

**ZESZYTY
NAUKOWE
POLITECHNIKI
ŚLĄSKIEJ**

Adam KLIMEK

**METODY DOSKONALENIA
ODWROTNYCH
MODELI DIAGNOSTYCZNYCH**

MECHANIKA

Z. 134

**GLIWICE
1999**

POLITECHNIKA ŚLĄSKA

ZESZYTY NAUKOWE

Nr 1445

Adam KLIMEK

**METODY DOSKONALENIA
ODWROTNYCH
MODELI DIAGNOSTYCZNYCH**

OPINIODAWCY

Prof. dr hab. inż. Stanisław Drobnik

Prof. dr hab. inż. Bogdan Żółtowski

KOLEGIUM REDAKCYJNE

REDAKTOR NACZELNY - Prof. dr hab. Zygmunt Kleszczewski

REDAKTOR DZIAŁU - Dr hab. inż. Andrzej Buchacz
Profesor Politechniki Śląskiej

SEKRETARZ REDAKCJI - Mgr Elżbieta Leško

REDAKCJA

Mgr Kazimiera Szafir

REDAKCJA TECHNICZNA

Alicja Nowacka

Wydano za zgodą
Rektora Politechniki Śląskiej

Publikacja dofinansowana przez Komitet Badań Naukowych
w ramach projektu badawczego nr 7 T07B 050 15p02

PL ISSN 0434-0817

Wydawnictwo Politechniki Śląskiej
ul. Akademicka 5, 44-100 Gliwice
tel./fax 237-13-81

Nakład 110+53 egz. Ark. wyd. 11,5. Ark. druk. 9,625. Papier offset. kl. III 70x100 80 g
Oddano i podpisano do druku 10.12.1999 r. Druk ukończono w grudniu 1999 r.
Zam. 51/99

Fotokopie, druk i oprawę wykonano w UKiP sc, *J&D Gębka*,
Gliwice, ul. Pszczyńska 44, tel./fax 231-87-09

Monografia opracowana została na podstawie mojej pracy doktorskiej, napisanej pod kierunkiem prof. dra hab. inż. Wojciecha Cholewy, którą obroniłem przed Radą Wydziału Mechanicznego Technologicznego we wrześniu 1999 roku. W opracowaniu zostały uwzględnione uwagi recenzentów pracy doktorskiej: prof. dra hab. inż. Stanisława Drobnika i dra hab. Wojciecha Moczulskiego.

Składam serdeczne podziękowania prof. dr hab. inż. Janowi Kicińskiemu z Instytutu Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku za udostępnienie zbioru programów wchodzących w skład systemu MESWIR oraz możliwość przeprowadzania czasochłonnych obliczeń na komputerach IMP PAN w Gdańsku, bez czego nie byłoby możliwe przeprowadzenie opisanych w pracy badań.

Dziękuję również Koleżankom i Kolegom z Katedry Podstaw Konstrukcji Maszyn za okazaną mi pomoc i życzliwość podczas wykonywania pracy.

Szczególne podziękowania kieruję do żony Renaty oraz syna Dominika, których wyrozumiałość i cierpliwość odegrały nie mniejszą rolę niż uwagi i wskazówki merytoryczne. Im autor dedykuje niniejszą pracę.

Adam Klimek

Spis treści

Wykaz ważniejszych oznaczeń	9
1. Wstęp	10
1.1. Identyfikacja relacji diagnostycznych	11
1.2. Odwrotne modele diagnostyczne	14
1.3. Kierunki doskonalenia odwrotnych modeli diagnostycznych	17
1.4. Zakres badań	19
2. Metody identyfikacji modeli relacji	22
2.1. Ogólny opis zadania poszukiwania modelu danych	22
2.1.1. Formalny opis zadania	22
2.1.2. Zadanie wyznaczania modelu odwrotnego	24
2.1.3. Postać modelu	25
2.1.4. Rodzaje danych	26
2.1.5. Przybliżone modele odwzorowań	28
2.2. Interpolacyjne modele odwzorowań	34
2.2.1. Algorytm W11	37
2.2.2. Algorytm W12	38
2.2.3. Algorytm W13	41
2.2.4. Interpolacja za pomocą kombinacji funkcji wykładniczych	42
3. Wybór liczby i rodzaju wejściowych cech modelu	45
3.1. Pojęcie cechy	45
3.2. Ogólny opis zagadnienia wyboru cech	46
3.3. Przegląd metod wyboru cech	48
3.3.1. Metody uwzględniające wartości cech sygnałów diagnostycznych	49
3.3.2. Metody uwzględniające klasy wartości cech stanów	51
3.3.3. Metody uwzględniające wartości cech stanów	53
4. Planowanie badań symulacyjnych	58
4.1. Planowanie podstawowych badań symulacyjnych	60
4.2. Planowanie uzupełniających badań symulacyjnych	61
4.3. Adaptacyjne sterowanie procesem badań symulacyjnych	62
4.3.1. Miara jakości wyznaczanego modelu	64
4.3.2. Metody badania rozmieszczenia danych w przestrzeniach wielowymiarowych	67
4.3.3. Globalna optymalizacja jakości modelu odwrotnego	77
4.3.4. Lokalna optymalizacja jakości modelu odwrotnego	79
4.3.5. Podsumowanie	82

5. Weryfikacja metody adaptacyjnego sterowania badaniami symulacyjnymi	84
5.1. Opis stanowiska	85
5.1.1. Układ pomiarowy	86
5.1.2. Podstawowe dane techniczne stanowiska	88
5.2. Model układu	89
5.2.1. Model numeryczny	89
5.2.2. Dyskretyzacja wirnika układu	90
5.2.3. Zakres weryfikacji doświadczalnej przyjętego modelu	92
5.2.4. Wyniki badań i wnioski	94
5.3. Generowanie i doskonalenie odwrotnych modeli diagnostycznych	96
5.3.1. Uwagi ogólne	96
5.3.2. Charakterystyka zadania diagnostycznego	100
5.3.3. Podstawowy zbiór przykładów	101
5.3.4. Dane testowe	103
5.3.5. Uzupełniające badania symulacyjne	104
5.3.6. Wyniki otrzymane dla danych pochodzących z symulacji	106
5.3.7. Wyniki otrzymane dla danych pochodzących z pomiarów	114
5.3.8. Wyniki otrzymane dla danych pochodzących z symulacji z szumem	119
5.3.9. Podsumowanie	123
6. Podsumowanie	125
Dodatki	128
Dodatek A. Oceny jednoznaczności odwzorowania	128
A.1. Kryteria ogólne	128
A.2. Badanie histogramów łącznego rozkładu	131
A.3. Badanie lokalnych odchyłeń	133
A.4. Badanie liczby najbliższych sąsiadów	134
Dodatek B. Badanie skuteczności algorytmów interpolacji dla potrzeb adaptacyjnego sterowania badaniami symulacyjnymi	136
B.1. Zakres badań	136
B.2. Rozpatrywane przypadki	137
B.3. Otrzymane wyniki	139
B.4. Wnioski	144
Literatura	145
Streszczenie	153

Contents

Table of important symbols	9
1. Introduction	10
1.1. Identification of diagnostic relations	11
1.2. Inverse diagnostic models	14
1.3. Directions of improvement of inverse diagnostic models	17
1.4. The scope of investigations	19
2. Methods of identification of relation models	22
2.1. General description of task of search for a model	22
2.1.1. Formal description of task	22
2.1.1.2. Task of determining inverse model	24
2.1.1.3. Form of a model	25
2.1.1.4. Types of data	26
2.1.1.5. Approximated mapping models	28
2.2. Interpolation mapping model	34
2.2.1. W11 algorithm	37
2.2.2. W12 algorithm	38
2.2.3. W13 algorithm	41
2.2.4. Interpolation using combination of exponential function	42
3. Selection of number and type of model input features	45
3.1. Concept of feature	45
3.2. General description of problem of feature selection	46
3.3. Review of methods of feature selection	48
3.3.1. Methods based on values of diagnostic signal features	49
3.3.2. Methods based on classes of state features	51
3.3.3. Methods based on values of state features	53
4. Planning simulation investigations	58
4.1. Planning primary simulation investigations	60
4.2. Planning complementary simulation investigations	61
4.3. Adaptation control of simulation investigations	62
4.3.1. Quality measure of determined model	64
4.3.2. Methods of inspection of data arrangement in multidimensional spaces	67
4.3.3. Global optimisation of inverse model quality	77
4.3.4. Local optimisation of inverse model quality	79
4.3.5. Recapitulation	82
5. Verification of method of adaptation control of simulation investigations	84
5.1. Description of a stand	85

5.1.1. Meter circuit	86
5.1.2. Elementary technical data of a stand	88
5.2. Model of a stand	89
5.2.1. Numerical model	89
5.2.2. Discretisation of rotor of stand	90
5.2.3. Scope of experimental verification of considered stand	92
5.2.4. Results of investigations and conclusions	94
5.3. Generation and improvement of inverse diagnostic model	96
5.3.1. General remarks	96
5.3.2. Description of diagnostic task	100
5.3.3. Primary set of examples	101
5.3.4. Test data	103
5.3.5. Complementary simulation investigations	104
5.3.6. Obtained results for data coming from simulation investigations	106
5.3.7. Obtained results for data coming from measurement	114
5.3.8. Obtained results for data coming from simulation investigations with noise	119
5.3.9. Recapitulation	123
6. Sum up	125
Appendices	128
Appendix A. Estimations of uniqueness of mapping	128
A.1. General criteria	128
A.2. Investigations of histograms of joint distribution	131
A.3. Investigations of local deviations	133
A.4. Investigations of number of nearest neighbours	134
Appendix B. Investigation of effectiveness of interpolation algorithms for adaptation control of simulation investigations	136
B.1. Scope of investigations	136
B.2. Considered cases	137
B.3. Obtained results	139
B.4. Conclusions	144
Literature	145
Summaries	153

Wykaz ważniejszych oznaczeń

S	zbiór stanów diagnozowanego obiektu; przestrzeń stanów
U	obserwowany układ
V	zbiór symptomów diagnozowanego obiektu określonych w wyniku pomiaru lub odpowiedniej symulacji; przestrzeń symptomów
X	zbiór wejść obiektu
Y	zbiór wyjść obiektu
\mathfrak{R}^M	przestrzeń metryczna M – wymiarowa
$dist(x, y)$	miara odległości między x i y
$simi(x, y)$	miara podobieństwa między x i y
$dim(x)$	wymiarowość (liczba wymiarów) x
$\varepsilon(x)$	otoczenie x
$J(x)$	miara jakości lokalnego modelu odwrotnego wyznaczana w otoczeniu x
\wedge	symbol oznaczający, że wielkość, nad którą występuje, jest wielkością szacowaną
\underline{a}	macierz jednowymiarowa (wierszowa lub kolumnowa)
\underline{A}	macierz wielowymiarowa
<i>druk pochyły</i>	oznaczenie zmiennej lub stałej
<i>druk prosty</i>	oznaczenie funkcji specjalnej lub operatora

1. Wstęp

Diagnostyka [7], [8] jako uznana dziedzina wiedzy zajmuje się rozpoznawaniem badanego stanu rzeczy przez zaliczenie go do znanego typu lub gatunku, przez przyczynowe i celowościowe wyjaśnienie tego stanu rzeczy, określenie jego fazy obecnej oraz przewidywanej. Termin *diagnostyka* [98] pochodzi z języka greckiego (*diagnosis*) i oznacza rozpoznanie, określenie. Diagnostyka odnosić się może do wszelkich obiektów naturalnych - w tej liczbie człowieka, świata zwierzęcego i roślinnego - oraz obiektów sztucznych, powstałych w wyniku działań człowieka, przede wszystkim maszyn i urządzeń technicznych.

Wobec diagnostyki wysuwa się postulat, by była prawdziwa i adekwatna, tzn. by uwzględniała cechy specyficzne danego stanu rzeczy albo zmiany, a także podawała możliwie pełne rozpoznanie typu, uwarunkowań i rozwoju badanego zdarzenia.

Ostatnie dziesięciolecia w technice cechuje wzrost złożoności środków technicznych z jednej strony, zaś z drugiej wzrost odpowiedzialności zadań, jakie te środki techniczne realizują. Stąd też powstała i ciągle rozkwita nowa dziedzina wiedzy - *diagnostyka techniczna*. Zajmuje się ona oceną stanu obiektów (środków technicznych) przez bezpośrednie badanie ich własności i pośrednie badanie procesów towarzyszących działaniu tych obiektów, tzw. procesów resztkowych [3], [7], [8], [40], [87], [115], [116]. Głównymi zadaniami diagnostyki technicznej maszyn są [3], [7], [8], [40], [87], [115], [116]:

- *diagnoza* – określenie bieżącego stanu technicznego;
- *geneza* – określenie przyczyn zaistnienia obecnego stanu;
- *prognoza* – określenie horyzontu czasowego przyszłej zmiany stanu.

Obiektywnej oceny stanu obiektu można dokonać na podstawie przesłanek opartych na:

- informacjach o konstrukcji obiektu;
- danych określających warunki działania obiektu;
- wynikach pomiarów dostępnych do obserwacji symptomów stanu technicznego;
- historii dotychczasowej eksploatacji obiektu.

Diagnostyka techniczna maszyn jest jedną z tych dziedzin, które w ostatnim czasie burzliwie się rozwijają. Pojawiają się nowe problemy badawcze oraz powstają metody, umożliwiające wspomaganie wnioskowania diagnostycznego (np. [4], [9], [27], [43], [44], [51], [54], [70], [72], [73], [84], [85], [86], [110]). Szczególną rolę odgrywają systemy doradcze (np. [10], [12], [17], [18], [19], [24], [30]), wspomagające diagnostów w rozwiązywaniu wielu zadań diagnostycznych. Obecny stopień rozwoju komputerowych systemów, wspomagających diagnostykę maszyn i procesów, wymaga pilnego opracowania skutecznych algorytmów, pozwalających na identyfikację relacji diagnostycznych, będących podstawą określania reguł,

tworzących bazy wiedzy diagnostycznych systemów doradczych [27] [41]. Reguły takie wskazują możliwe przyczyny (np. uszkodzona panewka łożyska) obserwowanych skutków (np. wysoka amplituda drgań korpusu łożyska). Niestety, brak jest dokładnej wiedzy diagnostycznej oraz niezawodnych źródeł. Aktualnie proces pozyskiwania reguł często opiera się wyłącznie na opiniach specjalistów. Droga ta jest skuteczna podczas definiowania reguł ogólnych dotyczących klas maszyn. Posiada jednak znaczące ograniczenia, związane z trudnościami uwzględniania specyficznych cech rozpatrywanego egzemplarza obiektu (np. sztywność fundamentu) oraz z trudnościami wywołanymi potrzebą rozpatrywania pełnego pola możliwych wariantów [27] [41].

1.1. Identyfikacja relacji diagnostycznych

W diagnostyce technicznej maszyn podstawowe znaczenie ma *relacja stan-sygnal* [7]. Jest to relacja przyczynowo-skutkowa. Może być wyrażona następującym równaniem (na podstawie [33]):

$$(\underline{v}, \underline{v}1) = \Phi(\underline{s}, \underline{s}1, \underline{s}2, \underline{s}3); \quad (1)$$

gdzie:

$\underline{v} = [v_1, v_2, \dots, v_f]^T$ - macierz wartości uwzględnianych cech wyznaczonych na podstawie rejestrowanych sygnałów diagnostycznych;

$\underline{v}1 = [v1_1, v1_2, \dots, v1_j]^T$ - macierz wartości nieznanych lub pomijanych cech wyznaczonych na podstawie rejestrowanych sygnałów diagnostycznych, będących skutkiem działania obiektu;

$\underline{s} = [s_1, s_2, \dots, s_k]^T$ - macierz wartości cech stanu diagnozowanego obiektu, poszukiwanych jako wynik procesu diagnozowania (np. rozkład niewyrównoważenia elementów wirujących);

$\underline{s}1 = [s1_1, s1_2, \dots, s1_l]^T$ - macierz wartości znanych cech, określających warunki działania diagnozowanego obiektu (np. wartość prędkości obrotowej, wartość obciążenia);

$\underline{s}2 = [s2_1, s2_2, \dots, s2_m]^T$ - macierz wartości znanych cech, które dla rozpatrywanego obiektu nie ulegają zmianom (np. wartości cech konstrukcji obiektu);

$\underline{s}3 = [s3_1, s3_2, \dots, s3_n]^T$ - macierz wartości cech trudnych do oszacowania i pomiaru, które należy przyjmować jako wartości losowe (np. wartość tłumienia drgań przez posadowienie rozpatrywanego obiektu);

Φ - operator przyporządkowania.

Pozyskiwanie relacji stan-sygnal odbywa się najczęściej eksperymentalnie. Można wyróżnić dwie podstawowe formy eksperymentów diagnostycznych, zmierzających do identyfikacji tych relacji [7]:

- *eksperyment czynny*;
- *eksperyment bierny*.

Eksperyment czynny jest stosowany szczególnie wtedy, gdy poszukiwane są relacje stan-sygnal w warunkach laboratoryjnych z kontrolowaną zmianą cech stanu $\{s, s_1, s_2\}$ [115], [116]. Występują tu zarówno znane cechy stanu obiektu, jak i odpowiadające im symptomy $\{y\}$. Eksperyment czynny jest szczególnie przydatny wtedy, gdy czas przeznaczony na badania jest krótki, a liczba danych pomiarowych jest niewielka. Stosowany jest najczęściej dla potrzeb identyfikacji i optymalizacji modelu matematycznego nowego lub modernizowanego obiektu. W zastosowaniach diagnostycznych kontrolowana zmiana stanu oznacza demontaż zespołów, co, oprócz kłopotów organizacyjnych, jest równoważne, po ponownym montażu, innemu („nowemu”) egzemplarzowi maszyny [115], [116]. Praktyczne stosowanie tej formy badań w diagnostyce jest stosunkowo częste, chociaż wymaga doboru odpowiedniej organizacji eksperymentu czynnego i jest możliwe w zasadzie tylko w warunkach laboratoryjnych.

Eksperyment bierny polega na obserwacji sygnałów diagnostycznych z równoczesnym pomiarem cech stanu $\{s\}$ dla jednej lub dwu wartości czasu eksploatacji, jednak bez możliwości ingerencji w wartości cech stanu badanego obiektu. Typowym przykładem pomiaru dla jednej wartości czasu eksploatacji jest pomiar cech stanu tuż przed planowaną naprawą maszyny lub tuż przed wyłączeniem maszyny z ruchu w obawie przed awarią (na wniosek zespołu diagnostycznego). W takich przypadkach po demontażu można dokonać pomiarów wszystkich interesujących nas cech stanu. Lepszym wariantem jest wykonywanie pomiarów dla dwu wartości czasu eksploatacji, gdzie badań cech stanu dokonuje się pierwszy raz z chwilą uruchomienia maszyny, zaś drugi raz, podobnie jak poprzednio, przy planowanej naprawie lub po zaistniałej awarii. Zaletą tej formy eksperymentu jest niezakłócanie normalnej pracy obiektu, co w warunkach przemysłowych jest sprawą ogromnej wagi.

Do ograniczeń tej formy badań należy zaliczyć między innymi [7], [115]:

- długi czas zbierania koniecznej informacji;
- fragmentaryczność zebranych informacji ze względu na niewielki zazwyczaj zakres zmian wartości cech stanów w czasie normalnej pracy.

Przedstawione własności powodują, że metody budowania modeli oparte na wynikach biernego eksperymentu diagnostycznego stosuje się tam, gdzie [115]:

- wyniki pomiarów mogą mieć przybliżony charakter jakościowy, np. w badaniach rozpoznawczych;
- nie ma możliwości przeprowadzania eksperymentu czynnego, np. urządzenia bez regulacji, jednostkowe, maszyny krytyczne, itp.;

- istnieją warunki do prowadzenia długotrwałych obserwacji obiektu lub grupy obiektów.

