_3$ )		X		
E1	Błąd				X
E2	Koniec	X	X	X	


W praktyce nie zawsze jest dostęp do sygnału prędkości wirowania wału. W związku z tym podjęto próbę znalezienia innych cech, ze zbioru cech pozyskiwanych z sygnałów przemieszczeń (4.1), które pozwolą na skuteczną klasyfikację warunków działania danego fragmentu obiektu. W tym celu zastosowano analizę korelacji wzajemnej  $R_{xy}$  dla prędkości obrotowej wału i każdej cechy punktowej ze zbioru (4.1). W wyniku otrzymano dwie cechy, które są skorelowane z prędkością wirowania wału na poziomie równym przynajmniej 0.9, są to: częstotliwość maksymalnej wartości widma amplitudowego składowej  $x_{(.)}$  ( $f_{axmax}$ ) i składowej  $y_{(.)}$  ( $f_{aymax}$ ). Ostatecznie wyznaczone cechy podawano na wejście klasyfikatora działającego zgodnie z metodą klasyfikacji z użyciem miar odległości.

W przypadku klasyfikatora w postaci sieci neuronalnej, w wyniku ewolucyjnej optymalizacji zbioru cech podawanych na wejście otrzymano wyniki, które zamieszczono w tab. 4.2.

Tab. 4.2. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów B (cechy są szeregowane od najczęściej występującej)

	cechy relewantne	pozostałe cechy
$m_1^L$	$f_{ax_{max}}, T_1, f_{ay_{max}}$	$y_{AVE}, x_{P-P}, x_{PEAK}$
$m_2^L$	$f_{ay_{max}}, T_1, x_{P-P}$	$f_{ax_{max}}, I_y, x_{PEAK}$
$m_3^L$	$f_{ax_{max}}, f_{ay_{max}}, T_1$	$I_x, r_{PEAK}$
$m_4^L$	$T_1, f_{ay_{max}}, r_{PEAK}$	$f_{ax_{max}}, Ku_r$

Przykład przebiegu wartości średniej funkcji przystosowania całej populacji w kolejnych pokoleniach pokazano na rys. 4.2.



Rys. 4.2. Średnia wartość funkcji przystosowania całej populacji w kolejnych pokoleniach; model  $m_1^L$ , Moduł B

Empirycznie ustalono, że najlepszym zbiorem cech relewantnych podawanych na

wejście sieci neuronalnej każdego Modułu B, będzie zbiór następujących czterech cech:

$$\{f_{\_axmax}, f_{\_aymax}, T_1, x_{P-P}\} \quad (4.2)$$

### Uzgadnianie opinii

Proces uzgadniania opinii zrealizowano za pomocą czterech metod:

1. metody opartej na teorii zbiorów - suma zbiorów ze zliczaniem powtarzających się elementów,
2. metody agregacji opinii - operator średniej quasi-arytmetycznej,
3. metody agregacji opinii - operator t-conorm,
4. automatu komórkowego.

Spośród wymienionych metod wyjaśnienia wymaga metoda bazująca na automacie komórkowym. Dla każdego modelu lokalnego wyznaczono zbiory sąsiadów  $\Lambda$ , a następnie każdy z nich podzielono na dwa podzbiory: podzbiór sąsiadów *bliskich* ( $\Lambda^B$ ) i podzbiór sąsiadów *dalekich* ( $\Lambda^D$ ). Podstawą do orzeczenia czy dany model należy do któregoś zbiory sąsiadów było bezpośrednie sąsiedztwo fragmentów obiektu w rozpatrywanym obiekcie. Zatem dla poszczególnych modeli lokalnych wyróżniono następujące zbiory sąsiadów:

1.  $\Lambda_1^B = \{m_3^L, m_2^L\}$ ,  $\Lambda_1^D = \{m_4^L\}$ ;
2.  $\Lambda_2^B = \{m_1^L, m_4^L\}$ ,  $\Lambda_2^D = \{m_3^L\}$ ;
3.  $\Lambda_3^B = \{m_1^L\}$ ,  $\Lambda_3^D = \{m_2^L\}$ ;
4.  $\Lambda_4^B = \{m_2^L\}$ ,  $\Lambda_4^D = \{m_1^L\}$ .

Następnie, dla każdego Modułu B wyznaczano wektor trzech wartości stopni przekonania o pracy maszyny w danych warunkach działania:

$$\langle b(\text{rozbieg}), b(\text{praca ustalona}), b(\text{wybieg}) \rangle \quad (4.3)$$

Każda wartość  $b(\cdot)$  zawierała się w przedziale  $[0;1]$ . Wartość  $b(\cdot) = 1$  oznacza pełne przekonanie o tym, że fragment obiektu działa w danych warunkach. Jako stan bazowy przyjmowano wartość równą 1 dla stopnia przekonania wstępnie sklasyfikowanego warunku działania. Pozostałe dwa stopnie przekonania posiadały wartość równą 0. Funkcję przejścia stanowił zbiór reguł porównujących poszczególne wartości stopni przekonania danego modelu lokalnego z wartościami stopni przekonania modeli lokalnych z podzbiorów  $\Lambda^B$  i  $\Lambda^D$ . Porównanie następowało według następujących reguł:

1. W przypadku, gdy model lokalny pochodzi z podzbioru  $\Lambda^B$  i:
  - (a) jego poszczególne wartości stopni przekonania są równe lub większe od własnych, to zwiększ własne odpowiadające wartości stopni przekonania o 0.25;



- (b) jego poszczególne wartości stopni przekonania są mniejsze od własnych, to zmniejsz własne odpowiadające wartości stopni przekonania o 0.15;
2. W przypadku, gdy model lokalny pochodzi z podzbioru  $\Lambda^D$  i:
- (a) jego poszczególne wartości stopni przekonania są równe lub większe od własnych, to zwiększ własne odpowiadające wartości stopni przekonania o 0.15;
- (b) jego poszczególne wartości stopni przekonania są mniejsze od własnych, to zmniejsz własne odpowiadające wartości stopni przekonania o 0.10;

Działanie automatu komórkowego kończono po 50 krokach. Na podstawie wartości stopni przekonania (wzór 6.1) przeprowadzano proces wyostrenia opinii z użyciem operatora  $\max(\cdot)$  i na tej podstawie modele lokalne określały najbardziej prawdopodobne warunki działania całego obiektu. W przypadku, gdy dwa lub trzy stopnie przekonania osiągały tę samą wartość, to uznawano, że proces uzgadniania opinii zakończył się niepomyślnie.

Tab. 4.3. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów C modelu  $m_1^L$  (cechy są szeregowane od najczęściej występującej)

$m_1^L$

	cechy relewantne	pozostałe cechy
$w_1$	$C_y, Ku_x, a_{r3}$	$x_{AVE}, a_{r05}$
$w_2$	$y_{PEAK-}, ReR_{zz}, r_{AVE}$	$a_{x04}, a_{y4}, Y_{RMS}$
$w_3$	$I_x, f_{-ay_{max}}, y_{PEAK}$	$C_x, Y_{RMS}, r_{RMS}$
$w_1+w_2+w_3$	$x_{AVE}, x_{P-P}, f_{-ax_{max}}, C_x, r_{AVE}, a_{y4}$	$x_{PEAK+}$

Tab. 4.4. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów C modelu  $m_2^L$  (cechy są szeregowane od najczęściej występującej)

$m_2^L$

	cechy relewantne	pozostałe cechy
$w_1$	$f_{-ay_{max}}, r_{PEAK}, a_{r04}$	$K_y, a_{x04}$
$w_2$	$a_{y3}, y_{PEAK-}, f_{-ay_{max}}, x_{RMS}$	$\varphi_{x1}, a_{y4}, C_r$
$w_3$	$y_{P-P}, f_{-ax_{max}}, x_{AVE}$	$C_x, y_{PEAK-}$
$w_1+w_2+w_3$	$f_{-ax_{max}}, x_{AVE}, y_{PEAK}, y_{P-P}$	$\varphi_0$

## Moduł C

Zadaniem Modułu C jest określenie klasy stanu fragmentu obiektu na podstawie wartości cech sygnałów dostarczanych przez poszczególne Moduły A oraz informacji o bieżącej

Tab. 4.5. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów C modelu  $m_3^L$  (cechy są szeregowane od najczęściej występującej)

$m_3^L$

	cechy relewantne	pozostałe cechy
$w_1$	$\varphi_0, S_r, a_{r04}, y_{PEAK}, f_{ax_{max}}$	$x_{PEAK}, a_{r033}$
$w_2$	$f_{ax_{max}}, y_{PEAK}, Ku_y, x_{PEAK}$	$C_r, a_{x033}$
$w_3$	$n_{obr}, f_{ay_{max}}, y_{PEAK}, S_r$	$x_{AVE}, y_{AVE}$
$w_1+w_2+w_3$	$Ku_y, S_r, f_{ay_{max}}, a_{r4}, f_{ax_{max}}$	$a_{r1}, \varphi_0$

Tab. 4.6. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów C modelu  $m_4^L$  (cechy są szeregowane od najczęściej występującej)


$m_4^L$

	cechy relewantne	pozostałe cechy
$w_1$	$a_{y05}, K_r, C_x, a_{r4}$	$x_{RMS}, y_{AVE}$
$w_2$	$r_{AVE}, x_{PEAK}, f_{ax_{max}}, a_{x4}, a_{r1}$	$r_0, ReR_{zz}, S_r, f_{ay_{max}}$
$w_3$	$r_{RMS}, y_{PEAK}, f_{ax_{max}}, \varphi_0, x_{PEAK}$	$f_{ay_{max}}, a_{x4}$
$w_1+w_2+w_3$	$r_{PEAK}, y_{PEAK}, I_x, f_{ay_{max}}$	$a_{x033}$

klasie warunków działania obiektu. W związku z tym, dla każdego Modułu C należało zbudować trzy klasyfikatory - po jednym dla każdego, symulowanego warunku działania obiektu. Biorąc pod uwagę wyniki (p. 4.5) działania klasyfikatorów neuronalnych zbudowanych na potrzeby rozpoznawania warunków działania obiektu, zdecydowano, że ten typ klasyfikatora zostanie również użyty dla zadania określania klas stanu fragmentów obiektu. Zastosowana sieć typu feed-forward zbudowana była z jednej warstwy ukrytej zawierającej 5 neuronów z sigmoidalną funkcją przejścia oraz jednej warstwy wyjściowej zawierającej 4 neurony z liniową funkcją przejścia. Sieci neuronalne zostały poddane optymalizacji z użyciem algorytmu ewolucyjnego o następujących parametrach:

- liczba osobników  $p$  (stała) = 30,
- liczba rozpatrywanych cech =  $max$  7,
- liczba pokoleń = 50,
- współczynnik krzyżowania = 30 [%],
- współczynnik mutacji = 1 [%].

W wyniku optymalizacji otrzymano zbiory cech relewantnych, które zaprezentowano w tabelach 4.3 ÷ 4.6. Wiersz  $w_1 + w_2 + w_3$  zawiera zbiór cech uzyskany po uwzględnieniu



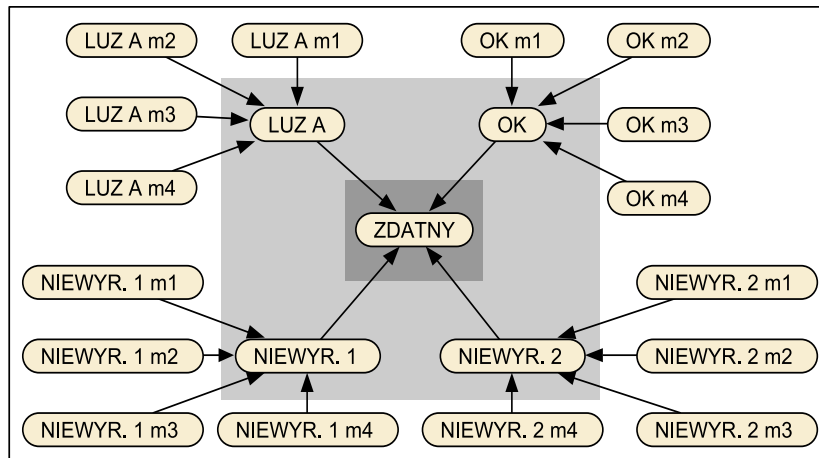
Rys. 4.3. Średnia wartość funkcji przystosowania całej populacji w kolejnych pokoleniach; model  $m_3^L$ , Moduł C.  $w_1$  - rozbieg,  $w_2$  - praca ustalona,  $w_3$  - wybieg

wszystkich przykładów uczących dla rozpatrywanych trzech warunków działania obiektu. Przykład przebiegu wartości średniej funkcji przystosowania całej populacji w kolejnych pokoleniach dla poszczególnych warunków działania pokazano na rys. 4.3.

### Łączenie modeli lokalnych

Na rys. 4.4 przedstawiono postać sieci przekonań, którą opracowano z użyciem programu Netica [113]. Zadaniem sieci stwierdzeń jest synteza wyników generowanych przez poszczególne modele lokalne  $m_i^L$ . Wyróżnione, ciemniejsze obszary pokazują różne stopnie szczególności. Wynikiem działania każdego modelu lokalnego jest zbiór wartości stopni przekonania  $b_j$  o wystąpieniu danego stanu technicznego  $s_j$ . W rozpatrywanym przypadku każdy model lokalny rozpoznawał cztery stany:

- $s_0$  fragment obiektu jest zdalny,
- $s_1$  nadmierny luz promieniowy w łożysku A,
- $s_2$  nadmierne niewyrównoważenie tarczy 1,
- $s_3$  nadmierne niewyrównoważenie tarczy 2.



Rys. 4.4. Sieć przekonań - synteza modelu globalnego. Oznaczenia: m1 - model lokalny  $m_1^L$ , m2 -  $m_2^L$ , m3 -  $m_3^L$ , m4 -  $m_4^L$ , ZDATNY -  $s'_0$ , OK -  $s_0$ , LUZ A -  $s_1$ , NIEWYR. 1 -  $s_2$ , NIEWYR. 2 -  $s_3$

Każda pojedyncza wartość stopnia przekonania jest przypisywana do odpowiedniego stwierdzenia  $z_{i,j}$ . Stwierdzenia są zapisywane z dwoma indeksami: indeks  $i$  odpowiada numerowi modelu lokalnego, indeks  $j$  odpowiada numerowi stanu. Wyjątek stanowi indeks  $i = 0$ , który dotyczy całego obiektu. Wykaz stwierdzeń umieszczono w tab. 4.7. Razem utworzono 16 stwierdzeń, które stanowiły wejście do sieci. Na wyjściu znajduje się jedno stwierdzenie  $z_{00}$  o treści *Obiekt jest zdatny*. Pozostałe cztery stwierdzenia pomocnicze  $z_{01} \div z_{04}$  mają za zadanie grupować stwierdzenia tego samego typu. Tabele z wartościami prawdopodobieństw warunkowych dla stwierdzeń pomocniczych i stwierdzenia wyjściowego zamieszczono w tabelach 4.8  $\div$  4.12. Wartości prawdopodobieństw warunkowych generowano z użyciem wiedzy eksperckiej na podstawie następujących zasad:

1. Wartość stwierdzenia wyjściowego  $z_{00}$  (*Obiekt jest zdatny*) powinna rosnąć wraz ze wzrostem wartości stwierdzenia  $z_{01}$  i spadkiem wartości stwierdzeń  $z_{02}$ ,  $z_{03}$  i  $z_{04}$ , przy czym największy wpływ na zmiany wartości tego stwierdzenia powinno mieć stwierdzenie  $z_{01}$  (*Fragment obiektu jest zdatny*).
2. Wartość stwierdzenia pomocniczego  $z_{01}$  (*Fragment obiektu jest zdatny*) powinna rosnąć wraz ze wzrostem wartości stwierdzeń  $z_{11}$ ,  $z_{21}$ ,  $z_{31}$  i  $z_{41}$ , przy czym wszystkie stwierdzenia mają ten sam wpływ na wartość tego stwierdzenia.
3. Wartość stwierdzenia pomocniczego  $z_{02}$  (*Występuje nadmierny luz promieniowy w łożysku A*) powinna rosnąć wraz ze wzrostem wartości stwierdzeń  $z_{12}$ ,  $z_{22}$ ,  $z_{32}$  i  $z_{42}$ , przy czym największy wpływ na zmiany wartości tego stwierdzenia powinno mieć stwierdzenie  $z_{32}$ , które jest związane z modelem lokalnym  $m_3^L$ , czyli pośrednio z węzłem łożyskowym A.
4. Wartość stwierdzenia pomocniczego  $z_{03}$  (*Występuje nadmierne niewyrównoważenie tarczy 1*) powinna rosnąć wraz ze wzrostem wartości stwierdzeń  $z_{13}$ ,  $z_{23}$ ,  $z_{33}$  i  $z_{43}$ , przy czym największy wpływ na zmiany wartości tego stwierdzenia powinno mieć

Tab. 4.7. Wykaz stwierdzeń

identyfikator	treść stwierdzenia
stwierdzenie wyjściowe	
$z_{00}$	Obiekt jest zdatny ( $s'_0$ )
stwierdzenia pomocnicze (grupujące)	
$z_{01}$	Fragment obiektu jest zdatny ( $s_0$ )
$z_{02}$	Występuje nadmierny luz promieniowy w łożysku A ( $s_1$ )
$z_{03}$	Występuje nadmierne niewyrównoważenie tarczy 1 ( $s_2$ )
$z_{04}$	Występuje nadmierne niewyrównoważenie tarczy 2 ( $s_3$ )
stwierdzenia wejściowe związane z modelem $m_1^L$	
$z_{11}$	Fragment obiektu jest zdatny ( $s_0$ )
$z_{12}$	Występuje nadmierny luz promieniowy w łożysku A ( $s_1$ )
$z_{13}$	Występuje nadmierne niewyrównoważenie tarczy 1 ( $s_2$ )
$z_{14}$	Występuje nadmierne niewyrównoważenie tarczy 2 ( $s_3$ )
stwierdzenia wejściowe związane z modelem $m_2^L$	
$z_{21}$	Fragment obiektu jest zdatny ( $s_0$ )
$z_{22}$	Występuje nadmierny luz promieniowy w łożysku A ( $s_1$ )
$z_{23}$	Występuje nadmierne niewyrównoważenie tarczy 1 ( $s_2$ )
$z_{24}$	Występuje nadmierne niewyrównoważenie tarczy 2 ( $s_3$ )
stwierdzenia wejściowe związane z modelem $m_3^L$	
$z_{31}$	Fragment obiektu jest zdatny ( $s_0$ )
$z_{32}$	Występuje nadmierny luz promieniowy w łożysku A ( $s_1$ )
$z_{33}$	Występuje nadmierne niewyrównoważenie tarczy 1 ( $s_2$ )
$z_{34}$	Występuje nadmierne niewyrównoważenie tarczy 2 ( $s_3$ )
stwierdzenia wejściowe związane z modelem $m_4^L$	
$z_{41}$	Fragment obiektu jest zdatny ( $s_0$ )
$z_{42}$	Występuje nadmierny luz promieniowy w łożysku A ( $s_1$ )
$z_{43}$	Występuje nadmierne niewyrównoważenie tarczy 1 ( $s_2$ )
$z_{44}$	Występuje nadmierne niewyrównoważenie tarczy 2 ( $s_3$ )

stwierdzenie  $z_{13}$ , które jest związane z modelem lokalnym  $m_1^L$ , czyli pośrednio z tarczą 1.

5. Wartość stwierdzenia pomocniczego  $z_{04}$  (*Występuje nadmierne niewyrównoważenie*

tarczy 2) powinna rosnąć wraz ze wzrostem wartości stwierdzeń  $z_{14}$ ,  $z_{24}$ ,  $z_{34}$  i  $z_{44}$ , przy czym największy wpływ na zmiany wartości tego stwierdzenia powinno mieć stwierdzenie  $z_{24}$ , które jest związane z modelem lokalnym  $m_2^L$ , czyli pośrednio z tarczą 2.

Dodatkowe stwierdzenie  $z_{00}$  reprezentujące stan  $s'_0$  (stan pełnej zdatności całego obiektu) wprowadzono po to, żeby w łatwy sposób sprawdzić czy obiekt jest zdatny do wypełniania wymaganych funkcji. W przypadku, gdy obiekt jest niezdatny (wartość stwierdzenia  $z_{00}$  jest niższa od założonej wartości granicznej), sprawdzane są wartości stwierdzeń  $z_{01} \div z_{04}$ . Proces ten można kontynuować, aż do stwierdzeń będącymi liśćmi drzewa stwierdzeń.

Tab. 4.8. Wartości prawdopodobieństw warunkowych stwierdzenia wyjściowego  $z_{00}$ . Oznaczenia:  $z_{0,j}$  - stwierdzenie ukryte (grupujące),  $j$  - indeks stanu  $s_j$

identyfikator węzła:  $z_{00}$

stan		identyfikator węzła			
TAK	NIE	$z_{01}$	$z_{02}$	$z_{03}$	$z_{04}$
0,3	0,7	TAK	TAK	TAK	TAK
0,4	0,6	TAK	TAK	TAK	NIE
0,4	0,6	TAK	TAK	NIE	TAK
0,5	0,5	TAK	TAK	NIE	NIE
0,4	0,6	TAK	NIE	TAK	TAK
0,5	0,5	TAK	NIE	TAK	NIE
0,5	0,5	TAK	NIE	NIE	TAK
1,0	0,0	TAK	NIE	NIE	NIE
0,0	1,0	NIE	TAK	TAK	TAK
0,0	1,0	NIE	TAK	TAK	NIE
0,0	1,0	NIE	TAK	NIE	TAK
0,0	1,0	NIE	TAK	NIE	NIE
0,0	1,0	NIE	NIE	TAK	TAK
0,0	1,0	NIE	NIE	TAK	NIE
0,0	1,0	NIE	NIE	NIE	TAK
0,5	0,5	NIE	NIE	NIE	NIE

### 4.3.3. Identyfikacja modeli globalnych

Na potrzeby badań weryfikacyjnych dodatkowo zbudowano modele globalne obiektu. Identyfikację modeli podzielono na dwa etapy:

**Etap 1** Identyfikacja modelu rozpoznającego warunki działania obiektu.

**Etap 2** Identyfikacja modelu rozpoznającego stan obiektu.

W obydwu etapach obliczenia przeprowadzono dla zbioru danych uczących  $DU$  będącego sumą zbiorów danych uczących pozyskanych na potrzeby identyfikacji modeli lokalnych:

$$DU = DU_1 \cup DU_2 \cup DU_3 \cup DU_4 \quad (4.4)$$

Tab. 4.9. Wartości prawdopodobieństw warunkowych stwierdzenia pomocniczego  $z_{01}$ . Oznaczenia:  $z_{i,1}$  - stwierdzenie wejściowe,  $i$  - indeks modelu lokalnego  $m_i^L$

**identyfikator węzła:  $z_{01}$**

<b>stan</b>		<b>identyfikator węzła</b>			
<i>TAK</i>	<i>NIE</i>	$z_{11}$	$z_{21}$	$z_{31}$	$z_{41}$
1,0	0,0	TAK	TAK	TAK	TAK
0,9	0,1	TAK	TAK	TAK	NIE
0,9	0,1	TAK	TAK	NIE	TAK
0,6	0,4	TAK	TAK	NIE	NIE
0,9	0,1	TAK	NIE	TAK	TAK
0,6	0,4	TAK	NIE	TAK	NIE
0,6	0,4	TAK	NIE	NIE	TAK
0,3	0,7	TAK	NIE	NIE	NIE
0,9	0,1	NIE	TAK	TAK	TAK
0,6	0,4	NIE	TAK	TAK	NIE
0,6	0,4	NIE	TAK	NIE	TAK
0,3	0,7	NIE	TAK	NIE	NIE
0,6	0,4	NIE	NIE	TAK	TAK
0,3	0,7	NIE	NIE	TAK	NIE
0,3	0,7	NIE	NIE	NIE	TAK
0,0	1,0	NIE	NIE	NIE	NIE

Tab. 4.10. Wartości prawdopodobieństw warunkowych stwierdzenia pomocniczego  $z_{02}$ . Oznaczenia:  $z_{i,2}$  - stwierdzenie wejściowe,  $i$  - indeks modelu lokalnego  $m_i^L$

**identyfikator węzła:  $z_{02}$**

<b>stan</b>		<b>identyfikator węzła</b>			
<i>TAK</i>	<i>NIE</i>	$z_{12}$	$z_{22}$	$z_{32}$	$z_{42}$
1,0	0,0	TAK	TAK	TAK	TAK
1,0	0,0	TAK	TAK	TAK	NIE
0,9	0,1	TAK	TAK	NIE	TAK
0,8	0,2	TAK	TAK	NIE	NIE
1,0	0,0	TAK	NIE	TAK	TAK
1,0	0,0	TAK	NIE	TAK	NIE
0,6	0,4	TAK	NIE	NIE	TAK
0,5	0,5	TAK	NIE	NIE	NIE
1,0	0,0	NIE	TAK	TAK	TAK
1,0	0,0	NIE	TAK	TAK	NIE
0,4	0,6	NIE	TAK	NIE	TAK
0,3	0,7	NIE	TAK	NIE	NIE
0,8	0,2	NIE	NIE	TAK	TAK
0,7	0,3	NIE	NIE	TAK	NIE
0,1	0,9	NIE	NIE	NIE	TAK
0,0	1,0	NIE	NIE	NIE	NIE

Tab. 4.11. Wartości prawdopodobieństw warunkowych stwierdzenia pomocniczego  $z_{03}$ . Oznaczenia:  $z_{i,3}$  - stwierdzenie wejściowe,  $i$  - indeks modelu lokalnego  $m_i^L$

**identyfikator węzła:  $z_{03}$**

<b>stan</b>		<b>identyfikator węzła</b>			
<i>TAK</i>	<i>NIE</i>	$z_{13}$	$z_{23}$	$z_{33}$	$z_{43}$
1,0	0,0	TAK	TAK	TAK	TAK
1,0	0,0	TAK	TAK	TAK	NIE
1,0	0,0	TAK	TAK	NIE	TAK
1,0	0,0	TAK	TAK	NIE	NIE
1,0	0,0	TAK	NIE	TAK	TAK
1,0	0,0	TAK	NIE	TAK	NIE
1,0	0,0	TAK	NIE	NIE	TAK
0,7	0,3	TAK	NIE	NIE	NIE
1,0	0,0	NIE	TAK	TAK	TAK
1,0	0,0	NIE	TAK	TAK	NIE
0,8	0,2	NIE	TAK	NIE	TAK
0,5	0,5	NIE	TAK	NIE	NIE
0,8	0,2	NIE	NIE	TAK	TAK
0,5	0,5	NIE	NIE	TAK	NIE
0,3	0,7	NIE	NIE	NIE	TAK
0,0	1,0	NIE	NIE	NIE	NIE

Tab. 4.12. Wartości prawdopodobieństw warunkowych stwierdzenia pomocniczego  $z_{04}$ . Oznaczenia:  $z_{i,4}$  - stwierdzenie wejściowe,  $i$  - indeks modelu lokalnego  $m_i^L$

**identyfikator węzła:  $z_{04}$**

<b>stan</b>		<b>identyfikator węzła</b>			
<i>TAK</i>	<i>NIE</i>	$z_{14}$	$z_{24}$	$z_{34}$	$z_{44}$
1,0	0,0	TAK	TAK	TAK	TAK
1,0	0,0	TAK	TAK	TAK	NIE
1,0	0,0	TAK	TAK	NIE	TAK
1,0	0,0	TAK	TAK	NIE	NIE
1,0	0,0	TAK	NIE	TAK	TAK
0,8	0,2	TAK	NIE	TAK	NIE
1,0	0,0	TAK	NIE	NIE	TAK
0,5	0,5	TAK	NIE	NIE	NIE
1,0	0,0	NIE	TAK	TAK	TAK
1,0	0,0	NIE	TAK	TAK	NIE
1,0	0,0	NIE	TAK	NIE	TAK
0,7	0,3	NIE	TAK	NIE	NIE
0,8	0,2	NIE	NIE	TAK	TAK
0,3	0,7	NIE	NIE	TAK	NIE
0,5	0,5	NIE	NIE	NIE	TAK
0,0	1,0	NIE	NIE	NIE	NIE



Do testów użyto zbioru będącego sumą zbiorów danych testujących służących do oceny klasyfikatorów modeli lokalnych:

$$DT = DT_1 \cup DT_2 \cup DT_3 \cup DT_4 \quad (4.5)$$

### Identyfikacja modelu rozpoznającego warunki działania obiektu

Tak jak w przypadku modeli lokalnych, dla modelu globalnego zidentyfikowano dwa klasyfikatory warunków działania - klasyfikator używający miar odległości oraz klasyfikator neuronalny. Parametry klasyfikatorów były takie same jak w przypadku identyfikacji Modułów B. Również w tym przypadku klasyfikator neuronalny został poddany optymalizacji z użyciem algorytmu ewolucyjnego. Parametry algorytmu ewolucyjnego były takie same jak w przypadku identyfikacji klasyfikatorów Modułów B. W wyniku obliczeń otrzymano cechy relewantne przedstawione w tab. 4.13.