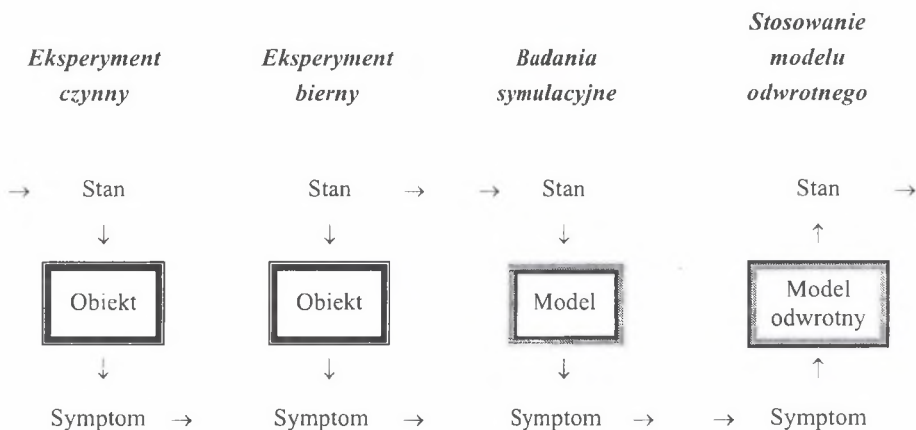
Przyjęcie w badaniu diagnostycznym jednej z przedstawionych form eksperymentu jest warunkowane wieloma czynnikami, między innymi [115]:

- możliwością realizacji danej formy eksperymentu i zmiennymi warunkami pracy obiektu;
- trudnościami wprowadzania określonych stanów zużycia lub stopnia uszkodzenia elementów.

Sam przebieg (pomiar i wnioskowanie) realizowanej formy eksperymentu jest zależny od wielu czynników, wśród których do najważniejszych należą [115]:

- klasa badanych obiektów (proste, złożone);
- charakter sygnału diagnostycznego (zakres zmienności, wartości graniczne);
- wartości i charakter oddziałujących zakłóceń;
- przyjęta metodyka analizy wyników pomiarów.

Przedstawione formy eksperymentów diagnostycznych pozwalają na identyfikację relacji występujących pomiędzy stanem technicznym i jego symptomami. Konieczność przeprowadzania tych eksperymentów na rzeczywistych obiektach wprowadza istotne ograniczenia stosowania tych eksperymentów. Na przykład, eksperymentów czynnych [27] [41] nie można przeprowadzać na rzeczywistych dużych obiektach technicznych (np. turbospoły) ze względu na wysoki koszt i stopień ryzyka.



Rys. 1. Metody identyfikacji relacji diagnostycznych [41]

Fig. 1. Methods of identification of diagnostic relations [41]

Z tego względu eksperymenty czynne zastępowane są ostatnio badaniami symulacyjnymi, w których stosowane są modele przekształcające zadane przyczyny (stany) w odpowiednie ich skutki (symptomy) (np. [20], [53], [54], [58]). Istotną zaletą badań symulacyjnych jest to, że

możliwe jest badanie nawet ekstremalnych warunków działania obiektu, niedopuszczalnych w trakcie normalnej eksploatacji.

Prowadzenie badań symulacyjnych wymaga jednak [41]:

- dużej wiedzy, dotyczącej parametrycznego doboru potencjalnych defektów w sposób umożliwiający otrzymanie określonego symptomu;
- opisu i odpowiedniej analizy prowadzonej przez osobę interpretującą wyniki badań symulacyjnych w celu przekształcenia tych wyników w reguły diagnostyczne.

W celu identyfikacji relacji diagnostycznych dużo większe znaczenie praktyczne [41] miałyby zastosowanie modeli odwrotnych (rys. 1), charakteryzujących się eliminacją potrzeby jawnego sterowania badaniami symulacyjnymi i umożliwiającymi identyfikowanie reguł diagnostycznych, w których przesłanką jest symptom, a konkluzją - stan techniczny.

1.2. Odwrotne modele diagnostyczne

Model diagnostyczny [25], [26] to relacja pomiędzy cechami stanu obiektu a cechami sygnałów diagnostycznych, wyznaczana (identyfikowana) na podstawie wyników eksperymentów. Podczas definiowania takich modeli stosuje się między innymi [25], [26]:


- statystykę matematyczną i analizę regresji;
- teorię układów uczących się i teorię aproksymacji;
- teorię optymalnych decyzji i teorię informacji;
- metody automatycznego wnioskowania oraz teorie sieci neuronalnych;
- metody funkcji potencjalnych;
- lingwistykę teoretyczną;
- teorię rozpoznawania obrazów (wzorców);
- teorię grafów;
- metody wnioskowania przyczynowego;
- metody analizy czynnikowej i kanonicznej;
- teorię zbiorów i relacji rozmytych;
- metody pozyskiwania wiedzy reprezentowanej w postaci deklaratywnej;
- odkrycia w bazach danych.

Ze względu na różne potrzeby diagnostyczne mogą być tworzone następujące rodzaje modeli [25], [26]:

- *modele indywidualne*, opisujące właściwości pojedynczego obiektu;
- *modele grupowe*, opisujące wspólne właściwości pewnej klasy obiektów.

W dalszej części pracy rozważane będą modele indywidualne. Nowym sposobem uzyskania modelu diagnostycznego, zaproponowanym w [32], [33], [34], [41], jest otrzymanie go w wyniku odwracania znanego modelu matematycznego rozpatrywanego obiektu. Taki model nosi nazwę odwrotnego modelu diagnostycznego. Modelowanie rzeczywistych obiektów jest zagadnieniem bardzo złożonym. Poszczególne układy obiektów badań posiadają nieliniowe charakterystyki, opisywane za pomocą równań różniczkowych nieliniowych, co eliminuje możliwość bezpośredniego stosowania modeli analitycznych. Dlatego zazwyczaj stosowane są modele numeryczne reprezentowane proceduralnie w postaci odpowiednich programów komputerowych. Dla modeli numerycznych nie istnieją analityczne odwzorowania odwrotne, co stanowi podstawową trudność w stosowaniu modeli odwrotnych.

W [32], [33], [34], [41] zaproponowano interesującą koncepcję wyznaczania modelu odwrotnego. W koncepcji tej zakłada się, że znany jest model M (rys. 2), który pozwala na wyznaczenie wartości wyjść $\{v, v1\}$ dla zadanego zbioru wartości wejść $\{s, s1, s2, s3\}$.



Rys. 2. Wyznaczanie modelu odwrotnego N dla danego modelu M obiektu O z zastosowaniem klasyfikatora C [32]


Fig. 2. Determination of N inverse model for given M model of O object with application of C classifier [32]

Model ten może być zapisany (na przykład) w postaci programu komputerowego. Z punktu widzenia zastosowań diagnostycznych wymienione wartości wejść i wyjść mogą mieć następujące znaczenie [21], [32], [33], [34]:

- s - wartości cech poszukiwanych jako wynik procesu diagnozowania (np. rozkład niewyrównoważenia elementów wirujących);
- $s1$ - wartości znanych cech, określających warunki działania obiektu (np. wartość prędkości obrotowej, wartość obciążenia);

- s_2 - wartości znanych cech, które dla rozpatrywanego obiektu nie ulegają zmianom (np. wartość cech konstrukcyjnych obiektu);
- s_3 - wartości cech trudnych do oszacowania i pomiaru, które należy przyjmować jako wartości losowe, wpływające na ograniczenie dokładności modelu (np. wartość tłumienia drgań przez posadowienie rozpatrywanego obiektu);
- v - wartości cech znanych, będących skutkiem działania obiektu i określane w wyniku pomiaru lub odpowiedniej symulacji (np. wartość cech drgań);
- v_1 - wartości cech nieznanych lub pomijanych, będących skutkiem działania obiektu.

Model M opisuje relacje przyczynowo-skutkowe występujące pomiędzy wartościami wejściowymi - przyczynami $\{s, s_1, s_2, s_3\}$ oraz wartościami wyjściowymi - skutkami $\{v, v_1\}$. W wyniku odwracania modelu M zakłada się, że (rys. 2) uzyskany będzie model N , przekształcający znane, określane w wyniku pomiaru lub symulacji wartości $\{v, v_1\}$ w poszukiwane wartości $\{s\}$. Należy podkreślić, że z punktu widzenia relacji przyczynowo-skutkowych wartości $\{s, s_1, s_2, *\}$ opisują wyłącznie wybrane przyczyny, a wartości $\{v, v_1\}$ wybrane ich skutki. Oznacza to, że można przypuszczać, iż dokładny model odwrotny N nie istnieje, ponieważ brak jest podstaw do zakładania, że model M jest odwzorowaniem jednoznacznym [21], [32], [33], [34]. W celu uniknięcia wynikających stąd trudności (powodujących, że zadanie może nie posiadać rozwiązania – rys. 3) w [32], [33], [41] ograniczono dokładność poszukiwanego modelu odwrotnego zakładając, iż będzie on wyznaczał klasy wartości cech $\{s\}$, a nie dokładne wartości tych cech.



Rys. 3. Zadanie odwracania modelu M może nie posiadać rozwiązania [32]

Fig. 3. Inverse task of M model could have no solution [32]

Klasyfikator definiujący wyznaczone klasy oznaczono literą C (rys. 2). Model N rozpatrywany może być jako *czarna skrzynka*, której parametry mogą być identyfikowane w wyniku procesu trenowania [21], [32], [33], [34].

Zaletą proponowanego postępowania jest to, że stosowanie modelu M i wyznaczanie modelu odwrotnego N mogą być traktowane jako procesy rozłączne - realizowane w różnym czasie i na różnych komputerach (co pokazano w [32]).

Podejmowane były próby [32], [33], [34] odwracania modelu numerycznego za pomocą sieci neuronalnych. Badania te potwierdziły możliwość odwracania modeli numerycznych. Z kolei w [21], [41] zwrócono uwagę na zasadnicze różnice występujące pomiędzy algorytmami przeznaczonymi do identyfikacji globalnych modeli odwrotnych (których przykładem są modele wyznaczone za pomocą sieci neuronalnych) oraz lokalnych modeli odwrotnych. Omawiając zagadnienia związane z wyznaczaniem modeli relacji pokazano [21], [41], że w rozpatrywanej klasie zadań mogą występować zarówno rozwiązania wieloznaczne, jak i poszukiwane rozwiązanie może nie istnieć (rys. 3), co uzasadnia potrzebę odpowiedniego badania jakości wyznaczonego modelu i potrzebę prób doskonalenia tego modelu.


1.3. Kierunki doskonalenia odwrotnych modeli diagnostycznych

Podczas formułowania reguł dla diagnostycznych systemów doradczych pomocne są modele diagnostyczne uzyskane w wyniku odwracania znanych modeli rozpatrywanych obiektów (rys. 1). Określanie modelu rozpatrywanego obiektu w postaci modelu numerycznego poważnie utrudnia lub eliminuje możliwość odwracania takiego modelu w sposób analityczny. Zakładając, że diagnostyczny model odwrotny będzie wyznaczany zgodnie z koncepcją pokazaną na rys. 2, operację odwracania modelu numerycznego można przeprowadzić na podstawie przykładów danych, opisujących zadane stany rozpatrywanego obiektu oraz odpowiadające tym stanom symptomy ($\{s, \underline{x}_1, \underline{x}_2, \underline{y}\}$), które można uzyskać przez zastosowanie modelu obiektu dla wybranych stanów maszyny. Uwzględniane zbiory przykładów nie są najczęściej zbiorami licznymi. Odwzorowanie przestrzeni stanów maszyny w przestrzeń symptomów, reprezentowane ograniczonym zbiorem przykładów, nie musi być jednak odwzorowaniem jednoznacznym, tzn. można otrzymać identyczne symptomy dla różnych stanów maszyny (rys. 3). Prowadzić to może do lokalnej niejednoznaczności wyznaczonego modelu odwrotnego. Jakość modelu odwrotnego wyznaczonego na podstawie przykładów zależna jest między innymi od:

- *postaci modelu;*
- *liczby i rodzaju wejściowych cech modelu;*
- *odpowiedniego wypełnienia przykładami rozpatrywanych wielowymiarowych przestrzeni symptomów i stanów.*

Podejmowano próby definiowania zaleceń pozwalających na wybór optymalnej liczby i rodzaju wejściowych cech modelu (np. [31], [60], [71], [101]), jak również zaleceń dotyczących wyboru postaci modelu w zależności od rodzaju danych. W [21], [41] wyjaśniono, że próby poszukiwania globalnych modeli odwrotnych w postaci odpowiednio trenowanej sieci neuronalnej są próbami nieracjonalnymi i zwrócono uwagę na szczególną przydatność wybranej klasy algorytmów interpolacji wielowymiarowej, umożliwiających wyznaczanie modeli lokalnych. Algorytmy te są skuteczne wtedy, gdy dostępny zbiór przykładów odpowiednio wypełnia rozpatrywany obszar przestrzeni stanów i symptomów.

Brak jest w literaturze opisu metod określających działania, które zapewniałyby odpowiednie wypełnienie przykładami wielowymiarowej przestrzeni symptomów. Duża liczba wymiarów rozpatrywanych przestrzeni nie pozwala na stosowanie klasycznych metod planowania eksperymentów opisanych np. w [76]. W ramach prac wykonywanych w Katedrze Podstaw Konstrukcji Maszyn oraz w Instytucie Maszyn Przepływowych PAN w Gdańsku podjęte zostały próby odwracania numerycznego modelu rzeczywistego obiektu (wornika dwupodporowego). Wyniki tych badań pokazano w monografii [41]. Przedmiotem symulacji były drgania wymuszone, spowodowane niewyrównoważeniem przykładanym w różnych płaszczyznach wornika pod różnymi kątami fazowymi. Podjęta próba identyfikacji modelu odwrotnego dotyczyła określenia płaszczyzny, wartości oraz kątów fazowych przyłożonych niewyważ na podstawie wybranych wartości cech drgań mierzonych w odpowiednich punktach. Model odwrotny wyznaczany był według algorytmów [41] przeznaczonych do poszukiwania lokalnych modeli odwrotnych (wyznaczano modele interpolacyjne). Otrzymane wyniki wskazały potrzebę opracowania metod doskonalenia wyznaczanych modeli odwrotnych (poprawy jakości wyznaczanych modeli odwrotnych) przez odpowiednią aktualizację zbioru przykładów.



Rys. 4. Iteracyjne doskonalenie modelu odwrotnego (na podstawie [41])

Fig. 4. Iterative improvement of inverse model (on the basis of [41])

Aktualizacja ta ma prowadzić do właściwego wypełnienia przykładami przestrzeni stanów i symptomów, przy czym zakłada się, że:

- Modele lokalne są korzystniejsze od modeli globalnych, wyznaczanych jako modele odwrotne (słuszność tego założenia wykazano w [21], [41]).
- Możliwe jest doskonalenie diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów.

Rysunek 4. pokazuje ogólną koncepcję iteracyjnego doskonalenia modelu odwrotnego przez optymalizację zbioru przykładów.

1.4. Zakres badań

Celem przeprowadzonych badań było opracowanie podstaw teoretycznych, realizacja odpowiedniego oprogramowania oraz weryfikacja własnych metod doskonalenia diagnostycznych modeli odwrotnych, wyznaczanych na podstawie przykładów opisujących stany rozpatrywanego obiektu oraz odpowiadające tym stanom symptomy. Szczególną uwagę poświęcono metodom pozwalającym na optymalizację zbioru przykładów, pociągającą za sobą optymalizację jakości wyznaczanego modelu odwrotnego.

Podstawowa treść monografii jest zawarta w trzech głównych rozdziałach (rozdziały 2., 3., 4.). W rozdziale 5. opisano badania weryfikujące, proponowaną przez autora metodę adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającą do optymalizacji jakości wyznaczanych modeli odwrotnych.

W rozdziale 2. na podstawie przeprowadzonych badań literaturowych opisano zagadnienia dotyczące metod identyfikacji modeli relacji. W szczególności przedstawiono formalny opis zadania związanego z identyfikacją modeli relacji, w którym pokazano, że można rozpatrywać różne klasy modeli (modele ilościowe, modele jakościowe oraz modele mieszane). Ze względu na zamienne stosowanie w literaturze terminów: dane uczące, dane trenujące, dane wzorcowe pokazano występujące pomiędzy tymi terminami różnice. W dalszej części rozdziału rozpatrywano wybrane klasy modeli relacji, mianowicie – globalne oraz lokalne modele ilościowe. Pokazano interesujący algorytm wyznaczania modeli częściowo jednostronnych, będących przykładem przybliżonych modeli odwzorowań, przez wielokrotne trenowanie sieci neuronalnych. Główną uwagę poświęcono algorytmom zmierzającym do wyznaczania lokalnych modeli – interpolacyjnych modeli odwzorowań. Rozpatrywane w diagnostyce technicznej maszyn przestrzenie cech są najczęściej przestrzeniami wielowymiarowymi. Ze względu na potrzeby rozpatrywanych zadań identyfikacji modeli opisano wybrane algorytmy interpolacji w przestrzeniach wielowymiarowych. Pominięto klasyczne algorytmy interpolacji, przeznaczone głównie do stosowania w przestrzeniach o małej liczbie wymiarów (najczęściej o dwóch lub trzech wymiarach), które można znaleźć w ogólnodostępnej literaturze.

W rozdziale 3. omówiono zagadnienia związane z wyborem liczby i rodzaju wejściowych cech modelu. Jest to zagadnienie niezmiernie istotne, ponieważ jakość wyznaczanego modelu odwrotnego nie może być lepsza od jakości danych uczących, na podstawie których model został wyznaczony. Podobnie jak w zadaniach klasyfikacji uwzględnianie nadmiernej liczby cech może prowadzić do pogorszenia jakości wyznaczanego modelu odwrotnego. Omówiono pojęcie cechy oraz ogólnie sformułowano zagadnienie wyboru cech. Na podstawie badań literaturowych opisano wybrane metody wyboru cech pod kątem zastosowania ich do zadań wyznaczania modeli odwrotnych. Metody wyboru cech podzielono na trzy grupy (metody uwzględniające wartości cech sygnałów diagnostycznych, metody uwzględniające klasy wartości cech stanów i metody uwzględniające wartości cech stanów). W trzeciej grupie metod zostały zaproponowane przez autora dwie metody wyboru cech sygnałów diagnostycznych, bazujące bezpośrednio na zadaniu odwracania (jedna z metod polega na badaniu jakości wyznaczanych modeli odwrotnych, druga na – badaniu jednoznaczności odwzorowania rozpatrywanej przestrzeni symptomów w przestrzeni stanów).

W rozdziale 4. skupiono się na zagadnieniach związanych z planowaniem badań symulacyjnych. Zakładając, że diagnostyczny model odwrotny wyznaczany jest na podstawie danych (wyznaczonych przez model obiektu) opisujących zadane stany rozpatrywanego obiektu oraz odpowiadające tym stanom symptomy, istotna jest „jakość” tych przykładów. Od przykładów zależy powodzenie operacji odwracania modelu oraz jakość wyznaczonego modelu odwrotnego. Zaproponowano dwuetapowe planowanie badań symulacyjnych (podstawowe i uzupełniające). Następnie pokazano istotę, proponowanego przez autora, adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającymi do poprawy jakości wyznaczanego modelu odwrotnego. W szczególności zwrócono uwagę na to, że globalna optymalizacja jakości modelu odwrotnego jest nieracjonalna. Skoncentrowano się na możliwości sterowania badaniami symulacyjnymi, zmierzającymi do poprawy jakości lokalnego modelu odwrotnego, związanego z wyróżnionym punktem w wielowymiarowej przestrzeni symptomów. Wyróżniony punkt w wielowymiarowej przestrzeni symptomów może być określany w wyniku pomiarów wartości cech sygnałów diagnostycznych na rzeczywistym obiekcie.

W rozdziale 5. opisano badania weryfikujące, proponowaną przez autora metodę adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającą do optymalizacji jakości wyznaczanych modeli odwrotnych. Opisano obiekt, dla którego wyznaczano dane będące podstawą weryfikacji proponowanej metody. Obiektem badań był wirnik dwupodporowy, stanowiący część stanowiska laboratoryjnego, znajdującego się w Katedrze Podstaw Konstrukcji Maszyn. Głównym elementem stanowiska jest zestaw RotorKit firmy Bently Nevada [94], [95]. Przyjęty obiekt rzeczywisty pod względem zachowań dynamicznych odwzorowany został za pomocą liniowego modelu teoretycznego i zespołu programów, wchodzących w skład systemu MESWIR [56], [58], [80], opracowanego w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku. System programów MESWIR służy do analizy dynamiki wielopodporowych wirników łożyskowanych ślizgowo przy zastosowaniu

metody elementów skończonych. Pokazano również wyniki weryfikacji doświadczalnej modelu teoretycznego. Opisano eksperyment, w którym proces generowania modeli odwrotnych przeprowadzono w rozproszonym środowisku obliczeniowym. Model teoretyczny (symulator) znajdował się w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku, natomiast baza danych, zawierająca przykłady danych do operacji odwracania modelu oraz oprogramowanie sterujące uzupełnianymi badaniami symulacyjnymi znajdowały się w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach. Dane przesyłane były pomiędzy oboma ośrodkami za pomocą komputerowej sieci (Internet). Pokazano także wyniki przeprowadzonych eksperymentów zmierzających do weryfikacji zaproponowanej metody doskonalenia diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów. Wyznaczano modele odwrotne, pozwalające na określenie stanu niewyrównoważenia rozpatrywanego obiektu na podstawie ocen drgań mierzonych w pobliżu opraw łożyskowych. Uzyskane wyniki wskazały formalną poprawność przedstawionej w pracy metody doskonalenia diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów oraz potwierdziły przyjęte w pracy tezy.

W rozdziale 6. dokonano podsumowania pracy oraz określono możliwe kierunki dalszych prac badawczych, zmierzające głównie do zastosowania opracowanej metody adaptacyjnego sterowania badaniami symulacyjnymi dla potrzeb optymalizacji jakości wyznaczanych modeli odwrotnych w zagadnieniach nieliniowych. Istotnym zagadnieniem jest również opracowanie algorytmów zmierzających do optymalizacji jakości modelu odwrotnego w przypadku stwierdzenia niejednoznaczności odwzorowania przestrzeni symptomów w przestrzeni stanów.

2. Metody identyfikacji modeli relacji

2.1. Ogólny opis zadania poszukiwania modelu danych


Liczne badania doświadczalne związane są z identyfikacją analitycznych modeli obiektów rzeczywistych. Często ogólna postać modelu jest znana i wynika np. z analizy działania badanego obiektu, a proces *identyfikacji modelu* sprowadza się do wyznaczenia wartości odpowiedniego zbioru parametrów modelu [21]. Odrębną klasę stanowią zadania, w których postać modelu nie jest znana. W celu zaznaczenia, iż postać modelu nie jest znana, zadania te określa się jako *poszukiwanie modelu danych*. Rozwiązywanie takich zadań wymaga wykonania dwóch kroków [21]:

- wyboru postaci modelu;
- identyfikacji modelu (określenia wartości parametrów modelu o wybranej postaci).

Takie zadanie (poszukiwanie modelu danych) rozwiązywane jest w trakcie identyfikacji modeli odwrotnych.

2.1.1. Formalny opis zadania

Podczas realizacji procesu identyfikacji modeli odwrotnych zakłada się, że poszukiwany model N (rys. 2) jest modelem jakiegoś wirtualnego, statycznego (nie zmieniającego się w czasie) układu U , który każdemu zbiorowi wartości wejść x przyporządkowuje odpowiedni zbiór wartości wyjść y .

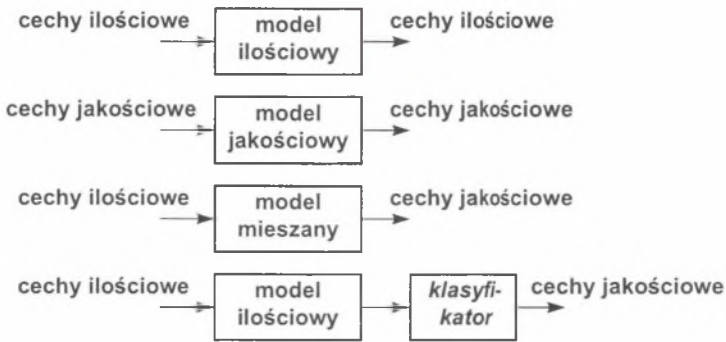


Rys. 5. Obserwowany układ U [21]

Fig. 5. Observed system U [21]

Rozpatrywane mogą być różne klasy modeli układu U . Podejmowane są próby definiowania modeli jakościowych, stosujących między innymi jakościowe równania różniczkowe, bazujące na wielkościach *rośnie*, *maleje*, *maleje szybko*, *maleje bardzo szybko* itp. Teoria takich modeli nie jest jeszcze w pełni opracowana i ich praktyczne stosowanie jest zadaniem bardzo trudnym. Warto jednak zwrócić uwagę na oczekiwane zalety takich modeli, wśród których na pierwszym miejscu wymienia się wysoką stabilność wyznaczonego modelu oraz jego znaczną odporność na zakłócenia. Prowadzi to do sprzecznego z intuicją, ale

prawdziwego wniosku, iż wynik jakościowy [21] może być w wielu sytuacjach wynikiem dokładniejszym niż wynik ilościowy. Biorąc pod uwagę ten wniosek, czasem stosuje się model ilościowy połączony z odpowiednim klasyfikatorem (rys. 6). Model taki widziany jest z zewnątrz jako model mieszany (rys. 6).



Rys. 6. Klasy modeli [21]

Fig. 6. Classes of models [21]

W niniejszej pracy rozpatrywane będą głównie modele ilościowe. Zakłada się, że struktura i działanie układu U (rys. 5) nie są znane. Jego działanie obserwuje zewnętrzny obserwator. Dla obserwatora tego dostępne są, jako wynik obserwacji w chwili t , następujące zbiory liczb [21]:

- zbiór wartości wyjść

$$\{y_1(t), y_2(t), \dots, y_H(t)\} \quad (2)$$

- zbiór wybranych wartości wejść

$$\{x_1(t), x_2(t), \dots, x_M(t)\} \quad (3)$$

takie, że dla każdej chwili czasu t

$$y_h(t) \in Y_h \quad ; \quad h = 1, 2, \dots, H \quad (4)$$

$$x_m(t) \in X_m \quad ; \quad m = 1, 2, \dots, M, \quad (5)$$

gdzie

$$Y_1, Y_2, \dots, Y_H \quad (6)$$

$$X_1, X_2, \dots, X_M \quad (7)$$

są przestrzeniami wartości wyjść i wejść.

Ogólna liczba wejść oraz wartości pozostałych, nie objętych obserwacją, wejść

$$\{x_{M+1}, x_{M+2}, \dots\} \quad (8)$$

nie jest znana. Wartości wejść (8) będą traktowane jako zakłócenia. Wynikiem obserwacji prowadzonych w chwilach

$$t_1, t_2, \dots, t_L \quad (9)$$

są zbiory wartości:

$$\begin{aligned} \underline{w}_1 &= \{x_{1,1}, x_{1,2}, \dots, x_{1,M}, y_{1,1}, y_{1,2}, \dots, y_{1,H}\} \\ \underline{w}_2 &= \{x_{2,1}, x_{2,2}, \dots, x_{2,M}, y_{2,1}, y_{2,2}, \dots, y_{2,H}\} \\ &\dots \\ \underline{w}_L &= \{x_{L,1}, x_{L,2}, \dots, x_{L,M}, y_{L,1}, y_{L,2}, \dots, y_{L,H}\} \end{aligned} \quad (10)$$

Elementy zbiorów wartości wyjść (2) oraz elementy zbiorów wartości wejść (3) mogą być zapisywane w postaci macierzy

$$\underline{y}(t) = [y_1(t), y_2(t), \dots, y_H(t)] \quad (11)$$

$$\underline{x}(t) = [x_1(t), x_2(t), \dots, x_M(t)] \quad (12)$$

Macierze (11), (12) mogą być interpretowane [21] jako współrzędne punktów przestrzeni wielowymiarowych. Kolejne współrzędne (osie) takiej przestrzeni odpowiadają rozpatrywanym wejściom i wyjściom (atrybutom) badanego obiektu. Wartości współrzędnych (liczby) są wartościami wejść i wyjść (wartościami atrybutów).

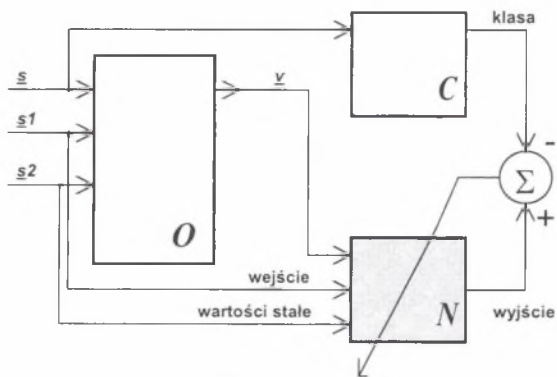
Poszukiwany model ma umożliwiać wyznaczanie zbioru wartości wyjść (2) dla zadanego zbioru wartości wejść (3). Należy podkreślić, że z założenia o braku znajomości struktury i działania układu U wynika brak możliwości uwzględniania informacji o strukturze lub działaniu podczas wyboru postaci modelu opisującego układ U . Postać tego modelu powinna być dobierana odpowiednio do postaci zbioru danych (10). Zbiór danych (10) nazywany jest zbiorem danych uczących.

2.1.2. Zadanie wyznaczania modelu odwrotnego

Opisane zadanie identyfikacji modelu jest zadaniem bardzo ogólnym. Zadanie takie może występować [21] w różnych dziedzinach wiedzy i dotyczyć może różnych zastosowań praktycznych.

W zakresie zadań związanych z odwracaniem modeli układ U (rys. 5) odpowiada modelom odwrotnym N (rys. 2 i rys. 7).

Przyjęty opis zadania umożliwia zastosowanie omawianych dalej algorytmów do wyznaczania modeli odwrotnych (pozwalających na wyznaczanie reguł diagnostycznych) zarówno na podstawie wyników badań symulacyjnych (rys. 2), jak i na podstawie wyników obserwacji obiektu prowadzonych w warunkach biernego eksperymentu diagnostycznego (rys. 7). Możliwość taka wynika z faktu, iż wyniki obu rodzajów badań mogą być zapisywane w postaci zbioru danych uczących (10).



Rys. 7. Wyznaczanie modelu odwrotnego N na podstawie wyników biernego eksperymentu diagnostycznego, prowadzonego dla obiektu O [21]

Fig. 7. Determination of N inverse diagnostic models on the basis of passive approach results for O object [21]

2.1.3. Postać modelu

Literatura dotycząca metod wyznaczania modeli jest bardzo obszerna. Dalsze rozważania zostaną ograniczone do wybranych klas modeli. W [21] zaproponowano przeprowadzenie wyboru klas modelu na podstawie następujących kryteriów:

- rodzaj zależności, stanowiących elementy modelu, które mogą być zidentyfikowane na podstawie zbiorów wartości (10):
 - ⇒ *modele odwzorowań* zawierające funkcje odwzorowujące zbiory wartości wejść (3) w zbiory wartości wyjść (2);
 - ⇒ *modele relacji* zawierające relacje określające podzbiory odpowiadających sobie wartości wejść (3) i wartości wyjść (2), w iloczynie kartezjańskim przestrzeni wartości wejść (7) i wyjść (6);
- istota działania modelu:
 - ⇒ *modele aproksymacyjne*, zastępujące (z zadaną dokładnością) zbiór wartości (10);
 - ⇒ *modele interpolacyjne*, rozpięte na zbiorach przykładów stanowiących odpowiedni podzbiór danych uczących (10) i wymagające umieszczenia tego podzbioru w definicji modelu;
- stopień złożoności modelu:
 - ⇒ *modele uogólniające*, w których liczba parametrów niezbędnych do zapisania modelu jest znacznie mniejsza od ogólnej liczby danych uczących (10), na podstawie których modele te zostały wyznaczone;

⇒ *modele pełne*, w których liczba parametrów niezbędnych do zapisania modelu jest porównywalna z liczbą danych uczących (10), na podstawie których model ten został wyznaczony;

- zakres modelu

⇒ *modele globalne*, opisujące dane uczące (10) w pełnej przestrzeni ich wartości

$$X_1 \times X_2 \times \dots \times X_M \times Y_1 \times Y_2 \times \dots \times Y_H \quad (13)$$

⇒ *modele lokalne*, opisujące dane uczące (10) w wybranym obszarze przestrzeni (13), stanowiącym cylindryczne otoczenie określonego punktu

$$\underline{x}_0 = [x_{0,1}, x_{0,2}, \dots, x_{0,M}] \quad (14)$$

w rzucie

$$X_1 \times X_2 \times \dots \times X_M \quad (15)$$

przestrzeni (13),

- jakość rozwiązania:

⇒ *modele dokładne*, pozwalające na wyznaczanie rozwiązań dokładnych,

⇒ *modele przybliżone*, pozwalające na wyznaczanie wyłącznie rozwiązań przybliżonych lub rozmytych.

W dalszej części pracy rozważane będą wybrane klasy modeli: modele lokalne oraz modele globalne. Przedstawione w [21] wyniki przeprowadzonych badań algorytmów pozwalających na wyznaczanie modeli globalnych i lokalnych wykazują szczególną przydatność tych drugich. Jednocześnie wskazują, że próby poszukiwania globalnego modelu odwrotnego w postaci odpowiednio trenowanej sieci neuronalnej są próbami nieracjonalnymi. Z tego też względu główny nacisk w pracy zostanie położony na algorytmy pozwalające na wyznaczanie modeli lokalnych.

2.1.4. Rodzaje danych

Często w literaturze zamiennie stosuje się terminy: dane uczące, dane trenujące, dane wzorcowe. W celu wyeliminowania mogących wystąpić nieporozumień oraz niejednoznaczności w rozdziale tym zostaną opisane wymienione pojęcia, których definicje zamieszczono w [21].

Poszukiwany model danych wyznaczany będzie na podstawie zbioru danych (10). Dane te nazywane są danymi uczącymi

$$W_L = \{\underline{w}_1, \underline{w}_2, \dots, \underline{w}_L\} \quad (16)$$

Dane uczące są podstawą do określenia parametrów modelu, jak również do jego weryfikacji. Wspólną cechą stosowanych metod weryfikacji jest to, że w zbiorze danych uczących (16) wskazywany jest podzbiór *danych trenujących*

$$W_D = \left\{ \left\{ \underline{x}_1, \underline{y}_1 \right\}, \left\{ \underline{x}_2, \underline{y}_2 \right\}, \dots, \left\{ \underline{x}_D, \underline{y}_D \right\} \right\} \subseteq W_L \quad (17)$$

oraz podzbiór danych testujących

$$W_T = \left\{ \left\{ \underline{x}_1, \underline{y}_1 \right\}, \left\{ \underline{x}_2, \underline{y}_2 \right\}, \dots, \left\{ \underline{x}_T, \underline{y}_T \right\} \right\} \subseteq W_L \quad (18)$$

Dane trenujące (17) stosowane są do wyznaczenia wartości parametrów modelu, a dane testujące (18) do jego weryfikacji. Stosowane są różne strategie wyznaczania zbiorów W_D i W_T [25], na przykład:

- zbiór danych trenujących W_D (17) oraz zbiór danych testujących W_T (18) są równe pełnemu zbiorowi danych uczących W_L (16)

$$W_D = W_T = W_L \quad (19)$$

- zbiór danych trenujących W_D (17) obejmuje połowę elementów zbioru danych uczących W_L (16), a zbiór danych testujących W_T (18) obejmuje pozostałe elementy zbioru W_L

$$W_D \cup W_T = W_L; \quad W_D \cap W_T = \emptyset; \quad |W_D| = |W_T| = \frac{1}{2}|W_L|; \quad (20)$$

- podział (20) wyznaczany jest przemienne w dwóch krokach

$$\begin{aligned} W_{D,1} &= W_D; & W_{T,1} &= W_T; \\ W_{D,2} &= W_T; & W_{T,2} &= W_D \end{aligned} \quad (21)$$

- dla każdego elementu \underline{w}_l ze zbioru uczącego W_L poszukiwany model wyznaczany jest na podstawie pozostałych danych uczących, a uzyskany wynik testowany jest na podstawie danych \underline{w}_l

$$W_{D,l} = W_L \setminus \{\underline{w}_l\}, \quad W_{T,l} = \{\underline{w}_l\}, \quad \forall \underline{w}_l \in W_L, \quad (22)$$

gdzie podział (22) ustalany jest L -krotnie, pociągając za sobą L -krotne wyznaczanie modelu oraz jego testowanie.

Wyznaczanie danych trenujących i testujących zgodnie z (19) prowadzić może do zbyt optymistycznych (zawyżonych) wyników badania jakości poszukiwanego modelu. Stosowanie (19) jest uzasadnione wyłącznie wtedy, gdy dysponuje się licznym zbiorem reprezentatywnych danych uczących. Z kolei wyznaczanie danych trenujących i testujących zgodnie z (22) prowadzić może do zbyt pesymistycznych (zaniżonych) wyników badania jakości poszukiwanego modelu.

Dla potrzeb modeli interpolacyjnych wyróżniany jest dodatkowo, w zbiorze danych uczących (16), podzbiór danych wzorcowych

$$W_P = \left\{ \left\{ \underline{x}_1, \underline{y}_1 \right\}, \left\{ \underline{x}_2, \underline{y}_2 \right\}, \dots, \left\{ \underline{x}_P, \underline{y}_P \right\} \right\} \subseteq W_L, \quad (23)$$

które umieszczane są w definicji modelu.

2.1.5. Przybliżone modele odwzorowań

W podrozdziale tym zostaną opisane przybliżone modele odwzorowań wprowadzone przez prof. dra hab. inż. W. Cholewę w [13], [16] na przykładzie modeli jednostronnych oraz częściowo jednostronnych, które należą do klasy aproksymacyjnych modeli odwzorowań. Algorytmy zmierzające do wyznaczania dokładnych modeli odwzorowań można znaleźć w literaturze, np. [75], [77], [91], [103] wraz z omówieniem ich głównych zalet i wad. Z tego też względu algorytmy te nie będą w pracy szczegółowo omawiane. Jednak w celu wyjaśnienia istoty proponowanych w [13], [16] przybliżonych modeli odwzorowań konieczne jest krótkie omówienie zagadnień związanych z wyznaczaniem dokładnych modeli odwzorowań.

Dokładne modele odwzorowań

Typowym przykładem dokładnych modeli odwzorowań mogą być modele aproksymacyjne, których wyznaczanie polega na identyfikacji, na podstawie zbioru danych (10), funkcji przekształcającej z *odpowiednią dokładnością* wartości wejść $\underline{x}(t)$ (3) w oceny $\hat{y}(t)$ wartości wyjść (2) [21]:

$$\{\hat{y}_1(t), \hat{y}_2(t), \dots, \hat{y}_H(t)\} = \underline{f}(x_1(t), x_2(t), \dots, x_M(t)) \quad (24)$$

Funkcja $\underline{f}(\bullet)$ ma umożliwić wyznaczanie ocen wartości wyjść dla zadanego zbioru wartości wejść. Ze względu na taki cel postępowania zakłada się, że wartości wyjść są skutkiem wartości wejść. Oznacza to, że wartość każdego wyjścia y_h w (2) zależy wyłącznie od zbioru wartości wejść (3) i do jej wyznaczenia nie są potrzebne wartości pozostałych wyjść w (2). Pozwala to na uproszczenie zadania (24) i zastąpienie go zbiorem zadań poprzez przyjęcie, iż poszukiwana jest funkcja odwzorowująca zbioru wartości wejść (3) w *odpowiednio dokładne przybliżenie* wartości wybranego wyjścia

$$\hat{y}_h(t) = f_h(x_1(t), x_2(t), \dots, x_M(t)). \quad (25)$$

Rozwiązaniem zadania (25) jest funkcja przekształcająca przestrzeń \mathfrak{R}^M w \mathfrak{R} . Rozwiązaniem zadania (24) będzie odpowiedni zbiór rozwiązań zadań (25).

$$\underline{f} = \{f_1, f_2, \dots, f_H\} \quad (26)$$

Funkcja (26) jest modelem zbioru $d_{\underline{f}} = \{\hat{f}_1, \hat{f}_2, \dots, \hat{f}_H\} | 10$.