Tab. 4.13. Wyniki optymalizacji zbioru danych wejściowych klasyfikatora warunków działania modelu globalnego (cechy są szeregowane od najczęściej występującej)

	cechy relewantne	pozostałe cechy
$m^G$	$T_1, f_{ay_{max}}, y_{PEAK}, C_y$	$f_{ax_{max}}$

### Identyfikacja modelu rozpoznającego stan obiektu

Ten etap identyfikacji był taki sam jak w przypadku identyfikacji Modułów C modeli lokalnych. Również w tym przypadku zastosowano klasyfikatory neuronalne, które wcześniej poddano optymalizacji ewolucyjnej. W wyniku optymalizacji otrzymano zbiory cech relewantnych, które zaprezentowano w tab. 4.14.

Tab. 4.14. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów stanu modelu globalnego (cechy są szeregowane od najczęściej występującej)

$m^G$	cechy relewantne	pozostałe cechy
$w_1$	$r_{P-P}, a_{r4}, y_{P-P}, x_{PEAK}, f_{ay_{max}}, K_x, r_{AVE}$	$y_{PEAK}$
$w_2$	$ReR_{ZZ}, \phi_{r4}, y_{RMS}, r_{RMS}, C_y, I_y, x_{RMS}$	$x_{AVE}$
$w_3$	$R_{RMS}, f_{ax_{max}}, x_{PEAK}, f_{ay_{max}}, K_x, r_{AVE}, a_{r3}$	$y_{PEAK}, y_{AVE}$
$w_1+w_2+w_3$	$f_{ax_{max}}, y_{RMS}, r_{P-P}, \phi_0$	$S_r, \phi_{r2}$

## 4.4. Przebieg badań

Opisane w p. 4.1.3 zbiory danych podzielono na równoliczne zbiory danych uczących  $DU$  i danych testujących  $DT$ . Z uwagi na to, że bezpośrednia informacja o prędkości obrotowej wału jest informacją, która pozwala klasyfikatorom (patrz p. 4.3.2) bezbłędnie rozpoznać aktualne warunki działania, zdecydowano, że ta cecha nie będzie wchodziła do zbiorów danych. Dane uczące posłużyły do budowy klasyfikatorów modeli lokalnych opisanych w p. 4.3.2 oraz klasyfikatorów modelu globalnego opisanych w p. 4.3.3, a dane testujące zastosowano w trzech etapach badań weryfikacyjnych:

**Etap 1** Weryfikacja rozpoznawania warunków działania obiektu.

**Etap 2** Weryfikacja rozpoznawania stanu fragmentu obiektu.

**Etap 3** Weryfikacja rozpoznawania stanu obiektu.

Etap pierwszy polegał na tym, że na początku wybierano typ klasyfikatora - metodę klasyfikacji z użyciem miar odległości lub metodę klasyfikacji z użyciem sieci neuronalnej. Następnie na wejście podawano przykłady testujące i uruchamiano proces klasyfikacji warunków działania fragmentów obiektu i uzgadniania opinii o warunkach działania całego obiektu. W przypadku klasyfikatora neuronalnego był to zbiór cech 4.2. Uzgadnianie opinii przeprowadzano na cztery sposoby opisane w p. 4.3.2. Jako wyniki odczytywano opinię o klasie warunków działania fragmentu obiektu wypracowaną przez model globalny i poszczególne modele lokalne oraz wspólną uzgodnioną opinię o klasach warunków działania całego obiektu. Wyniki te porównywano z wynikami wzorcowymi uzyskanymi na podstawie danych uwzględniających prędkość obrotową wału. W tym celu przyjęto prostą ocenę, której ogólną postać można zapisać następująco:

$$OC = \frac{l}{l_w} \quad (4.6)$$

gdzie:

$l$  - liczba poprawnie rozpoznanych przykładów,

$l_w$  - liczba wszystkich przykładów.

Powyższy wzór opisuje względną, procentową wartość poprawnie rozpoznanych przykładów testowych. Im większa wartość miary  $OC$  tym lepsza jakość.

Etap drugi polegał na tym, że na wejście klasyfikatora stanu podawano przykłady uczące zawierające wartości cech relewantnych określone w procesie optymalizacji ewolucyjnej (tab. 4.3 ÷ 4.6, tab. 4.13 i tab. 4.14). Zbiór przykładów uczących był zależny od warunków działania obiektu. Jako wyniki odczytywano klasy stanów i porównywano je z wynikami wzorcowymi. Również na tym etapie badań przyjęto ocenę zadaną wzorem 4.6.

Ostatni etap badań dotyczył weryfikacji sieci stwierdzeń. Tablice prawdopodobieństw warunkowych (tab. 4.8 ÷ tab. 4.12) były budowane z użyciem wiedzy eksperta.

Badanie polegało na tym, że na wejście podawano wartości stopni przekonania o wystąpieniu danej klasy stanu technicznego fragmentu obiektu generowane przez Moduły C poszczególnych modeli lokalnych. Jako wartości odczytywano stopnie przekonania o wystąpieniu danej klasy stanu technicznego obiektu.

## 4.5. Wyniki eksperymentu

### Weryfikacja metod rozpoznawania warunków działania obiektu

Tab. 4.15. Sprawności klasyfikatorów warunków działania obiektu (opis w tekście)

*METODA KLASYFIKACJI Z UŻYCIEM MIAR ODLEGŁOŚCI*

	$m^G$	$m^L_1$	$m^L_2$	$m^L_3$	$m^L_4$	suma elementów	średnia quasi-arytmetyczna	operator t-conorm	automat komórkowy
$w_1$	0,731	0,775	0,775	0,592	0,775	0,775	0,775	0,775	0,775
$w_2$	0,969	0,975	0,975	0,950	0,975	0,975	0,950	0,950	0,975
$w_3$	0,718	0,675	0,675	0,617	0,675	0,675	0,700	0,667	0,675
<i>średnia</i>	0,806	0,808	0,808	0,717	0,808	0,808	0,808	0,800	0,808

*METODA KLASYFIKACJI Z UŻYCIEM SIECI NEURONALNEJ*

	$m^G$	$m^L_1$	$m^L_2$	$m^L_3$	$m^L_4$	suma elementów	średnia quasi-arytmetyczna	operator t-conorm	automat komórkowy
$w_1$	0,931	0,963	0,963	0,788	0,963	0,963	0,963	0,963	0,963
$w_2$	0,956	1,000	1,000	0,688	1,000	1,000	0,825	0,688	1,000
$w_3$	0,912	0,950	0,950	0,875	0,950	0,950	0,950	0,888	0,950
<i>średnia</i>	0,933	0,971	0,971	0,783	0,971	0,971	0,913	0,846	0,971

W tabeli 4.15 przedstawiono sprawności działania klasyfikatora warunków działania modelu globalnego (kolumna:  $m^G$ ) i klasyfikatorów poszczególnych fragmentów obiektu (kolumny:  $m^L_1$ ,  $m^L_2$ ,  $m^L_3$ ,  $m^L_4$ ) oraz wyniki skuteczności metod uzgadniania wspólnej opinii modeli lokalnych o warunkach działania całego obiektu (kolumny: *suma elementów*, *średnia quasi-arytmetyczna*, *operator t-conorm*, *automat komórkowy*). W wierszach znajdują się wyniki klasyfikacji każdego warunku działania z osobna (wiersze:  $w_1$ ,  $w_2$ ,  $w_3$ ) oraz wypadkowa skuteczność klasyfikatorów (wiersz *średnia*).

### Weryfikacja metod rozpoznawania stanu obiektu

W tabeli 4.16 przedstawiono średnie sprawności klasyfikatorów stanów modelu globalnego i modeli lokalnych. Kolumna  $m^G$  reprezentuje model globalny, a kolumny  $m^L_1$ ,  $m^L_2$ ,  $m^L_3$ ,  $m^L_4$  reprezentują poszczególne modele lokalne. Wiersze  $w_1$ ,  $w_2$ ,  $w_3$  reprezentują pojedyncze klasy warunków działania obiektu. Natomiast wiersz  $w_1 + w_2 + w_3$  zawiera

wartości ocen po uwzględnieniu danych testujących wszystkich trzech klas warunków działania obiektu razem.

Tab. 4.16. Średnie sprawności klasyfikatorów stanów (opis w tekście)

	$m^G$	$m^L_1$	$m^L_2$	$m^L_3$	$m^L_4$
$w_1$	0,621	0,800	0,775	0,900	0,825
$w_2$	0,869	1,000	1,000	1,000	1,000
$w_3$	0,675	0,800	0,775	0,850	0,800
$w_1+w_2+w_3$	0,631	0,725	0,716	0,808	0,733

Tabela 4.17 zawiera szczegółowe wyniki działania klasyfikatorów stanów. Każda tabela związana jest z pojedynczą klasą warunków działania lub wszystkimi klasami warunków działania łącznie. Kolumny  $s_0, s_1, s_2, s_3$  reprezentują rozpoznawane klasy stanów obiektu. Wiersze tabel określają model globalny i modele lokalne.

### Weryfikacja sieci przekonań

W tabeli 4.18 przedstawiono wpływ wartości stwierdzeń wejściowych  $z_{1(.)}, z_{2(.)}, z_{3(.)}, z_{4(.)}$  na wartości stwierdzeń pomocniczych  $z_{01}, z_{02}, z_{03}$  i  $z_{04}$  oraz stwierdzenia wyjściowego  $z_{00}$  (patrz tab. 4.7), przy czym w danej chwili była zmieniana wartość tylko jednego stwierdzenia, a pozostałe stwierdzenia miały przypisaną wartość 0.

Tabela 4.19 przedstawia wpływ wartości stwierdzeń pomocniczych  $z_{01}, z_{02}, z_{03}, z_{04}$  na wartość stwierdzenia wyjściowego  $z_{00}$ , przy czym w danej chwili była zmieniana wartość jednego stwierdzenia, a pozostałe stwierdzenia miały przypisaną wartość 0. Wartości stwierdzeń wejściowych  $z_{1(.)}, z_{2(.)}, z_{3(.)}, z_{4(.)}$  nie były zmieniane.

W tabeli 4.20 przedstawiono wpływ wzajemnego oddziaływania wartości stwierdzeń pomocniczych  $z_{01}, z_{02}, z_{03}, z_{04}$  i stwierdzenia wyjściowego  $z_{00}$ , przy czym w danej chwili była zmieniana wartość jednego stwierdzenia. Wartości stwierdzeń wejściowych  $z_{1(.)}, z_{2(.)}, z_{3(.)}, z_{4(.)}$  nie były zmieniane.

## 4.6. Wnioski

W przypadku modeli lokalnych, w trakcie wyznaczania cech relewantnych (p. 4.3.2) przeznaczonych do budowy klasyfikatorów warunków działania najczęściej powtarzały się następujące cechy (tab. 4.2):

- częstotliwość wartości maksymalnej w widmie amplitudowym składowej  $x$  lub  $y$  ( $f_{_a(.)max}$ ),

Tab. 4.17. Sprawności klasyfikatorów stanów (rozwińnięcie tabeli 4.16, opis w tekście)

$w_1$					
	$s_0$	$s_1$	$s_2$	$s_3$	średnia
$m^G$	0,991	0,933	0,083	0,466	0,621
$m^L_1$	1,000	1,000	0,600	0,600	0,800
$m^L_2$	1,000	0,900	0,800	0,400	0,775
$m^L_3$	1,000	0,900	1,000	0,700	0,900
$m^L_4$	1,000	1,000	0,600	0,700	0,825

$w_2$					
	$s_0$	$s_1$	$s_2$	$s_3$	średnia
$m^G$	1,000	0,750	1,000	0,725	0,869
$m^L_1$	1,000	1,000	1,000	1,000	1,000
$m^L_2$	1,000	1,000	1,000	1,000	1,000
$m^L_3$	1,000	1,000	1,000	1,000	1,000
$m^L_4$	1,000	1,000	1,000	1,000	1,000

$w_3$					
	$s_0$	$s_1$	$s_2$	$s_3$	średnia
$m^G$	0,900	0,900	0,475	0,400	0,675
$m^L_1$	1,000	0,900	0,400	0,900	0,800
$m^L_2$	1,000	0,900	0,700	0,500	0,775
$m^L_3$	0,900	1,000	1,000	0,500	0,850
$m^L_4$	1,000	0,900	0,600	0,700	0,800

$w_1+w_2+w_3$					
	$s_0$	$s_1$	$s_2$	$s_3$	średnia
$m^G$	1,000	0,908	0,300	0,316	0,631
$m^L_1$	1,000	0,900	0,250	0,725	0,725
$m^L_2$	1,000	0,933	0,525	0,400	0,715
$m^L_3$	1,000	0,766	0,833	0,633	0,808
$m^L_4$	1,000	0,900	0,100	0,933	0,733

Tab. 4.18. Przykładowe wyniki działania sieci stwierdzeń. Wpływ wartości stwierdzeń wejściowych na wartości stwierdzenia wyjściowego i stwierdzeń pomocniczych

Stwierdzenia wejściowe		Stwierdzenie wyjściowe i stwierdzenia pomocnicze				
id	wartość	z00	z01	z02	z03	z04
z1÷4,1	0.0	0.500	0.000	0.000	0.000	0.000
z1÷4,1	0.6	0.590	0.179	0.000	0.000	0.000
z1÷4,1	1.0	0.649	0.299	0.000	0.000	0.000
z12	0.0	0.500	0.000	0.000	0.000	0.000
z12	0.6	0.350	0.000	0.300	0.000	0.000
z12	1.0	0.250	0.000	0.499	0.000	0.000
z22	0.0	0.500	0.000	0.000	0.000	0.000
z22	0.6	0.410	0.000	0.180	0.000	0.000
z22	1.0	0.350	0.000	0.299	0.000	0.000
z32	0.0	0.500	0.000	0.000	0.000	0.000
z32	0.6	0.290	0.000	0.420	0.000	0.000
z32	1.0	0.150	0.000	0.699	0.000	0.000
z42	0.0	0.500	0.000	0.000	0.000	0.000
z42	0.6	0.470	0.000	0.060	0.000	0.000
z42	1.0	0.450	0.000	0.099	0.000	0.000
z13	0.0	0.500	0.000	0.000	0.000	0.000
z13	0.6	0.290	0.000	0.000	0.420	0.000
z13	1.0	0.150	0.000	0.000	0.699	0.000
z2;3,3	0.0	0.500	0.000	0.000	0.000	0.000
z2;3,3	0.6	0.350	0.000	0.000	0.299	0.000
z2;3,3	1.0	0.250	0.000	0.000	0.499	0.000
z43	0.0	0.500	0.000	0.000	0.000	0.000
z43	0.6	0.410	0.000	0.000	0.180	0.000
z43	1.0	0.350	0.000	0.000	0.299	0.000
z1;4,3	0.0	0.500	0.000	0.000	0.000	0.000
z1;4,3	0.6	0.350	0.000	0.000	0.000	0.299
z1;4,3	1.0	0.250	0.000	0.000	0.000	0.499
z24	0.0	0.500	0.000	0.000	0.000	0.000
z24	0.6	0.290	0.000	0.000	0.000	0.420
z24	1.0	0.150	0.000	0.000	0.000	0.699
z34	0.0	0.500	0.000	0.000	0.000	0.000
z34	0.6	0.410	0.000	0.000	0.000	0.180
z34	1.0	0.350	0.000	0.000	0.000	0.299

Tab. 4.19. Przykładowe wyniki działania sieci stwierdzeń. Wpływ wartości stwierdzeń pomocniczych na stwierdzenie wyjściowe  $z_{00}$ 

Stwierdzenia wejściowe		Stwierdzenie wyjściowe i stwierdzenia pomocnicze				
id	wartość	z00	z01	z02	z03	z04
z01	0.0	0.500	0.000	0.000	0.000	0.000
z01	0.2	0.631	0.262	0.000	0.000	0.000
z01	0.4	0.743	0.487	0.000	0.000	0.000
z01	0.6	0.840	0.681	0.000	0.000	0.000
z01	0.8	0.925	0.850	0.000	0.000	0.000
z01	1.0	0.999	0.999	0.000	0.000	0.000
z02	0.0	0.500	0.000	0.000	0.000	0.000
z02	0.2	0.319	0.000	0.361	0.000	0.000
z02	0.4	0.199	0.000	0.601	0.000	0.000
z02	0.6	0.113	0.000	0.772	0.000	0.000
z02	0.8	0.049	0.000	0.900	0.000	0.000
z02	1.0	0.000	0.000	0.999	0.000	0.000
z03	0.0	0.500	0.000	0.000	0.000	0.000
z03	0.2	0.259	0.000	0.000	0.480	0.000
z03	0.4	0.144	0.000	0.000	0.711	0.000
z03	0.6	0.076	0.000	0.000	0.847	0.000
z03	0.8	0.031	0.000	0.000	0.936	0.000
z03	1.0	0.000	0.000	0.000	0.999	0.000
z04	0.0	0.500	0.000	0.000	0.000	0.000
z04	0.2	0.259	0.000	0.000	0.000	0.480
z04	0.4	0.144	0.000	0.000	0.000	0.711
z04	0.6	0.076	0.000	0.000	0.000	0.847
z04	0.8	0.031	0.000	0.000	0.000	0.936
z04	1.0	0.000	0.000	0.000	0.000	0.999

- okres trajektorii ( $T_1$ ),
- wartość międzyszczytowa ( $x_{p-p}$ ).

Wszystkie wymienione cechy są zależne od prędkości obrotowej wału  $n_{obr}$ . Natomiast w trakcie poszukiwania cech relewantnych do budowy klasyfikatorów stanów Modułów C modeli lokalnych (tab. 4.3 ÷ tab. 4.6) nie doszukano się takiej powtarzalności cech. W zasadzie każdy Moduł C, w zależności od warunków działania, dysponuje własnym zbiorem cech relewantnych. Podobne wnioski można wyciągnąć z wyników uzyskanych

Tab. 4.20. Przykładowe wyniki działania sieci stwierdzeń. Wzajemne oddziaływanie wartości stwierdzeń pomocniczych i stwierdzenia wyjściowego

Stwierdzenia wejściowe		Stwierdzenie wyjściowe i stwierdzenia pomocnicze				
id	wartość	z00	z01	z02	z03	z04
z00	0.0	0.000	0.471	0.715	0.806	0.806
z00	0.2	0.067	0.506	0.708	0.800	0.800
z00	0.4	0.162	0.555	0.699	0.792	0.792
z00	0.6	0.303	0.627	0.686	0.780	0.780
z00	0.8	0.537	0.748	0.663	0.761	0.761
z00	1.0	0.996	0.985	0.619	0.722	0.722
z01	0.0	0.006	0.000	0.693	0.787	0.787
z01	0.2	0.104	0.262	0.693	0.787	0.787
z01	0.4	0.187	0.487	0.693	0.787	0.787
z01	0.6	0.260	0.681	0.693	0.787	0.787
z01	0.8	0.323	0.850	0.693	0.787	0.787
z01	1.0	0.378	0.999	0.693	0.787	0.787
z02	0.0	0.279	0.587	0.000	0.787	0.787
z02	0.2	0.251	0.587	0.361	0.787	0.787
z02	0.4	0.232	0.587	0.601	0.787	0.787
z02	0.6	0.219	0.587	0.772	0.787	0.787
z02	0.8	0.209	0.587	0.900	0.787	0.787
z02	1.0	0.201	0.587	0.999	0.787	0.787
z03	0.0	0.294	0.587	0.693	0.000	0.787
z03	0.2	0.252	0.587	0.693	0.480	0.787
z03	0.4	0.231	0.587	0.693	0.711	0.787
z03	0.6	0.220	0.587	0.693	0.847	0.787
z03	0.8	0.212	0.587	0.693	0.936	0.787
z03	1.0	0.206	0.587	0.693	0.999	0.787
z04	0.0	0.294	0.587	0.693	0.787	0.000
z04	0.2	0.252	0.587	0.693	0.787	0.480
z04	0.4	0.231	0.587	0.693	0.787	0.711
z04	0.6	0.220	0.587	0.693	0.787	0.847
z04	0.8	0.212	0.587	0.693	0.787	0.936
z04	1.0	0.206	0.587	0.693	0.787	0.999



w trakcie poszukiwania cech relewantnych dla modelu globalnego (tab. 4.13 i tab. 4.14). Należy dodać, że poszukiwanie cech relewantnych z użyciem algorytmów heurystycznych (w tym przypadku algorytmu ewolucyjnego) powoduje, że otrzymywany zbiór cech nie zawsze jest powtarzalny.

Na przykładowym wykresie 4.2 widać, że w procesie optymalizacji zbiorów cech relewantnych dla Modułów B nie było problemów ze znalezieniem takich cech dla których klasyfikator osiągał sprawność bliską 100 [%]. Wykres 4.3 pokazuje zaobserwowaną dla wszystkich przypadków poszukiwania zbiorów cech relewantnych dla klasyfikatorów Modułów C prawidłowość: klasyfikator stanu największą sprawność ( $\sim 100$  [%]) osiągał w przypadku pracy ustalonej ( $w_2$ ), nieco niższą ( $\sim 90$  [%]) w przypadku rozbiegu maszyny ( $w_1$ ) i najniższą ( $\sim 85$  [%]) w przypadku wybiegu maszyny ( $w_3$ ). Zgodnie z przewidywaniami nieustalone warunki pracy obiektu powodują najwięcej kłopotów z identyfikacją stanu. W przyjętym obiekcie badań najwięcej problemów sprawiały nieliniowości pojawiające się w trakcie symulowania niesprawności typu *nadmierne niewyrównoważenie tarczy 1* ( $s_2$ ) i *nadmierne niewyrównoważenie tarczy 2* ( $s_3$ ). Wysoka sprawność klasyfikatora w przypadku ustalonych warunków pracy ( $w_0$ ) obiektu wynika stąd, że sygnały pochodzą z prostego symulatora, do których nie wprowadzano szumu.

W przypadku analizowania sprawności poszczególnych klasyfikatorów Modułów B (tab. 4.15, wiersz *średnia*) metoda z użyciem klasyfikatora neuronalnego dała lepsze rezultaty niż w przypadku metody opartej na klasyfikacji z użyciem miar odległości. Wyniki były lepsze od 5 [%] do 10 [%] w zależności od warunków działania. Dla obydwu metod zazwyczaj modele lokalne  $m^L$  dawały nieznacznie lepsze wyniki od modelu globalnego  $m^G$ . Wyjątkiem był model lokalny  $m_3^L$ . Wszystkie modele (wiersze  $w_1$  i  $w_3$ ) miały problemy z rozpoznawaniem nieustalonych warunków pracy obiektu. Zdarzało się, że sprawność klasyfikatora modelu  $m_3^L$  wynosiła zaledwie 61 [%] (dla metody klasyfikacji z użyciem miar odległości). Przyczyną niskiej sprawności klasyfikatorów Modułu B modelu lokalnego  $m_3^L$  jest stan  $s_1$  (*nadmierny luz promieniowy w łożysku A*), który powodował powstawanie w widmach sygnałów  $x$  i  $y$  składowych wyższych harmonicznych o dużych wartościach amplitud. Z tych widm wyznaczane były wartości niektórych cech (np.  $f\_a(\cdot)_{max}$ , zob. p. 4.3.2), a co za tym idzie informacja zawarta w wartościach tych cech mogła być błędnie wyznaczona.

Porównując skuteczność metod przeznaczonych do uzgadniania opinii modeli lokalnych  $m^L$  z skutecznością klasyfikatora warunków działania modelu globalnego  $m^G$  (tab. 4.15) można stwierdzić, że koszt użycia metod agregacji nie zawsze jest uzasadniony. Choć w większości przypadków metody uzgadniania opinii dały lepsze rezultaty, to różnice w skuteczności działania nie były duże i zawierały się w zakresie od 0,2 [%] do 3,8 [%]. Należy zauważyć, że najwyższa skuteczność metod uzgadniania wypadkowej opinii w żadnym przypadku nie była wyższa od największej sprawności działania jakiegokolwiek Modułu B. Wynika z tego, że wszystkie metody agregacji działały prawidłowo - został spełniony warunek graniczny i warunek kompensacji (p. 2.10.1)

Analizując skuteczność poszczególnych metod uzgadniania opinii (tab. 4.15) najlepsze rezultaty daje zliczanie elementów zbiorów (p. 3.2.3) oraz zastosowanie automatu komórkowego (p. 4.3.2). Dla obu metod uzyskano identyczne wyniki; średnia skuteczność dla klasyfikatora neuronalnego wyniosła 97,1 [%]. Można sądzić, że stanem ustalonym dla automatu komórkowego była suma elementów zbiorów propozycji warunków działania. W przypadku pozostałych dwóch metod wyniki były nieco gorsze i wynosiły 84,6 [%] i 91,3 [%].

Porównując sprawności klasyfikatorów Modułów C modeli lokalnych i klasyfikatora stanu modelu globalnego (tab. 4.16) widać, że klasyfikator stanu modelu globalnego znacznie gorzej radził sobie z rozpoznawaniem stanu obiektu. W zależności od rozpatrywanych warunków działania ( $w_1$ ,  $w_2$  lub  $w_3$ ) wynik był gorszy od sprawności klasyfikatorów modeli lokalnych w zakresie od 10 [%] do 15,4 [%]. Szczegółowe wyniki sprawności działania klasyfikatorów (tab. 4.17) wyraźnie pokazują, że użycie globalnego modelu daje gorsze rezultaty od użycia zbioru modeli lokalnych. Dla wszystkich klasyfikatorów zauważono, że stan  $s_2$  często był błędnie interpretowany jako stan  $s_3$ , co wiąże się z ich podobnym charakterem, tj. nadmiernym niewyrównoważeniem tarczy 1 lub tarczy 2.

Ostatni etap badań polegał na weryfikacji poprawności działania sieci przekonań. Analiza wartości stwierdzeń ujętych w tabelach od 4.18 do 4.20 pokazuje, że sieć stwierdzeń działa prawidłowo:

1. Zmiana wartości stwierdzeń wejściowych powoduje zmianę wartości odpowiadających stwierdzeń w warstwach wyższych (tab. 4.18 i tab. 4.19).
2. Zmiana wartości stwierdzeń  $z_{01}$ ,  $z_{02}$ ,  $z_{03}$  lub  $z_{04}$  nie powoduje zmiany wartości stwierdzeń w tej samej warstwie, natomiast powoduje zmianę wartości stwierdzenia w warstwie wyższej (tab. 4.20).
3. Zmiana wartości stwierdzenia  $z_{00}$  powoduje zmianę wartości stwierdzeń w warstwie niższej (tab. 4.20).

Celowo nie zostaną skomentowane wielkości zmian tych wartości, ponieważ zależą one również od wartości prawdopodobieństw warunkowych, które są ustalane przez ekspertów (tutaj przez autora rozprawy, patrz p. 4.3.2). Uzyskane wyniki oceniono pozytywnie. Jednak wyjaśnienia wymaga fakt, że ustalenie pewnej wartości stwierdzenia wejściowego np.  $z_{00}$  (tab. 4.20) nie powoduje takiej samej zmiany dla tego samego stwierdzenia traktowanego jako stwierdzenie wyjściowe. Otóż, w sieci stwierdzeń zmiana wartości jednego z węzłów powoduje zmianę wartości węzłów sąsiednich, które z kolei wpływają na zmianę wartości węzła, którego wartość została zmodyfikowana.

---

### Weryfikacja metody /1/

---

W poprzednim rozdziale pokazano, że opracowana metoda sprawdza się w modelowaniu prostych obiektów. Postanowiono pokazać przykład zastosowania zaproponowanej metody dla bardziej rozbudowanego obiektu - turbogeneratora o mocy 215 [MW]. Stwierdzenie, że sprawności poszczególnych klasyfikatorów modeli lokalnych są większe od sprawności klasyfikatorów modelu globalnego pozwoli orzec, że postawione tezy są słuszne, a metoda jest poprawnie sformułowana. Badania przeprowadzono na udostępnionych danych pochodzących z symulatora numerycznego opracowanego w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk (IMP PAN) w Gdańsku. Badania przeprowadzono w celu potwierdzenia badań weryfikacyjnych wykonanych dla prostej maszyny wirnikowej.

Otrzymane dane z IMP PAN zawierają wyniki eksperymentów, w których turbogenerator działał w następujących stanach technicznych [83]:

- 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.

Wszystkie stany techniczne były symulowane dla stałej prędkości wirowania wału.

Prezentowane dane były wcześniej wykorzystywane podczas realizacji wybranych fragmentów Projektu Badawczego Zamawianego PBZ-K015/T10/2001 pt. „Kompleksowy model sprzężonych oddziaływań aerodynamicznych, mechanicznych i elektrycznych


zachodzących w obiektach energetycznych dużej mocy”. W wyniku realizacji projektu powstała monografia [83], która zawierała m.in. rozdziały: *Diagnostyczne modele obiektów* [27], *Cechy i obrazy sygnałów* [26], *Relevantne cechy sygnałów* [28], *Modele wielostopniowe. Przykład* [44], *Skalowanie wielowymiarowe* [140], *Wybór cech z zastosowaniem analizy wrażliwości* [137], *Trajektoria i cechy trajektorii* [46], *Optymalizacja ewolucyjna zbioru uwzględnianych cech* [43], *Wartości cech sygnałów przemieszczeń* [42], *Hierarchiczne struktury danych* [22], *Sygnały prędkości i przyspieszeń* [41].

Ponadto dostarczone dane były używane podczas realizacji prac doktorskich do identyfikacji i badań związanych z wielomodelami diagnostycznymi [157], identyfikacji odwrotnych modeli diagnostycznych z użyciem algorytmów ewolucyjnych i ich weryfikacji [150], weryfikacji metod doskonalenia sieci bayesowskich [13] oraz do poszukiwania i weryfikacji metod badania wrażliwości sygnałów diagnostycznych [138].

## 5.1. Obiekt badań

### 5.1.1. Charakterystyka obiektu

Obiektem badań był turbogenerator o mocy 215 [MW] zbudowany z turbiny 13K215 i generatora. Schemat badanego turbogeneratorsa pokazano na rys. 5.1. Badanymi niezdatnościami były przemieszczenia podpór łożyskowych względem kinetostatycznej linii wału.



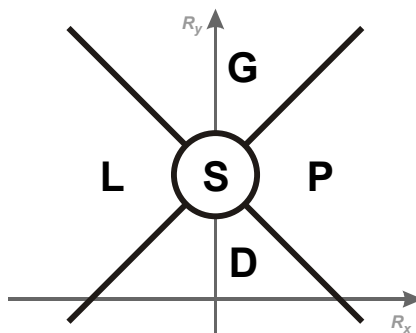
Rys. 5.1. Szkic poglądowy turbogeneratorsa z turbiną 13K215 [85]. Oznaczenia: WP - część wysokoprężna, SP - część średnioprężna, NP - część niskoprężna, GEN - generator, 1 ÷ 7 - nr węzła łożyskowego

W maszynach wirnikowych istotnym problemem jest wyosiowanie wirnika. Nieprawidłowe wykonanie tej operacji powoduje, że pojawiają się niesprawności, takie jak: przycieranie wirnika o korpus lub nieprawidłowe działanie łożysk hydrodynamicznych. Skutkiem tego jest nadmierny wzrost drgań obiektu i w jego następstwie przejście obiektu w stan niezdatności. Prawidłowe ustalenie łożysk, a tym samym kinetostatycznej linii wału [94] pozwala na wyeliminowanie niektórych niesprawności i poprawia stabilność działania turbogeneratorsa.

### 5.1.2. Warunki działania i stany obiektu

Zbiór danych uczących był wyznaczany dla stałej prędkości wirowania wału. W związku z tym cały obiekt posiadał tylko jeden warunek działania:

$w_1^O$  : praca ustalona ( $n_{obr} = 3000[obr/min]$ ).



Rys. 5.2. Klasy w przestrzeni reakcji podporowych [150]. Oznaczenia: opis w tekście

Postanowiono, że lokalne warunki działania będą opisywane przez wartości reakcji podporowych. W związku z tym wyróżniono pięć klas warunków działania dla każdej podpory  $i$  (rys. 5.2), które odpowiadają pięciu klasom reakcji podporowych [150]:

$w_{i,1}$  : koniec wektora przesunięty w lewo względem położenia nominalnego (L),

$w_{i,2}$  : koniec wektora przesunięty w górę (G),

$w_{i,3}$  : koniec wektora przesunięty w prawo (P),

$w_{i,4}$  : koniec wektora przesunięty w dół (D),

$w_{i,5}$  : nominalna wartość reakcji podporowej (S).

Badanymi niezdatnościami były lokalne przemieszczenia podpór łożyskowych  $i$ . W sumie określono 35 klas stanów - po 5 dla każdej z 7 podpór ( $i \in [1; 7]$ ):

$s_{i,1}$  : podpora przesunięta w lewo względem położenia nominalnego (L),

$s_{i,2}$  : podpora przesunięta w górę (G),

$s_{i,3}$  : podpora przesunięta w prawo (P),

$s_{i,4}$  : podpora przesunięta w dół (D),

$s_{i,5}$  : nominalna wartość przemieszczenia podpory (S).

Klasy przemieszczeń zostały określone tak jak w przypadku klas reakcji podporowych (rys. 5.2).

### 5.1.3. Dane symulacyjne

Dane symulacyjne zawierały m.in. sygnały składowych  $x$  i  $y$  przemieszczeń promieniowych w dwóch wzajemnie prostopadłych kierunkach każdej podpory łożyskowej oraz informacje o niezdatnościach i wartościach reakcji podporowych. Łącznie wybrano 89 przykładów [127]:

- przypadek bazowy,
- przemieszczenia małe - zestaw 1: 4 kierunki  $\cdot$  7 łożysk = 28 przypadków,
- przemieszczenia duże - zestaw 3: 4 kierunki  $\cdot$  7 łożysk = 28 przypadków,
- jednoczesne przemieszczenia łożyska 5 i 6 - zestaw 2: 4 kierunki  $\cdot$  2 łożyska  $\cdot$  4 kierunki = 32 przypadki.

Pierwsze trzy zbiory danych były danymi uczącymi  $DU$ , natomiast przypadki jednoczesnego przemieszczania łożysk były danymi testującymi  $DT$ . W każdym przykładzie uwzględniano 316 punktowych cech sygnałów  $x$  i  $y$  oraz  $r$  (wzór 3.1) mierzonych dla trzech przypadków przemieszczeń względnych i bezwzględnych. W sumie rozpatrywano 3792 cech.

## 5.2. Plan badań

Badania weryfikacyjne przeprowadzono według następujących kroków:

1. Przeprowadzono dekompozycję przestrzenną obiektu na fragmenty.
2. Przeprowadzono identyfikację modeli lokalnych. Dla każdego modelu lokalnego przeprowadzono:
  - (a) identyfikację Modułu A - wybrano i zastosowano funkcje wyznaczające wartości cech sygnałów;
  - (b) identyfikację Modułu B - z dostępnych danych trenujących wyznaczono zbiór cech relewantnych, które posłużyły wraz ze zbiorem możliwych lokalnych warunków działania do budowy klasyfikatora warunków działania oraz wybrano metody uzgadniania opinii wypracowywanych przez Moduły B;
  - (c) identyfikację Modułu C - z dostępnych danych trenujących wyznaczono zbiór cech relewantnych, które posłużyły wraz ze zbiorem możliwych lokalnych stanów obiektu do budowy klasyfikatora stanów.
3. Zidentyfikowano Moduł D - określono zbiór stwierdzeń, utworzono strukturę sieci stwierdzeń oraz dobrano jej parametry.
4. Przeprowadzono identyfikację modeli globalnych - klasyfikatora lokalnych warunków działania i klasyfikatora lokalnych stanów.

5. Dla zidentyfikowanych modeli lokalnych i modeli globalnych przeprowadzono badania porównawcze:
  - (a) Sprawdzono sprawności klasyfikatorów warunków działania.
  - (b) Sprawdzono skuteczność procesu uzgadniania opinii o lokalnych warunkach działania fragmentów obiektu.
  - (c) Sprawdzono sprawności klasyfikatorów stanów.
  - (d) Sprawdzono poprawność działania sieci stwierdzeń.

### 5.2.1. Opracowane oprogramowanie

Podobnie jak w przypadku wstępnych badań weryfikacyjnych (p. 4.2.1), identyfikację Modułów A, B i C oraz badania weryfikacyjne przeprowadzono z użyciem programu MATLAB [103]. W tym celu utworzono pakiet funkcji przeznaczonych do:

- wyznaczania wartości cech sygnałów diagnostycznych,
- tworzenia zbiorów cech relewantnych,
- budowy klasyfikatorów warunków działania i klasyfikatorów stanów,
- przeprowadzania procesu agregacji i uzgadniania opinii o warunkach działania fragmentów obiektów.

Moduł D identyfikowano w programie Netica [113]. Na potrzeby weryfikacji utworzonej sieci opracowano zbiór klas i ich metod w języku Java [143].

## 5.3. Model obiektu

### 5.3.1. Dekompozycja obiektu na fragmenty

W przypadku rozpatrywanego turbogeneratorsa (rys. 5.1) zdecydowano się zastosować dekompozycję przestrzenną. W związku z tym badany obiekt  $O$  podzielono na siedem fragmentów:

$o_1 \in$  węzeł łożyskowy nr 1,

$o_2 \in$  węzeł łożyskowy nr 2,

$o_3 \in$  węzeł łożyskowy nr 3,

$o_4 \in$  węzeł łożyskowy nr 4,

$o_5 \in$  węzeł łożyskowy nr 5,

$o_6 \in$  węzeł łożyskowy nr 6,

$o_7 \in$  węzeł łożyskowy nr 7.

Każdy fragment  $o_i$  ma przyporządkowane sygnały składowych  $x_{(\cdot)}$  i  $y_{(\cdot)}$  przemieszczeń promieniowych mierzonych w dwóch wzajemnie prostopadłych kierunkach.

### 5.3.2. Identyfikacja modeli lokalnych

Dla każdego fragmentu obiektu został zidentyfikowany jeden model lokalny:

$$o_1 \rightarrow m_1^L, o_2 \rightarrow m_2^L, o_3 \rightarrow m_3^L, o_4 \rightarrow m_4^L, o_5 \rightarrow m_5^L, o_6 \rightarrow m_6^L, o_7 \rightarrow m_7^L,$$

zbudowany z Modułu A, Modułu B i Modułu C. Identyfikację modułów opisano w dalszej części tego punktu.

#### Moduł A

Identyfikowane Moduły A na wejściu posiadały trzy rodzaje sygnałów przemieszczeń promieniowych mierzonych w dwóch wzajemnie prostopadłych kierunkach  $x_{(\cdot)}$ ,  $y_{(\cdot)}$  i związane z rozpatrywanym fragmentem obiektu. Mierzono przemieszczenia czopa względem panwi ( $el$ ), przemieszczenia bezwzględne panwi ( $bpl$ ) oraz przemieszczenia bezwzględne czopa ( $bcl$ ). Dla składowych przemieszczeń wyznaczane były cechy punktowe własne w dziedzinie czasu i dziedzinie częstotliwości oraz cechy punktowe wzajemne w dziedzinie czasu. Fragment wyznaczanego zbioru 3792 cech ma następującą postać:

$$\{ x_{AVE}; x_{RMS}; x_{PEAK}; x_{PEAK+}; x_{PEAK-}; x_{P-P}; K_x; C_x; I_x; Ku_x; S_x; a_{x1}; a_{x2}; a_{x3}; a_{x4}; a_{x5}; a_{x6}; a_{x7}; a_{x8}; \Phi_{x1}; \Phi_{x2}; \Phi_{x3}; \Phi_{x4}; y_{AVE}; y_{RMS}; y_{PEAK}; y_{PEAK+}; y_{PEAK-}; y_{P-P}; K_y; C_y; I_y; Ku_y; S_y; a_{y1}; a_{y2}; a_{y3}; a_{y4}; a_{y5}; a_{y6}; a_{y7}; a_{y8}; \Phi_{y1}; \Phi_{y2}; \Phi_{y3}; \Phi_{y4}; r_{AVE}; r_{RMS}; r_{PEAK}; r_{PEAK+}; r_{PEAK-}; r_{P-P}; K_r; C_r; I_r; Ku_r; S_r; a_{r1}; a_{r2}; a_{r3}; a_{r4}; a_{r5}; a_{r6}; a_{r7}; a_{r8}; \Phi_{r1}; \Phi_{r2}; \Phi_{r3}; \Phi_{r4}; s_{max}; s_{maxP-P}; ReR_{zz}; T_1 \}$$

Oznaczenia sygnałów i ich cech wprowadzono za [42, 22].

#### Moduł B

Identyfikowane modele były neuronalnymi klasyfikatorami lokalnych warunków działania. Zastosowana sieć neuronalna była siecią typu feed-forward zbudowaną z jednej warstwy ukrytej zawierającej 4 neurony z sigmoidalną funkcją przejścia oraz jednej warstwy wyjściowej zawierającej 5 neuronów z liniową funkcją przejścia. Sieci neuronalne zostały poddane optymalizacji z użyciem algorytmu ewolucyjnego (p. 2.3) o następujących parametrach:

- genotyp osobnika  $p$  jest chromosomem zbudowanym z rzeczywistoliczbowego ciągu o długości odpowiadającej liczbie rozpatrywanych cech punktowych (każda cecha posiada własny identyfikator);
- fenotyp osobnika  $p$  stanowi rozkład przykładów trenujących w przestrzeni cech relewantnych (dla danego osobnika);



- populacje początkowe są generowane losowo;
- selekcja jest przeprowadzana metodą selekcji proporcjonalnej;
- sukcesja jest przeprowadzana według modelu elitarnego;
- krzyżowanie osobników jest przeprowadzane jako jednopunktowe;
- wartości parametrów algorytmu są następujące:
  - liczba osobników  $p$  (stała) = 90,
  - liczba rozpatrywanych cech =  $max$  10,
  - liczba pokoleń = 50,
  - współczynnik krzyżowania = 30 [%],
  - współczynnik mutacji = 1 [%].

Wyniki ewolucyjnej optymalizacji zbioru cech zamieszczono w tabeli 5.1.

Pierwszych sześć członów przyjętego oznaczenia obliczanych cech informuje o [22]:

$u$  - nazwie struktury z danymi,

$lo(n)$  - identyfikatorze węzła łożyskowego ( $n \in [1;7]$ ),

$el, bpl, bcl$  - rodzaju przemieszczeń: przemieszczenia czopa względem panwi ( $el$ ), przemieszczenia bezwzględne panwi ( $bpl$ ) lub przemieszczenia bezwzględne czopa ( $bcl$ ),

$x, y, r, rn$  - rodzaju składowej  $x$  lub  $y$  sygnałów przemieszczeń oraz o trajektorii centralnej  $r$  lub trajektorii niecentralnej  $rn$ ,

$c$  - wektorze cech punktowych sygnałów przemieszczeń.

Ostatni człon oznacza rodzaj cechy sygnału [22]:

$ave$  - wartość średnia,

$rms$  - wartość skuteczna,

$pp$  - wartość międzyszczytowa,

$ppl$  - wartość szczytowa dodatnia,

$pmi$  - wartość szczytowa ujemna,

$p$  - wartość szczytowa bezwzględna,

$k$  - współczynnik kształtu,

Tab. 5.1. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów B (opis oznaczeń w tekście)

	cechy relewantne		pozostałe cechy
$m^L_1$	u.lo(1).el.x.c.i u.lo(1).bpl.y.c.rms u.lo(1).el.y.c.a3 u.lo(1).bcl.rm.c.sinfi0	u.lo(1).bpl.x.c.ku u.lo(1).bcl.r.c.k u.lo(1).bcl.y.c.c	u.lo(1).bpl.x.c.ppl u.lo(1).bpl.y.c.a3 u.lo(1).bcl.x.c.a3 u.lo(1).bca.r.c.obr1k2 u.lo(1).bca.rm.c.r0 u.lo(1).bpl.rm.c.r0
$m^L_2$	u.lo(2).bpl.r.c.f4 u.lo(2).bca.r.c.f2 u.lo(2).bcl.y.c.f4	u.lo(2).el.y.c.k u.lo(2).el.y.c.a05 u.lo(2).el.y.c.f1	u.lo(2).el.x.c.a040 u.lo(2).bcl.xy.c.t1 u.lo(2).bpl.r.c.a2 u.lo(2).el.r.c.a025 u.lo(2).bca.x.c.k u.lo(2).el.r.c.obr1k3
$m^L_3$	u.lo(3).bca.r.c.ku u.lo(3).bca.r.c.a033 u.lo(3).bcl.x.c.c u.lo(3).bcl.x.c.f1	u.lo(3).el.r.c.a033 u.lo(3).el.r.c.s u.lo(3).bca.r.c.a4 u.lo(3).el.r.c.f2	u.lo(3).el.y.c.a033 u.lo(3).el.y.c.a1 u.lo(3).el.r.c.a1 u.lo(3).bca.r.c.a025
$m^L_4$	u.lo(4).bca.r.c.f2 u.lo(4).bcl.x.c.ppl u.lo(4).bca.r.c.i u.lo(4).bpl.y.c.f4	u.lo(4).el.y.c.ave u.lo(4).el.rm.c.sinfi0 u.lo(4).el.y.c.a033 u.lo(4).bca.x.c.a040	u.lo(4).bca.r.c.ppl u.lo(4).bca.y.c.ppl u.lo(4).bcl.r.c.f3 u.lo(4).el.r.c.a040
$m^L_5$	u.lo(5).bpl.r.c.obr1k3 u.lo(5).bpl.y.c.a033 u.lo(5).el.x.c.a040 u.lo(5).bcl.x.c.a1	u.lo(5).el.rm.c.r0 u.lo(5).bcl.r.c.p u.lo(5).el.r.c.pmi	u.lo(5).el.y.c.a025 u.lo(5).el.y.c.p u.lo(5).el.x.c.a4 u.lo(5).bpl.r.c.a033
$m^L_6$	u.lo(6).bpl.x.c.ppl u.lo(6).bca.x.c.f2 u.lo(6).bcl.r.c.a025 u.lo(6).bpl.x.c.a040 u.lo(6).bcl.x.c.a040	u.lo(6).el.y.c.a05 u.lo(6).bca.y.c.k u.lo(6).el.r.c.smax u.lo(6).bpl.x.c.f2	u.lo(6).bcl.y.c.f2 u.lo(6).el.x.c.a05 u.lo(6).bca.x.c.pp u.lo(6).el.x.c.a4 u.lo(6).bca.r.c.obr1k2 u.lo(6).bca.r.c.a1
$m^L_7$	u.lo(7).el.r.c.f1 u.lo(7).el.x.c.a1 u.lo(7).bpl.x.c.f1 u.lo(7).el.x.c.pmi u.lo(7).bca.x.c.f3 u.lo(7).el.r.c.rms	u.lo(7).el.r.c.a025 u.lo(7).el.r.c.ppl u.lo(7).bpl.x.c.f2 u.lo(7).el.x.c.k u.lo(7).el.r.c.f3	u.lo(7).el.x.c.ku u.lo(7).bpl.y.c.f1 u.lo(7).bcl.r.c.f3 u.lo(7).el.r.c.a1

$c$  - współczynnik szczytu,

$i$  - współczynnik impulsowości,

$s$  - współczynnik asymetrii (skośność),

$ku$  - współczynnik skupienia (koncentracji, kurtoza),

$r0$  - promień środka trajektorii niecentralnej liczony w układzie biegunowym,

$sinfi0$  - sinus kąta przesunięcia fazowego promienia środka trajektorii niecentralnej,

$\cos fi0$  - cosinus kąta przesunięcia fazowego promienia środka trajektorii niecentralnej,

$a025$  - składowa widma amplitudowego o częstotliwości  $0.25X$ ,

$a033$  - składowa widma amplitudowego o częstotliwości  $0.33X$ ,

$a040$  - składowa widma amplitudowego o częstotliwości  $0.4X$ ,

$a05$  - składowa widma amplitudowego o częstotliwości  $0.5X$ ,

$a1$  - składowa widma amplitudowego o częstotliwości  $1X$ ,

$a2$  - składowa widma amplitudowego o częstotliwości  $2X$ ,

$a3$  - składowa widma amplitudowego o częstotliwości  $3X$ ,

$a4$  - składowa widma amplitudowego o częstotliwości  $4X$ ,

$f1$  - faza składowej widma amplitudowego o częstotliwości  $1X$ ,

$f2$  - faza składowej widma amplitudowego o częstotliwości  $2X$ ,

$f3$  - faza składowej widma amplitudowego o częstotliwości  $3X$ ,

$f4$  - faza składowej widma amplitudowego o częstotliwości  $4X$ ,

$smax$  - maksymalne promieniowe przemieszczenie wału,

$t1$  - okres trajektorii,

$sto$  - stopień okresowości trajektorii,

$obr1k$  - obraz nr 1 trajektorii [44],

$obr1k2$  - obraz nr 2 trajektorii [44],

$obr1k3$  - obraz nr 3 trajektorii [44].

### **Uzgadnianie opinii**

Proces uzgadniania opinii zrealizowano za pomocą trzech metod:

1. metody agregacji opinii - operator średniej quasi-arytmetycznej,
2. metody agregacji opinii - operator t-conorm,
3. automatu komórkowego.