Stosowanie modeli aproksymacyjnych wymaga przyjęcia założenia, że jedną z własności danych jest to, że poszukiwane funkcje (25) istnieją. O tym, czy założenie to jest spełnione czy też nie, decydują dane uczące (10).

W celu wyznaczenia funkcji (25), jako fragmentu modelu danych uczących (10), konieczne jest przyjęcie odpowiedniego kryterium jakości przybliżenia zbioru (10) przez zbiór funkcji (25). Powszechnie stosowane są kryteria minimalnoodległościowe, których podstawowymi przedstawicielami są [13], [16]:

$$\sum_{l=1}^L \left\| y_l - \hat{y}(x_l) \right\| \rightarrow \min \quad (27)$$


oraz:

$$\sum_{l=1}^L \left(\left\| y_l - \hat{y}(x_l) \right\|^2 \right) \rightarrow \min \quad (28)$$

Zastosowanie kryterium minimalnoodległościowego wymaga przyjęcia ogólnej postaci funkcji (25) i prowadzi do modeli aproksymujących (przybliżających) dane. Duże znaczenie praktyczne, ze względu na prostą postać algorytmów związanych z jego stosowaniem, ma tzw. *kryterium najmniejszych kwadratów* (28).

Ogólna istota wyznaczania przybliżonych modeli odwzorowań

Główną niedogodnością dokładnych aproksymacyjnych modeli odwzorowań jest brak prostych sposobów przekazywania informacji o dokładności modelu, zwłaszcza wtedy, gdy dokładność ta zależy wyraźnie od wartości zmiennych niezależnych x [13], [16]. Rysunek 8. pokazuje przykład różnej *jakości* modelu, gdzie na końcach rozpatrywanego przedziału zmiennej x model jest "bardziej dokładny" niż w środkowej części tego przedziału. Sytuacja taka występuje wyraźnie wtedy, gdy zmienna x nie obejmuje wszystkich czynników będących przyczynami zmian zmiennej y .



Rys. 8. Liniowy model danych [13]

Fig. 8. Linear data model [13]

Ogólnym sposobem określania lokalnych niedokładności modelu może być zastąpienie funkcji (25) parą funkcji [13], [16]:

$$\langle \hat{y}_-(\underline{x}), \hat{y}_+(\underline{x}) \rangle \quad (29)$$

takich, że

$$P\left[\left(\hat{y}_-(\underline{x}) \leq y(\underline{x})\right) \wedge \left(y(\underline{x}) \leq \hat{y}_+(\underline{x})\right)\right] \geq \alpha, \quad (30)$$

gdzie $P[\cdot]$ jest funkcją prawdopodobieństwa, a α oznacza wartość progową tej funkcji.

Funkcje (29) mogą być interpretowane jako szczególnie rodzaj zapisu brzegów przedziału ufności dla poszukiwanej nieznannej funkcji (25). Funkcje te są *jednostronnymi modelami danych* (modelami ograniczającymi te dane odpowiednio *od dołu* i *od góry*). Dla

$$\alpha = 1 \quad (31)$$

warunek (30) oznacza, że funkcje (29) wyznaczają przedział (w przestrzeni wielowymiarowej), zawierający wszystkie dane. Po przyjęciu (dla uproszczenia zadania), iż przedział wyznaczany przez funkcje (29) jest symetryczny względem funkcji (25), można wprowadzić symetryczne odchylenie wielowymiarowe $\Delta\hat{y}(\underline{x})$ [14], [21]:

$$\Delta\hat{y}(\underline{x}) = \hat{y}(\underline{x}) - \hat{y}_-(\underline{x}) = \hat{y}_+(\underline{x}) - \hat{y}(\underline{x}), \quad (32)$$

pozwalające na zapisywanie funkcji (29) w postaci:

$$\hat{y}_-(\underline{x}) = \hat{y}(\underline{x}) - \Delta\hat{y}(\underline{x}) \quad \text{oraz} \quad \hat{y}_+(\underline{x}) = \hat{y}(\underline{x}) + \Delta\hat{y}(\underline{x}) \quad (33)$$

Należy zwrócić uwagę na różnicę pomiędzy symetrycznym odchyleniem wielowymiarowym, opisanym zależnością (32) i stosowanym w statystyce odchyleniem standardowym. Różnica polega między innymi na tym, że odchylenie standardowe rozpatrywane jest najczęściej jako wartość stała, niezależna od \underline{x} , stanowiąca globalną charakterystykę danych.

Modele jednostronne


Na modele jednostronne nałożony jest warunek, aby spełniały one zależność (30). Ponieważ warunek ten spełnia nieskończenie wiele funkcji (29), w [13], [21] wprowadzono dodatkowe kryterium jakości modelu w postaci (27). Ponadto założono, że poszukiwany model zapisywany będzie w postaci:

$$\hat{y}_h(\underline{x}) = \sum_{k=1}^K [a_{h,k} \cdot f_k(\underline{x})], \quad (34)$$

gdzie $f_k(\underline{x})$ są dowolnymi funkcjami wielowymiarowej zmiennej \underline{x} (nie zakłada się, że są to funkcje liniowe). W celu rozwiązania tak sformułowanego zadania [21] należy zastosować odpowiedni algorytm programowania liniowego, np. opisywany w większości podręczników algorytm typu *simpleks* [91], [102].


Rysunek 9. i rys. 10. pokazują przykłady modeli jednostronnych, wyznaczonych z uwzględnieniem zależności (31) dla różnie dobranych w zależności (34) parametrów K oraz funkcji $f_k(\underline{x})$. Na rys. 9 widać, że obszary zawierające dane trenujące szacowane są z dużym

nadmiarem (modele wyznaczone były dla $K=2$, $f_1(x)=1$, $f_2(x)=x$). Niedogodność tę można wyeliminować zwiększając stopień funkcji (34) (rys. 10 - modele wyznaczone były dla $K=6$, $f_1(x)=1$, $f_2(x)=x^1$, $f_3(x)=x^2$, $f_4(x)=x^3$, $f_5(x)=x^4$, $f_6(x)=x^5$).



Rys. 9. Para jednostronnych liniowych modeli danych [13]

Fig. 9. Pair of unilateral linear data models [13]



Rys. 10. Para jednostronnych nieliniowych modeli danych [13]

Fig. 10. Pair of unilateral non-linear data models [13]

Zaletą modeli jednostronnych, wyznaczanych z zachowaniem warunku (31), jest to, że obejmują one wszystkie dane trenujące. Cecha ta może być jednak wadą [21], zwłaszcza wtedy, gdy dane trenujące zawierają elementy obciążone nadmiernymi odchyłkami. Dane

takie, występujące najczęściej w niewielkiej liczbie, mogą być przyczyną małej dokładności wyznaczanego modelu. W celu uniknięcia tej niedogodności można stosować modele częściowo jednostronne.

Modele częściowo jednostronne

Cechą charakterystyczną modeli częściowo jednostronnych jest to, że obejmują one jedynie część danych trenujących. Modele takie można otrzymać w wyniku iteracyjnego wykonania następujących działań [13], [21]:

- a) wyznaczenia modelu jednostronnego;
- b) pominięcia zadanej liczby danych zlokalizowanych najbliżej granicy wyznaczonego obszaru jednostronnego;
- c) powrót do kroku *a*, jeżeli postać wyznaczonego modelu nie jest zadowalająca (np. odległości brzegów wyznaczonego przedziału są zbyt duże).

Algorytm ten gwarantuje otrzymanie wyniku, jest to jednak związane z koniecznością wykonania dużej liczby działań.

Innym skutecznym sposobem wyznaczania modeli jednostronnych jest modelowanie odchyłek (reszt) wcześniej wyznaczonego modelu nieliniowego. Jest to postępowanie polegające na wykonaniu następujących działań [13], [16]:

- wyznaczenia modelu (25) dla danych trenujących, jako modelu nieliniowego (np. za pomocą sieci neuronalnej),
- modelowania odchyłek, dla których przyjęto założenie (32):

⇒ wyznaczenie reszt $\underline{\delta}_h(\underline{x})$ dla tak otrzymanego modelu:

$$\underline{\delta}_h(\underline{x}) = \underline{\hat{y}}(\underline{x}) - \underline{y}(\underline{x}) \quad (35)$$

⇒ wyznaczenie bezwzględnych wartości reszt (35):

$$\underline{\Delta y}(\underline{x}) = [|\delta_1(\underline{x})|, |\delta_2(\underline{x})|, \dots, |\delta_H(\underline{x})|] \quad (36)$$


⇒ wyznaczenie modelu (32) dla reszt (36), np. za pomocą sieci neuronalnej.

- zapisania pary częściowo jednostronnych modeli w postaci (29) z uwzględnieniem (33).

Rysunek 11 pokazuje przykład modelu otrzymanego za pomocą opisanego algorytmu, z zastosowaniem sieci neuronalnych, posiadających odpowiednio 1, 3, 1 węzłów w kolejnych warstwach. Należy zauważyć, że część danych trenujących występuje poza obszarem wyznaczonym przez parę modeli częściowo jednostronnych. W celu odpowiedniego przyjęcia progowej wartości prawdopodobieństwa α , występującej w (30), konieczne jest rozpoznanie charakteru rozkładu reszt (36). Zadanie to może być związane z dużymi trudnościami. W wielu zastosowaniach praktycznych dopuszczalna jest modyfikacja (33) do postaci [13], [16]:


$$\hat{y}_-(x) = \hat{y}(x) - \beta \cdot \Delta \hat{y}(x) \quad \text{oraz} \quad \hat{y}_+(x) = \hat{y}(x) + \beta \cdot \Delta \hat{y}(x); \quad \beta > 0, \quad (37)$$

gdzie β jest parametrem określającym względną szerokość wyznaczonego obszaru symetrycznego.



Rys. 11. Para częściowo jednostronnych nieliniowych modeli danych (gdzie linia przerywana jest wykresem nieliniowego modelu danych) [13]

Fig. 11. Pair of partially unilateral non-linear data models (where the dashed line represents diagram of non-linear data model) [13]



Rys. 12. Rodzina trzech par częściowo jednostronnych nieliniowych modeli danych [13]

Fig. 12. Family of three pairs of partially unilateral non-linear data models [13]

Rysunek 12 pokazuje przykład rodziny par modeli częściowo jednostronnych, wyznaczonych wg (37) dla parametru β równego 1, 2 i 3.

Opisany algorytm wyznaczania modeli częściowo jednostronnych umożliwia (w wyniku wielokrotnego zastosowania sieci neuronalnych) uzyskanie modeli zawierających informacje o lokalnej dokładności wyznaczanego opisu rozpatrywanych danych. Niedogodnością stosowania sieci neuronalnych jest to, że zwiększanie liczby węzłów sieci neuronalnych pozwala zawsze na uzyskanie rozwiązania [21]. Otrzymane rozwiązanie stanowić może dobry opis danych, nie będąc jednak ich odpowiednim uogólnieniem.

2.2. Interpolacyjne modele odwzorowań

Modele interpolacyjne są przykładem lokalnych modeli odwrotnych [21].

Zadanie pozwalające na wyznaczanie przybliżonej wartości $\hat{y}(\underline{x})$ funkcji $y(\underline{x})$ dla dowolnego argumentu \underline{x} na podstawie znanych przykładów wartości tej funkcji:

$$\left\{ y(\underline{x}_p) : \underline{x}_p \in X_P \right\} \quad (38)$$

dla skończonego zbioru przykładów wartości argumentów:

$$X_P = \{ \underline{x}_i \}, \quad (39)$$

nazywane jest interpolacją [21].

Najczęściej zakłada się, że wartości wyznaczonej funkcji interpolującej $\hat{y}(\underline{x})$ odpowiadają (są równe) znanym wartościom funkcji $y(\underline{x})$ w punktach odpowiadających elementom zbioru przykładów wartości argumentów X_P :

$$\forall \underline{x}_p \in X_P : \hat{y}(\underline{x}_p) = y(\underline{x}_p) \quad (40)$$

Znane są liczne publikacje dotyczące stosowania sieci triangulacyjnych, czyli sieci utworzonych w terenie przez punkty o znanej dokładnie lokalizacji i wysokości (o znanych współrzędnych), służące jako osnowa geodezyjna do opisu powierzchni terenu. Punkty triangulacji pozwalają na rozpatrywanie rozpiętych na nich funkcji składanych z odcinków, będących funkcjami liniowymi lub definiowanych jako wielomiany wyższych stopni. Opisywane w literaturze metody postępowania dotyczą głównie przestrzeni dwu- lub trójwymiarowych (np. [5], [6], [75], [91], [97], [103]). Uogólnianie tych metod na przestrzenie o większej liczbie wymiarów nie jest jednak zadaniem prostym. Algorytmy bazujące na wielowymiarowych sieciach (siatkach) triangulacyjnych nie będą rozpatrywane w tej pracy.

Pierwotwór licznej grupy algorytmów interpolacyjnych zaproponowano w pracy [96]. Nieznane wartości funkcji wyznaczone są na podstawie danych wzorcowych następująco:

$$\hat{y}(\underline{x}) = \frac{\sum_{i=1}^P w_i(\underline{x}) y(\underline{x}_i)}{\sum_{i=1}^P w_i(\underline{x})}, \quad (41)$$

gdzie funkcja wagi definiowana może być na przykład w postaci:

$$w_i(\underline{x}) = \|\underline{x} - \underline{x}_i\|^\mu \quad \text{dla} \quad \mu < 0 \quad (42)$$

Zapisując (41) w równoważnej postaci [90]

$$\hat{y}(\underline{x}) = \frac{\underline{y}(\underline{x}_j) + \sum_{i=1, i \neq j}^P \frac{w_i(\underline{x}) y(\underline{x}_i)}{w_j(\underline{x})}}{1 + \sum_{i=1, i \neq j}^P \frac{w_i(\underline{x})}{w_j(\underline{x})}}; \quad \text{dla} \quad j=1,2,\dots,P, \quad (43)$$

można zauważyć, że jeśli funkcja wagi (42) posiada własność:

$$\lim_{\underline{x}_j \rightarrow \underline{c}} w_j(\underline{x}_j) = \infty \quad \text{dla} \quad j=1,2,\dots,P, \quad (44)$$

to

$$\lim_{\underline{x}_j \rightarrow \underline{c}} \hat{y}(\underline{x}_j) = \underline{y}(\underline{x}_j) \quad \text{dla} \quad j=1,2,\dots,P \quad (45)$$

Pokazana metoda postępowania jest skuteczna i prowadzi do stabilnych rozwiązań wtedy, gdy poszukiwane są modele dokładne [21]. Z wcześniejszych rozważań wynika, że skutkiem braku znajomości pełnego zbioru wejść modelu jest istnienie zakłóceń oraz potrzeba rozpatrywania modeli przybliżonych. Uzasadnia to rezygnację z uwzględniania, charakterystycznego dla zadań interpolacji, założenia (40) przyjmującego, iż wartości wyznaczonej funkcji interpolującej są równe znanym wartościom funkcji (38).


Zakłada się, że poszukiwane będą wartości funkcji $\underline{y}(\underline{x})$ na podstawie znanych wartości tej funkcji, określonych dla skończonego zbioru wartości argumentów $\{\underline{x}\}$. Uwzględniając wcześniejsze postulaty, uzasadniające potrzebę poszukiwania modeli uogólniających, rezygnuje się z założenia, iż wartości funkcji interpolującej będą równe znanym wartościom funkcji dla zbioru argumentów $\{\underline{x}\}$. Oznacza to rezygnację z wymagania, dla którego wykres funkcji interpolującej ma przechodzić przez węzły interpolacji. Rozwiązywanie tak rozumianego zadania interpolacji wymaga przyjęcia jednego z następujących dodatkowych wymagań [21]:

- określone zostanie kryterium pozwalające na ocenę dokładności lub jakości przybliżenia;
- zadana zostanie klasa funkcji aproksymujących.

Ze względu na potrzeby rozpatrywanych zadań identyfikacji modeli opisane będą wybrane algorytmy interpolacji w przestrzeniach wielowymiarowych. Klasyczne algorytmy interpolacji, przeznaczone głównie do stosowania w przestrzeniach o małej liczbie wymiarów (dwu lub trzech wymiarów), opisywane są w dostępnej literaturze (np. [5], [6], [75], [91], [97], [103]).

Jak wspomniano, modele interpolacyjne są przykładem modeli lokalnych, czyli modeli wyznaczanych w pewnym obszarze rozpatrywanych przestrzeni. Interesujący nas obszar może być wyznaczony jako otoczenie rozpatrywanego punktu \underline{x}_n w wielowymiarowej przestrzeni. Elementami należącymi do takiego otoczenia mogą być wartości wejść \underline{x}_j [21]:

- należące do wielowymiarowej elipsoidy o średnicach \underline{d} i ze środkiem w punkcie \underline{x}_n ;
- należące do wielowymiarowej kostki o bokach \underline{d} i ze środkiem w punkcie \underline{x}_n (rys. 13);
- należące do zbioru L najbliższych sąsiadów punktu \underline{x}_n .



Rys. 13. Wejście \underline{x}_j należące do otoczenia $\varepsilon(\underline{x}_n)$ wartości wejścia \underline{x}_n i odpowiadające mu wyjście $y_{j,h}$ [21]

Fig. 13. \underline{x}_j input belonging to $\varepsilon(\underline{x}_n)$ of \underline{x}_n input and corresponding $y_{j,h}$ output [21]

Średnice \underline{d} elipsoidy oraz długości boków \underline{d} kostki określać można na podstawie odchylen kwadratowych wartości wejść. Wielkości te mogą być również określane na podstawie zakresów zmian wartości wejść [21]:

$$d_k = \frac{1}{L} \left(\max_{n=1}^N (x_{n,k}) - \min_{n=1}^N (x_{n,k}) \right), \quad (46)$$

gdzie liczba L przyjmowana jest arbitralnie (np. $L=10$).

Podczas wyznaczania wartości parametrów modelu w otoczeniu punktu \underline{x}_n z uwzględnieniem definicji wielowymiarowej elipsoidy lub wielowymiarowej kostki należy przyjmować

wielkość uwzględnianego otoczenia badanych punktów w przestrzeni wejść (bezpośrednio lub pośrednio, np. przez przyjęcie liczby L w (46)). Przyjmowanie stałej wielkości tego ruchomego otoczenia (bez znajomości rozmieszczenia punktów) może prowadzić do obszarów zawierających zbyt dużo lub zbyt mało elementów [21]. W celu uniknięcia tej niedogodności można wprowadzić definicję otoczenia określonego przez liczbę L najbliższych sąsiadów - uwzględniane ruchome otoczenie zawiera stałe zadaną liczbę elementów. Liczbę uwzględnianych najbliższych sąsiadów L należy przyjmować arbitralnie, starając się, aby spełnione były warunki [21]:


$$L > 10 \tag{47}$$

$$L < N / 10 \tag{48}$$

Praktyczną niedogodnością takiej definicji otoczenia jest konieczność wykonywania dużej liczby obliczeń.