W przypadku automatu komórkowego, dla każdego modelu lokalnego wyznaczono zbiory sąsiadów  $\Lambda$ , a następnie każdy z nich podzielono na dwa podzbiory: podzbiór sąsiadów *bliskich* ( $\Lambda^B$ ) i podzbiór sąsiadów *dalekich* ( $\Lambda^D$ ). Podstawą do orzeczenia czy dany model należy do któregoś z zbiorów sąsiadów było bezpośrednie sąsiedztwo fragmentów obiektu w rozpatrywanym obiekcie. Zatem dla poszczególnych modeli lokalnych wyróżniono następujące zbiory sąsiadów:

1.  $\Lambda_1^B = \{m_2^L\}$ ,  $\Lambda_1^D = \{m_3^L\}$ ;
2.  $\Lambda_2^B = \{m_1^L, m_3^L\}$ ,  $\Lambda_2^D = \{m_4^L\}$ ;
3.  $\Lambda_3^B = \{m_2^L, m_4^L\}$ ,  $\Lambda_3^D = \{m_1^L, m_5^L\}$ ;
4.  $\Lambda_4^B = \{m_3^L, m_5^L\}$ ,  $\Lambda_4^D = \{m_2^L, m_6^L\}$ ;
5.  $\Lambda_5^B = \{m_4^L, m_6^L\}$ ,  $\Lambda_5^D = \{m_3^L, m_7^L\}$ ;
6.  $\Lambda_6^B = \{m_5^L, m_7^L\}$ ,  $\Lambda_6^D = \{m_4^L\}$ ;
7.  $\Lambda_7^B = \{m_6^L\}$ ,  $\Lambda_7^D = \{m_5^L\}$ .

Następnie, dla każdego Modułu B wyznaczano wektor pięciu wartości stopni przekonania o pracy fragmentu maszyny w danych warunkach działania:

$$\langle b(w_1), b(w_2), b(w_3), b(w_4), b(w_5) \rangle \quad (5.1)$$

Każda wartość  $b(\cdot)$  zawierała się w przedziale  $[0; 1]$ . Wartość  $b(\cdot) = 1$  oznacza pełne przekonanie o tym, że fragment obiektu działa w danych warunkach. Jako stan bazowy przyjmowano wartość równą 1 dla stopnia przekonania wstępnie sklasyfikowanego warunku działania. Pozostałe stopnie przekonania posiadały wartość równą 0. Rolę funkcji przejścia pełniły dwie sieci neuronalne. Danymi uczącymi i testującymi dla tych sieci były zbiory przykładów opisanych w p. 5.1.3, przy czym rozpatrywanymi cechami były klasy reakcji podporowych. Każda z sieci transformowała opinie o lokalnych warunkach działania generowane przez sąsiadów należących do zbiorów  $\Lambda^B$  i  $\Lambda^D$  na opinię o lokalnych warunkach działania danego fragmentu obiektu. Otrzymane opinie, opinia pierwotna i opinia sąsiadów, były agregowane za pomocą jednego z dwóch operatorów agregacji:

1. operatora t-conorm,
2. operatora średniej quasi-arytmetycznej (z parametrem  $\alpha = -10$ ).

Należy zauważyć, że operatory agregacji były raz używane niezależnie od siebie i automatu komórkowego, a raz pełniły rolę funkcji przejścia wyznaczającej stan komórki w bieżącym kroku działania automatu komórkowego. W sumie utworzono dwa automaty komórkowe. Działanie każdego automatu komórkowego kończono po 50 krokach.

Na podstawie uzyskanych wartości stopni przekonania o warunkach działania fragmentu obiektu przeprowadzano proces wyostrenia opinii z użyciem operatora  $\max(\cdot)$  i porównywano poprawność otrzymywanych wyników z klasami wzorcowymi wyznaczonymi w p. 5.1.2.

## Moduł C

Obiekt działał w jednej klasie warunków działania  $w_1^O$  - *praca ustalona*. Zatem należało zbudować jeden klasyfikator stanu dla każdego fragmentu obiektu. Również w tym przypadku został użyty klasyfikator neuronalny. Zastosowana sieć neuronalna zbudowana była z jednej warstwy ukrytej zawierającej 4 neurony z sigmoidalną funkcją przejścia oraz jednej warstwy wyjściowej zawierającej 5 neuronów z liniową funkcją przejścia. Sieci neuronalne zostały poddane optymalizacji z użyciem algorytmu ewolucyjnego o następujących parametrach:

- liczba osobników  $p$  (stała) = 90,
- liczba rozpatrywanych cech =  $max$  15,
- liczba pokoleń = 50,
- współczynnik krzyżowania = 30 [%],
- współczynnik mutacji = 1 [%].

W wyniku optymalizacji otrzymano zbiory cech relewantnych, które przedstawiono w tabeli 5.2.

## Łączenie modeli lokalnych

Na rys. 5.3 przedstawiono postać sieci przekonań, którą opracowano z użyciem programu Netica [113]. Zadaniem sieci stwierdzeń jest synteza wyników generowanych przez poszczególne modele lokalne  $m_i^L$ . Wyróżnione, ciemniejsze obszary pokazują różne stopnie szczegółowości. Wynikiem działania każdego modelu lokalnego jest zbiór wartości stopni przekonania  $b_j$  o wystąpieniu danego lokalnego stanu technicznego  $s_j$ . W rozpatrywanym przypadku każdy model lokalny rozpoznawał pięć klas stanów każdego fragmentu obiektu (p. 5.1.2). Każda pojedyncza wartość stopnia przekonania jest przypisywana do odpowiedniego stwierdzenia  $z_{i,j}$ . Stwierdzenia są zapisywane z dwoma indeksami: indeks  $i$  odpowiada numerowi modelu lokalnego, indeks  $j$  odpowiada numerowi stanu. Wyjątek stanowi indeks  $i = 0$ , który dotyczy całego obiektu. Wykaz stwierdzeń umieszczono w tab. 5.3 i tab. 5.4. Razem utworzono 35 stwierdzeń, które stanowiły wejście do sieci. Na wyjściu znajduje się jedno stwierdzenie  $z_{00}$  o treści *Obiekt jest zdatny*. Pozostałe stwierdzenia pomocnicze  $z_{01} \div z_{07}$  mają za zadanie grupować stwierdzenia związane z przemieszczeniami danego fragmentu obiektu. Tabele z wartościami prawdopodobieństw warunkowych dla stwierdzenia wyjściowego i stwierdzeń pomocniczych zamieszczono w tab. 5.5 i tab. 5.6.

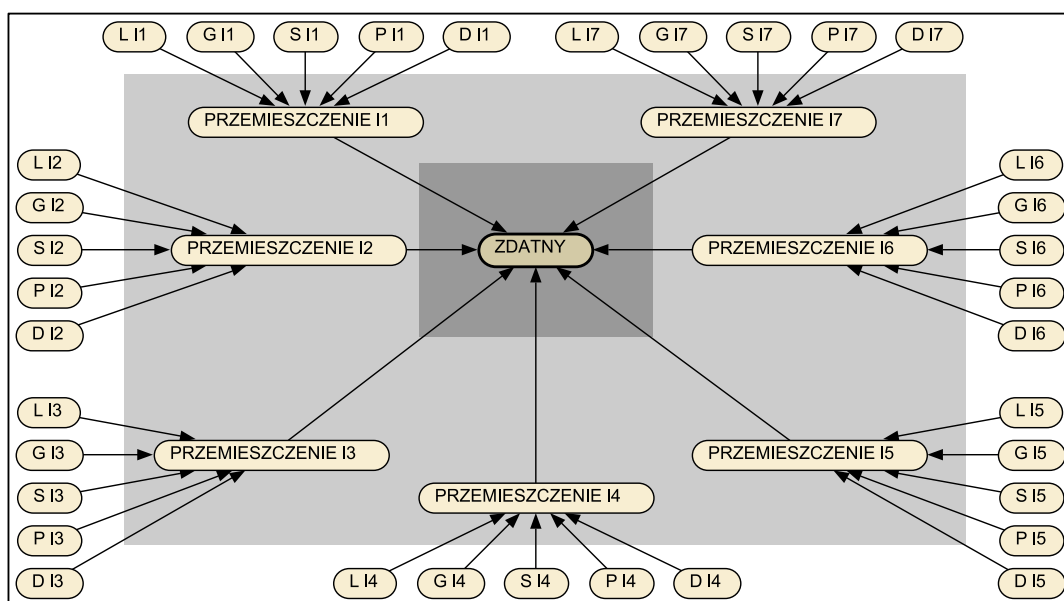
Wartości prawdopodobieństw warunkowych generowano z użyciem wiedzy eksperckiej na podstawie następujących zasad:

1. Wartość stwierdzenia wyjściowego  $z_{00}$  (*Obiekt jest zdatny*) powinna rosnąć wraz ze spadkiem wartości stwierdzeń  $z_{01}$ ,  $z_{02}$ ,  $z_{03}$ ,  $z_{04}$ ,  $z_{05}$ ,  $z_{06}$  i  $z_{07}$ .

Tab. 5.2. Wyniki optymalizacji zbioru danych wejściowych klasyfikatorów Modułów C (opis oznaczeń w tekście)

	cechy relewantne		pozostałe cechy	
$m^L_1$	u.lo(1).bcl.x.c.f2 u.lo(1).bpl.y.c.a1 u.lo(1).bca.r.c.pmi u.lo(1).bcl.x.c.pp	u.lo(1).bcl.x.c.f3 u.lo(1).bpl.r.c.a040 u.lo(1).bcl.r.c.c u.lo(1).bcl.x.c.p	u.lo(1).bpl.r.c.f4 u.lo(1).bca.xy.c.t1 u.lo(1).bca.x.c.a3 u.lo(1).bpl.r.c.a3 u.lo(1).bpl.x.c.pp	u.lo(1).el.y.c.i u.lo(1).bca.rm.c.sinfi0 u.lo(1).bpl.y.c.a033 u.lo(1).bcl.r.c.a1 u.lo(1).bpl.y.c.a025
$m^L_2$	u.lo(2).el.x.c.f1 u.lo(2).bca.r.c.a025 u.lo(2).bca.r.c.obr1k u.lo(2).bpl.r.c.pmi u.lo(2).bcl.r.c.obr1k2	u.lo(2).bcl.x.c.f4 u.lo(2).el.rm.c.r0 u.lo(2).bca.x.c.ku u.lo(2).bcl.y.c.a025 u.lo(2).bpl.x.c.p	u.lo(2).el.x.c.f1 u.lo(2).el.r.c.p u.lo(2).bpl.y.c.k u.lo(2).el.y.c.p u.lo(2).el.y.c.a05	u.lo(2).el.y.c.a1 u.lo(2).el.r.c.a1 u.lo(2).bpl.r.c.f2 u.lo(2).bca.y.c.rms
$m^L_3$	u.lo(3).bca.r.c.obr1k u.lo(3).bpl.y.c.k u.lo(3).el.r.c.a025 u.lo(3).el.xy.c.t1 u.lo(3).bcl.x.c.ave u.lo(3).bpl.x.c.a1 u.lo(3).bca.r.c.a05	u.lo(3).bpl.r.c.f2 u.lo(3).el.x.c.a4 u.lo(3).el.y.c.p u.lo(3).el.r.c.f2 u.lo(3).bpl.y.c.ppl u.lo(3).bpl.r.c.pmi u.lo(3).bpl.x.c.a05	u.lo(3).bpl.y.c.pmi u.lo(3).bpl.r.c.f2 u.lo(3).el.x.c.a05	
$m^L_4$	u.lo(4).el.x.c.rms u.lo(4).el.x.c.ppl u.lo(4).el.r.c.smax u.lo(4).bpl.x.c.p u.lo(4).el.r.c.pmi u.lo(4).bcl.rm.c.r0	u.lo(4).bpl.r.c.s u.lo(4).el.x.c.a05 u.lo(4).el.x.c.a025 u.lo(4).el.r.c.pp u.lo(4).bcl.x.c.p	u.lo(4).bcl.y.c.pp u.lo(4).bca.r.c.obr1k2 u.lo(4).bcl.y.c.pmi u.lo(4).el.r.c.pmi	u.lo(4).bpl.y.c.a040 u.lo(4).bcl.rm.c.sinfi0 u.lo(4).el.r.c.a3 u.lo(4).bpl.y.c.a3
$m^L_5$	u.lo(5).bcl.r.c.f1 u.lo(5).bpl.x.c.a025 u.lo(5).bpl.r.c.c u.lo(5).bcl.x.c.ppl u.lo(5).el.r.c.pmi u.lo(5).bpl.y.c.s	u.lo(5).el.r.c.a4 u.lo(5).el.rm.c.cosfi0 u.lo(5).bpl.rm.c.r0 u.lo(5).el.x.c.s u.lo(5).el.y.c.rms u.lo(5).el.y.c.f2	u.lo(5).el.r.c.f4 u.lo(5).bca.x.c.k u.lo(5).el.y.c.a1 u.lo(5).bpl.y.c.k	
$m^L_6$	u.lo(6).bcl.y.c.f3 u.lo(6).bpl.x.c.a2 u.lo(6).bca.y.c.ppl u.lo(6).bca.x.c.pmi	u.lo(6).bca.y.c.f3 u.lo(6).bcl.y.c.s u.lo(6).bca.x.c.a4 u.lo(6).bca.y.c.f4	u.lo(6).bcl.y.c.f2 u.lo(6).el.rm.c.cosfi0 u.lo(6).bca.r.c.a1 u.lo(6).bca.y.c.p u.lo(6).bca.y.c.a05 u.lo(6).el.xy.c.sto	u.lo(6).el.r.c.f3 u.lo(6).bca.y.c.a3 u.lo(6).bca.y.c.f3 u.lo(6).el.r.c.ppl u.lo(6).bpl.r.c.spp u.lo(6).bpl.r.c.ppl
$m^L_7$	u.lo(7).bca.y.c.i u.lo(7).bcl.x.c.f2 u.lo(7).bpl.r.c.a040 u.lo(7).el.x.c.p u.lo(7).bpl.x.c.ave u.lo(7).el.r.c.a040	u.lo(7).el.r.c.pp u.lo(7).bca.y.c.ku u.lo(7).bca.y.c.ppl u.lo(7).bpl.r.c.a4 u.lo(7).bcl.x.c.a2	u.lo(7).bcl.xy.c.sto u.lo(7).bca.y.c.a4 u.lo(7).bpl.y.c.f2 u.lo(7).bca.r.c.s	u.lo(7).el.y.c.ppl u.lo(7).bcl.y.c.pmi u.lo(7).el.y.c.a025

2. Wartości stwierżeń pomocniczych  $z_{01} \div z_{07}$  (*Przemieszczenie podpory li*) powinny rosnać wraz ze wzrostem wartości stwierżeń  $z_{i1}$ ,  $z_{i2}$ ,  $z_{i3}$  i  $z_{i4}$  (*Przemieszczenie podpory li* w kierunku {L, G, P lub D}) i spadkiem wartości stwierżenia  $z_{i5}$  (*Brak przemieszczenia podpory li*), przy czym wartości stwierżeń  $z_{i1}$ ,  $z_{i2}$ ,  $z_{i3}$  i  $z_{i4}$  mają największy wpływ.



Rys. 5.3. Sieć przekonań - synteza modelu globalnego. Oznaczenia:  $11 \div 17$  - modele lokalne podpór łożyskowych; ZDATNY - stan pełnej zdatności obiektu ( $s_{0,0}$ ); PRZEMIESZCZENIE  $li$  - przemieszczenie wybranej podpory ( $s_{i,0}$ ); L  $li$  - przemieszczenie w lewo ( $s_{i,1}$ ); G  $li$  - przemieszczenie w górę ( $s_{i,2}$ ); P  $li$  - przemieszczenie w prawo ( $s_{i,3}$ ); D  $li$  - przemieszczenie w dół ( $s_{i,4}$ ); S  $li$  - brak przemieszczenia ( $s_{i,5}$ )

Dodatkowe stwierdzenie  $z_{00}$  reprezentujące dodatkowy stan  $s'_0$  (stan pełnej zdatności całego obiektu) wprowadzono po to, żeby w łatwy sposób sprawdzić czy obiekt jest zdalny do wypełniania wymaganych funkcji. W przypadku, gdy obiekt jest niezdatny (wartość stwierdzenia  $z_{00}$  jest niższa od założonej wartości granicznej), sprawdzane są wartości stwierdzeń  $z_{01} \div z_{07}$ . Proces ten można kontynuować, aż do stwierdzeń będącymi liśćmi drzewa stwierdzeń.

### 5.3.3. Identyfikacja modeli globalnych

Na potrzeby badań weryfikacyjnych zbudowano modele globalne obiektu rozpoznające warunki działania fragmentu obiektu oraz stany fragmentów obiektu. Obliczenia przeprowadzono dla zbioru danych uczących  $DU$  będącego sumą zbiorów danych uczących pozyskanych na potrzeby identyfikacji modeli lokalnych:

$$DU = DU_1 \cup DU_2 \cup DU_3 \cup DU_4 \cup DU_5 \cup DU_6 \cup DU_7 \quad (5.2)$$

Analogicznie, zbiór danych testujących  $DT$  był sumą zbiorów danych testowych poszczególnych modeli lokalnych:

$$DT = DT_1 \cup DT_2 \cup DT_3 \cup DT_4 \cup DT_5 \cup DT_6 \cup DT_7 \quad (5.3)$$

Tab. 5.3. Wykaz stwierdzeń (cd. w tab. 5.4)

identyfikator	treść stwierdzenia
stwierdzenie wyjściowe	
z00	Obiekt jest zdalny ( $s'_0$ )
stwierdzenia pomocnicze (grupujące)	
z01	Występuje nadmierne przemieszczenie w podporze 1
z02	Występuje nadmierne przemieszczenie w podporze 2
z03	Występuje nadmierne przemieszczenie w podporze 3
z04	Występuje nadmierne przemieszczenie w podporze 4
z05	Występuje nadmierne przemieszczenie w podporze 5
z06	Występuje nadmierne przemieszczenie w podporze 6
z07	Występuje nadmierne przemieszczenie w podporze 7
stwierdzenia wejściowe związane z modelem $m_1^L$	
z11	Występuje nadmierne przemieszczenie w podporze 1 w lewo ( $s_{1,1}$ )
z12	Występuje nadmierne przemieszczenie w podporze 1 w górę ( $s_{1,2}$ )
z13	Występuje nadmierne przemieszczenie w podporze 1 w prawo ( $s_{1,3}$ )
z14	Występuje nadmierne przemieszczenie w podporze 1 w dół ( $s_{1,4}$ )
z15	Brak przemieszczenia w podporze 1 ( $s_{1,5}$ )
stwierdzenia wejściowe związane z modelem $m_2^L$	
z21	Występuje nadmierne przemieszczenie w podporze 2 w lewo ( $s_{2,1}$ )
z22	Występuje nadmierne przemieszczenie w podporze 2 w górę ( $s_{2,2}$ )
z23	Występuje nadmierne przemieszczenie w podporze 2 w prawo ( $s_{2,3}$ )
z24	Występuje nadmierne przemieszczenie w podporze 2 w dół ( $s_{2,4}$ )
z25	Brak przemieszczenia w podporze 2 ( $s_{2,5}$ )
stwierdzenia wejściowe związane z modelem $m_3^L$	
z31	Występuje nadmierne przemieszczenie w podporze 3 w lewo ( $s_{3,1}$ )
z32	Występuje nadmierne przemieszczenie w podporze 3 w górę ( $s_{3,2}$ )
z33	Występuje nadmierne przemieszczenie w podporze 3 w prawo ( $s_{3,3}$ )
z34	Występuje nadmierne przemieszczenie w podporze 3 w dół ( $s_{3,4}$ )
z35	Brak przemieszczenia w podporze 3 ( $s_{3,5}$ )

### Identyfikacja modelu rozpoznającego lokalne warunki działania obiektu

Tak jak w przypadku modeli lokalnych, dla modelu globalnego zidentyfikowano jeden neuronalny klasyfikator warunków działania. Parametry klasyfikatora oraz parametry al-



Tab. 5.4. Wykaz stwierdzeń (cd. tab. 5.3)

identyfikator	treść stwierdzenia
stwierdzenia wejściowe związane z modelem $m_4^L$	
z <sub>41</sub>	Występuje nadmierne przemieszczenie w podporze 4 w lewo ( $s_{4,1}$ )
z <sub>42</sub>	Występuje nadmierne przemieszczenie w podporze 4 w górę ( $s_{4,2}$ )
z <sub>43</sub>	Występuje nadmierne przemieszczenie w podporze 4 w prawo ( $s_{4,3}$ )
z <sub>44</sub>	Występuje nadmierne przemieszczenie w podporze 4 w dół ( $s_{4,4}$ )
z <sub>45</sub>	Brak przemieszczenia w podporze 4 ( $s_{4,5}$ )
stwierdzenia wejściowe związane z modelem $m_5^L$	
z <sub>51</sub>	Występuje nadmierne przemieszczenie w podporze 5 w lewo ( $s_{5,1}$ )
z <sub>52</sub>	Występuje nadmierne przemieszczenie w podporze 5 w górę ( $s_{5,2}$ )
z <sub>53</sub>	Występuje nadmierne przemieszczenie w podporze 5 w prawo ( $s_{5,3}$ )
z <sub>54</sub>	Występuje nadmierne przemieszczenie w podporze 5 w dół ( $s_{5,4}$ )
z <sub>55</sub>	Brak przemieszczenia w podporze 5 ( $s_{5,5}$ )
stwierdzenia wejściowe związane z modelem $m_6^L$	
z <sub>61</sub>	Występuje nadmierne przemieszczenie w podporze 6 w lewo ( $s_{6,1}$ )
z <sub>62</sub>	Występuje nadmierne przemieszczenie w podporze 6 w górę ( $s_{6,2}$ )
z <sub>63</sub>	Występuje nadmierne przemieszczenie w podporze 6 w prawo ( $s_{6,3}$ )
z <sub>64</sub>	Występuje nadmierne przemieszczenie w podporze 6 w dół ( $s_{6,4}$ )
z <sub>65</sub>	Brak przemieszczenia w podporze 6 ( $s_{6,5}$ )
stwierdzenia wejściowe związane z modelem $m_7^L$	
z <sub>71</sub>	Występuje nadmierne przemieszczenie w podporze 7 w lewo ( $s_{7,1}$ )
z <sub>72</sub>	Występuje nadmierne przemieszczenie w podporze 7 w górę ( $s_{7,2}$ )
z <sub>73</sub>	Występuje nadmierne przemieszczenie w podporze 7 w prawo ( $s_{7,3}$ )
z <sub>74</sub>	Występuje nadmierne przemieszczenie w podporze 7 w dół ( $s_{7,4}$ )
z <sub>75</sub>	Brak przemieszczenia w podporze 7 ( $s_{7,5}$ )

gorytmu ewolucyjnego były takie same jak w przypadku identyfikacji Modułów B. W wyniku obliczeń otrzymano cechy relewantne pokazane w tab. 4.13.

### Identyfikacja modelu rozpoznającego stan fragmentu obiektu

Również w tym przypadku zastosowano klasyfikatory neuronalne, które wcześniej poddano optymalizacji ewolucyjnej. W wyniku optymalizacji otrzymano zbiory cech relewantnych, które zaprezentowano w tab. 5.8.

Tab. 5.5. Wartości prawdopodobieństw warunkowych stwierdzenia wyjściowego  $z_{00}$ . Oznaczenia:  $z_{0,j}$  - stwierdzenie pomocnicze (grupujące),  $j$  - indeks fragmentu obiektu

**identyfikator węzła:  $z_{00}$**

stan		identyfikator węzła						
TAK	NIE	$z_{01}$	$z_{02}$	$z_{03}$	$z_{04}$	$z_{05}$	$z_{06}$	$z_{07}$
0,0	1,0	przynajmniej jedna wartość = TAK						
1,0	0,0	NIE	NIE	NIE	NIE	NIE	NIE	NIE

Tab. 5.6. Wartości prawdopodobieństw warunkowych stwierdzeń pomocniczych  $z_{0j}$ . Oznaczenia:  $z_{i\{1\div 5\}}$  - stwierdzenia wejściowe,  $i$  - indeks modelu lokalnego  $m_i^L$ ,  $\{1 \div 5\}$  - klasy stanów,  $j$  - indeks fragmentu obiektu

**identyfikator węzła:  $z_{0j}$**

stan		identyfikator węzła				
TAK	NIE	$z_{i1}$	$z_{i2}$	$z_{i3}$	$z_{i4}$	$z_{i5}$
1	0	jedna i więcej wartości = TAK				NIE
0,9	0,1	dwie i więcej wartości = TAK				TAK
0,5	0,5	jedna wartość = TAK				TAK
0,5	0,5	NIE	NIE	NIE	NIE	NIE
0	1	NIE	NIE	NIE	NIE	TAK

Tab. 5.7. Wyniki optymalizacji zbioru danych wejściowych klasyfikatora warunków działania modelu globalnego (opis oznaczeń w p. 5.3.2)

	cechy relewantne		pozostałe cechy
$m^G$	u.lo(n).bcl.y.c.rms	u.lo(n).bpl.x.c.a3	u.lo(n).bcl.x.c.ku
	u.lo(n).el.r.c.smax	u.lo(n).bca.r.c.obr1k	u.lo(n).bcl.rn.c.cosfi0
	u.lo(n).bcl.r.c.a4	u.lo(n).bcl.r.c.a040	u.lo(n).bpl.r.c.a025
	u.lo(n).bpl.r.c.a040	u.lo(n).bca.x.c.p	u.lo(n).bca.xy.c.sto
	u.lo(n).el.r.c.a033	u.lo(n).el.y.c.ave	u.lo(n).el.r.c.a4
	u.lo(n).bpl.y.c.i	u.lo(n).bcl.y.c.a4	u.lo(n).el.x.c.a3
			u.lo(n).el.r.c.a1
			u.lo(n).el.r.c.f2

## 5.4. Przebieg badań

Opisane w p. 5.1.3 zbiory danych podzielono na zbiory danych uczących  $DU$  i danych testujących  $DT$ . Dane uczące  $DU$  obejmują przykłady przemieszczania tylko jednej podpory w danej chwili (zestaw 1 i zestaw 3, p. 5.1.3). Natomiast dane testujące  $DT$  dotyczą przypadków jednoczesnego przemieszczania łożysk o numerach 5 i 6 (zestaw 2). Dane uczące posłużyły do budowy klasyfikatorów modeli lokalnych opisanych w p. 5.3.2 oraz klasyfikatorów modelu globalnego opisanych w p. 5.3.3, a dane testujące zastosowano w

Tab. 5.8. Wyniki optymalizacji zbioru danych wejściowych klasyfikatora stanu modelu globalnego (opis oznaczeń w p. 5.3.2)

	cechy relewantne		pozostałe cechy	
$m^G$	u.lo(n).bcl.r.c.smax	u.lo(n).bca.y.c.pmi	u.lo(n).bpl.x.c.a05	u.lo(n).bpl.xy.c.t1
	u.lo(n).bca.y.c.s	u.lo(n).bca.y.c.c	u.lo(n).el.r.c.obr1k2	u.lo(n).el.r.c.ku
	u.lo(n).el.y.c.pmi	u.lo(n).bca.y.c.f4	u.lo(n).el.y.c.i	u.lo(n).bpl.r.c.p
	u.lo(n).bca.y.c.a3	u.lo(n).bpl.r.c.pmi	u.lo(n).bpl.r.c.k	u.lo(n).el.y.c.pp
	u.lo(n).el.r.c.f1	u.lo(n).bcl.r.c.p	u.lo(n).el.r.c.a3	u.lo(n).el.x.c.a2
	u.lo(n).bpl.r.c.f3	u.lo(n).bcl.y.c.f2	u.lo(n).el.x.c.rms	u.lo(n).el.r.c.rms
	u.lo(n).bcl.r.c.a2	u.lo(n).bpl.rm.c.sinfi0	u.lo(n).bpl.r.c.p	u.lo(n).el.y.c.a2

trzech etapach badań weryfikacyjnych:

**Etap 1** Weryfikacja rozpoznawania warunków działania obiektu.

**Etap 2** Weryfikacja rozpoznawania stanu fragmentu obiektu.

**Etap 3** Weryfikacja rozpoznawania stanu całego obiektu.

Etap pierwszy polegał na tym, że na wejście klasyfikatora podawano przykłady testujące i uruchamiano proces klasyfikacji warunków działania fragmentów obiektu i uzgadniania opinii o tych warunkach. Uzgadnianie opinii przeprowadzano na trzy sposoby opisane w p. 5.3.2. Jako wyniki odczytywano opinię o klasie warunków działania fragmentu obiektu wypracowaną przez model globalny i poszczególne modele lokalne oraz uzgodnioną opinię o klasach warunków działania fragmentów obiektu. Sprawności klasyfikatorów wyznaczano z użyciem wzoru 4.6.

Etap drugi polegał na tym, że na wejście klasyfikatora Modułu C podawano przykłady testujące zawierające wartości cech relewantnych określone w procesie optymalizacji ewolucyjnej. Jako wyniki odczytywano klasy stanu i porównywano je z wynikami wzorcowymi. Również w tym etapie badań przyjęto ocenę zadaną wzorem 4.6.

Ostatni etap badań dotyczył weryfikacji sieci stwierdzeń. Tak jak we wstępnych badaniach weryfikacyjnych, także i tutaj tablice prawdopodobieństw warunkowych (tab. 5.5 i tab. 5.6) były budowane z użyciem wiedzy eksperta. Badanie polegało na tym, że na wejście podawano wartości stopni przekonania o wystąpieniu danej klasy stanu technicznego fragmentu obiektu generowane przez Moduły C poszczególnych modeli lokalnych. Jako wartości odczytywano stopnie przekonania o wystąpieniu danej klasy stanu technicznego obiektu.

## 5.5. Wyniki eksperymentu

### Weryfikacja metod rozpoznawania warunków działania obiektu

W tabeli 5.9 przedstawiono sprawności działania klasyfikatora warunków działania modelu globalnego (kolumna:  $m^G$ , wiersz: *opinia pierwotna*) i klasyfikatorów poszczególnych

Tab. 5.9. Sprawności klasyfikatorów warunków działania fragmentów obiektu (opis w tekście)

	$m^G$	$m^L_1$	$m^L_2$	$m^L_3$	$m^L_4$	$m^L_5$	$m^L_6$	$m^L_7$
<b>opinia pierwotna</b>	0.594	1.000	1.000	0.750	0.781	0.813	0.938	0.719
<i>po uzgadnianiu opinii o warunkach działania</i>								
<b>t-conorm</b>	n/d	1.000	0.969	0.906	0.094	0.875	0.719	0.750
<b>średnia quasi-arytmetyczna</b>	n/d	1.000	1.000	0.969	0.938	0.875	1.000	0.719
<b>automat komórkowy (t-conorm)</b>	n/d	1.000	0.969	0.843	0.250	0.906	0.843	0.750
<b>automat komórkowy (średnia quasi-arytmetyczna)</b>	n/d	1.000	1.000	0.969	0.719	0.938	1.000	0.719

modeli lokalnych (kolumny:  $m^L_1, m^L_2, m^L_3, m^L_4, m^L_5, m^L_6, m^L_7$ , wiersz: *opinia pierwotna*) oraz wyniki skuteczności metod uzgadniania opinii modeli lokalnych o warunkach działania fragmentów obiektu (wiersze: *t-conorm*, *średnia quasi-arytmetyczna*, *automat komórkowy (t-conorm)* i *automat komórkowy (średnia quasi-arytmetyczna)*)).

### Weryfikacja metod rozpoznawania stanu obiektu

W tabeli 5.10 przedstawiono sprawności klasyfikatorów stanów modelu globalnego (kolumna:  $m^G$ ) i modeli lokalnych (kolumny:  $m^L_1, m^L_2, m^L_3, m^L_4, m^L_5, m^L_6, m^L_7$ ). Wiersze opisane jako *z dodatkowymi informacjami o lokalnych warunkach działania* i *bez dodatkowych informacji o lokalnych warunkach* informują o tym czy w zbiorze danych uczących były uwzględniane informacje o lokalnych warunkach działania obiektu pochodzące z Modułów B.

Tab. 5.10. Sprawności klasyfikatorów stanów (opis w tekście)

	$m^G$	$m^L_1$	$m^L_2$	$m^L_3$	$m^L_4$	$m^L_5$	$m^L_6$	$m^L_7$
<b>z dodatkowymi informacjami o lokalnych warunkach działania</b>	0.563	1.000	1.000	1.000	0.969	0.438	0.438	0.906
<b>bez dodatkowych informacji o lokalnych warunkach działania</b>	0.563	1.000	1.000	0.969	0.906	0.250	0.219	0.844

Tab. 5.11. Przykładowe wyniki działania sieci stwierdzeń. Wpływ wartości wybranych stwierdzeń wejściowych na wartości stwierdzeń pomocniczych

Stwierdzenia wejściowe		Stwierdzenia pomocnicze						
id	wartość	z01	z02	z03	z04	z05	z06	z07
z51	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z51	0.6	0.500	0.500	0.500	0.500	0.800	0.500	0.500
z51	1.0	0.500	0.500	0.500	0.500	1.000	0.500	0.500
z52	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z52	0.6	0.500	0.500	0.500	0.500	0.800	0.500	0.500
z52	1.0	0.500	0.500	0.500	0.500	1.000	0.500	0.500
z53	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z53	0.6	0.500	0.500	0.500	0.500	0.800	0.500	0.500
z53	1.0	0.500	0.500	0.500	0.500	1.000	0.500	0.500
z54	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z54	0.6	0.500	0.500	0.500	0.500	0.800	0.500	0.500
z54	1.0	0.500	0.500	0.500	0.500	1.000	0.500	0.500
z55	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z55	0.6	0.500	0.500	0.500	0.500	0.200	0.500	0.500
z55	1.0	0.500	0.500	0.500	0.500	0.000	0.500	0.500
z61	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z61	0.6	0.500	0.500	0.500	0.500	0.500	0.800	0.500
z61	1.0	0.500	0.500	0.500	0.500	0.500	1.000	0.500
z62	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z62	0.6	0.500	0.500	0.500	0.500	0.500	0.800	0.500
z62	1.0	0.500	0.500	0.500	0.500	0.500	1.000	0.500
z63	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z63	0.6	0.500	0.500	0.500	0.500	0.500	0.800	0.500
z63	1.0	0.500	0.500	0.500	0.500	0.500	1.000	0.500
z64	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z64	0.6	0.500	0.500	0.500	0.500	0.500	0.800	0.500
z64	1.0	0.500	0.500	0.500	0.500	0.500	1.000	0.500
z65	0.0	0.500	0.500	0.500	0.500	0.500	0.500	0.500
z65	0.6	0.500	0.500	0.500	0.500	0.500	0.200	0.500
z65	1.0	0.500	0.500	0.500	0.500	0.500	0.000	0.500

### Weryfikacja sieci przekonań

W tabeli 5.11 przedstawiono wpływ wartości stwierdzeń wejściowych  $z_{5(.)}$  i  $z_{6(.)}$  na wartości stwierdzeń pomocniczych  $z_{01}$ ,  $z_{02}$ ,  $z_{03}$ ,  $z_{04}$ ,  $z_{05}$ ,  $z_{06}$  i  $z_{07}$  (patrz tab. 4.7), przy czym w danej chwili była zmieniana wartość tylko jednego stwierdzenia, a pozostałe

stwierdzenia miały przypisaną wartość 0. Z uwagi na to, że tabele prawdopodobieństw warunkowych stwierdzeń  $z_{1(.)}$ ,  $z_{2(.)}$ ,  $z_{3(.)}$ ,  $z_{4(.)}$  i  $z_{7(.)}$  są takie same jak tabele prawdopodobieństw warunkowych stwierdzeń  $z_{5(.)}$  i  $z_{6(.)}$ , zdecydowano się nie zamieszczać tych wyników.

Tab. 5.12. Przykładowe wyniki działania sieci stwierdzeń. Wpływ wartości stwierdzeń pomocniczych na stwierdzenie wyjściowe  $z_{00}$

Stwierdzenia wejściowe		Stwierdzenie wyjściowe i stwierdzenia pomocnicze							
id	wartość	$z_{00}$	$z_{01}$	$z_{02}$	$z_{03}$	$z_{04}$	$z_{05}$	$z_{06}$	$z_{07}$
$z_{01}$	0.0	0.007	0.000	0.749	0.500	0.500	0.499	0.500	0.499
$z_{01}$	0.6	0.003	0.599	0.749	0.499	0.499	0.499	0.500	0.499
$z_{01}$	1.0	0.000	0.999	0.749	0.500	0.500	0.499	0.500	0.499
$z_{02}$	0.0	0.007	0.499	0.000	0.750	0.499	0.500	0.499	0.500
$z_{02}$	0.6	0.003	0.499	0.599	0.750	0.499	0.500	0.499	0.500
$z_{02}$	1.0	0.000	0.499	0.999	0.750	0.499	0.500	0.499	0.500
$z_{03}$	0.0	0.007	0.500	0.499	0.000	0.750	0.500	0.500	0.500
$z_{03}$	0.6	0.003	0.500	0.499	0.600	0.750	0.500	0.500	0.500
$z_{03}$	1.0	0.000	0.500	0.499	0.999	0.750	0.500	0.500	0.500
$z_{04}$	0.0	0.007	0.499	0.499	0.500	0.000	0.750	0.500	0.500
$z_{04}$	0.6	0.003	0.499	0.499	0.500	0.600	0.750	0.500	0.500
$z_{04}$	1.0	0.000	0.499	0.499	0.500	0.999	0.750	0.499	0.500
$z_{05}$	0.0	0.007	0.499	0.500	0.499	0.499	0.000	0.750	0.500
$z_{05}$	0.6	0.003	0.499	0.500	0.499	0.500	0.600	0.750	0.500
$z_{05}$	1.0	0.000	0.500	0.500	0.500	0.500	0.999	0.750	0.500
$z_{06}$	0.0	0.007	0.499	0.499	0.500	0.499	0.500	0.000	0.750
$z_{06}$	0.6	0.003	0.499	0.499	0.499	0.499	0.500	0.599	0.750
$z_{06}$	1.0	0.000	0.499	0.499	0.499	0.499	0.500	0.999	0.750
$z_{07}$	0.0	0.007	0.750	0.499	0.499	0.499	0.499	0.499	0.000
$z_{07}$	0.6	0.003	0.750	0.499	0.499	0.499	0.499	0.499	0.600
$z_{07}$	1.0	0.000	0.750	0.499	0.499	0.499	0.499	0.499	0.999

Tabela 5.12 przedstawia wpływ wartości stwierdzeń pomocniczych  $z_{01}$ ,  $z_{02}$ ,  $z_{03}$ ,  $z_{04}$ ,  $z_{05}$ ,  $z_{06}$  i  $z_{07}$  na wartość stwierdzenia wyjściowego  $z_{00}$ , przy czym w danej chwili była zmieniana wartość jednego stwierdzenia, a pozostałe stwierdzenia miały przypisaną wartość 0. Wartości stwierdzeń wejściowych  $z_{1(.)}$ ,  $z_{2(.)}$ ,  $z_{3(.)}$ ,  $z_{4(.)}$ ,  $z_{5(.)}$ ,  $z_{6(.)}$  i  $z_{7(.)}$  nie były zmieniane.

W tabeli 5.13 przedstawiono wpływ wzajemnego oddziaływania wartości stwierdzeń pomocniczych  $z_{01}$ ,  $z_{02}$ ,  $z_{03}$ ,  $z_{04}$ ,  $z_{5(.)}$ ,  $z_{6(.)}$  i  $z_{7(.)}$ , przy czym w danej chwili była zmieniana wartość jednego stwierdzenia. Wartości stwierdzeń wejściowych  $z_{1(.)}$ ,  $z_{2(.)}$ ,  $z_{3(.)}$ ,  $z_{4(.)}$ ,  $z_{5(.)}$ ,  $z_{6(.)}$  i  $z_{7(.)}$  nie były zmieniane.

Tab. 5.13. Przykładowe wyniki działania sieci stwierdzeń. Wzajemne oddziaływanie wartości stwierdzeń pomocniczych i stwierdzenia wyjściowego


Stwierdzenia wejściowe		Stwierdzenie wyjściowe i stwierdzenia pomocnicze							
id	wartość	z00	z01	z02	z03	z04	z05	z06	z07
z00	0.0	0.000	0.856	0.856	0.856	0.856	0.856	0.856	0.856
z00	0.4	0.000	0.856	0.856	0.856	0.856	0.856	0.856	0.856
z00	0.6	0.000	0.856	0.856	0.856	0.856	0.856	0.856	0.856
z00	1.0	1.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
z01	0.0	0.000	0.000	0.856	0.856	0.856	0.856	0.856	0.856
z01	0.2	0.000	0.598	0.856	0.856	0.856	0.856	0.856	0.856
z01	0.4	0.000	0.798	0.856	0.856	0.856	0.856	0.856	0.856
z01	0.6	0.000	0.899	0.856	0.856	0.856	0.856	0.856	0.856
z01	0.8	0.000	0.959	0.856	0.856	0.856	0.856	0.856	0.856
z01	1.0	0.000	0.999	0.856	0.856	0.856	0.856	0.856	0.856
z02	0.0	0.000	0.856	0.000	0.856	0.856	0.856	0.856	0.856
z02	0.6	0.000	0.856	0.899	0.856	0.856	0.856	0.856	0.856
z02	1.0	0.000	0.856	0.999	0.856	0.856	0.856	0.856	0.856
z03	0.0	0.000	0.856	0.856	0.000	0.856	0.856	0.856	0.856
z03	0.6	0.000	0.856	0.856	0.899	0.856	0.856	0.856	0.856
z03	1.0	0.000	0.856	0.856	0.999	0.856	0.856	0.856	0.856
z04	0.0	0.000	0.856	0.856	0.856	0.000	0.856	0.856	0.856
z04	0.6	0.000	0.856	0.856	0.856	0.899	0.856	0.856	0.856
z04	1.0	0.000	0.856	0.856	0.856	0.999	0.856	0.856	0.856
z05	0.0	0.000	0.856	0.856	0.856	0.856	0.000	0.856	0.856
z05	0.6	0.000	0.856	0.856	0.856	0.856	0.899	0.856	0.856
z05	1.0	0.000	0.856	0.856	0.856	0.856	0.999	0.856	0.856
z06	0.0	0.000	0.856	0.856	0.856	0.856	0.856	0.000	0.856
z06	0.6	0.000	0.856	0.856	0.856	0.856	0.856	0.899	0.856
z06	1.0	0.000	0.856	0.856	0.856	0.856	0.856	0.999	0.856
z07	0.0	0.000	0.856	0.856	0.856	0.856	0.856	0.856	0.000
z07	0.6	0.000	0.856	0.856	0.856	0.856	0.856	0.856	0.899
z07	1.0	0.000	0.856	0.856	0.856	0.856	0.856	0.856	0.999

## 5.6. Wnioski

Spośród wszystkich cech relewantnych wyznaczanych dla klasyfikatorów Modułów B (tab. 5.1) nie zaobserwowano, żeby jakaś cecha wyróżniała się na tle innych cech. Każdy klasyfikator warunków działania posiadał swój własny, niepowtarzalny zbiór cech relewantnych. Podobnie jest w przypadku klasyfikatorów stanów (tab. 5.2) oraz klasyfikatorów modeli globalnych warunków działania (tab. 5.7) i stanów (tab. 5.8). Tutaj również nie ma cech które dominowałyby nad innymi. Proces zbieżności optymalizacji ewolucyjnej wszystkich klasyfikatorów miał postać podobną tak jak to pokazano na

wykresach 4.2 i 4.3 otrzymanych w przypadku przeprowadzania badań wstępnych.

Model globalny z weryfikacją warunków działania fragmentów obiektu radził sobie przeciętnie (tab. 5.9). Uzyskana sprawność niespełna 60 [%] jest o 12.5 [%] niższa od najmniejszej sprawności, którą posiada klasyfikator modelu  $m_7^L$ . Podczas uzgadniania opinii doskonale sprawdził się operator agregacji średnia quasi-arytmetyczna. Zarówno w agregacji jak i podczas iteracyjnego uzgadniania opinii z użyciem automatu komórkowego. W wyniku jego działania średnia sprawność wszystkich klasyfikatorów modeli lokalnych wzrosła o 7.1 [%]. Największy wzrost sprawności uzyskał klasyfikator modelu  $m_4^L$  wynoszący 15.2 [%]. Zastosowanie operatora agregacji t-conorm w przypadku klasyfikatora modelu  $m_4^L$  dało złe rezultaty. Sprawność tego klasyfikatora obniżyła się o 68.7 [%].



Rys. 5.4. Zmiany sprawności klasyfikatorów lokalnych warunków działania (Moduły B) modeli  $m_3^L$ ,  $m_4^L$  i  $m_6^L$  w kolejnych krokach działania automatu komórkowego

W trakcie przeprowadzania procesu uzgadniania opinii o lokalnych warunkach działania fragmentu obiektu, zauważono, że wartości niektórych komórek automatu komórkowego oscylowały wokół punktu równowagi. Oscylacje te polegały na tym, że sprawności niektórych klasyfikatorów modeli lokalnych zmieniały się w pewnym zakresie z częstością kilku kroków działania automatu. Na wykresie 5.4 pokazano przykład tego zjawiska dla wybranych modeli lokalnych  $m_4^L$  i  $m_6^L$ . Cykle pojawiały się tylko w przypadku użycia



operatora agregacji t-conorm. Ponadto pokazano na przykładzie modelu  $m_3^L$  prawidłową zbieżność „stanu” (tutaj sprawności klasyfikacji lokalnych warunków działania) komórki do wartości ustalonej.

Porównując sprawności klasyfikatorów Modułów C modeli lokalnych i klasyfikatora stanu modelu globalnego (tab. 5.10) widać, że klasyfikator stanu modelu globalnego nie zawsze dawał gorsze rezultaty. Jego sprawność była niższa od średniej sprawności modeli lokalnych i w zależności od tego czy były uwzględniane informacje o lokalnych warunkach działania pochodzące z Modułów B lub nie zawierała się w przedziale od 17.9 [%] do 25.9 [%]. Jednak jego sprawność była zawsze wyższa od sprawności klasyfikatorów modeli lokalnych  $m_5^L$  i  $m_6^L$ , które osiągały wartość nie większą niż 43.8 [%].

Modele lokalne  $m_5^L$  i  $m_6^L$  są związane z odpowiadającymi im węzłami łożyskowymi o numerach 5 i 6. W przeprowadzanych testach właśnie podpory tych węzłów były przemieszczane. Podobne badania były przeprowadzane w [157], gdzie szczegółowej analizie poddano 8 różnych klas modeli rozpoznających stany. Prawie wszystkie modele uzyskiwały bardzo niskie sprawności, łącznie z klasyfikatorem neuronalnym. Wyjątkiem był klasyfikator Fuzzy k-Means (FkM) bazujący na metodzie grupowania zbiorów rozmytych. Sprawności klasyfikatorów modeli  $m_5^L$  i  $m_6^L$  osiągnęły wartość 62.5 [%], lecz sprawności klasyfikatorów pozostałych modeli osiągały wartości niższe niż w innych metodach, np. dla klasyfikatora modelu  $m_2^L$  sprawność wynosiła 46.9 [%]. Tak słabe wyniki działania klasyfikatorów 5 i 6 są powodowane tym, że były przemieszczane dwie podpory jednocześnie, lecz przemieszczenie jednej było zwykle dużo większe od przemieszczenia podpory drugiej [157]. W rzeczywistości łożyska 5 i 6 leżą blisko siebie (rys. 5.1) i są gabarytowo dużymi i najbardziej obciążonymi łożyskami [127, 128]. W związku z tym ich oddziaływanie na inne łożyska, a przede wszystkim ich oddziaływanie wzajemne powoduje w rezultacie tak niską sprawność klasyfikatorów modeli  $m_5^L$  i  $m_6^L$ .

Analiza wyników zawartych w tabelach 5.9 i 5.10 pozwala wyciągnąć następujące wnioski:

1. Zastosowanie metod uzgadniania opinii polepsza działanie klasyfikatorów rozpoznających lokalne warunki działania.
2. Sprawność klasyfikatorów modeli lokalnych jest zwykle lepsza od sprawności klasyfikatora modelu globalnego.
3. Uwzględnienie informacji o lokalnych warunkach działania obiektu polepsza sprawność klasyfikatora stanu lokalnego.

Analiza wyników działania sieci stwierdzeń (tabele: 5.11, 5.12 i 5.13) pozwala orzec, że zbudowana sieć działa poprawnie i zgodnie z przewidywaniami:

1. Zmiana wartości stwierdzeń wejściowych powoduje zmianę wartości odpowiadających stwierdzeń w warstwach wyższych (tab. 5.11).

2. Zmiana wartości stwierdzeń  $z_{01}$ ,  $z_{02}$ ,  $z_{03}$ ,  $z_{04}$ ,  $z_{05}$ ,  $z_{06}$  lub  $z_{07}$  nie powoduje zmiany wartości stwierdzeń w tej samej warstwie, natomiast powoduje zmianę wartości stwierdzenia w warstwie wyższej (tab. 5.12).
3. Zmiana wartości stwierdzenia  $z_{00}$  powoduje zmianę wartości stwierdzeń w warstwie niższej (tab. 5.13).

Należy zauważyć, że nagłe zmiany wartości stwierdzenia  $z_{00}$  wynikają z przyjętych wartości w tabeli prawdopodobieństw warunkowych (tab. 5.5), z której wynika, że tylko wartości *NIE* wszystkich stwierdzeń  $z_{0j}$  stwierdzenie  $z_{00}$  przyjmuje wartość *TAK*. Ta sama przyczyna powoduje tak małe zmiany wartości stwierdzenia  $z_{00}$  w przypadku analizy wpływu zmian wartości stwierdzeń pomocniczych na to stwierdzenie (tab. 5.12). Podobnie jak w przypadku badań wstępnych celowo nie zostaną skomentowane wielkości zmian wartości stwierdzeń.

W trakcie przeprowadzanych badań weryfikacyjnych opisanych w rozdziale 5, zauważono, że modele lokalne  $m_5^L$  i  $m_6^L$  mają niską sprawność (p. 5.5). Jak napisano we wnioskach do tych badań (p. 5.6) prawdopodobnie „słabe wyniki działania klasyfikatorów 5 i 6 są powodowane tym, że były przemieszczane dwie podpory jednocześnie, lecz przemieszczenie jednej było zwykle dużo większe od przemieszczenia podpory drugiej”. Ponadto, „w rzeczywistości łożyska 5 i 6 leżą blisko siebie (rys. 5.1) i są gabarytowo dużymi i najbardziej obciążonymi łożyskami. W związku z tym ich oddziaływanie na inne łożyska, a przede wszystkim ich oddziaływanie wzajemne powoduje tak niską sprawność klasyfikatorów modeli  $m_5^L$  i  $m_6^L$ ”. Dlatego postanowiono poszukać nowego sposobu podziału przestrzeni reakcji podporowych oraz zastosować inne klasy modeli lokalnych i przeprowadzić badania porównawcze [134]. Do identyfikacji modeli lokalnych będą użyte przede wszystkim dane symulacyjne związane z węzłami łożyskowymi nr 5 i 6. W celu pełnej identyfikacji modeli lokalnych związanych z tymi węzłami, na pewnych etapach tej identyfikacji potrzebne będą dane związane z węzłami łożyskowymi nr 4 i 7.

## 6.1. Obiekt badań

### 6.1.1. Charakterystyka obiektu

Obiektem badań był turbogenerator, którego opis zamieszczono w p. 5.1. Schemat badanego turbogeneratorsa pokazano na rysunku 5.1.

### 6.1.2. Dane symulacyjne

Dane symulacyjne zostały przedstawione w p. 5.1.3. Dodatkowo uwzględniono 28 przypadków przekoszenia panwi względem czopa. Łącznie wybrano 117 przykładów [127]:

- przypadek bazowy,
- przemieszczenia małe - zestaw 1: 4 kierunki · 7 łożysk = 28 przypadków,
- przemieszczenia duże - zestaw 3: 4 kierunki · 7 łożysk = 28 przypadków,
- jednoczesne przemieszczenia łożyska 5 i 6 - zestaw 2: 4 kierunki · 2 łożyska · 4 kierunki = 32 przypadki,
- przekoszenia panwi względem czopa - zestaw 4: 2 płaszczyzny · 2 kierunki · 7 łożysk = 28 przypadków.