2.2.1. Algorytm W11

Opisany algorytm zaczerpnięto z [21].



Rys. 14. Przykłady wykresów funkcji (50) dla $a=10$ oraz $b=1$ i $b=2$ w dwuwymiarowym ograniczonym otoczeniu elementu \underline{x} [21]

Fig. 14. Examples of diagrams of function (50) for $a=10$ and $b=1$ and $b=2$ in two-dimensional bounded neighbourhood of \underline{x} element [21]

Wartości funkcji $\underline{y}(\underline{x})$, dla dowolnego \underline{x} , wyznaczone są jako średnie ważone znanych wartości funkcji:

$$\underline{y}(\underline{x}) = \frac{\sum_{\underline{x}_i \in \mathcal{E}(\underline{x})} v(\underline{x}, \underline{x}_i) \underline{y}(\underline{x}_i)}{\sum_{\underline{x}_i \in \mathcal{E}(\underline{x})} v(\underline{x}, \underline{x}_i)}, \tag{49}$$


gdzie $\mathcal{A}(\underline{x})$ jest ograniczonym lub nieograniczonym otoczeniem punktu (elementu) \underline{x} w przestrzeni wartości argumentów funkcji $v(\underline{x})$ oraz gdzie funkcja $v(\underline{x}, \underline{x}_i)$ posiada tę własność, iż jej wartości bezwzględne są „duże” w bezpośrednim otoczeniu elementu \underline{x} oraz „małe” (dążące do zera) dla elementów oddalonych znacznie od \underline{x} . Powoduje to, że na wartość $v(\underline{x})$ w (49) wpływać będą przede wszystkim elementy bezpośrednio sąsiadujące z \underline{x} . Zakładając, że elementy \underline{x} są elementami przestrzeni metrycznej, w której zdefiniowano miarę odległości $d(\underline{x}, \underline{x}_i)$, można rozpatrywać $v(\underline{x}, \underline{x}_i)$ jako $v(d(\underline{x}, \underline{x}_i))$. Przykładem takiej funkcji jest

$$v(d(\underline{x}, \underline{x}_i)) = \exp(-a d^b(\underline{x}, \underline{x}_i)) \quad (50)$$

Niedogodnością algorytmu W11 jest potrzeba odpowiedniego skalowania wszystkich wartości \underline{x} . Skalowanie to ma (może mieć) znaczny wpływ na wartości odległości występujących w (50).

2.2.2. Algorytm W12

Opisany algorytm zaczerpnięto z [21]. Innym sposobem określania modelu interpolacyjnego jest wyznaczenie odpowiedniego lokalnego modelu liniowego, identyfikowanego w bezpośrednim otoczeniu wyróżnionego punktu, dla którego poszukiwany jest ten model (rys. 15). Identyfikacja takiego modelu lokalnego następuje na podstawie najbliższych sąsiadów wyróżnionego punktu.



Rys. 15. Lokalny model liniowy [21]

Fig. 15. Local linear model [21]

Funkcja $\hat{y}(\underline{x})$ wyznaczana jest z uwzględnieniem (25) i (26). Oznacza to potrzebę określenia algorytmu wyłącznie dla indywidualnego wyznaczania wartości funkcji jednowymiarowych

$$\hat{y}_1(\underline{x}), \hat{y}_2(\underline{x}), \dots, \hat{y}_H(\underline{x}). \quad (51)$$

Wartości funkcji (51) wyznaczone są na podstawie znanych wartości danych wzorcowych (17). W celu wyznaczenia nieznannej wartości funkcji $\hat{y}_h(\underline{x})$, dla $h=1,2,\dots,H$ oraz dla zadanego elementu \underline{x} , wykonywane są kolejne kroki algorytmu W12.

- W zbiorze danych wzorcowych (17) wyznaczany jest najbliższy sąsiad \underline{x}_0 elementu (punktu) \underline{x} , dla którego wartość funkcji $y_h(\underline{x}_0)$ jest znana.
- W zbiorze danych wzorcowych (17) wyznaczany jest podzbiór

$$X = \{\underline{x}_1, \dots, \underline{x}_K\}, \text{ gdzie } \underline{x}_0 \notin X, \quad (52)$$

zawierający kolejnych ($K \geq 2$) najbliższych sąsiadów elementu (punktu) \underline{x} , dla których wartości funkcji $y_h(\underline{x}_k)$ są znane.

- Wartości elementów zbioru (52) zapisywane są w macierzy prostokątnej \underline{A} jako wartości określone względem elementu \underline{x}_0 (co umożliwi lokalną linearyzację modelu).

$$\underline{A} = \begin{bmatrix} (\underline{x}_1 - \underline{x}_0)^T \\ \vdots \\ (\underline{x}_K - \underline{x}_0)^T \end{bmatrix} = \begin{bmatrix} x_{1,1} - x_{0,1}, & \dots, & x_{1,M} - x_{0,M} \\ \vdots & & \vdots \\ x_{K,1} - x_{0,1}, & \dots, & x_{K,M} - x_{0,M} \end{bmatrix} \quad (53)$$

- Wartości funkcji $y_h(\underline{x}_k)$, dla $\underline{x}_k \in X$, zapisywane są w macierzy kolumnowej \underline{b}_h jako wartości określone względem wartości funkcji $y_h(\underline{x}_0)$.

$$\underline{b}_h = \begin{bmatrix} y_h(\underline{x}_1) - y_h(\underline{x}_0) \\ \vdots \\ y_h(\underline{x}_K) - y_h(\underline{x}_0) \end{bmatrix} \quad (54)$$

- Przyjmowany jest następujący model, na podstawie którego wyznaczone są wartości funkcji (51):

$$\hat{y}_h(\underline{x}) = (\underline{x} - \underline{x}_0)^T \underline{a}_h + y_h(\underline{x}_0) \quad (55)$$

Przyjęcie modelu (55) oznacza, iż wykresem poszukiwanej funkcji jest płaszczyzna „najlepiej” dopasowana do punktów wyznaczonych przez dane wzorcowe i przechodząca przez punkt

$$\left(\underline{x}_0, y(\underline{x}_0) \right) \quad (56)$$

- M -elementowa macierz kolumnowa \underline{a}_h w (55) wyznaczana jest jako rozwiązanie układu równań (57), otrzymanego przez zapisanie danych (52) z uwzględnieniem (53), (54) i (55).

$$\underline{b}_h = \underline{A} \underline{a}_h + \underline{\delta}_h \quad (57)$$

- Rozwiązanie układu (57) ma minimalizować funkcję kryterialną dla reszt

$$z_h^2 = \sum_{k=1, \dots, K} (\delta_{h,k})^2 \rightarrow \min, \quad (58)$$

gdzie zakłada się, że:

$$\sum_{k=1, \dots, K} (\delta_{h,k}) = 0 \quad (59)$$

- Poszukiwana wartość funkcji $\hat{y}_h(\underline{x})$ i jej odchylenia wyznaczone są

$$\hat{y}_h(\underline{x}) = (\underline{x} - \underline{x}_0)^T \underline{a}_h + y_h(\underline{x}_0) \pm \frac{\beta z}{\sqrt{K-1}}, \quad (60)$$

gdzie β , podobnie jak w (37), jest parametrem określającym względną szerokość symetrycznego przedziału ufności, a z wyznaczone jest wg (58) i (57).

- Przedział ufności wynikający z (60) pozwala na zapisanie ogólnego modelu (29) w postaci pary modeli częściowo jednostronnych:

$$\hat{y}_{h-}(\underline{x}) = (\underline{x} - \underline{x}_0)^T \underline{a}_h + y_h(\underline{x}_0) - \frac{\beta z}{\sqrt{K-1}} \quad (61)$$

$$\hat{y}_{h+}(\underline{x}) = (\underline{x} - \underline{x}_0)^T \underline{a}_h + y_h(\underline{x}_0) + \frac{\beta z}{\sqrt{K-1}} \quad (62)$$

Układ równań (57) może mieć różną postać, zależną od wartości danych. W celu uzyskania odpowiedniej niezawodności opisywanego postępowania nie można zakładać, że rząd macierzy (53) w (57) jest dostatecznie duży. Stwierdzenie to zmusza do rezygnacji z klasycznych metod rozwiązywania zadania (58). Zalecane jest postępowanie polegające na dekompozycji macierzy \underline{A} (53), zawierającej K wierszy i M kolumn, wg algorytmu SVD (singular value decomposition) [47]

$$\underline{A} = \underline{U} \underline{W} \underline{V}^T, \quad (63)$$

gdzie:

\underline{U} - macierz posiadająca K wierszy i M ortonormalnych kolumn taka, że

$$\underline{U}^T \underline{U} = \underline{1} \quad (64)$$

\underline{W} - macierz diagonalna posiadająca M kolumn i wierszy oraz nieujemne elementy diagonalne (singular values),

\underline{V} - macierz kwadratowa posiadająca M wierszy i M ortonormalnych kolumn taka, że

$$\underline{V}^T \underline{V} = \underline{1} \quad (65)$$

Zaletą proponowanego postępowania jest to, że dekompozycja (63) może być przeprowadzana również wtedy, gdy macierz \underline{A} jest macierzą osobliwą lub źle uwarunkowaną:

- Dla osobliwej macierzy \underline{A} macierz \underline{W} zawierać będzie wyłącznie r niezerowych elementów diagonalnych, gdzie r jest rzędem macierzy \underline{A} . Pozostałe elementy diagonalne będą miały wartości zerowe.

- Dla macierzy \underline{A} źle uwarunkowanej mogą wystąpić elementy diagonalne o bardzo małych wartościach. Zastąpienie tych elementów wartościami zerowymi jest równoważne transformacji macierzy \underline{A} do stabilnej postaci osobliwej.

Poszukiwana macierz \underline{a}_h w (57) wyznaczana jest na podstawie macierzy uzyskanych w wyniku dekompozycji (63).

$$\underline{a}_h = \underline{V} \underline{W}^{-1} \underline{U}^T \underline{b}_h \quad (66)$$

W celu wyznaczenia \underline{W}^{-1} zakłada się, że iloczyn $\underline{W}^{-1} \underline{W}$ jest macierzą *prawie* jednostkową rzędu r , posiadającą M kolumn i wierszy.

$$\underline{W}^{-1} \underline{W} = \begin{bmatrix} 1 & & & & & \\ & \ddots & & & & \\ & & 1 & & & \\ & & & 0 & & \\ & & & & 0 & \\ & & 0 & & & \ddots & \\ & & & & & & 0 \end{bmatrix} \begin{matrix} 1 \\ \vdots \\ r \\ r+1 \\ \vdots \\ M \end{matrix} \quad (67)$$

Elementy diagonalne macierzy odwrotnej \underline{W}^{-1} wyznaczane są następująco:

$$\underline{W}^{-1} \Big|_{m,m} = \begin{cases} 1/w_{m,m} & \text{dla } w_{m,m} > 0 \\ 0 & \text{dla } w_{m,m} = 0 \end{cases} \quad (68)$$

2.2.3. Algorytm W13

Opisany algorytm zaczerpnięto z [21]. Algorytm W12 pozwala na skuteczne wyznaczanie poszukiwanych wartości funkcji wtedy, gdy dane wzorcowe są zadane dostatecznie gęsto. Uzyskanie takich danych, zwłaszcza w wielowymiarowych przestrzeniach wartości cech, jest zadaniem trudnym. W celu zwiększenia wpływu bezpośrednich sąsiadów rozpatrywanych elementów wprowadzono dodatkową funkcję oceniającą stopień ważności danych $\nu(\underline{x}_i)$ do wyznaczania danych $\nu(\underline{x})$. Funkcja ta może występować w różnych wersjach:

- przyjmuje stałe wartości równe 1

$$\nu(\underline{x}, \underline{x}_i) = 1, \quad (69)$$

- zależy od odległości elementów i przyjmuje wartość maksymalną dla zerowej odległości elementów, na przykład


$$\nu(\underline{x}, \underline{x}_i) = \begin{cases} \frac{1}{1+d(\underline{x}, \underline{x}_i)} & \text{dla } \underline{x}_i \in \mathcal{E}(\underline{x}) \\ 0 & \text{dla } \underline{x}_i \notin \mathcal{E}(\underline{x}) \end{cases} \quad (70)$$

Algorytm W13 jest zmodyfikowaną wersją algorytmu W12. Modyfikacja polega na następującej zmianie zależności (53) i (54):

$$\underline{A} = \begin{bmatrix} (x_{1,1} - x_{0,1})v(\underline{x}, \underline{x}_1), & \dots, & (x_{1,M} - x_{0,M})v(\underline{x}, \underline{x}_1) \\ \vdots & & \vdots \\ (x_{K,1} - x_{0,1})v(\underline{x}, \underline{x}_K), & \dots, & (x_{K,M} - x_{0,M})v(\underline{x}, \underline{x}_K) \end{bmatrix} \quad (71)$$

$$\underline{b}_h = \begin{bmatrix} (y_h(\underline{x}_1) - y_h(\underline{x}_0))v(\underline{x}, \underline{x}_1) \\ \vdots \\ (y_h(\underline{x}_K) - y_h(\underline{x}_0))v(\underline{x}, \underline{x}_K) \end{bmatrix} \quad (72)$$

Rysunek 16 pokazuje przykład pary częściowo jednostronnych modeli, uzyskanych za pomocą algorytmu W13, z zastosowaniem funkcji (70).



Rys. 16. Para częściowo jednostronnych, nieliniowych modeli danych, wyznaczonych wg algorytmu W13 ($K=5$, $\beta=100\%$) [21]

Fig. 16. Pair of partially unilateral non-linear data models, determined up to the W13 algorithm ($K=5$, $\beta=100\%$) [21]

2.2.4. Interpolacja za pomocą kombinacji funkcji wykładniczych

Opisany algorytm zaczerpnięto z [114]. Algorytm ten jest szczególnym przypadkiem opisanego we wcześniejszym rozdziale algorytmu W13 dla stopnia ważności danych.

$$v(\underline{x}, \underline{x}_i) = \exp(-d^2(\underline{x}, \underline{x}_i)/2\rho^2) \quad (73)$$

Podobnie jak w przypadku algorytmu W12 algorytm określony jest wyłącznie dla indywidualnego wyznaczania wartości funkcji jednowymiarowych. W algorytmie tym zakłada się, że $y_h(\underline{x})$ jest M - wymiarową funkcją, która jest określona w rozpatrywanym obszarze G . Wewnątrz obszaru G funkcja $y_h(\underline{x})$ ma znane wartości:

$$\underline{b}_h = \begin{bmatrix} y_h(\underline{x}_1) \\ \vdots \\ y_h(\underline{x}_K) \end{bmatrix} \quad (74)$$

w K punktach $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_K$. Zakładając, że interesuje nas określenie wartości funkcji w punkcie $\underline{x}_s = [x_{s1}, x_{s2}, \dots, x_{sM}]$ przynależnym do obszaru G , przyjmuje się następujący model, na podstawie którego wyznaczane są wartości funkcji $\hat{y}_h(\underline{x}_s)$:

$$\hat{y}_h(\underline{x}_s) = \underline{c}(\underline{x}_s)^T \underline{a}_h + \mu_h, \quad (75)$$

gdzie:

$$\underline{c}(\underline{x}_s) = \begin{bmatrix} c_1(\underline{x}_s) \\ \vdots \\ c_K(\underline{x}_s) \end{bmatrix} \quad (76)$$

$$c_i(\underline{x}_s) = \exp\left(-\frac{d^2(\underline{x}_i, \underline{x}_s)}{2\rho^2}\right); \quad i = 1, 2, \dots, K \quad (77)$$

$$\underline{a}_h = \underline{\Sigma}^{-1}(\underline{b}_h - \underline{\varphi}_h), \quad (78)$$

gdzie:

$\underline{\Sigma}$ jest $K \times K$ macierzą kowariancji dla zmiennych punktów, której elementami są:

$$\sigma_{ij} = \exp\left(-\frac{d^2(\underline{x}_i, \underline{x}_j)}{2\rho^2}\right); \quad i, j = 1, 2, \dots, K \quad (79)$$

i

$$\underline{\varphi}_h = \begin{bmatrix} \mu_h \\ \vdots \\ \mu_h \end{bmatrix} \quad (80)$$

Funkcja interpolująca wyznaczana zgodnie ze wzorem (75) zapewnia ściśle dopasowanie do danych K punktów i jest ciągła we wszystkich jego pochodnych. Dokładność estymacji zależy od dwóch wybranych parametrów - μ_h i ρ . Rozwiązanie sprowadza się do znalezienia dwóch wybranych parametrów μ_h i ρ do ustalenia najlepszej estymacji, które tworzą interpolującą funkcję $\hat{y}_h(\mu_h, \rho, \underline{x}_s)$.

W [114] zaproponowano wyznaczenie μ_h według następującej zależności:

$$\mu_h = \frac{1}{K} \sum_{i=1}^K y_h(\underline{x}_i), \quad (81)$$

natomiast wartość ρ przez minimalizację funkcji:

$$H(\rho) = \sum_{j=1}^r \left(\hat{y}_h(\rho, \underline{x}_j) - y_h(\underline{x}_j) \right)^2, \quad (82)$$

gdzie r - liczba dodatkowych punktów w obszarze G , różnych od pierwotnych K punktów startowych.

Opisany algorytm polega więc na wstępnym dopasowaniu funkcji interpolującej do K punktów w rozpatrywanym obszarze G , a następnie poszukiwaniu najlepszego dopasowania do wybranych z obszaru G r punktów różnych od K punktów startowych.

3. Wybór liczby i rodzaju wejściowych cech modelu

W rozdziale tym opisano wyłącznie wybrane metody wyboru liczby i rodzaju wejściowych cech modelu. Poruszana w tym rozdziale tematyka jest na tyle szeroka, że mogłaby być przedmiotem odrębnych prac. Dlatego też rozdział ten zamieszczono głównie w celu podkreślenia złożoności zagadnień, jakie występują podczas wyboru wejściowych cech modelu. Zagadnienie optymalizacji wyboru cech dla potrzeb modeli odwrotnych nie zostało jeszcze wyczerpująco rozwiązane. Rozdział ten nie jest przeglądem możliwych metod wyboru cech, a jedynie wskazuje możliwe klasy metod wyboru cech, dla których przytoczono wybrane przykłady metod.

3.1. Pojęcie cechy

Z filozoficznego punktu widzenia cecha jest czymś, co odróżnia w porządku poznania jakiś przedmiot od innego przedmiotu, umożliwiając jego rozpoznanie. Cecha diagnostyczna jest własnością szczególnie wyraźnie ułatwiającą rozpoznanie przedmiotów danego rodzaju wśród innych [45], [116]. W innym ujęciu dowolny abstrakt lub konkret można opisać za pomocą zbioru atrybutów, które w ogólnym przypadku mogą mieć charakter ilościowy bądź jakościowy. Atrybut przysługujący danemu obiektowi nazywany jest cechą. Zapisywany jest on w postaci $\langle \text{nazwa cechy}, \text{wartość cechy} \rangle$ [25]:

$$x_i = \langle \text{nam}(x_i), \text{val}(x_i) \rangle \quad (83)$$

Czasami stosowany jest zapis wskazujący obiekt, którego cechy są aktualnie rozpatrywane, czyli $\langle \text{Obiekt}, \text{Atrybut}, \text{Wartość atrybutu} \rangle$. W dalszej części pracy zakłada się, że znany jest obiekt, dla którego rozpatrywane są cechy i w celu uproszczenia zapisu stosowane będzie oznaczenie wartości danej cechy przez x_i zamiast $\text{val}(x_i)$.