Wszystkie opracowywane klasyfikatory były testowane metodą *leave-one-out*. Zatem zbiór danych uczących *DU* zawsze zawierał 116 przykładów, a zbiór danych testujących *DT* tylko jeden przykład. W każdym przykładzie uwzględniano 316 punktowych cech sygnałów *x* i *y* oraz trajektorii *r* mierzonych dla trzech przypadków przemieszczeń względnych i bezwzględnych.

### 6.1.3. Warunki działania i stany obiektu

Zbiór danych uczących był wyznaczany dla stałej prędkości wirowania wału. W związku z tym cały obiekt posiadał tylko jeden warunek działania:

$w_1^0$  : praca ustalona ( $n_{obr} = 3000[obr/min]$ ).

W p. 5.1.2 postanowiono, że lokalne warunki działania będą opisywane przez wartości reakcji podporowych i za [150] wyróżniono pięć klas warunków działania dla każdej podpory *i* (rys. 5.2).




Rys. 6.1. Reakcje wału w węzłach łożyskowych nr 4, 5, 6 i 7 w przypadku przemieszczenia podpory łożyska nr 5 w prawo [134]

Na potrzeby przeprowadzenia badań porównawczych wybranych modeli lokalnych zrezygnowano z tego podejścia. Z *III zasady dynamiki (zasada akcji i reakcji)* wiadomo, że ciała oddziałują na siebie wzajemnie z siłami równymi co do wartości i kierunku, lecz o przeciwnych zwrotach. Przykładowe rozkłady reakcji wału w węzłach łożyskowych nr 4,

5, 6 i 7 w przypadku przemieszczenia podpory łożyska nr 5 w prawo pokazano na rys. 6.1.

Zaproponowano, że przestrzeń reakcji podporowych będzie dzielona według wspomnianej zasady. Przyjęto podział tej przestrzeni na 4 klasy, które pokazano na rys. 6.2. Dana klasa jest opisana w układzie biegunowym przez kąt  $\theta$  oraz, dla klasy 1 i 4, wartość graniczną reakcji  $\rho$ . Ze względu na różne wartości reakcji i ich odchylenia od pionu, dla każdej podpory przyjęto różne wartości parametrów  $\theta$  i  $\rho$ , które zestawiono w tab. 6.1.



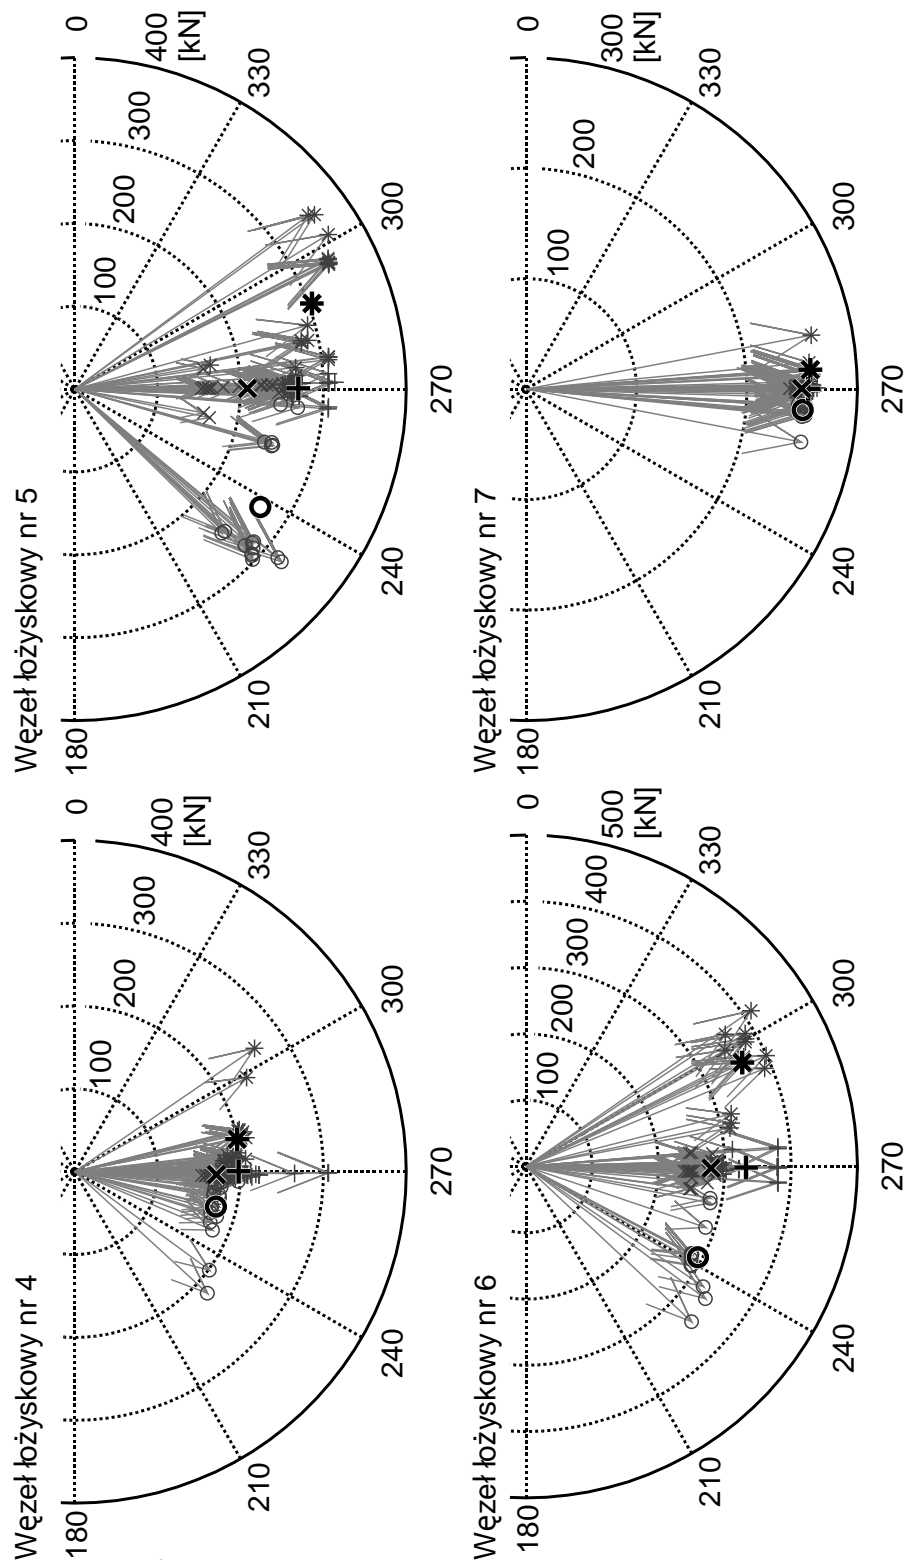
Rys. 6.2. Klasy w przestrzeni reakcji podporowych [134].  $\theta$ ,  $\rho$  - parametry określające granice klas reakcji podporowych

Tab. 6.1. Wartości parametrów  $\theta$  i  $\rho$  dla łożysk nr 4, 5, 6 i 7 [134]

	klasa reakcji podporowej			
	1	2	3	4
L4	$267^\circ \leq \theta \leq 273^\circ$ $180 > \rho$	$180^\circ < \theta < 267^\circ$	$273^\circ < \theta < 360^\circ$	$267^\circ \leq \theta \leq 273^\circ$ $180 \leq \rho$
L5	$267^\circ \leq \theta \leq 273^\circ$ $250 > \rho$	$180^\circ < \theta < 267^\circ$	$273^\circ < \theta < 360^\circ$	$267^\circ \leq \theta \leq 273^\circ$ $250 \leq \rho$
L6	$262^\circ \leq \theta \leq 278^\circ$ $291.28 > \rho$	$180^\circ < \theta < 262^\circ$	$278^\circ < \theta < 360^\circ$	$262^\circ \leq \theta \leq 278^\circ$ $291.98 \leq \rho$
L7	$269^\circ \leq \theta \leq 271^\circ$ $254.22 > \rho$	$180^\circ < \theta < 269^\circ$	$271^\circ < \theta < 360^\circ$	$269^\circ \leq \theta \leq 271^\circ$ $254.22 \leq \rho$

Wartości parametru  $\rho$  podane są w [kN]

Wartości parametrów  $\theta$  i  $\rho$  poszukiwano iteracyjnie. Początkowe wartości tych parametrów ustalano na podstawie informacji o symulowanych stanach technicznych. Zestaw 1 i zestaw 3 danych symulacyjnych (p. 6.1.2) zawierał przypadki pojedynczych przemieszczeń podpór. Uwzględniając te informacje niektóre przykłady miały z góry narzuconą klasę reakcji podporowej, co pozwoliło na wstępne ustalanie wartości parametrów  $\theta$  i  $\rho$ . Następnie, uwzględniając wartości tych parametrów, wyznaczano brakujące klasy reakcji



Rys. 6.3. Wyznaczone klasy w przestrzeni reakcji podporowych dla węzłów łożyskowych nr 4, 5, 6 i 7 [134]. Strzałki oznaczają wektory reakcji wału, symbole na końcach wektorów oznaczają przynależność do danej klasy, oznaczenia klas: + - klasa 1, o - klasa 2, \* - klasa 3, x - klasa 4, ciemniejszym kolorem wyróżniono przedstawicieli klas

podporowych dla pozostałych przykładów. Wyznaczone klasy reakcji podporowych każdej podpory łożyskowej były weryfikowane z klasami reakcji podporowych podpór sąsiednich zgodnie z przyjętą wcześniej zasadą. Po tej weryfikacji sprawdzano liczbę przypadków które nie spełniały tej zasady. W zależności od rodzaju błędnie ustalonych klas zmieniano wartość jednego z parametrów. Dla nowej wartości parametru  $\theta$  lub  $\rho$  wyznaczano nowe klasy reakcji podporowych i ponownie przeprowadzano proces weryfikacji z klasami reakcji sąsiednich. Proces kończono, gdy liczba przypadków niespełniających zasady akcji i reakcji była minimalna.

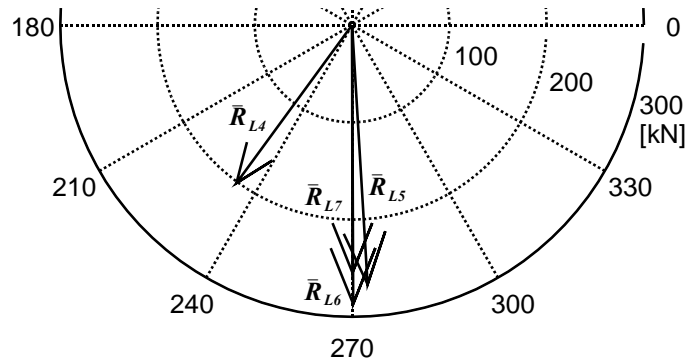
W wyniku podziału przestrzeni reakcji podporowych otrzymano klasy, które pokazano na rys. 6.3. Reprezentanci klas zostali wybrani na drodze uśredniania współrzędnych poszczególnych członków klas w przyjętym układzie współrzędnych.

Spośród 117 analizowanych przykładów zawierających wartości klas reakcji podpór łożyskowych nr 4, 5, 6 i 7, przyjęta zasada akcji i reakcji nie została spełniona w 11 przykładach, co pokazano w tab. 6.2.

Tab. 6.2. Przykłady wyznaczonych klas reakcji nie spełniających przyjętej zasady akcji i reakcji [134]

Identyfikator przykładu	Łożysko nr			
	4	5	6	7
15	4	1	1	4
34	2	3	4	1
35	3	2	1	4
36	3	2	1	4
49	2	3	4	1
50	2	3	4	1
64	2	3	4	1
74	2	3	4	1
75	2	3	1	4
87	2	3	4	1
108	3	2	4	1

Na rysunku 6.4 pokazano przykład o identyfikatorze 34, który dotyczy przesunięcia podpory łożyska  $L4$  w prawo. Widać, że reakcja wału w podporze  $L4$  jest nadmiernie przesunięta w lewo od pionu i została prawidłowo przypisana do klasy 2. Temu przesunięciu odpowiada dużo mniejsze przesunięcie w prawo od pionu reakcji podpory  $L5$  (klasa 3). Natomiast reakcje podpór  $L6$  i  $L7$  pokryły się z pionem i zostały przypisane odpowiednio do klasy 4 i klasy 1. Zapewne takie rozpoznanie klas reakcji podporowych bierze się stąd, że przemieszczenia podpory  $L4$  mają niewielki wpływ na podpory  $L6$  i  $L7$ .



Rys. 6.4. Reakcje wału w węzłach łożyskowych nr 4, 5, 6 i 7 w przypadku przemieszczenia podpory łożyska nr 3 w lewo [134]

Pozostałe przykłady wymienione w tab. 6.2 dotyczą podobnych sytuacji oraz dodatkowo przypadków równoczesnego przemieszczania dwóch podpór (przypadki o identyfikatorach od 64 do 87, zestaw danych nr 2) i jednego przypadku przekoszenia panwi (przypadek o identyfikatorze 108, zestaw danych nr 4).

Badanymi niezdatnościami (stanami technicznymi obiektu) były lokalne przemieszczenia podpór łożyskowych. W sumie określono 20 klas stanów - po 5 dla każdej z 4 podpór ( $i \in [4, 5, 6, 7]$ ):

- $s_{i,1}$  : podpora przesunięta w lewo względem położenia nominalnego (L),
- $s_{i,2}$  : podpora przesunięta w górę (G),
- $s_{i,3}$  : podpora przesunięta w prawo (P),
- $s_{i,4}$  : podpora przesunięta w dół (D),
- $s_{i,5}$  : nominalna wartość przemieszczenia podpory (S).

Klasy przemieszczeń zostały określone tak jak to pokazano na rys. 5.2.

## 6.2. Plan badań

Badania weryfikacyjne przeprowadzono według następujących kroków:

1. Przeprowadzono dekompozycję przestrzenną obiektu na fragmenty.
2. Przeprowadzono identyfikację modeli lokalnych dla wybranych fragmentów obiektu. Dla każdego modelu lokalnego przeprowadzono:
  - (a) identyfikację Modułu A - wybrano i zastosowano funkcje wyznaczające wartości cech sygnałów;



- (b) identyfikację Modułu B - z dostępnych danych trenujących wyznaczono zbiór cech relewantnych (zbiór cech relewantnych wyznaczono na potrzeby badań opisanych w p. 5.3.2), które posłużyły, wraz ze zbiorem możliwych lokalnych warunków działania, do budowy klasyfikatora warunków działania oraz wybrano metody uzgadniania opinii wypracowywanych przez Moduły B;
  - (c) identyfikację Modułu C - z dostępnych danych trenujących wyznaczono zbiór cech relewantnych (zbiór cech relewantnych wyznaczono na potrzeby badań opisanych w p. 5.3.2), które posłużyły, wraz ze zbiorem możliwych lokalnych stanów obiektu, do budowy klasyfikatora stanów.
3. Dla zidentyfikowanych modeli lokalnych przeprowadzono badania porównawcze:
- (a) Sprawdzono sprawności klasyfikatorów warunków działania.
  - (b) Sprawdzono skuteczność procesu uzgadniania opinii o lokalnych warunkach działania fragmentów obiektu.
  - (c) Sprawdzono sprawności klasyfikatorów stanów.

### 6.2.1. Opracowane oprogramowanie

Identyfikację modeli lokalnych oraz badania weryfikacyjne przeprowadzono z użyciem programu MATLAB [103]. W tym celu utworzono pakiet funkcji przeznaczonych do:

- wyznaczania wartości cech sygnałów diagnostycznych,
- tworzenia zbiorów cech relewantnych,
- budowy klasyfikatorów warunków działania i klasyfikatorów stanów,
- przeprowadzania procesu agregacji i uzgadniania opinii o warunkach działania fragmentów obiektów.

## 6.3. Model obiektu

### 6.3.1. Dekompozycja obiektu na fragmenty

Tak jak w p. 5.3.2 dla rozpatrywanego turbogeneratorsa (rys. 5.1) zdecydowano się zastosować dekompozycję przestrzenną i podzielono obiekt  $O$  na siedem fragmentów. Każdy fragment  $o_i$  ma przyporządkowane sygnały składowych  $x_{(.)}$  i  $y_{(.)}$  przemieszczeń promieniowych mierzonych w dwóch wzajemnie prostopadłych kierunkach. Jak wspomniano wcześniej, w badaniach uwzględniono tylko węzły łożyskowe nr 4, 5, 6 i 7 (fragmenty:  $o_4, o_5, o_6, o_7$ ).

### 6.3.2. Identyfikacja modeli lokalnych

Dla wybranych fragmentów obiektu zostały zidentyfikowane modele lokalne:

$$o_4 \rightarrow m_4^L, o_5 \rightarrow m_5^L, o_6 \rightarrow m_6^L, o_7 \rightarrow m_7^L.$$

Modele lokalne  $m_5^L$  i  $m_6^L$  zostały w pełni zidentyfikowane, tzn. zidentyfikowano Moduł A, Moduł B i Moduł C. Ze względu na to, że na jednym z etapów identyfikacji Modułu B wybranego modelu lokalnego przeprowadzany jest proces uzgadniania opinii o warunkach działania z Modułami B sąsiednich modeli lokalnych, postanowiono, że dla modeli lokalnych  $m_4^L$  i  $m_7^L$  zostanie przeprowadzona identyfikacja częściowa, która będzie polegała na identyfikacji tylko Modułów A i B.

#### Moduł A

Identyfikację Modułów A przeprowadzono identycznie jak w p. 5.3.2.

#### Moduł B

Identyfikowane modele były klasyfikatorami lokalnych warunków działania. Do budowy klasyfikatorów użyto następujących metod:

1. sieć neuronalną typu cascade forward [58],
2. metodę klasyfikacji z użyciem kryterium najbliższego sąsiada (NN) z metryką euklidesową [145],
3. metodę SVM (Support Vector Machine) [81, 152, 17].

Sieć neuronowa typu cascade forward jest siecią z grupy sieci wielowarstwowych. Różni się tym od innych sieci z tej grupy (np. sieci neuronowej typu feed forward), że neurony warstwy wejściowej są połączone z neuronami warstwy ukrytej oraz bezpośrednio z neuronami warstwy wyjściowej. Zastosowana sieć była siecią zbudowaną z jednej warstwy ukrytej zawierającej 3 neurony z sigmoidalną funkcją przejścia oraz jednej warstwy wyjściowej zawierającej 4 neurony z liniową funkcją przejścia. Sieć neuronalna na wejściu posiadała zbiór cech relewantnych pozyskanych na drodze optymalizacji z użyciem algorytmu ewolucyjnego. Wyniki ewolucyjnej optymalizacji zbioru cech zamieszczono w tabeli 5.1.

W przypadku metody klasyfikacji z użyciem kryterium najbliższego sąsiada zastosowano miarę odległości euklidesowej zadaną wzorem 2.31. Na wejście klasyfikatora podawano pełny, nieoptymalizowany zbiór cech punktowych wyznaczanych przez dany Moduł A.

Metoda SVM polega na poszukiwaniu pewnej hiperpłaszczyzny rozdzielającej dany zbiór obiektów na 2 klasy, przy czym odległość pomiędzy tymi klasami powinna być jak największa. W badaniach przyjęto podział zbioru reakcji na 4 klasy. W związku z

tym zbudowano 4 klasyfikatory. Każdy klasyfikator rozpoznawał wybraną klasę reakcji podporowej, a pozostałe klasy były traktowane jako „inne klasy”. Na przykład, gdy rozpoznawano klasę 3, to klasy 1, 2, i 4 były traktowane łącznie jako „inna klasa”. Po przeprowadzeniu testów dla każdego klasyfikatora SVM, dokonywano porównania wyników otrzymanych od wszystkich 4 klasyfikatorów. Jeżeli dla danego przykładu została poprawnie rozpoznana klasa lokalnych warunków działania przez odpowiedni klasyfikator, a pozostałe trzy klasyfikatory rozpoznały klasę jako „inną”, to uznawano, że przykład został zweryfikowany poprawnie. Każdy klasyfikator SVM na wejściu posiadał pełny zbiór cech wyznaczanych przez odpowiednie Moduły A.

### Agregacja opinii

Agregację opinii o lokalnych warunkach przeprowadzano w czterech krokach:

**Krok 1** Wybór sąsiadów, z którymi dany model lokalny będzie uzgadniał opinię.

**Krok 2** Przyjęcie sposobu zapisywania wartości stopni przekonania o wystąpieniu danej klasy warunków działania.

**Krok 3** Wybór sposobów pozyskiwania informacji o warunkach działania od sąsiadów.

**Krok 4** Wybór metody agregacji.

#### Krok 1

Dla modeli lokalnych  $m_5^L$  i  $m_6^L$  wyznaczono zbiory sąsiadów  $\Lambda$ . Podstawą do orzeczenia czy dany model należy do zbioru sąsiadów było bezpośrednie sąsiedztwo fragmentów obiektu w rozpatrywanym obiekcie. Zatem dla poszczególnych modeli lokalnych wyróżniono następujące podzbiory sąsiadów:

$$\Lambda_5 = \{m_4^L, m_6^L\};$$

$$\Lambda_6 = \{m_5^L, m_7^L\}.$$

#### Krok 2

Wartości stopni przekonania o wystąpieniu danej klasy warunków działania  $w_i$  były zapisywane w postaci wektora czterech wartości:

$$\langle b(w_1), b(w_2), b(w_3), b(w_4) \rangle \quad (6.1)$$

Każda wartość  $b(\cdot)$  zawierała się w przedziale  $[0; 1]$ . Wartość  $b(\cdot) = 1$  oznacza pełne przekonanie o tym, że fragment obiektu działa w danych warunkach.

#### Krok 3

Informację o warunkach działania pozyskiwano od sąsiadów za pomocą metody SVM i sieci neuronalnej typu cascade forward. Na wejścia podawano wektory wartości stopni przekonania pochodzące od sąsiadów ze zbiorów  $\Lambda$ . Na wyjściu odczytywano

wektor stopni przekonania mówiący o tym, że wybrany fragment obiektu, według opinii sąsiadów, pracuje w danych warunkach działania.

#### Krok 4

Agregację opinii zrealizowano za pomocą operatora średniej quasi-arytmetycznej z parametrem  $\alpha = -10$  (wzór 3.11). Operator posiadał na wejściu dwie opinie - opinia pierwsza była własną opinią pierwotną generowaną przez Moduł B danego modelu lokalnego, natomiast opinia druga była opinią sąsiadów wyznaczoną w kroku 3.

Ostatecznie, na podstawie uzyskanych wartości stopni przekonania (wzór 6.1) o działaniu fragmentu obiektu w danych warunkach przeprowadzano proces wyostrenienia opinii z użyciem operatora  $\max(\cdot)$ :

$$\max(\langle b(w_1), b(w_2), b(w_3), b(w_4) \rangle), \quad (6.2)$$

a następnie sprawdzano poprawność otrzymanych wyników porównując je z klasami reakcji podporowych wyznaczonymi w p. 6.1.3.

#### Moduł C

Obiekt działał w jednej klasie warunków działania  $w_1^O$  - *praca ustalona*. Zatem należało zbudować jeden klasyfikator stanu dla każdego fragmentu obiektu. Rozpoznawanie stanów technicznych fragmentów obiektu ( $o_5$  i  $o_6$ ) przeprowadzono z użyciem dwóch metod:

1. sieci neuronalnej typu cascade forward,
2. metody SVM.

Zastosowana sieć neuronalna była zbudowana z jednej warstwy ukrytej zawierającej 4 neurony z sigmoidalną funkcją przejścia oraz jednej warstwy wyjściowej zawierającej 5 neuronów z liniową funkcją przejścia. Podobnie jak klasyfikator warunków działania, także tutaj zbiór wejściowy był zbiorem cech relewantnych, który otrzymano w wyniku optymalizacji ewolucyjnej przeprowadzonej na potrzeby badań opisanych w 5.3.2. Wyniki tej optymalizacji przedstawiono w tabeli 5.2.

Metoda SVM została użyta w podobny sposób jak przy tworzeniu klasyfikatorów warunków działania, przy czym w tym przypadku utworzono 5 klasyfikatorów odpowiadającym 5 klasom stanów technicznych każdego fragmentu obiektu. Każdy klasyfikator na wejściu posiadał zbiór wszystkich cech punktowych wyznaczanych przez dany Moduł A.

Na wejścia budowanych klasyfikatorów stanów podawano dodatkowe informacje o lokalnych warunkach działania, zarówno w postaci wartości stopni przekonania o

przynależności warunków działania do wybranych klas (wzór 6.1), jak i wartości przynależności ostrej (wzór 6.2). Dodatkowo sprawdzono działanie klasyfikatorów stanów bez uwzględniania informacji o warunkach działania. Informacja o warunkach działania była dostarczana przez Moduły B. Na potrzeby identyfikacji Modułu C zrezygnowano z danych wygenerowanych z wykorzystaniem metody klasyfikacji z kryterium najbliższego sąsiada. W związku z tym zostały uwzględnione informacje o warunkach działania fragmentu obiektu otrzymane w wyniku zastosowania metod:

1. sieci neuronalnej typu cascade-forward,
2. metody SVM.

Powyżej wymienione metody identyfikacji warunków działania zostały użyte zarówno do generowania opinii pierwotnej przez Moduły B jak i do agregacji opinii. Razem utworzono 8 zbiorów przykładów: 2 metody rozpoznawania stanów · 2 metody rozpoznawania warunków działania · 2 metody agregacji opinii pochodzącej od sąsiadów.

## 6.4. Przebieg badań

Opisane w p. 6.1.2 zbiory danych podzielono na zbiory danych uczących  $DU$  i danych testujących  $DT$ . Zastosowana metoda testowania klasyfikatorów *leave-one-out* automatycznie powodowała, że zbiór danych testujących zawierał zawsze jeden przykład, a pozostałe wchodziły w skład zbioru uczącego. Badania weryfikacyjne przeprowadzono w dwóch etapach:

**Etap 1** Weryfikacja rozpoznawania warunków działania obiektu (Moduł B).

**Etap 2** Weryfikacja rozpoznawania stanu fragmentu obiektu (Moduł C).

Etap pierwszy polegał na tym, że budowano klasyfikator na podstawie danych uczących  $DU$ , a następnie na wejście klasyfikatora podawano przykład testujący  $DT$  i uruchamiano proces klasyfikacji warunków działania fragmentu obiektu. Proces ten powtórzono 117 razy. Następnie przeprowadzano proces agregacji opinii. Agregację opinii przeprowadzano na dwa sposoby opisane w p. 6.3.2. Jako wyniki tego etapu badań weryfikacyjnych odczytywano opinię pierwotną o klasie warunków działania fragmentu obiektu wypracowaną przez poszczególne modele lokalne  $m_4^L$ ,  $m_5^L$ ,  $m_6^L$  i  $m_7^L$  oraz uzgodnioną opinię o klasach warunków działania fragmentów obiektu dla modeli  $m_5^L$  i  $m_6^L$ . Sprawności klasyfikatorów wyznaczano z użyciem wzoru 4.6.