Nazwa cechy powinna jednoznacznie identyfikować znaczenie cechy. Wartość cechy występować może w różnych postaciach. W [22] wyróżniono następujące klasy cech:

- *cechy liczbowe* (wartością cechy jest pojedynczy element ciągłego lub dyskretnego zbioru wartości cech) i *cechy funkcyjne* (wartościami cechy są funkcje);
- *cechy jednowymiarowe* (uwzględniane są tylko wartości jednej cechy punktowej) i *cechy wielowymiarowe* (uwzględniane są równocześnie wartości wielu cech punktowych);
- *cechy ilościowe* (cechy, dla których możliwe jest uporządkowanie ich wartości; stanowią one zwykle bezpośredni wynik obliczeń lub ocenę pomiaru wielkości fizycznej, np. wartości skuteczne amplitudy prędkości drgań) i *cechy jakościowe* (cechy, dla których nie zawsze jest możliwe uporządkowanie ich wartości, które określane są najczęściej w

wyniku kodowania symbolicznego lub uzyskane w wyniku odpowiedniej dyskretyzacji cech ilościowych [99]);

- *cechy dokładne* (wartości cechy są określone precyzyjnie, np. temperatura w łożysku wynosi 55 [°C]) i *cechy przybliżone* (wartości cechy są uogólnione, np. temperatura w łożysku wynosi prawie 55 [°C]).

Zakłada się, że w dalszej części pracy rozpatrywane będą wyłącznie cechy liczbowe, co nie wprowadza ograniczeń zbioru możliwych do uwzględniania wartości cech. Ponieważ wszystkie cechy funkcyjne mogą być (po ich dyskretyzacji) zastępowane ciągami cech punktowych przyjęto, że wartości cech będących elementami takiego ciągu zapisywane są w postaci macierzy obserwacji \underline{y}^N (macierzy wartości cech). Wymaga to, w przypadku wartości nieokreślonych ilościowo (wartości jakościowe), przyjęcia kodu umożliwiającego zapisywanie ich w postaci liczb [9], np. „jasny kolor oleju” = 1, „ciemny kolor oleju” = 3.

3.2. Ogólny opis zagadnienia wyboru cech

Wejścia, stany i wyjścia diagnozowanego obiektu w danej chwili czasu eksploatacji są opisywane za pomocą cech oraz wartości tych cech [84], [116]. Bezpośrednia ocena cech stanu nie jest łatwa, wskutek tego dokonuje się oceny symptomów stanu, którymi np. mogą być cechy sygnałów diagnostycznych. Oceny symptomów stanu otrzymywane są najczęściej w wyniku przeprowadzonego procesu grupowania, a następnie klasyfikacji wartości cech [22].

Celem grupowania jest wyznaczenie klas obiektów w jakimś ogólnym zbiorze tych obiektów. Natomiast zadaniem klasyfikacji jest przyporządkowanie wskazanego obiektu opisanego przez znane wartości cech do jednej z wcześniej wyznaczonych lub przyjętych klas. Dwa obiekty powinny być przyporządkowane (zakwalifikowane) do tej samej klasy wtedy, gdy obiekty te są podobne. Przyporządkowanie obiektów do różnych klas powinno nastąpić wtedy, gdy obiekty te nie są podobne. Wynik klasyfikacji może być wynikiem dokładnym (w przypadku rozpatrywania dokładnych klas wartości cech) lub wynikiem przybliżonym (w przypadku rozpatrywania przybliżonych klas wartości cech) [22].

Wyznaczany podczas badań zbiór wartości cech orzekający o obserwowanym obiekcie może być zbiorem bardzo licznym. Istnieje trudne do rozwiązania zadanie wyboru cech, które mogą być pominięte w dalszych rozważaniach (zadanie ograniczania liczby wymiarów przestrzeni wartości cech). Istotnym problemem jest znalezienie odpowiedzi na pytanie, jaka w ogólnym przypadku powinna być wartość liczby wymiarów M (liczby cech). Do „pełnego” opisu rzeczywistego obiektu w każdym przypadku należałoby wykorzystać ogromną liczbę cech. Podejmowanie decyzji o ograniczeniu liczności zbioru cech wymaga jednak dużej ostrożności [9], ponieważ podczas sformalizowanego postępowania zmierzającego do ograniczenia liczby cech uwzględniane są wyłącznie te związki pomiędzy cechami, które występują dla rozpatrywanej rodziny wartości cech (będącej wynikiem badań). Wybór ograniczonego zbioru cech może zmienić się po zmianie tej rodziny.

W większości podręczników związanych z zadaniem klasyfikacji zwraca się wyraźnie uwagę na to, że jakość klasyfikatora nie może być lepsza od jakości danych uczących, na podstawie których został on wyznaczony [25], [99]. Oznacza to, że wybór uwzględnianych cech obiektów oraz dobór odpowiednich technik pozyskiwania ich wartości jest zadaniem wymagającym szczególnej uwagi.

Często popełniany jest błąd, polegający na uwzględnianiu nadmiernej liczby cech. Na wielu przykładach można pokazać, że stopnie ważności cech, będących elementami takich licznych zbiorów, są bardzo zróżnicowane [25]. Wiele z nich może zawierać informacje nie związane z konstruowanym klasyfikatorem. Przy wyborze cech odpowiednich do potrzeb wynikających z celu badań należy odrzucić (pominąć) cechy „mniej” ważne. Postępowanie takie jest czasami krytykowane jako błędne, a głównym argumentem jego przeciwników jest stwierdzenie, iż dodatkowe dane mogą wyłącznie zwiększyć wiedzę o obiektach. Stwierdzenie to jest jednak prawdziwe wyłącznie wtedy, gdy rozpatrywany jest nieskończony źródłowy zbiór obiektów. Jednak dla skończonego zbioru obiektów [25] (a w badaniach diagnostycznych dysponuje się wyłącznie takimi zbiorami), stosowanych do wyznaczania danych źródłowych, jakość konstruowanego klasyfikatora może pogarszać się po uwzględnieniu nieważnych cech.

Wybór uwzględnianych cech może być rozpatrywany jako zadanie, którego celem jest wyznaczenie transformacji z N -wymiarowej przestrzeni wartości cech w przestrzeń M -wymiarową, gdzie $M < N$ [25]. Wynikiem transformacji danych źródłowych są macierze \underline{v}^M reprezentujące odpowiadające im macierze \underline{v}^N . Optymalizacja liczności zbioru uwzględnianych cech jest dokonywana w świetle kryteriów, które obejmują między innymi następujące czynniki [25]:

1. Informacje stanowiące podstawę wyboru:

- wybór uwzględnianych cech dokonywany jest bez uwzględniania wartości klasyfikatora uczącego; stosowane są metody nazywane skalowaniem wielowymiarowym oraz analiza czynnikowa;
- wybór uwzględnianych cech dokonywany jest na podstawie analizy klasyfikatora uczącego.

2. Rodzaj wybieranych cech:

- wybierane są wyłącznie cechy będące elementami rozpatrywanego zbioru;
- poszukiwany jest zbiór nowych cech, które wyznaczane będą na podstawie transformacji cech wejściowych.

3. Zależności między cechami:

- cechy wyjściowe są nieskorelowane i wybierane są te cechy, które charakteryzują się największą wariancją;
- cechy wyjściowe są skorelowane i wybór cech poprzedzany jest identyfikacją zbioru cech niezależnych (poszukiwanie ortogonalnej bazy przestrzeni wartości

cech), w którym odrzuca się następnie cechy charakteryzujące się najmniejszą wariancją.

W dalszej części pracy metody ograniczania liczby rozpatrywanych cech będą rozważane pod kątem zastosowań dla potrzeb doskonalenia diagnostycznych modeli odwrotnych. Zbiór wejść dla takiego modelu stanowić mogą wartości cech sygnałów diagnostycznych mierzonych na obiekcie, natomiast zbiór wyjść wartości cech stanów bądź klasy wartości cech stanów obiektu. W szczególności dane uczące dla modelu odwrotnego mogą być zapisane w postaci (10). Ze względu na postawiony cel, jakim jest określenie modelu odwrotnego, pozwalającego na wyznaczenie wartości lub klas wartości cech stanów na podstawie wartości cech sygnałów diagnostycznych, zakłada się, że ograniczaniu poddawany będzie jedynie zbiór cech sygnałów diagnostycznych mierzonych na obiekcie (zbiór ten jest najczęściej zbiorem bardzo licznym). W ogólności zbiór cech stanów również jest zbiorem bardzo licznym. W praktyce jednak rozpatrywane zbiory cech stanów są nieliczne, gdyż ograniczenie liczby rozróżnianych stanów odbywa się poprzez zmniejszenie stopnia szczegółowości identyfikacji tych stanów. Dlatego ograniczanie liczebności zbioru cech stanów nie będzie rozpatrywane. W takim podejściu do problemu możliwe jest wyróżnienie trzech grup metod pozwalających na wybór optymalnej liczby cech sygnałów diagnostycznych:

1. Metody, w których wybór liczby cech sygnałów diagnostycznych dokonywany jest jedynie na podstawie wartości tych cech.
2. Metody, w których wybór liczby cech sygnałów diagnostycznych dokonywany jest na podstawie klas wartości tych cech bądź klas wartości odpowiadających im stanów (konieczne jest posiadanie klas wartości cech sygnałów diagnostycznych lub klas wartości cech stanów).
3. Metody, w których wybór liczby cech sygnałów diagnostycznych dokonywany jest na podstawie wartości cech stanów (konieczne jest posiadanie zbioru uczącego zapisanego w postaci (10), który do określonego zbioru wartości cech sygnałów diagnostycznych przypisuje określony zbiór wartości cech stanów).

3.3. Przegląd metod wyboru cech

Kolejne podrozdziały przedstawiają przykładowe metody dla każdej z wyróżnionych trzech grup metod, pozwalające na wybór optymalnej liczby cech sygnałów diagnostycznych. Metody zaczerpnięte z literatury będą prezentowane w ogólnym zarysie z pominięciem szczegółów, które można znaleźć w ogólnodostępnej (często cytowanej) literaturze. Oczywiście, opisane w dalszych podrozdziałach metody nie wyczerpują tematu związanego z metodami ograniczania liczebności zbioru cech. Wiele interesujących algorytmów zmierzających do ograniczania liczby rozpatrywanych cech można znaleźć np. w [99], [101]. Prace nad poszukiwaniem nowych metod (algorytmów) trwają. Przykładem może być tutaj [71], gdzie przedstawiono liczbowe miary wrażliwości cech sygnałów diagnostycznych,

które mogą być stosowane w celu wstępnego ograniczania liczby cech. Z kolei w [109] opisano zastosowanie metod opartych na algorytmach genetycznych.

3.3.1. Metody uwzględniające wartości cech sygnałów diagnostycznych

W przypadku metod uwzględniających wartości cech sygnałów diagnostycznych wybór uwzględnianych cech może być dokonany arbitralnie przez osobę prowadzącą badania. Jawnie lub domyślnie przyjmowanym kryterium wyboru jest uwzględnienie wyłącznie tych cech, które są niezależne. Skuteczność takiego wyboru zależy głównie od wiedzy i intuicji badacza. Optymalne przeprowadzenie arbitralnego wyboru jest trudne, a nawet niewykonalne, jeżeli początkowa liczba cech jest duża [9]. Miarą ilościową związku między wartościami cech jest współczynnik korelacji [1], [103], [108]. Współczynnik korelacji wynoszący 1.0 oznacza całkowite powiązanie wartości cech, natomiast współczynnik korelacji wynoszący 0.0 oznacza brak związku liniowego. Nie mówi to nic o zależności lub niezależności wartości cech. Korelacja jest miarą przewidywalności zmian wartości jednej cechy ze zmian wartości innej cechy lub innych cech. Stosować można analityczne metody podobieństw w postaci korelacji liniowej, korelacji rangowej Kendalla i korelacji rangowej Spearmana [1], [103], [108]. Korelacje rangowe mają tę zaletę, że nie wymaga się skalowania wartości. Ważna jest jedynie względna wartość (nie uwzględnia tego korelacja liniowa).

Metodą analizy wielowymiarowej, w której założeniach tkwi redukcja macierzy wartości cech, jest *analiza składowych głównych* uznawana za szczególnie przydatną ze względu na takie jej właściwości, jak [81]:

- możliwość sprowadzenia uzyskanych wyników do przestrzeni dwu- a nawet jednowymiarowej;
- stosunkowo mała strata informacji przy przejściu z przestrzeni N -wymiarowej do przestrzeni o mniejszej liczbie wymiarów;
- nieskorelowanie zmiennych wynikowych, tj. składowych głównych;
- jednostkowa wariancja składowych głównych.

Do głównych wad tej metody należy zaliczyć fakt, że postać składowych głównych jest wrażliwa na zmiany skali wartości rozpatrywanych cech [81]. Nie ma również żadnych racjonalnych kryteriów pozwalających na podjęcie decyzji, kiedy wyjaśniany poprzez składowe główne procent całkowitej zmienności wartości cech jest wystarczająco duży.

Istotą tej metody jest transformacja cech wejściowych \underline{v}^N w nowe cechy V_j , zwane składowymi głównymi, w ten sposób, że składowa V_1 zawiera największy ładunek informacji pierwotnej, wnoszony przez wszystkie cechy, składowa V_2 – mniejszy, składowa V_3 – jeszcze mniejszy itd. Jeżeli kilka pierwszych składowych głównych wyjaśnia znaczną część całkowitej zmienności wartości cech oraz jeżeli można im nadać pewną interpretację merytoryczną, to rozpatrywany obiekt można za ich pomocą opisać w „oszczędniejszy” sposób.

Po przeprowadzeniu obliczeń obiekt charakteryzowany jest przez N składowych głównych V_j zamiast poprzednich N cech. Do ostatecznej analizy przyjmuje się zwykle mniej niż N – składowych głównych V_j ; $j=1,2,\dots,N$. Wybór liczby uwzględnianych składowych głównych dokonywany jest arbitralnie. Są jednak pewne ogólne zalecenia dotyczące wyboru liczby składowych głównych.

Kryteria dotyczące wyboru liczby składowych głównych bazują na badaniu wartości własnych, odpowiadających wektorom własnym macierzy kowariancji wartości cech, które wyznaczane są w trakcie realizacji metody. Wektory własne określają kierunki osi przestrzeni cech głównych. Wartości własne odpowiadające wektorom własnym poddaje się ocenie. Do oceny wartości wektorów własnych stosuje się najczęściej kryteria Kaisera i Cattela [103]. Kryterium Kaisera polega na uwzględnianiu tylko tych wektorów własnych, dla których odpowiadające im wartości własne są większe od jedności. W przypadku kryterium Cattela porządkuje się wartości własne w ciągu malejącym. Następnie wykonuje się wykres wartości własnych (na osi odciętych znajdują się numery kolejnych wartości własnych, na osi rzędnych znajdują się wartości własne) i określa na wykresie miejsce, w którym kończy się gwałtowny spadek wartości własnych. Stosowanie obu kryteriów (Kaisera i Cattela) prowadzi do zbliżonych wyników, jeżeli rozpatruje się wielowymiarowe przestrzenie i zakłada się ograniczenie liczby cech do relatywnie małej liczby składowych głównych. W przypadku stosowania kryterium Kaisera najczęściej uwzględniana jest mniejsza liczba wartości własnych niż w przypadku stosowania kryterium Cattela.

Inne kryterium badania istotności wartości własnych opisano w [9], gdzie do wyboru liczby uwzględnianych wartości własnych, a tym samym liczby generowanych nowych cech, wykorzystuje się kryterium:

$$\frac{\lambda_M}{\lambda_1} \geq \beta, \quad (84)$$

gdzie:

λ_1 - pierwsza (największa uwzględniana) wartość własna;

λ_M - M -ta (najmniejsza uwzględniana) wartość własna;

β - stała przyjmowana arbitralnej; na podstawie [9] zaleca się $0.1 \geq \beta \geq 0.01$.

Stosunkowo często stosowaną metodą do ograniczania liczby uwzględnianych cech jest *analiza czynnikowa* [88], [103]. W analizie czynnikowej zakłada się, że wartości każdej z rozpatrywanych cech są przedstawiane w postaci liniowej funkcji pewnej małej liczby nieobserwowalnych wspólnych M czynników i jednego „ukrytego” czynnika specyficznego. Wspólne czynniki generują zależności pomiędzy wartościami cech, natomiast czynniki specyficzne mają swój udział tylko w zmienności wartości poszczególnych cech. Liczbę wspólnych czynników M wybiera się arbitralnie przed wykonaniem obliczeń. W praktyce wyznaczony model czynnikowy poddaje się najczęściej testowaniu (czy M czynnikowy model dobrze odtwarza zaobserwowane dla rozpatrywanych wartości cech kowariancje i

współczynniki korelacji) poprzez przeprowadzenie testu istotności χ^2 . W większości przypadków po wyznaczeniu wspólnych czynników dokonuje się obrotu układu współrzędnych, którego osiami są wyznaczone czynniki. Zazwyczaj okazuje się, że nowe czynniki (wyznaczone po obrocie układu) umożliwiają ich łatwiejszą interpretację dla rozważanych cech. Opracowanych jest wiele strategii zmierzających do obrotu układu współrzędnych. Są to między innymi strategie zwane [103]: *varimax*, *quartimax* i *equamax*. Istotą np. strategii *varimax* jest poszukiwanie takich nowych osi współrzędnych, dla których wariancja nowych czynników będzie maksymalna.

3.3.2. Metody uwzględniające klasy wartości cech stanów


Przykładem metody, w której wybór liczby cech sygnałów diagnostycznych dokonywany jest na podstawie odpowiadających im klas wartości cech stanów, jest metoda bazująca na stosowaniu sieci neuronalnych. Wiele interesujących metod można również zaadaptować z dziedziny uczenia maszynowego [84]. Przykładem mogą być: algorytmy budowy drzewa decyzyjnego oraz algorytmy *PROMISE* i *PROMISE-2* – szczegółowy opis tych algorytmów można znaleźć np. w [84]. W dalszej części jako przykład metody pozwalającej na ograniczanie liczności zbioru cech zostanie opisana metoda bazująca na stosowaniu sieci neuronalnych.

W ostatnich latach można zauważyć ogromne zainteresowanie zagadnieniami związanymi z sieciami neuronalnymi. O intensywności prowadzonych na świecie badań nad sieciami neuronalnymi zarówno z punktu widzenia rozwoju teorii, jak i zastosowania świadczy lawinowo narastająca liczba publikacji (np. [2], [16], [46], [49], [52], [59], [69], [77], [100], [105]), powstawanie nowych czasopism naukowych, organizacja konferencji i kongresów, a także liczne oprogramowanie profesjonalne [79] i dydaktyczne (np. [11], [28]). Ze względu na wielość publikacji omawiających podstawowe zagadnienia związane z sieciami neuronalnymi zagadnienia te nie będą w pracy omawiane.

Można wyróżnić bardzo wiele rodzajów sieci neuronalnych, przy czym kryteria podziału mogą być bardzo różne (np. ze względu na strukturę - sieci jednowarstwowe i wielowarstwowe, ze względu na metodę treningu - trenowanie z nauczycielem i bez nauczyciela, itd.). Dla zagadnień ograniczania liczby rozpatrywanych cech najczęściej stosowane są sieci typu *Feed Forward Back Propagation*. Dalsze rozważania będą dotyczyły tych właśnie sieci.

W pierwszym kroku opisywanej metody należy rozpatrywanemu zbiorowi wartości cech sygnałów diagnostycznych przyporządkować odpowiadające im klasy wartości cech stanów. Kolejnym krokiem jest zbudowanie struktury sieci, której liczba neuronów wejściowych zależy od liczby rozpatrywanych cech sygnałów diagnostycznych, natomiast liczba neuronów w warstwie wyjściowej jest zależna od liczby rozpatrywanych klas wartości cech stanów. Liczbę warstw ukrytych oraz liczbę neuronów w poszczególnych warstwach dobiera się zgodnie z ogólnie przyjętymi zasadami (np. [11], [15], [46], [69]). Jeśli rozpatruje się zbiór sześciu cech sygnałów diagnostycznych (np. wartości skuteczne amplitud przemieszczeń

drzań), którym przyporządkowuje się trzy klasy wartości cech stanów (np. stan obiektu dobry, zadowalający, niezadowalający), to sieć powinna zawierać sześć neuronów w warstwie wejściowej i trzy neurony w warstwie wyjściowej. Tak skonstruowaną sieć poddaje się procesowi trenowania, w wyniku którego otrzymuje się zbiór wag opisujących połączenia sieci. Rysunek 17 pokazuje strukturę sieci dla rozpatrywanego przykładu, w której dla uproszczenia nie uwzględniono warstw ukrytych.