Etap drugi polegał na tym, że, tak jak w etapie pierwszym, zbudowano i przetestowano 117 klasyfikatorów stanów Modułu C. Jako wyniki odczytywano klasę stanu i porównywano ją z klasami wzorcowymi. Również w tym etapie badań przyjęto ocenę zadaną wzorem 4.6.

## 6.5. Wyniki eksperymentu

### 6.5.1. Weryfikacja metod rozpoznawania warunków działania obiektu

W tabeli 6.3 zestawiono sprawności klasyfikatorów poszczególnych modeli lokalnych (kolumny:  $m_4^L$ ,  $m_5^L$ ,  $m_6^L$ ,  $m_7^L$ ) oraz wyniki skuteczności metod uzgadniania opinii modeli lokalnych o warunkach działania fragmentów obiektu. Przyjęte oznaczenia wierszy opisują

Tab. 6.3. Sprawności klasyfikatorów warunków działania fragmentów obiektu [134] (opis w tekście)

	$m_4^L$	$m_5^L$	$m_6^L$	$m_7^L$
ssn_cf	0.650	0.756	0.882	0.817
klas_euc	0.573	0.607	0.709	0.684
svm	0.624	0.761	0.803	0.633
<i>po uzgodnieniu opinii (agregacja metodą średniej quasi-arytmetycznej dla <math>\alpha = -10</math>)</i>				
ssn_cf+svm	n/d	0.803	0.889	n/d
klas_euc+svm	n/d	0.607	0.709	n/d
svm+svm	n/d	0.803	0.821	n/d
ssn_cf+ssn_cf	n/d	0.921	0.938	n/d
klas_euc+ssn_cf	n/d	0.693	0.757	n/d
svm+ssn_cf	n/d	0.904	0.956	n/d

Tab. 6.4. Szczegółowa analiza błędów klasyfikatorów warunków działania modeli  $m_5^L$  i  $m_6^L$  dla wariantu **svm+ssn\_cf** [134].  $w_i$  - klasy warunków działania

**svm+ssn\_cf**

$m_5^L$	$w_1$	$w_2$	$w_3$	$w_4$
$w_1$	54	2	2	4
$w_2$	0	15	0	0
$w_3$	1	0	17	0
$w_4$	2	0	0	20

$m_6^L$	$w_1$	$w_2$	$w_3$	$w_4$
$w_1$	26	0	0	2
$w_2$	0	11	0	0
$w_3$	0	0	14	0
$w_4$	2	1	0	61

zastosowaną metodę generowania opinii pierwotnej oraz metodę uzgadniania opinii:

**ssn\_cf** - generowanie opinii pierwotnej z użyciem sieci neuronalnej typu cascade forward,

**klas\_euc** - generowanie opinii pierwotnej z użyciem metody klasyfikacji wg strategii NN z metryką euclidesową,

**svm** - generowanie opinii pierwotnej z użyciem metody SVM,

**(.)+svm** - przekształcanie opinii sąsiadów z użyciem metody SVM,

**(.)+ssn\_cf** - przekształcanie opinii sąsiadów z użyciem sieci neuronalnej.

Dla modeli lokalnych  $m_4^L$  i  $m_7^L$  uzgadnianie opinii nie było przeprowadzane.

W tabeli 6.4 pokazano wyniki szczegółowej analizy błędów klasyfikatorów warunków działania modeli  $m_5^L$  i  $m_6^L$  dla wariantu **svm+ssn\_cf**.

### 6.5.2. Weryfikacja metod rozpoznawania stanu obiektu

W tabeli 6.5 przedstawiono sprawności klasyfikatorów stanów modeli lokalnych (kolumny:  $m_5^L$ ,  $m_6^L$ ). W tabeli ujęto sprawności zarówno dla klasyfikatorów uwzględniających na

Tab. 6.5. Sprawności klasyfikatorów stanów [134] (opis w tekście)

	$m_5^L$	$m_6^L$
<i>z uwzględnieniem klas warunków działania</i>		
<b>[ssn_cf+svm]+ssn_cf</b>	0.644	0.698
<b>[ssn_cf+ssn_cf]+ssn_cf</b>	0.628	0.695
<b>[svm+svm]+ssn_cf</b>	0.629	0.690
<b>[svm+ssn_cf]+ssn_cf</b>	0.627	0.676
<b>[ssn_cf+svm]+svm</b>	0.667	0.615
<b>[ssn_cf+ssn_cf]+svm</b>	0.709	0.590
<b>[svm+svm]+svm</b>	0.654	0.641
<b>[svm+ssn_cf]+svm</b>	0.667	0.564
<i>bez uwzględniania klas warunków działania</i>		
<b>ssn_cf</b>	0.627	0.674
<b>svm</b>	0.641	0.539

wejściu informacje o warunkach działania, jak i dla klasyfikatorów które nie uwzględniały takiej informacji. Przyjęte oznaczenia wierszy opisują zastosowaną metodę generowania opinii pierwotnej i metodę uzgadniania opinii (ujęte w nawiasach kwadratowych [..]) oraz metodę klasyfikacji stanów technicznych:

**[ssn\_cf+svm]** - generowanie opinii pierwotnej z użyciem sieci neuronalnej typu cascade forward i przekształcanie opinii sąsiadów z użyciem metody SVM,

**[ssn\_cf+ssn\_cf]** - generowanie opinii pierwotnej z użyciem sieci neuronalnej typu cascade forward i przekształcanie opinii sąsiadów z użyciem sieci neuronalnej,

**[svm+svm]** - generowanie opinii pierwotnej z użyciem metody SVM i przekształcanie opinii sąsiadów z użyciem metody SVM,

**[svm+ssn\_cf]** - generowanie opinii pierwotnej z użyciem metody SVM i przekształcanie opinii sąsiadów z użyciem sieci neuronalnej,

**[.]+ssn\_cf** - klasyfikacja stanu z użyciem sieci neuronalnej,

**[.]+svm** - klasyfikacja stanu z użyciem metody SVM.

W tabeli 6.6 pokazano wyniki szczegółowej analizy błędów klasyfikatorów stanów modeli  $m_5^L$  i  $m_6^L$  dla wariantu **[ssn\_cf+svm]+ssn\_cf**.

Tab. 6.6. Szczegółowa analiza błędów klasyfikatorów stanów modeli  $m_5^L$  i  $m_6^L$  dla wariantu **[ssn\_cf+svm]+ssn\_cf** [134].  $s_i$  - klasy stanów

<b>[ssn_cf+svm]+ssn_cf</b>					
$m_5^L$	$s_1$	$s_2$	$s_3$	$s_4$	$s_5$
$s_1$	5	0	1	0	4
$s_2$	0	2	0	0	6
$s_3$	0	1	4	0	4
$s_4$	1	0	0	6	4
$s_5$	4	7	5	4	59

$m_6^L$	$s_1$	$s_2$	$s_3$	$s_4$	$s_5$
$s_1$	4	1	1	1	3
$s_2$	0	5	2	0	4
$s_3$	2	2	5	1	2
$s_4$	1	0	1	4	4
$s_5$	3	2	1	4	64

## 6.6. Wnioski

Przyjęty podział przestrzeni reakcji podporowych (rys. 6.3) pozwolił na bardziej naturalne odwzorowanie charakteru reakcji łożysk turbogeneratora, niż przy zastosowaniu podziału wg [150] (rys. 5.2).



Analizując wyniki zawarte w tabeli 6.3 można stwierdzić, że w porównaniu do wyników uzyskanych z badań przeprowadzonych w roz. 5 (tab. 5.9) sprawności zastosowanych klasyfikatorów warunków działania były gorsze niż sprawności klasyfikatora w postaci sieci neuronalnej typu feed forward, który dla poszczególnych modeli uzyskał następujące rezultaty:  $m_4^L = 0.781$ ,  $m_5^L = 0.813$ ,  $m_6^L = 0.938$ ,  $m_7^L = 0.719$ . Można jednak stwierdzić, że wynik wynoszący ponad 80 [%] dla klasyfikatora neuronalnego w przypadku modelu  $m_6^L$  jest wynikiem dobrym. Należy wziąć również pod uwagę fakt, że zastosowane metody weryfikacji klasyfikatorów są różne. W opisywanych tutaj badaniach do weryfikacji użyto metody *leave-one-out*, a w badaniach opisanych w roz. 5 utworzono rozdzielne zbiory danych uczących i danych testujących.

Podczas uzgadniania opinii zastosowano operator agregacji średnia quasi-arytmetyczna, który najlepiej sprawdził się w badaniach przeprowadzonych w roz. 5. Ze względu na małą liczbę modeli lokalnych zrezygnowano z zastosowania iteracyjnego uzgadniania lokalnych warunków działania z użyciem automatu komórkowego. Z analizy wyników zawartych w tab. 6.3 wynika, że agregowanie opinii zazwyczaj polepszało sprawności klasyfikatorów. Tylko w przypadku zastosowania metody klasyfikacji z użyciem kryterium najbliższego sąsiada wraz z metodą SVM przeznaczoną do agregacji opinii sąsiadów skuteczność rozpoznawania lokalnych warunków działania nie zmieniła się. W pozostałych przypadkach wzrost wynosił co najwyżej 17 [%]. Najlepsze rezultaty w przypadku agregowania opinii sąsiadów dało zastosowanie sieci neuronalnej.

Z przedstawionych w tab. 6.4 rezultatów wynika, że wszystkie klasy warunków działania były zazwyczaj dobrze rozpoznawane. Najczęściej błędne rozpoznanie wybranej klasy polegało na wskazaniu klasy 1 lub klasy 4.

Analizując sprawności klasyfikatorów Modułów C modeli lokalnych  $m_5^L$  i  $m_6^L$  (tab. 6.5) widać, że uwzględnianie informacji o lokalnych warunkach działania pochodzących z Modułów B polepsza jakość rozpoznawania stanu technicznego. W przypadku modelu  $m_5^L$  najlepsze rezultaty daje generowanie opinii pierwotnej z użyciem sieci neuronalnej typu cascade forward i agregowanie opinii sąsiadów także z użyciem sieci neuronalnej oraz klasyfikacja stanu z użyciem metody SVM (sprawność równa 70 [%]), natomiast w przypadku modelu  $m_6^L$  również najlepsze efekty daje generowanie opinii pierwotnej z użyciem sieci neuronalnej typu cascade forward i agregowanie opinii sąsiadów z użyciem sieci neuronalnej, lecz z klasyfikacją stanu z użyciem sieci neuronalnej (sprawność równa około 70 [%]).

Klasyfikator stanu w postaci sieci neuronalnej typu cascade forward uzyskał nieznacznie lepszą średnią sprawność wynoszącą 65 [%], niż klasyfikator w postaci metody SVM, którego sprawność wynosiła około 61 [%].

Z przedstawionych w tab. 6.6 rezultatów wynika, że klasy stanów 1, 2,3 i 4 były przeciętnie rozpoznawane. Znacznie lepiej klasyfikatory rozpoznawały klasę 5. Najczęściej błędne rozpoznanie wybranej klasy polegało na wskazaniu klasy 5.

Analiza wyników zawartych w tabelach 6.3 i 6.5 pozwala wyciągnąć takie same wnioski jak w przypadku badań opisanych w rozdziale 5, czyli:

1. Zastosowanie metod uzgadniania opinii polepsza działanie klasyfikatorów rozpoznających lokalne warunki działania.
2. Uwzględnienie informacji o lokalnych warunkach działania obiektu polepsza sprawność klasyfikatora stanu lokalnego.

## 7.1. Podsumowanie

W rozprawie przedstawiono metodę pozwalającą na budowę systemu wnioskującego o stanie obiektu technicznego, przy czym badany obiekt jest traktowany jak układ rozproszony (p. 2.1). Prezentowaną metodę oparto na koncepcji budowy zbioru modeli lokalnych związanych z fragmentami badanego obiektu rzeczywistego, ostatecznie łączonych ze sobą do postaci modelu globalnego reprezentującego cały obiekt. Pokazano, że tworzone modele lokalne mogą być identyfikowane niezależnie od siebie. Założono przy tym, że każdy model lokalny jest zbudowany z trzech modułów:

**Moduł A** przeznaczony do wyznaczania wartości cech sygnałów;

**Moduł B** przeznaczony do identyfikacji warunków działania fragmentu obiektu oraz do komunikacji z Modułami B innych modeli lokalnych w celu uzgadniania wspólnej opinii o warunkach działania całego obiektu;

**Moduł C** przeznaczony do identyfikacji stanu fragmentu obiektu.

Łączenie modeli lokalnych przeprowadzono z użyciem sieci stwierdzeń (Moduł D). Każdy model lokalny (Moduł C) wyznaczał wartości stopni przekonania o pojawieniu się wybranych lokalnych stanów technicznych, a następnie uaktualniał wartości stwierdzeń odpowiadających tym stanom technicznym. Stwierdzenia te były traktowane jako stwierdzenia wejściowe sieci. Na podstawie ustalonych wartości stwierdzeń wejściowych i tablic prawdopodobieństw wyliczane były wartości stwierdzeń wyjściowych, które opisywały aktualny stan obiektu.

Pokazano w jaki sposób przeprowadzić dekompozycję obiektu technicznego na fragmenty w celu późniejszej identyfikacji modeli lokalnych związanych z tymi fragmentami. Opisano metody wspomagające wybór cech sygnałów diagnostycznych

przeznaczonych do budowy klasyfikatorów warunków działania i klasyfikatorów stanów. Scharakteryzowano najczęściej stosowane klasyfikatory i omówiono w jaki sposób przeprowadzić identyfikację każdego modułu.

Jednym z zadań Modułów B jest proces uzgadniania wspólnej opinii o warunkach działania całego obiektu. W pracy przedstawiono trzy grupy metod pozwalających na rozwiązanie tego problemu. Oprócz klasycznych metod takich jak operatory agregacji i operacje na zbiorach, na szczególną uwagę zasługują automaty komórkowe. Dzięki dyskretyzacji „przestrzeni” pozwalają one na prostą interpretację „odległości”, rozpatrywanej przestrzennie lub funkcjonalnie, a co za tym idzie uwzględnienie informacji otrzymywanych z *otoczenia lokalnego* z wagą zależną od tej „odległości”. Ponadto zaproponowano sposoby jak można rozwiązać problem komunikacji i wypracowywania wspólnej opinii pomiędzy modelami lokalnymi (Modułami B). Wskazano wyspecjalizowane narzędzia ułatwiające stosowanie protokołów wymiany informacji oraz opisano jak praktycznie zastosować metody uzgadniania wyników identyfikacji warunków działania.

Przeprowadzono badania, w których użyto model teoretyczny maszyny wirującej oraz model turbozespołu opracowany na podstawie rzeczywistego obiektu. Na podstawie otrzymanych cech sygnałów diagnostycznych utworzono system wnioskujący oparty na zbiorze modeli lokalnych według opisanych wskazówek oraz system wnioskujący bazujący na modelu globalnym. Następnie porównano skuteczności działania obydwu systemów. Uzyskane rezultaty pozwalają orzec, że jakość działania systemu opartego na zbiorze modeli lokalnych jest lepsza niż jakość działania systemu wykorzystującego model globalny.

## 7.2. Wnioski wynikające z pracy

### Wnioski ogólne

Wyniki z przeprowadzonych badań potwierdzają słuszność postawionych tez. Pokazano, że możliwe jest zbudowanie modelu globalnego występującego w postaci sieci modeli lokalnych, gdzie każdy model lokalny ma ograniczony dostęp do danych związanych z fragmentem obiektu oraz dysponuje własnym zbiorem klas warunków działania i własnym zbiorem klas stanów. Ponadto, pokazano, że można przeprowadzić indywidualną identyfikację modeli lokalnych, bez potrzeby wyznaczania w tym celu modelu globalnego.

### Wnioski szczegółowe

1. Uwzględnienie informacji o lokalnych warunkach działania obiektu polepsza sprawność klasyfikatorów stanu.
2. Sprawność modeli lokalnych jest zwykle wyższa od sprawności modelu globalnego.
3. Zastosowanie sieci stwierdzeń w syntezie modeli lokalnych (Moduł D) pozwala na zastosowanie wiedzy eksperckiej oraz zastosowanie warstw o różnych stopniach

szczegółowości.

4. Zastosowanie automatu komórkowego jako metody przeznaczonej do wypracowywania wspólnej opinii pozwala na użycie koncepcji *lokalnego widoku otoczenia*, czyli uwzględnienie podobieństwa pomiędzy modelami lokalnymi w jakości przekazywanej informacji.
5. Każdy model lokalny zbudowany jest z trzech modułów: A, B i C. Jakość działania pojedynczego modelu lokalnego zależy od jakości działania tych modułów. Jakość działania Modułu C zależy od jakości działania Modułu A i Modułu B. Jakość działania Modułu B zależy od jakości działania Modułu A.
6. Synteza modeli lokalnych do postaci modelu globalnego jest przeprowadzana z użyciem Modułu D, który zbudowany jest z sieci stwierdzeń. Na wejście tej sieci podawane są wyniki działania Modułów C. W związku z tym jakość działania sieci stwierdzeń zależy bezpośrednio od jakości działania Modułu C oraz pośrednio od jakości działania Modułów A i B.
7. Czas identyfikacji zbioru modeli lokalnych nie zawsze jest krótszy od czasu identyfikacji modelu globalnego. W przypadku identyfikowania złożonych modeli globalnych, rozpoznających stany fragmentów obiektów, koszt czasu budowy modelu jest dużo większy od kosztu czasu budowy zbioru modeli lokalnych. W przypadku identyfikowania prostych modeli globalnych, rozpoznających stany całego obiektu, koszt czasu tworzenia modelu jest mniejszy od kosztu czasu tworzenia zbioru modeli lokalnych.
8. Ogólny koszt optymalizacji modelu lokalnego, a co za tym idzie poprawa jakości działania zbioru modeli lokalnych, jest niższy od ogólnego kosztu optymalizacji modelu globalnego.

### 7.3. Kierunki dalszych badań

Pokazano, że zastosowanie sieci stwierdzeń sprawdza się w syntezie diagnostycznych modeli lokalnych. Na wyjściu każdego modelu lokalnego była generowana wartość stopnia przekonania wystąpienia danego lokalnego stanu technicznego. Wyznaczona wartość stopnia przekonania uaktualniała wartość stwierdzenia wejściowego odpowiadającemu temu stanowi. Na wyjściu sieci była odczytywana informacja o stanie całego obiektu. Przewiduje się, że sieci stwierdzeń równie dobrze sprawdzą się w uzgadnianiu wspólnej opinii o warunkach działania całego obiektu.

W pracy nie podjęto problemu optymalizacji metod przeznaczonych do uzgadniania wypadkowej opinii o warunkach działania całego obiektu. Zwrócono uwagę na dobre rezultaty uzyskane w przypadku zastosowania automatu komórkowego. Dalsze badania powinny skupić się na optymalizacji funkcji przejścia automatu komórkowego. Zastosowanie logiki rozmytej powinno polepszyć jakość procesu uzgadniania opinii o

warunkach działania całego obiektu.

W punkcie dotyczącym komunikacji pomiędzy modelami lokalnymi (p. 3.2) wspomniano o zastosowaniu systemu wieloagentowego. Wymienione środowisko JADE przeznaczone do budowy systemów wieloagentowych zastosowano w trakcie realizacji projektu DiaDyn [31] do wspomagania zarządzania i realizacji zleczanych zadań związanych np. z wyznaczeniem wartości stwierdzeń we wskazanej sieci stwierdzeń [129]. W dalszych badaniach przewiduje się zastosowanie systemu wieloagentowego do zbudowania systemu diagnostycznego według koncepcji przedstawionej w tej pracy.

W końcowej fazie realizacji pracy zwrócono uwagę na prace prof. W. Pedrycza (np. [117, 14]). W pracach tych podjęto problem rozproszonego grupowania z użyciem logiki rozmytej. Dalsze badania nad rozwojem metod przeznaczonych do poszukiwania zbiorów cech relewantnych używanych do budowy klasyfikatorów powinny uwzględnić informacje zawarte w tych pracach.

---

## Bibliografia

---

- [1] Aczel J.: On mean values. *Bulletin of the American Mathematical Society* 54, strony 392–400, 1948.
- [2] Aczel J.: *Lectures on Functional Equations and Applications*. Academic Press, New York 1966.
- [3] Ajdukiewicz K.: Klasyfikacja rozumowań. *Studia Logica II*, strony 278–300, 1955.
- [4] Arabas J.: *Wykłady z algorytmów ewolucyjnych*. Wydawnictwa Naukowo-Techniczne, Warszawa 2001.
- [5] Bartelmus W.: *Diagnostyka maszyn górniczych. Górnictwo odkrywkowe*. Śląsk Spółka z o.o., Katowice 1998.
- [6] Bartelmus W.: *Computer aided multistage gearbox diagnostic inference by computer simulation*, numer 38 serii *Monografie. Prace naukowe Instytutu Górnictwa*. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2002.
- [7] Bartelmus W.: *Condition monitoring of open cast mining machinery*. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2006.
- [8] Bartelmus W., Zimroz R.: Identyfikacja warunków eksploatacyjnych na potrzeby diagnostyki przekładni planetarnej do napędu koła czerpakowego. *Diagnostyka Nr 1(37)*, strony 151–158, 2006.
- [9] Basseville M., Abdelghani M., Beneveniste A.: *Subspace-based fault detection algorithms for vibration monitoring*, numer 36/1.
- [10] Będkowski L.: Ogólna teoria diagnostyki technicznej - rozprawa habilitacyjna. *Biuletyn WAT (dodatek)*, 3:25, 1981.
- [11] Będkowski L., Dąbrowski T.: *Podstawy eksploatacji, cz.2. Podstawy niezawodności eksploatacyjnej*. Wojskowa Akademia Techniczna, Warszawa, 2006.

- [12] Będkowski L., Dąbrowski T.: Elementy syntezy systemu wspomagającego diagnostę w procesach obsługowych. *XXVII Sympozjum "Diagnostyka Maszyn". Materiały konferencyjne*, strona 14, Węgierska Górka, 28.02-04.03.2000.
- [13] Bednarski M.: *Metody doskonalenia sieci bayesowskich stosowanych w diagnostycznych systemach doradczych*. Zeszyt 131. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.
- [14] Bouchachia A., Pedrycz W.: Data clustering with partial supervision. *Data Mining and Knowledge Discovery*, 12:47–78, 2006.
- [15] Cain J.: *Planning improvements in natural resources management. Guidelines for using Bayesian networks to support the planning and management of development programmes in the water sector and beyond*. Centre for Ecology & Hydrology, August 2001.
- [16] Calvo T., Mesiar R.: Generalized medians. *Proceedings of AGGREGATION'99, Palma de Maiorca*, strony 159–165, 1999.
- [17] Cawley G. C.: MATLAB support vector machine toolbox (v0.55β) [<http://theoval.sys.uea.ac.uk/~gcc/svm/toolbox>]. University of East Anglia, School of Information Systems, Norwich, Norfolk, U.K. NR4 7TJ, 2000.
- [18] Cempel C.: *Podstawy wibroakustycznej diagnostyki maszyn*. WNT, Warszawa, 1982.
- [19] Cempel C.: *Diagnostyka wibroakustyczna maszyn*. PWN, Warszawa, 1989.
- [20] Cempel C., Tomaszewski F., redaktorzy: *Diagnostyka maszyn. Zasady ogólne. Przykłady zastosowań*. Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom, 1992.
- [21] Cheng J., Bell D. A., Liu W.: Learning belief networks from data: An information theory based approach. *CIKM*, strony 325–331, 1997.
- [22] Cholewa A., Rzydzik S.: Hierarchiczne struktury danych. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 1244–1248, Gdańsk, 2005. Wydawnictwo IMP PAN.
- [23] Cholewa W.: *Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych*. Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 79. Wydawnictwo Politechniki Śląskiej, Gliwice, 1983.
- [24] Cholewa W.: Aggregation of fuzzy opinions - an axiomatic approach. *Fuzzy Sets and Systems*, 17:249–258, 1985.
- [25] Cholewa W.: Tablice ogłoszeń w diagnostycznych systemach doradczych. *Pomiary Automatyka Kontrola PAK*, 4:123–128, 1998.



- [26] Cholewa W.: Cechy i obrazy sygnałów. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbospołach energetycznych*, strony 1183–1221, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 24.
- [27] Cholewa W.: Diagnostyczne modele obiektów. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbospołach energetycznych*, strony 27–52, Gdańsk, 2005. Wydawnictwo IMP PAN.
- [28] Cholewa W.: Relewantne cechy sygnałów. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbospołach energetycznych*, strona 1261–1296, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 26.
- [29] Cholewa W.: Transakcje w diagnostycznych systemach doradczych. *II Krajowa Konferencja Naukowo-Techniczna „Diagnostyka Procesów Przemysłowych”*, strony 51–56, Łagów 1997.
- [30] Cholewa W.: Dekompozycja modeli diagnostycznych. *Pomiary Automatyka Kontrola PAK 9bis/2005*, strony 19–22, Rajgród 2005. Materiały konferencyjne Diagnostyka Procesów Przemysłowych DPP 2005.
- [31] Cholewa W.: Ogólna koncepcja systemu diadyn. W: Cholewa W., redaktor, *Warsztaty DIADYN. Materiały seminaryjne. wydanie II, poprawione i uzupełnione*, strony 4–14. Katedra PKM Politechniki Śląskiej, Ustroń, 2006-09-23.
- [32] Cholewa W.: Bazy danych w diagnostyce technicznej. *II Międzynarodowy Kongres Diagnostyki Technicznej*, strony 156–164, Warszawa 2000.
- [33] Cholewa W.: Systemy doradcze w diagnostyce technicznej. W: Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W., redaktorzy, *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, strony 543–580. WNT, Warszawa 2002.
- [34] Cholewa W., Kaźmierczak J.: *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów*. Skrypt uczelniany 1904. Wydawnictwo Politechniki Śląskiej, Gliwice 1995.
- [35] Cholewa W., Kaźmierczak J.: *Data Processing and Reasoning in Technical Diagnostics*. WNT, Warszawa 1995.
- [36] Cholewa W., Kiciński J.: *Odwrotne modele diagnostyczne*. Wydawnictwo Politechniki Śląskiej, Gliwice, 1997.
- [37] Cholewa W., Kiciński J.: *Diagnostyka techniczna. Metody odwracania nieliniowych modeli obiektów*. Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 120. Wydawnictwo Politechniki Śląskiej, Gliwice 2001.

- [38] Cholewa W., Korbicz J., Moczulski W., Timofiejczuk A.: Metody analizy sygnałów. W: Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W., redaktorzy, *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, strony 115–146. WNT, Warszawa 2002.
- [39] Cholewa W., Moczulski W.: *Diagnostyka techniczna maszyn. Pomiar i analiza sygnałów*. Skrypt uczelniany 1758. Politechnika Śląska, 1993.
- [40] Cholewa W., Pedrycz W.: *Systemy doradcze*. Skrypt uczelniany 1447. Wydawnictwo Politechniki Śląskiej, Gliwice 1987.
- [41] Cholewa W., Rogala T.: Sygnały prędkości i przyspieszeń. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 1188–1197, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 24.3.
- [42] Cholewa W., Rzydzik S.: Wartości cech sygnałów przemieszczeń. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 1184–1187, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 24.2.
- [43] Cholewa W., Urbanek G.: Optymalizacja ewolucyjna zbioru uwzględnianych cech. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 1289–1295, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 26.4.
- [44] Cholewa W., Urbanek G., Wojtusik J.: Modele wielostopniowe. Przykład. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strona 1314–1325, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 24.5.
- [45] Cholewa W., White M.: *Application of neural networks for inversing of vibration models*. Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 116. Wydawnictwo Politechniki Śląskiej, Gliwice, 1994.
- [46] Cholewa W., Wysogład B.: Trajektorie i cechy trajektorii. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 1197–1207, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 24.4.
- [47] Chow C. K., Liu C. N.: Approximating discrete probability distributions with dependence trees. *IEEE Transactions on Information Theory*, 14(3):462–467, 1968.
- [48] Cichosz P.: *Systemy uczące się*. WNT, Warszawa, 2000.
- [49] Ciesielski K., Dunin-Kępczyk B.: Systemy wieloagentowe. <http://www.mimuw.edu.pl/~kepczyk/>, 2007.

- [50] Ciupke K.: *Metoda selekcji i redukcji informacji w diagnostyce maszyn*. Zeszyt 118. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice 2001.
- [51] CLIPS: A tool for building expert systems. <http://www.ghg.net/clips/CLIPS.html>, czerwiec, 2006.
- [52] Collis J., Lee L., Thompson S.: Zeus Agent Toolkit. <http://labs.bt.com/projects/agents/zeus/>, maj 2006.
- [53] Cooper G. F., Herskovits E.: A bayesian method for the introduction of probabilistic networks from data. *Machine Learning*, 9(4):309–347, Boston 1992.
- [54] Coulouris G., Dollimore J., Kindberg T.: *Systemy rozproszone. Podstawy i projektowanie*. WNT, Warszawa 1998.
- [55] Cristian F.: Probabilistic clock synchronization. *Distributed Computing*, 3:146–158, 1989.
- [56] Czop P.: *Diagnostic models of rotating machinery under transient operating conditions*. Zeszyt 122. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2002.
- [57] Dąbrowski T.: Struktura procesu diagnozowania i jej uwarunkowania. V Krajowa Konferencja "Diagnostyka Techniczna Urządzeń i Systemów - DIAG'2003", Ref. zamówiony:81–92, Ustroń, 13-17.10.2003.
- [58] Demuth H., Beale M.: *Neural Network Toolbox User's Guide*. The MathWorks, Inc., 2002.
- [59] Detyniecki M.: Fundamentals on aggregation operators. <http://www.cs.berkeley.edu/~marcin/agop.pdf>, 2001.
- [60] Dietrych J.: *System i konstrukcja*. WNT, Warszawa 1978.
- [61] Dubois D., Prade H.: Weighted minimum and maximum operations in fuzzy set theory. *The Reliability of Expert Systems*, strony 64–118, 1986.
- [62] Dujmovic J. J.: Evaluation, comparison and optimization of hybrid computers. *Simulation of Systems*, strony 553–566, Amsterdam 1976.
- [63] Dyckhoff H., Pedrycz W.: Generalized means as model of compensative. *Fuzzy Sets and Systems*, 14:143–154, 1984.
- [64] Fidali M.: Koncepcja diagnozowania maszyn na podstawie analizy obrazów termograficznych. *Pomiary Automatyka Kontrola PAK 9bis/2005*, strony 309–311, 2005. Materiały konferencyjne Diagnostyka Procesów Przemysłowych DPP 2005.
- [65] FIPA - The Foundation for Intelligent Physical Agents: Home page. <http://www.fipa.org>, maj 2006.

- [66] Fischer M., Merritt M.: Appraising two decades of distributed computing theory research. *Distributed Computing* 16, strona 239–247, 2003.
- [67] Fodor J., Roubens M.: *Fuzzy Preference Modeling and Multicriteria Decision Support*. Kluwer Academic Publisher, Dordrecht 1994.
- [68] Garbisch M.: Fuzzy integrals in multicriteria decision making. *Fuzzy Sets and Systems* 69, strony 279–298, 1995.
- [69] Garcia-Molina H., Ullman J. D., Widom J.: *Implementacja systemów baz danych*. Wydawnictwa Naukowo-Techniczne, 2003.
- [70] Gerstenkorn T., Śródka T.: *Kombinatoryka i rachunek prawdopodobieństwa. Teoria, ćwiczenia i zbiór zadań*. Państwowe wydawnictwo naukowe, Warszawa 1967.
- [71] Goldberg D. E.: *Algorytmy genetyczne i ich zastosowania*. Wydawnictwa Naukowo-Techniczne, Warszawa 1995.
- [72] Garbisch M., Nguyen H. T., Walker E. A.: *Fundamentals of Uncertainty Calculi with Applications to Fuzzy Inference*. Kluwer Academic Publisher, Dordrecht 1995.
- [73] Gusella R., Zatti S.: The accuracy of the clock synchronization achieved by TEMPO in Berkeley UNIX 4.3BSD. *IEEE Transactions on Software Engineering*, 15/7:847–853, 1989.
- [74] Gutowitz H., redaktor: *Cellular Automata: Theory and Experiment*. The MIT Press, 1991.
- [75] Heczko R.: Systemy wieloagentowe. <http://ie.silesnet.cz/mas-pl.html>, 1998.
- [76] Herrera F., Herrera-Viedma E.: Aggregation operators for linguistic weighted information. *IEEE transactions on systems, Man and Cybernetics — Part A: Systems and Humans*, vol. 27, no. 5, strony 646–656, September 1997.
- [77] IEC-50 (191): *International Electrotechnical Vocabulary. Chapter 191: Dependability and quality of service*. British Standard, 1990.
- [78] IKV++ GmbH, Informations- und Kommunikationssysteme: Grasshopper Programmer's Guide. <http://www.grasshopper.de>, maj 2006.
- [79] Isermann R., Ballé P.: Terminology in the field of supervision, fault detection and diagnosis. *IFAC Committee SAFEPROCESS*, 1996.
- [80] Jeong I., Leon V.: Decision-making and cooperative interaction via coupling agents in organizationally distributed systems. *IEEE Transactions*, strony 789–802, 2002.
- [81] Joachims T.: Making Large-Scale SVM Learning Practical. LS8-Report, 24, Universität Dortmund, LS VIII-Report, 1998.

- [82] Kaźmierczak J.: *Eksploatacja systemów technicznych*. Wydawnictwo Politechniki Śląskiej, Gliwice, 2000.
- [83] Kiciński J., redaktor: *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, Gdańsk, 2005. Wydawnictwo IMP PAN.
- [84] Kiciński J.: Symptomy diagnostyczne turbozespołów energetycznych określone metodą komputerowej i analogowej symulacji ich defektów. *Mat. Ogólnopolskiego Seminarium Wibrodiagnostyka turbozespołów energetycznych*, strony 51–92, Gdańsk 1994.
- [85] Kiciński J., redaktor: *Symulacja defektów i budowa relacji diagnostycznych modelu numerycznego*. Zeszyt 125. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2005.
- [86] Kiciński J.: Funkcje modeli symulacyjnych w diagnostyce technicznej. *Materiały III Krajowej Konferencji Diagnostyka techniczna urządzeń i systemów DIAG'95*, strony 10–13, Szczyrk 1995.
- [87] Klimek A.: *Metody doskonalenia odwrotnych modeli diagnostycznych*. Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 134. Wydawnictwo Politechniki Śląskiej, Gliwice 1999.
- [88] Kościelny J., Syfert M.: Current diagnostics of power boiler system with use of fuzzy logic. *Proc. 4th IFAC Symp. Fault Detection, Supervision and Safety for Technical Process. SAFEPROCESS 2000*, 2:681–686, 2000.
- [89] Kościelny J. M.: *Diagnostyka zautomatyzowanych procesów przemysłowych*. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
- [90] Kolmogorov A.: Sur la notion de moyenne. *Atti delle Reale Accademia Nazionale dei Lincei Mem. Cl. Sci. Mat. Natur. Sez. 12*, strony 323–343, 1930.
- [91] Korbicz J.: Sztuczne sieci neuronowe i ich zastosowanie w diagnostyce procesów przemysłowych. *Pomiary Automatyka Kontrola*, 4:129–133, 1998.
- [92] Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W., redaktorzy: *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*. WNT, Warszawa 2002.
- [93] Koronacki J., Mielniczuk J.: *Statystyka dla studentów kierunków technicznych i przyrodniczych*. WNT, 2001.
- [94] Kostka P.: *Metody klasyfikacji kinetostatycznych linii wałów maszyn wirnikowych*. Zeszyt 121. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice 2001.

- [95] Kułakowski K.: *Automaty komórkowe*. OEN AGH, Kraków 2000.
- [96] Lab T. I.: JADE - Java Agent DEvelopment Framework. <http://jade.tilab.com>, maj 2006.
- [97] Lamport L.: Time, clocks and ordering of events in a distributed system. *Communications ACM*, 21/7:558–565, 1978.
- [98] Langley P.: Bacon 1. a general discovery system. *Proceedings of the Second National Meeting of the Canadian Society for Computational Studies of Intelligence*, 1978.
- [99] Langley P.: Rediscovering physics with bacon.3. *The Sixth International Joint Conference on Artificial Intelligence*, Tokyo 1979.
- [100] Leray P., Francois O.: BNT Structure Learning Package: Documentation and Experiments. Laboratoire PSI - INSA Rouen- FRE CNRS 2645, BP 08 - Av. de l'Université, 76801 St-Etienne du Rouvray Cedex, 15th November 2004.
- [101] Marciniak A., Korbicz J.: Modularne sieci neuronowe. W: Duch W., Korbicz J., L. R., R. T., redaktorzy, *Biocybernetyka i inżynieria biomedyczna 2000. Sieci neuronowe*, strony 135–177, Warszawa, 2000. Akademicka Oficyna Wydawnicza Exit. tom 6.
- [102] Marinescu D. C., Bölöni L. L.: BOND. A Multi-Agent System. <http://bond.cs.ucf.edu>, maj 2006.
- [103] MathWorks: MATLAB. <http://www.mathworks.com/>, 2007.
- [104] Mesiar R., Komorníková M.: Aggregation operators. *Proceeding of the XI Conference on applied Mathematics PRIM'96*, strony 193–211, 1997.
- [105] Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. WNT, Warszawa, 1999.
- [106] Mills D. L.: Internet time synchronization: the Network Time Protocol. *IEEE Transactions on Communications*, 39/10:1482–1493, 1991.
- [107] Moczulski W.: *Metoda wibroakustycznych badań maszyn wirnikowych w warunkach rozruchu i zatrzymywania*. Praca doktorska, Politechnika Śląska, IMIPKM, Gliwice, 1984.
- [108] Moczulski W.: Knowledge discovery in diagnostic databases. *Proc 2nd Symp. Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, AI-Mech, Gliwice*, 2:149–154, 2001.
- [109] Moczulski W.: *Diagnostyka techniczna. Metody pozyskiwania wiedzy*. Wydawnictwo Politechniki Śląskiej, Gliwice, 2002.

- [110] Moczulski W.: *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*. Mechanika. Zeszyty naukowe Politechniki Śląskiej. Zeszyt 130. Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
- [111] Mulawka J. J.: *Systemy ekspertowe*. WNT, 1996.
- [112] Niederliński A.: *Regułowe systemy ekspertowe*. Wydawnictwo pracowni komputerowej Jacka Skalmierskiego, Gliwice 2000.
- [113] NORSYS Software: *Netica. User's Manual*, 2007. <http://www.norsys.com>.
- [114] Patan K., Korbicz J., Mrugalski M.: Sztuczne sieci neuronowe w układach diagnostyki. W: Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W., redaktorzy, *Diagnostyka procesów*, strony 311–352, Warszawa, 2002. Wydawnictwa Naukowo-Techniczne.
- [115] Pawlak Z.: Rough sets. ICS PAS Reports, Warsaw, March 1982.
- [116] Pearl J.: *Probabilistic reasoning in intelligent systems*. Morgan Kaufman, San Mateo, CA 1988.
- [117] Pedrycz W.: Collaborative and knowledge-based fuzzy clustering. *International Journal of Innovative Computing, Information and Control*, 3:1–12, February 2007.
- [118] PN-93/N-50191: *Słownik terminologiczny elektryki. niezawodność i jakość usług*. Polski Komitet Normalizacji Norm i Jakości.
- [119] Pollack S., Hicks H. J., Harrison W.: *Tablice decyzyjne*. PWN, Warszawa 1975.
- [120] Psiuk K.: *Obiektowe modele procesu propagacji stanów w układach maszyn*. Zeszyt 119. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice 2001.
- [121] Radkowski S.: *Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych*. Biblioteka Problemów Eksploatacji. Warszawa-Radom, 2002.
- [122] Radkowski S.: Wykorzystanie bispektrum w diagnostyce wibroakustycznej. *Pomiary Automatyka Kontrola PAK 9bis/2005*, strony 227–230, Rajgród 2005. Materiały konferencyjne Diagnostyka Procesów Przemysłowych DPP 2005.
- [123] Randall R. B.: A new method of modeling gear faults. *Journal of Mechanical Design* 104, strona 259–267, 1982.
- [124] Rogala T.: Symulator drgań wirnika. Materiały wewnętrzne Katedry PKM Politechniki Śląskiej, 2004.
- [125] Rozwadowski T.: *Diagnostyka technicznych obiektów złożonych*. WAT, Warszawa 1983.
- [126] Rutkowska D., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, Warszawa 1997.

- [127] Rybczyński J.: *Przemieszczenia termiczne i montażowe podpór łożyskowych*. IMP PAN, 2004.
- [128] Rybczyński W.: Rozosiowania linii wirników. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strony 1024–1080, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 22.2.
- [129] Rzydzik S.: Moduł dia\_bel. Materiały wewnętrzne Katedry PKM Politechniki Śląskiej.
- [130] Rzydzik S.: Program „Klasyfikacja i Grupowanie”. <https://kpkp.polsl.pl/PROJEKTY/Klas/k005/mainkig.htm>, 2001.
- [131] Rzydzik S.: Application cellular automata to machine learning. Unpublished document, 2004.
- [132] Rzydzik S.: The conception of the autonomous system set. *Symposium on Methods of Artificial Intelligence*, Short papers book, 2005:109–110, November 2005.
- [133] Rzydzik S.: Rozproszony system wspomagający wnioskowanie z dynamicznym grupowaniem jego elementów. *Pomiary Automatyka Kontrola PAK 9bis/2005*, 2005. Materiały konferencyjne Diagnostyka Procesów Przemysłowych DPP 2005.
- [134] Rzydzik S.: Badania porównawcze wybranych metod identyfikacji lokalnych modeli diagnostycznych. Gliwice 2007.
- [135] Rzydzik S.: Application of selected heuristics to control of a mobile object. *AI-METH 2002*, November 13-15, Gliwice.
- [136] Rzydzik S.: Otoczenie lokalne w rozproszonych systemach wnioskujących. *1st Polish and International PD Forum – Conference on Computer Science*, Łódź-Bronisławów 11-14.04.2005.
- [137] Sławik D.: Wybór cech z zastosowaniem analizy wrażliwości. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strona 1275–1289, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 26.3.
- [138] Sławik D.: *Metody badania wrażliwości cech sygnałów diagnostycznych*. Zeszyt 126. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, 2006.
- [139] Silvert W.: Symmetric summation: a class of operations on fuzzy sets. *IEEE Transactions on Systems, Man and Cybernetics 9*, strony 659–667, 1979.
- [140] Skupnik D., Urbanek G.: Skalowanie wielowymiarowe. W: Kiciński J., redaktor, *Modelowanie i diagnostyka oddziaływań mechanicznych, i magnetycznych w turbozespołach energetycznych*, strona 1262–1275, Gdańsk, 2005. Wydawnictwo IMP PAN. r. 26.2.



- [141] Sobczak W., Malina W.: *Metody selekcji i redukcji informacji*. WNT, Warszawa, 1985.
- [142] Spirtes P., Glymour C., Scheines R.: *Causation, Prediction and Search*. The MIT Press, 2001.
- [143] Sun Microsystems, Inc.: Java Platform, Standard Edition (Java SE). <http://java.sun.com/javase/downloads/index.html>, maj 2006.
- [144] Tadeusiewicz R.: *Elementarne wprowadzenie do sieci neuronowych z przykładowymi programami*. Akademicka Oficyna Wydawnicza, Warszawa, 1988.
- [145] Tadeusiewicz R., Flasiński M.: *Rozpoznawanie obrazów*. Współczesna nauka i technika. Informatyka. Wydawnictwo naukowe PWN, Warszawa, 1991.
- [146] Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, 1993.
- [147] Timofiejczuk A.: *Metoda badania maszyn wirnikowych w warunkach rozruchu, rozbiegu i wybiegu*. Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 133. Wydawnictwo Politechniki Śląskiej, Gliwice 1999.
- [148] Treadway A., Duncan A., Newland C., Buckle P.: FIPA-OS Agent Toolkit. <http://sourceforge.net/projects/fipa-os/>, maj 2006.
- [149] Uhl T.: Zastosowanie analizy modalnej w diagnostyce. *Diagnostyka t. 10*, strony 24–32.
- [150] Urbanek G.: *Zastosowanie algorytmów ewolucyjnych w identyfikacji odwrotnych modeli diagnostycznych*. Zeszyt 132. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.
- [151] Urbanek G.: Grupowanie, klasyfikacja, selekcja. <http://https://kpkkm.polsl.pl/PROJEKTY/Klas/>, 2007.
- [152] Vapnik V.: *The Nature of Statistical Learning Theory*. Springer Verlag, New York, 1995.
- [153] Vemuri A., Polycarpou M.: *Neural-network-based robust fault diagnosis in robotic systems*, numer 8/6 serii *IEEE trans. Neural Networks*, strony 1410–1420. 1997.
- [154] Wachla D.: *Identyfikacja dynamicznych modeli diagnostycznych metodami odkryć wiedzy w bazach danych*. Zeszyt 130. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.
- [155] Walczyk Z., Kiciński J.: *Dynamika turbozespołów energetycznych - wybrane zagadnienia drgań prostych i sprzężonych*, numer 122. Wydawnictwo Politechniki Gdańskiej, Gdańsk 2001.
- [156] Wikipedia: Wolna encyklopedia. <http://pl.wikipedia.org/>, 2005.

- [157] Wojtusik J.: *Wielomodele diagnostyczne maszyn wirnikowych*. Zeszyt 128. Katedra Podstaw Konstrukcji Maszyn Politechniki Śląskiej, Gliwice, 2006.
- [158] Wydawnictwo Naukowe PWN: *Encyklopedia Popularna*. PWN, Warszawa 1992.
- [159] Wyleżoł M.: *Metody pozyskiwania procedur i relacji diagnostycznych od specjalistów w dziedzinie eksploatacji maszyn*. Praca doktorska, Politechnika Śląska, Katedra Podstaw Konstrukcji Maszyn, Gliwice 2000.
- [160] Wyrzykowski R.: Organizacja procesów obliczeniowych w równoległych i rozproszonych systemach komputerowych. [http://icis.pcz.czyst.pl/~roman/mat\\_dydy/prz\\_rown/org\\_proc/roz1\\_3.html#131](http://icis.pcz.czyst.pl/~roman/mat_dydy/prz_rown/org_proc/roz1_3.html#131), 2004.
- [161] Wysogład B.: *Metody reprezentacji drgań wałów maszyn wirnikowych w diagnostycznych bazach danych*. Mechanika. Zeszyty Naukowe Politechniki Śląskiej. Zeszyt 126. Wydawnictwo Politechniki Śląskiej, Gliwice 1996.
- [162] Yager R. R.: A new methodology for ordinal multiple aspect decisions based on fuzzy sets. *Decision Sciences* 12, strony 589–600, 1981.
- [163] Yager R. R., Kacprzyk J.: *The Ordered Weighted Averaging Operators, Theory and Applications*. Kluwer Academic Publisher, Boston, Dordrecht, London 1997.
- [164] Yager R. R., Rybalov A.: Full reinforcement operators in aggregation techniques. *IEEE Transactions on Systems, Man and Cybernetics* 28, strony 757–769, 1998.
- [165] Zadeh L. A.: Fuzzy sets. *Information and Control*, 8 (3):338–353, 1965.
- [166] Zahn C.: Graph-theoretical methods for detecting and describing gestalt clusters. *IEEE Transactions on Computers*, 1:68–86, 1971.
- [167] Zimmermann H. J., Zysno P.: Latent connectives in human decision making. *Fuzzy Sets and Systems* 4, strony 37–51, 1980.
- [168] Żółtowski B.: *Podstawy diagnostyki maszyn*. Wydawnictwo Uczelniane ATR, Bydgoszcz, 1996.
- [169] Żółtowski B., Ćwik Z.: *Leksykon diagnostyki technicznej*. Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej, Bydgoszcz, 1996.

---

## Streszczenie

---

Na potrzeby realizacji zadania diagnostycznego buduje się modele diagnostyczne badanych obiektów technicznych. Modele diagnostyczne dzieli się na dwie podstawowe klasy: modele globalne i modele lokalne. Model globalny opisuje dane uczące pochodzące z obiektu w pełnej przestrzeni ich wartości. Modele takie poddaje się optymalizacji ze względu na wejściowy zbiór cech sygnałów oraz strukturę. W wyniku poszukiwań otrzymywany jest zbiór modeli prostszych.

W pracy zaproponowano, żeby zrezygnować z poszukiwania modelu globalnego i zastąpić go zbiorem modeli lokalnych. Modele lokalne związane są z wybranymi fragmentami obiektu i reprezentują dane uczące tylko w wybranym obszarze przestrzeni wartości. Fragmenty obiektu, dzięki wzajemnym oddziaływaniom, tworzą układ rozproszony. W pracy modele lokalne identyfikowano tak jak modele globalne, przy czym na ich wejściach były dostępne wszystkie cechy sygnałów diagnostycznych całego obiektu. Zaproponowana struktura modelu lokalnego zawiera trzy współdziałające ze sobą moduły:

- Moduł A, który wyznacza wartości cech sygnałów diagnostycznych,
- Moduł B, który rozpoznaje warunki działania obiektu i uzgadnia tę opinię z Modułami B innych modeli lokalnych,
- Moduł C, który identyfikuje stan fragmentu obiektu.

Pokazano na przykładach jak identyfikować Moduły A, B i C oraz jak przeprowadzić syntezę modelu globalnego za pomocą sieci stwierdzeń (Moduł D). Opisano metody komunikacji pomiędzy Modułami B oraz zagadnienie synchronizacji czasu w układach rozproszonych.

W pracy przedstawiono podstawowe zagadnienia związane z diagnostyką w świetle podejmowanego problemu: sposoby dekompozycji obiektów, wybrane metody selekcji cech sygnałów diagnostycznych, najczęściej stosowane klasyfikatory oraz metody uzgadniania opinii.

Przeprowadzono badania weryfikacyjne zaproponowanej metody. Otrzymane wyniki pozwoliły stwierdzić słuszność postawionych tez.

**Słowa kluczowe:** układy rozproszone, diagnostyka maszyn, modele diagnostyczne, systemy wnioskujące

**Dziedziny:** diagnostyka maszyn, eksploatacja maszyn

---

## Summary

---

The need for execution of diagnostic tasks causes that diagnostic models of investigated objects are necessary to be built. Among these models two basic classes can be distinguished. They include global and local models. A global model describes learning data that is acquired on the basis of an object. Data concerns a full space of parameter values. Such models are optimized with consideration of an input set of signal features as well as a structure. As the result of searching a set of simpler models is being obtained.

In the thesis an idea of identification of a diagnostic model was presented. It was suggested that a search of one global model can be replaced with a set of local models. These models are related to selected fragments of an object and represent learning data in a limited area of parameter space only. Due to interactions these fragments are considered to be a distributed set. In the research presented in the thesis local models were identified in the same way as global ones, but on their inputs all features of diagnostic signals dealing with the whole object were accessible. A suggested structure of the local model contains three interacting modules:

- Module A, which determines values of features of diagnostic signals,
- Module B, which recognizes conditions of operation of an object and agrees its opinion with Modules B corresponding to other local models,
- Module C, which identifies a state of a fragment of an object.

Identifications of Modules A, B and C as well as synthesis of a global model with the use of statement networks (Module D) were shown. Methods of communication between Modules B and a problem of time synchronization in distributed systems were discussed.

Fundamental problems dealing with diagnostics of machinery were considered in the thesis: methods of decomposition of objects, some methods of selection of features of diagnostic signals and also most often applied classifiers and ways of reaching opinions.

Verification research of the proposed method was carried out. Obtained results confirmed correctness of formulated theses.

**Keywords:** distributed systems, diagnostics of machinery, diagnostic models, inference systems

**Domains:** diagnostics of machinery, maintenance of machinery