Rys. 17. Struktura sieci dla rozpatrywanego przykładu

Fig. 17. Structure of network for the considered example

W wyniku procesu trenowania poszczególnym połączeniom będą przypisane różne wartości wag (na rys. 17 różne grubości linii połączeń neuronów). Biorąc pod uwagę fakt, że połączenia sieci, którym przypisano (w wyniku trenowania sieci) małe wartości wag, będą miały mały wpływ na rozpoznawanie klas wartości cech stanów, można te połączenia pominąć [60]. Jeżeli żadne z połączeń dla danej cechy nie jest „ważne”, to można tę cechę pominąć (rys. 17 - cechy o oznaczeniu 0,1 i 0,5). W ten sposób można dokonać wstępnego ograniczenia liczby rozpatrywanych cech. Jest to jednak sposób mało efektywny. Co zrobić z cechami, dla których część połączeń jest „ważnych”, a część „nieważnych” (rys. 17 - np. cecha oznaczona 0,4)? Bardziej efektywnym sposobem jest określenie nowych cech, zastępujących rozpatrywane cechy, których liczba jest równa liczbie rozpatrywanych klas wartości cech stanów.

Nowe cechy mogą być definiowane jako suma ważona wartości „istotnych” cech symptomów - cech, dla których połączenia są „ważne” [100]. Kwestią do rozwiązania pozostaje określenie kryterium pozwalającego na rozróżnienie cech „ważnych” i cech „nieważnych”. Najczęściej „ważność” połączeń sieci ustalana jest na podstawie wartości bezwzględnej wag wyznaczonych dla tego połączenia [100]. Nowe wyznaczone cechy y_j (przy założeniu struktury sieci takiej jak na rys. 17) można opisać następującą zależnością:

$$y_j = \sum_{i=1}^N x_i w_{ij}; \quad j = 1, 2, \dots, M; \quad w_{ij} = \begin{cases} p_{ij} & \text{dla } |p_{ij}| \geq w_p \\ 0 & \text{dla } |p_{ij}| < w_p \end{cases} \quad (85)$$

gdzie:

M - liczba nowych cech;

N - liczba cech początkowych;

p_{ij} - wartości wagi połączenia pomiędzy i -tym neuronem warstwy wejściowej i j -tym neuronem warstwy wyjściowej, otrzymane w wyniku trenowania sieci;

w_{ij} - nowe wartości wag ustalone po ocenie „ważności” połączenia pomiędzy i -tym neuronem warstwy wejściowej i j -tym neuronem warstwy wyjściowej;

w_p - wartość progowa dla wag połączeń sieci ustalana arbitralnie.

Zdaniem autora założenia tej metody nie są do końca słuszne. Proces trenowania sieci neuronalnej poprzedzony jest przyjęciem początkowych wartości wag. Wagi te określane są losowo, co prowadzi każdorazowo do otrzymania innych wartości wag otrzymanych w wyniku procesu trenowania. Generowanie więc nowych cech (zgodnie z zależnością (85)) na podstawie wartości wag przypisanych poszczególnym połączeniom każdorazowo prowadzić będzie do innych wyników. Zdaniem autora możliwe jest stosowanie sieci neuronalnych do ograniczania liczności zbioru cech (stosowanie metody *leave-one-out*). Metoda ta polega na pomijaniu kolejnych cech i sprawdzaniu sprawności budowanego klasyfikatora (w postaci sieci neuronalnej) na podstawie ograniczonego zbioru cech. Jeśli pominięta cecha nie ma istotnego wpływu na sprawność budowanego klasyfikatora, to cechę tę pomija się w dalszych rozważaniach. Wadą takiego podejścia jest konieczność wielokrotnego trenowania sieci, które wynika z konieczności kilkukrotnego trenowania sieci po pominięciu wybranej cechy (nie można podejmować decyzji o pominięciu cechy lub nie na podstawie wyników otrzymanych z jednokrotnego trenowania sieci).

3.3.3. Metody uwzględniające wartości cech stanów

W przypadku metod, w których wybór liczby cech sygnałów diagnostycznych dokonywany jest na podstawie wartości cech stanów, zakłada się, że zbiór danych uczących zapisany jest w postaci (10). Analizę zbioru danych uczących zapisanych w postaci (10) można przeprowadzić z zastosowaniem metody *korelacji kanonicznej* [81], [103]. Analizę tę przeprowadza się w celu stwierdzenia, czy występują zależności liniowe pomiędzy dwoma zbiorami wartości cech. W przypadku zagadnień dotyczących odwracania modeli analizę można przeprowadzić w celu stwierdzenia, czy występują zależności liniowe pomiędzy zbiorem wartości cech stanów a zbiorem wartości cech sygnałów diagnostycznych rozpatrywanego obiektu. Najczęściej występowanie korelacji związane jest z tym, że tylko kilka cech ze zbioru cech sygnałów diagnostycznych powiązanych jest z innymi (ale też nie ze wszystkimi) cechami ze zbioru cech stanów. Wykrycie takich zależności pozwala na

stwierdzenie, które z cech stanów mają rzeczywisty wpływ na wartości cech sygnałów diagnostycznych. Dzięki temu dla potrzeb odwracania modelu numerycznego (a takie zadanie jest rozpatrywane) można wykorzystać znacznie mniejszy zbiór cech sygnałów diagnostycznych, nie tracąc przy tym na dokładności wyznaczanego modelu odwrotnego.

Metoda analizy korelacji kanonicznej polega na wyznaczeniu dwóch kombinacji liniowych, zwanych *zmiennymi kanonicznymi* o postaci:

$$U_1 = a_{11}x_1 + a_{12}x_2 + \dots + a_{1N}x_N \quad (86)$$

$$V_1 = b_{11}y_1 + b_{12}y_2 + \dots + b_{1H}y_H, \quad (87)$$

gdzie:

N - liczba wejść wyznaczanego modelu odwrotnego;

H - liczba wyjść wyznaczanego modelu odwrotnego.

Kombinacje te wyznaczane są w taki sposób, aby kwadrat współczynnika korelacji między nimi, zwany *współczynnikiem korelacji kanonicznej*, był maksymalny. Zmienne kanoniczne są więc tworzone tak, aby w maksymalnym stopniu uwypuklić liniowe zależności między wartościami cech należącymi do dwóch zbiorów wartości cech. Macierze:

$$\underline{a}_1 = [a_{11}, a_{12}, \dots, a_{1N}] \quad (88)$$

$$\underline{b}_1 = [b_{11}, b_{12}, \dots, b_{1H}] \quad (89)$$

nazywane są macierzami kanonicznymi.

Zmienne kanoniczne U_1 i V_1 syntetyzują zależności liniowe między wartościami cech należącymi do rozpatrywanych zbiorów wartości cech, ale czynią to w sposób przybliżony. Można wyznaczyć następane pary zmiennych kanonicznych, tzn. U_2 i V_2 , U_3 i V_3 , itd. aż do U_k i V_k , gdzie $k = \min\{N, H\}$.

Z praktycznego punktu widzenia istotne jest określenie, ile par zmiennych kanonicznych należy uwzględnić. Jednym ze sposobów jest przeprowadzenie testu χ^2 z kolejnym usuwaniem zmiennych kanonicznych. Test polega na tym, że najpierw bada się kombinacje wszystkich zmiennych kanonicznych, a następnie kolejno usuwa się najbardziej znaczące zmienne, powtarzając za każdym razem badanie. Jeżeli po usunięciu M -tej zmiennej wynik badania wskazuje na brak istotności występujących korelacji, oznacza to, że tylko M pierwszych zmiennych kanonicznych opisuje istotnie występujące zależności. Istnieje również możliwość określenia, jaki stopień zmienności wartości badanych cech został „objęty” przez poszczególne zmienne kanoniczne.

Inne metody wyboru liczby cech sygnałów diagnostycznych mogą bazować bezpośrednio na postawionym zadaniu, jakim jest odwracanie modeli. Na wstępie pracy założono, że rozpatrywane będą lokalne modele odwrotne. Dalsze rozważania prowadzone będą dla takich właśnie modeli. Przedstawione w pracy metody opierały się na analizie „pełnego” zbioru danych uczących. Metody opisywane w dalszej części pracy mają swoją podstawę w

podzbiorze zbioru danych uczących - lokalne modele odwrotne wyznaczone są na podstawie podzbioru zbioru danych uczących, który określany jest np. przez liczbę najbliższych sąsiadów rozpatrywanego punktu w przestrzeni symptomów.

Zakłada się, że rozpatrywana początkowa liczba cech sygnałów diagnostycznych wynosi N i na podstawie wartości tych cech będzie wyznaczany model odwrotny w najbliższym otoczeniu rozpatrywanego punktu \underline{y}_s^N w przestrzeni wartości cech. Po wyznaczeniu parametrów modelu odwrotnego możliwe jest wyznaczanie jakości tego modelu (patrz rozdział 4.3.1) $J(\underline{y}_s^N)$ (jakość lokalnego modelu odwrotnego związanego z punktem \underline{y}_s^N w przestrzeni wartości cech przy uwzględnieniu N cech sygnałów diagnostycznych). W kolejnym kroku wyznacza się modele odwrotne i ich jakości przy uwzględnieniu $M=N-1$ cech sygnałów diagnostycznych, przy czym uwzględnia się kolejno M cech sygnałów diagnostycznych z pominięciem cechy o numerze porządkowym 1, następnie cechy o numerze porządkowym 2, itd., aż do cechy o numerze porządkowym N . Następnie ze zbioru, którego elementami są wyznaczone jakości modelu odwrotnego, wybiera się ten element, którego wartość jest maksymalna:

$$J(\underline{y}_s^M) = \max \left\{ J(\underline{y}_s^{N,1}), J(\underline{y}_s^{N,2}), \dots, J(\underline{y}_s^{N,N}) \right\}, \quad (90)$$

gdzie:

$J(\underline{y}_s^M)$ - jakość lokalnego modelu odwrotnego wyznaczonego w najbliższym otoczeniu punktu \underline{y}_s^M określanego w M -wymiarowej przestrzeni wartości cech sygnałów diagnostycznych;

$J(\underline{y}_s^{N,i})$ - jakość lokalnego modelu odwrotnego wyznaczonego w najbliższym otoczeniu punktu $\underline{y}_s^{N,i}$ z pominięciem ze zbioru N cech sygnałów diagnostycznych cechy o numerze porządkowym i .

W dalszych rozważaniach pomija się tę cechę, z pominięciem której wartość miary jakości była maksymalna - cecha ta ma najmniejszy wpływ spośród rozpatrywanego zbioru N cech na jakość wyznaczonego modelu. Opisane kroki powtarza się dla kolejnych, coraz mniej licznych zbiorów cech sygnałów diagnostycznych. Pojawia się pytanie, o ile mniej cech można rozpatrywać, aby jakość wyznaczonego modelu była w dalszym ciągu zadowalająca? Zależy to oczywiście od założenia, jakie przyjmuje prowadzący badania. Oszacowanie straty jakości modelu odwrotnego wyznaczonego przy uwzględnieniu M cech sygnałów diagnostycznych w stosunku do modelu wyznaczonego na bazie N cech sygnałów diagnostycznych można oszacować wg zależności:

$$SJ(\underline{y}_s^{(K)}) = 1 - \frac{J(\underline{y}_s^M)}{J(\underline{y}_s^N)}, \quad (91)$$

gdzie:

$SJ(\underline{v}_s^{(K)})$ - strata jakości lokalnego modelu odwrotnego wyznaczonego w najbliższym otoczeniu punktu \underline{v}_s po pominięciu $K=N-M$ cech sygnałów diagnostycznych;

$J(\underline{v}_s^M)$ - jakość lokalnego modelu odwrotnego wyznaczonego w najbliższym otoczeniu punktu \underline{v}_s^M określanego w M -wymiarowej przestrzeni wartości cech sygnałów diagnostycznych ($M < N$);

$J(\underline{v}_s^N)$ - jakość lokalnego modelu odwrotnego wyznaczonego w najbliższym otoczeniu punktu \underline{v}_s^N określanego w N -wymiarowej przestrzeni wartości cech symptomów.

Podstawową wadą tej metody jest konieczność wykonania bardzo wielu obliczeń. Ograniczenie zbioru rozpatrywanych cech dokonywane jest na podstawie podzbioru danych uczących (jedynie dla modeli lokalnych). Może się okazać, że próby uogólniania wyników na inne lokalne modele (wyznaczane w innych obszarach przestrzeni wartości cech) mogą powodować dużo większe pogorszenie się jakości wyznaczanych modeli na podstawie M cech sygnałów diagnostycznych. Powodem tego może być „lokalny wpływ” stanu na wartości cech sygnałów diagnostycznych. W pewnych obszarach przestrzeni symptomów istotny wpływ na jakość modelu może mieć pewien zbiór cech, natomiast w innych obszarach - inne zbiory cechy. Można się również spodziewać, że proponowana metoda będzie nieskuteczna w przypadku, gdy przy uwzględnianiu N cech jakość modelu będzie bardzo niska. Stosowanie tej metody należałoby więc ograniczyć do lokalnego modelu odwrotnego o odpowiednio dużej jakości. Wydaje się, że realizacja metody musiałaby być przeprowadzana w dwóch etapach. W pierwszym etapie przeprowadzane jest doskonalenie modelu wynikające z uzupełniania zbioru przykładów przy uwzględnianiu N cech. Po uzyskaniu odpowiednio wysokiej jakości modelu odwrotnego wyznaczonego na podstawie N cech sygnałów diagnostycznych ograniczanie zbioru uwzględnianych cech sygnałów diagnostycznych, następnie zapamiętanie, że modele lokalne w rozpatrywanym obszarze można wyznaczać na podstawie ograniczonego zbioru M cech.

Na jakość wyznaczanych lokalnych modeli odwrotnych ma również wpływ niejednoznaczność odwzorowania przestrzeni symptomów w przestrzeń stanów. W rozdziale 2.2 zaprezentowano algorytmy wielowymiarowej interpolacji, umożliwiające uzyskiwanie modeli odwrotnych wyłącznie dla indywidualnego wyjścia (wyznaczanie wartości jednej cechy stanu). W takim ujęciu rozpatrywana dalej metoda ograniczania liczności zbioru cech sygnałów diagnostycznych dotyczyć będzie indywidualnego wyjścia z modelu odwrotnego. W konsekwencji dla każdego (indywidualnego) wyjścia otrzymane podzbiory zbioru cech mogą mieć różną liczbę elementów i same elementy też mogą się różnić. Elementami wyznaczonych podzbiorów cech mogą być różne cechy, co wynika z indywidualnego wpływu poszczególnych wartości cech stanów na wartości cech sygnałów diagnostycznych (np. wartość przykładanej niewyagi w pewnej płaszczyźnie będzie miała

inny wpływ na amplitudę przemieszczeń drgań mierzonych w łożysku, a inny na temperaturę w tym łożysku). Uwzględnianie cech, dla których odwzorowanie nie jest jednoznaczne, może mieć wpływ na jakość modelu wyznaczanego na podstawie tych cech. Wyznaczanie ocen niejednoznaczności odwzorowania wykonywane jest dla indywidualnych wyjść z modelu (cech stanów). Zakłada się, że rozpatrywana początkowa liczba cech sygnałów diagnostycznych wynosi N i na podstawie wartości tych cech wyznaczone będą indywidualne modele odwrotne w najbliższym otoczeniu rozpatrywanego punktu \underline{y}^N w przestrzeni symptomów. Oceny jednoznaczności odwzorowania można wyznaczyć zgodnie z algorytmami opisanymi w dodatku (Dodatek A). W pierwszym kroku ocena jednoznaczności odwzorowania wyznaczana jest przy uwzględnieniu N cech sygnałów diagnostycznych. W kolejnym kroku wyznacza się oceny jednoznaczności odwzorowania przy uwzględnieniu $M=N-1$ cech sygnałów diagnostycznych, przy czym, podobnie jak w poprzedniej metodzie, uwzględnia się kolejno M cech sygnałów diagnostycznych z pominięciem cechy o numerze porządkowym 1, następnie cechy o numerze porządkowym 2, itd., aż do cechy o numerze porządkowym N . Następnie spośród wyznaczonych wartości ocen jednoznaczności odwzorowania wybiera się wartość maksymalną:

$$q_h^M = \max\{q_h^{N,1}, q_h^{N,2}, \dots, q_h^{N,N}\}, \quad (92)$$

gdzie:

- q_h^M - wartość miary jednoznaczności odwzorowania dla h - tego wyjścia (h -tej cechy stanu) wyznaczanego modelu odwrotnego przy uwzględnieniu M cech sygnałów diagnostycznych;
- $q_h^{N,i}$ - wartość miary jednoznaczności odwzorowania dla h - tego wyjścia (h -tej cechy stanu) wyznaczanego modelu odwrotnego z pominięciem ze zbioru N cech sygnałów diagnostycznych, cechy o numerze porządkowym i .

W dalszych rozważaniach pomija się tę cechę, z pominięciem której wartość miary oceny jednoznaczności była maksymalna - cecha ta w największym stopniu ma wpływ na wartość oceny jednoznaczności odwzorowania. Opisane kroki powtarza się dla kolejnych coraz mniej licznych zbiorów cech. Należy się spodziewać, że w kolejnych krokach miara jednoznaczności odwzorowania powinna rosnąć - w kolejnych krokach eliminuje się te cechy sygnałów diagnostycznych, które mają największy wpływ na wartość miary niejednoznaczności odwzorowania. Podobnie jak w poprzedniej metodzie ograniczenia liczności zbioru cech dokonuje się na podstawie podzbioru danych uczących. Uogólnianie otrzymanych wyników na całą przestrzeń symptomów nie jest rozwiązaniem dobrym. Występować mogą jedynie lokalne niejednoznaczności odwzorowania i trudno dokonywać jakichkolwiek uogólnień. Metoda ta nie wymaga tak długiego czasu obliczeń jak metoda poprzednia (procedura określania ocen jednoznaczności odwzorowania nie jest tak czasochłonna jak badanie jakości modelu odwrotnego). Należy jednak pamiętać, że badanie niejednoznaczności odwzorowania dla danych nie określonych gęsto (a takie dane są rozpatrywane) nie jest sprawą łatwą. Zagadnienia te poruszono w dodatku (Dodatek A).

4. Planowanie badań symulacyjnych

Opisane w dalszej części rozdziału rozumowanie zostało przedstawione przez autora w [29]. Zgodnie z poczynionym na wstępie założeniem, że operacja odwracania modelu obiektu będzie przeprowadzona na podstawie przykładów danych opisujących zadane stany rozpatrywanego obiektu oraz odpowiadające tym stanom symptomy ($\{\underline{s}, \underline{s}1, \underline{s}2, \underline{v}\}$), konieczne jest posiadanie odpowiedniego zbioru przykładów. Zbiór przykładów można otrzymać w wyniku przeprowadzenia biernego eksperymentu diagnostycznego lub w wyniku stosowania oprogramowania symulacyjnego. Uzyskanie przykładów dzięki zastosowaniu symulatora wymaga odpowiedniego zaplanowania badań symulacyjnych. Zgodnie z przyjętym założeniem, że wyznaczane modele odwrotne będą doskonalone przez odpowiednią aktualizację zbioru przykładów, można wyodrębnić dwa etapy badań symulacyjnych:


- *badania symulacyjne podstawowe*, których celem jest otrzymanie podstawowego zbioru przykładów;
- *badania symulacyjne uzupełniające*, których celem jest uzupełnienie podstawowego zbioru przykładów nowymi przykładami.

Wynikiem podstawowych badań symulacyjnych jest podstawowy zbiór przykładów, na podstawie którego są identyfikowane wstępne modele odwrotne. Nie można przypuszczać, że tak wyznaczony model odwrotny jest modelem dokładnym [29], [32], [33], [34]. Model odwrotny otrzymany na podstawie podstawowego zbioru przykładów wymagać będzie doskonalenia (poprawy jakości). Zgodnie z założeniem, że doskonalenie modelu odwrotnego będzie realizowane przez odpowiednie uzupełnianie podstawowego zbioru przykładów nowymi danymi oraz że identyfikowane modele odwrotne będą modelami lokalnymi (wyznaczanymi tylko w wybranym obszarze, określonym np. przez wartości cech sygnałów diagnostycznych zmierzonych na obiekcie), ważne jest odpowiednie zaplanowanie uzupełniających badań symulacyjnych (przygotowanie odpowiednich zadań do wykonania ich przez symulator). Zadań tych nie przygotowuje się jednorazowo (jak w przypadku podstawowych badań symulacyjnych), lecz zgodnie z wymaganiami wynikającymi ze stosowania modelu odwrotnego.

Zaletą planowania w taki sposób uzupełniających badań symulacyjnych jest to, że stosowanie modelu numerycznego i wyznaczanie modelu odwrotnego mogą być traktowane jako procesy rozłączne - realizowane w różnym czasie i na różnych komputerach. W [38], [41] zaproponowano generowanie modeli odwrotnych w dwóch współdziałających autonomicznych procesach:

- 1) w procesie wyznaczania wartości cech sygnałów diagnostycznych opisujących zadane stany modelowanego obiektu (modelowanie z zastosowaniem posiadanego oprogramowania symulacyjnego);

- 2) w procesie wyznaczania stanów modelowanego obiektu na podstawie wartości cech sygnałów diagnostycznych opisujących te stany (odwracanie modelu na podstawie posiadanego zbioru przykładów).



Rys. 18. Dwa odrębne procesy generowania modeli odwrotnych [38]

Fig. 18. Two individual processes of inverse models generation [38]

W pierwszej kolejności wyznacza się początkowy zbiór przykładów. Do tego celu można zastosować odpowiednie oprogramowanie symulacyjne, które dla wybranych wartości opisujących stany obiektu wyznaczy odpowiadające im symptomy (przeprowadzenie podstawowych badań symulacyjnych).


Proces generowania modeli odwrotnych należy rozpocząć od wyjściowego zbioru przykładów. Zbiór ten trzeba uzupełniać w zależności od potrzeb wynikających z uzyskania odpowiedniej jakości wyznaczanego modelu odwrotnego (potrzeba przeprowadzenia uzupełniających badań symulacyjnych). Opisane procesy mogą być realizowane na jednym komputerze lub na wielu komputerach połączonych ze sobą siecią komputerową. Systemy operacyjne tych komputerów powinny zapewniać poprawność, niezawodność oraz bezpieczeństwo realizacji procesów [38].

Dla przykładu, proces stosowania modelu może być uruchamiany na komputerze **A**, natomiast proces odwracania modelu na komputerze **B** (rys. 18). Należy zaprojektować odpowiedni przepływ danych pomiędzy komputerami. Realizowanie tych procesów na odrębnych komputerach jest często uzasadnione potrzebami odpowiedniego pielęgnowania oprogramowania.

Rozpatrywanie rozproszonego środowiska obliczeniowego spowodowane jest również względami praktycznymi. Opisywane metody postępowania mogą być stosowane do oceny stanu technicznego dużych turbozespołów, których modele numeryczne mogą być realizowane na komputerach w wybranych ośrodkach badawczych, podczas gdy dane określające aktualne symptomy mogą być wyznaczone w sąsiedztwie obiektu (w elektrowni) [41].

4.1. Planowanie podstawowych badań symulacyjnych

Celem podstawowych badań symulacyjnych jest otrzymanie początkowego zbioru przykładów (danych), na podstawie którego wyznaczany będzie model odwrotny. Początkowy zbiór przykładów uzyskuje się stosując model numeryczny (symulator). Stosowanie modelu polega na podaniu na wejścia modelu znanych wartości cech stanów obiektu i otrzymaniu na wyjściach symptomów opisujących te stany. W początkowej fazie badań wybiera się z przestrzeni stanów S wartości cech stanów, dla których generowane będą dane. Wymaga to dużej wiedzy dotyczącej parametrycznego doboru potencjalnych defektów, tak by wartości współrzędnych punktów opisujących stany mieściły się w odpowiednich przedziałach. Dla potrzeb planowania podstawowych badań symulacyjnych można stosować ogólnie znane techniki planowania eksperymentu, np. planowanie dwupoziomowe, trójpoziomowe, wielopoziomowe itd. Opis różnych technik planowania eksperymentów można znaleźć między innymi w [76].



Rys. 19. Przykład odwzorowania równomiernie rozmieszczonych punktów przestrzeni stanów S w punkty przestrzeni symptomów V

Fig. 19. Example of mapping for uniform distribution of points in the S state space into points of V symptom space

Innym przykładem postępowania stosowanego podczas planowania podstawowych badań symulacyjnych może być równomierne rozmieszczenie wybranych wartości cech stanów w przestrzeni stanów. Niestety, równomierne rozmieszczenie punktów w przestrzeni stanów S nie gwarantuje równomiernego rozmieszczenia odpowiadających im punktów w przestrzeni symptomów V . Nierównomierne rozmieszczenie danych w przestrzeni symptomów

(występowanie obszarów o najmniejszej liczbie danych w przestrzeni symptomów), odpowiadające równomiernemu rozmieszczeniu danych w przestrzeni stanów, ma bezpośredni wpływ na jakość wyznaczanego modelu odwrotnego. Oczekiwana równomierność rozmieszczenia punktów w przestrzeni symptomów zależy od postaci odwzorowania przestrzeni stanów w przestrzeń symptomów, która nie jest znana w czasie planowania badań symulacyjnych. Rysunek 19 pokazuje przykład odwzorowania, które dla równomiernie rozmieszczonych punktów w przestrzeni stanów S nie zapewnia równomiernego rozmieszczenia odpowiadających im punktów w przestrzeni symptomów V . W celu umożliwienia graficznego zobrazowania takiego odwzorowania założono, że przestrzeń stanów jest przestrzenią dwuwymiarową (rozpiętą nad cechami $S1$ i $S2$), natomiast przestrzeń symptomów jest przestrzenią jednowymiarową.

4.2. Planowanie uzupełniających badań symulacyjnych

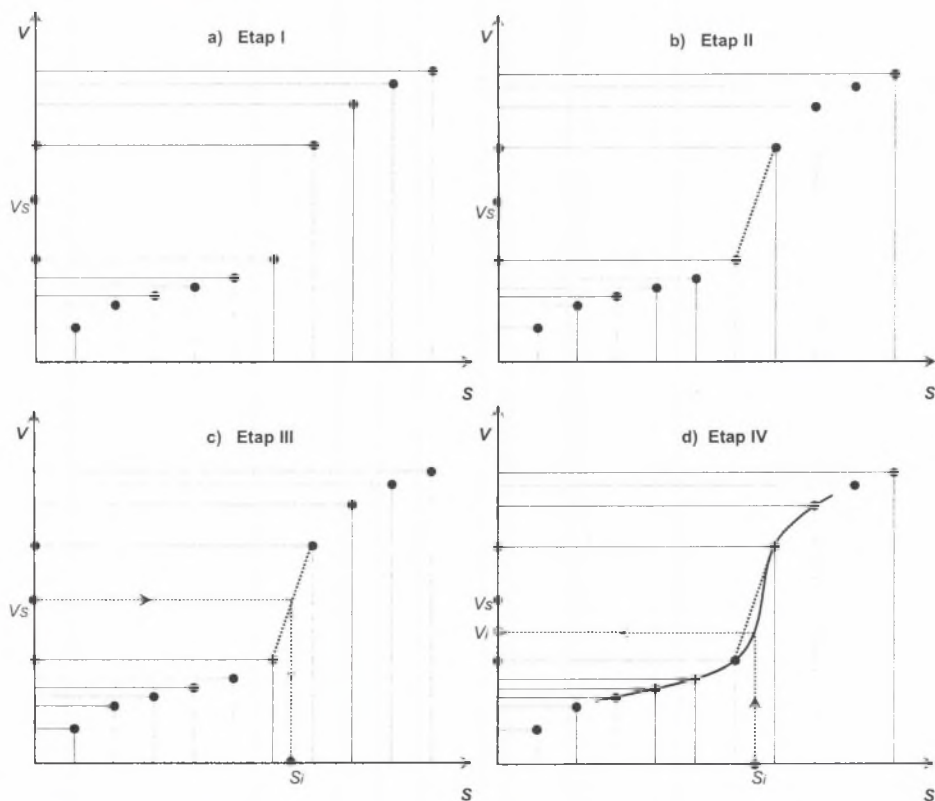
Do identyfikacji modeli lokalnych (rozpatrywane są właśnie takie modele) można stosować interpolacyjne modele odwzorowań. Zastosowanie interpolacji w celu identyfikowania modeli odwrotnych (pozwalających na określenie wartości cech stanów na podstawie symptomów) w przestrzeniach wielowymiarowych oznacza, że bezpośredni wpływ na jakość wyznaczanego modelu odwrotnego ma rozmieszczenie danych w przestrzeni symptomów V . Należy więc dążyć do odpowiedniego wypełnienia przestrzeni symptomów V nowymi przykładami. Celem uzupełniających badań symulacyjnych jest generowanie nowych przykładów, mających wypełniać obszary przestrzeni symptomów, w których jest najmniej danych. Wypełnianie obszarów o najmniejszej liczbie danych nowymi przykładami będzie prowadziło do optymalizacji jakości wyznaczanego modelu odwrotnego. Zaplanowanie uzupełniających badań symulacyjnych, podobnie jak badań podstawowych dla wybranych wartości cech stanów, pociągałoby za sobą konieczność wykonania bardzo dużej liczby obliczeń – wynika ona bezpośrednio z rozpatrywanych przestrzeni stanów, które są przestrzeniami wielowymiarowymi. W ogólnym przypadku mogłoby to nie doprowadzić do polepszenia jakości wyznaczanego modelu odwrotnego (odpowiedniego rozmieszczenia punktów w przestrzeni symptomów – zapełnienia obszarów o najmniejszej liczbie danych przykładami).

Dobór parametrów w sposób statyczny dla rozpatrywanego obiektu badań mógłby nie być właściwy dla innego obiektu badań (inne rozmieszczenie danych w przestrzeni symptomów – obszary o najmniejszej liczbie danych w innych miejscach przestrzeni). Wymaga się więc opracowania metod adaptacyjnego sterowania procesem planowania badań symulacyjnych. Metody te na podstawie przeprowadzonej analizy rozmieszczenia danych w przestrzeni symptomów V będą wskazywać odpowiednie zadania dla modelu numerycznego obiektu (podanie na wejście modelu numerycznego odpowiednich wartości cech stanów rozpatrywanego obiektu).

4.3. Adaptacyjne sterowanie procesem badań symulacyjnych

Celem adaptacyjnego sterowania procesem badań symulacyjnych jest poprawa jakości (doskonalenie) wyznaczanego modelu odwrotnego. Poprawę jakości wyznaczanego modelu proponuje się uzyskać przez odpowiednie wypełnienie danymi przestrzeni symptomów.

Należy jednak zwrócić uwagę, że w niektórych przypadkach poprawa jakości wyznaczanego modelu nie będzie możliwa. Powodem takiej sytuacji może być niejednoznaczność odwzorowania przestrzeni stanów S w przestrzeń symptomów V (rys. 3). Rysunek 20 ilustruje koncepcję prowadzenia adaptacyjnych badań symulacyjnych. W celu umożliwienia graficznego zobrazowania tej koncepcji założono, że przestrzeń stanów oraz przestrzeń symptomów są przestrzeniami jednowymiarowymi.



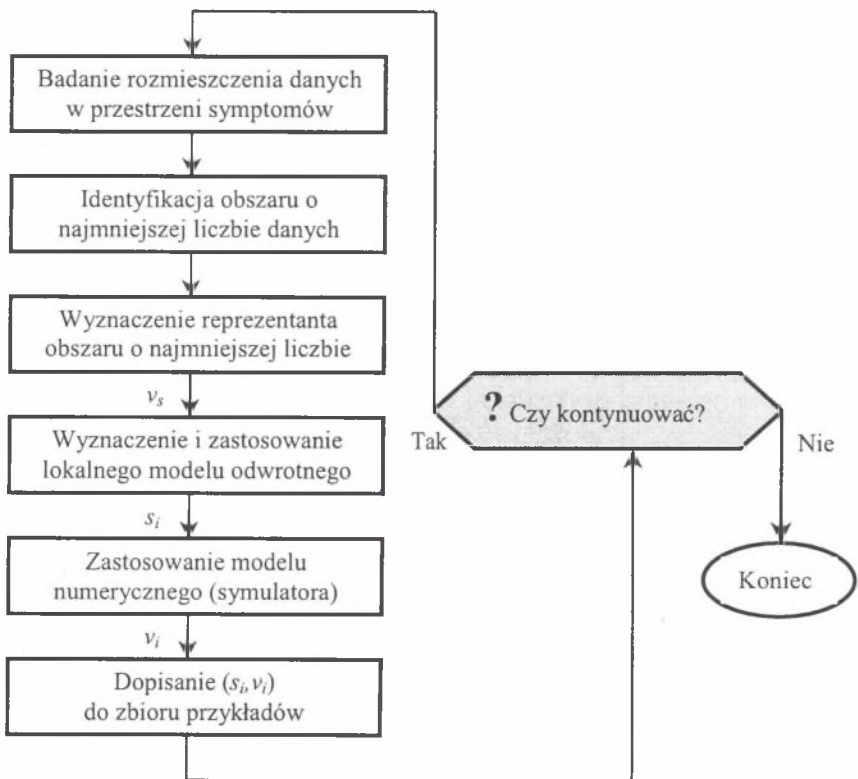
Rys. 20. Ilustracja kolejnych etapów procesu uzupełniania przestrzeni symptomów nowymi danymi - zbiór wyznaczonych wcześniej przykładów [63]

Fig. 20. Illustration of successive stages of new data generation process in symptom space – set of examples determined before [63]

Działania zmierzające do uzyskania nowych danych przykładowych, które zostaną dopisane do podstawowego zbioru przykładów, można podzielić na kilka etapów [29], [63], [66]:

- *Etap pierwszy* – identyfikacja w przestrzeni symptomów takiego obszaru o zadanym rozmiarze (np. objętości), który zawiera najmniej punktów oraz przyjęcie jego reprezentanta v_s (rys. 20a);
- *Etap drugi* – wyznaczenie wartości parametrów lokalnego modelu odwrotnego (rys. 20b);
- *Etap trzeci* – zastosowanie określonego wcześniej modelu lokalnego i wyznaczenie za jego pomocą wartości cech stanów s_i warunkujących (wg doskonalonego modelu odwrotnego) takie symptomy v_s (rys. 20c);
- *Etap czwarty* – zastosowanie symulatora w celu wyznaczenia cech symptomów v_i odpowiadających stanowi s_i (rys. 20d).

Wartości (v_i, s_i) stają się nowym przykładem, który dopisywany jest do podstawowego zbioru przykładów.



Rys. 21. Koncepcja procesu uzupełniania przestrzeni symptomów danymi [61]

Fig. 21. Concept of new data generation process in symptom space [61]

Należy zwrócić uwagę na to, że stosowany (w etapie trzecim) model odwrotny w rozpatrywanym przedziale jest pewnym przybliżeniem pełnej, nieznannej postaci modelu odwzorowania przestrzeni stanów w przestrzeń symptomów. Dlatego też zastosowanie symulatora dla wyznaczonych wartości s_i powoduje najczęściej, że wartości v_i otrzymane po zastosowaniu modelu nie będą równe wyznaczonym wcześniej wartościom reprezentanta obszaru v_s . Powtarzanie tych kroków spowoduje (w większości przypadków) coraz większe zagęszczanie się danych w przestrzeni symptomów, co z kolei prowadzi (w większości przypadków) do uzyskania modelu o wyższej jakości.

Przedstawione działania zmierzają do równomiernego wypełnienia przestrzeni symptomów danymi w sposób iteracyjny (rys. 21). Pojawia się pytanie: kiedy uznać, że przestrzeń symptomów została już wypełniona wystarczającą liczbą nowych przykładów? Czynnikiem informującym o możliwości zakończenia dalszego wypełniania przestrzeni symptomów nowymi przykładami może być jakość wyznaczanego modelu odwrotnego. Dla potrzeb określenia jakości tego modelu wymagane jest wprowadzenie odpowiedniej miary.

Kolejnym zagadnieniem wymagającym rozwiązania w celu umożliwienia adaptacyjnego sterowania badaniami symulacyjnymi jest określenie sposobu oraz metod badania rozmieszczenia danych w przestrzeni symptomów (poszukiwanie w przestrzeni symptomów obszarów o najmniejszej liczbie danych). Badanie to może być przeprowadzane globalnie oraz lokalnie. W kolejnych podrozdziałach zostaną opisane oba podejścia (globalne, lokalne), podstawowe wady i zalety takich podejść oraz metody umożliwiające badanie rozmieszczenia danych w przestrzeniach wielowymiarowych.

4.3.1. Miara jakości wyznaczanego modelu

Zgodnie z założeniami, że wyznaczone modele odwrotne będą modelami lokalnymi, rozważana miara jakości powinna pozwolić na określanie jakości takich właśnie modeli, przy czym nie musi umożliwiać określenia jakości globalnego modelu odwrotnego, np. wyznaczanego w wyniku trenowania sieci neuronalnej. Zakładając, że optymalizacja jakości modelu będzie przeprowadzana w obszarze związanym z wyróżnionym punktem w przestrzeni symptomów V (którego współrzędne mogą być określone np. w wyniku pomiaru na rzeczywistym obiekcie), wartość miary jakości wyznaczanego modelu może być oparta na kryteriach stosujących miary podobieństwa lub odległości pomiędzy dwoma punktami w przestrzeni symptomów. Wartość miary zależy od odległości pomiędzy dwoma punktami w przestrzeni symptomów, gdzie:

- pierwszy punkt określany jest przez wartości cech sygnałów diagnostycznych, dla których określane będą wartości stanów (rys. 20 – v_s);
- drugi punkt (rys. 20 – v_i) określany jest w wyniku stosowania symulatora dla stanów (rys. 20 – v_i) wyznaczonych przez model odwrotny .

Do najczęściej stosowanych miar podobieństwa lub odległości można zaliczyć [25]:

- miary podobieństwa,

$$simi_1(\underline{v}_i, \underline{v}_j) = \frac{1}{1 + \alpha \text{dist}(\underline{v}_i, \underline{v}_j)^\beta} \quad (93)$$

$$simi_2(\underline{v}_i, \underline{v}_j) = 1 - \frac{\text{dist}(\underline{v}_i, \underline{v}_j)}{\max_{i,j} (\text{dist}(\underline{v}_i, \underline{v}_j))} \quad (94)$$

$$simi_3(\underline{v}_i, \underline{v}_j) = e^{-\alpha \text{dist}(\underline{v}_i, \underline{v}_j)} \quad (95)$$

- odległość Mahalanobisa,

$$\text{dist}(\underline{v}_i, \underline{v}_j) = \sqrt{(\underline{v}_i - \underline{v}_j)^T \underline{\Sigma}^{-1} (\underline{v}_i - \underline{v}_j)} \quad (96)$$

$$\underline{\Sigma} = E \left\{ (\underline{v} - E\{\underline{v}\}) (\underline{v} - E\{\underline{v}\})^T \right\}$$

- odległość Minkowskiego,

$$\text{dist}(\underline{v}_i, \underline{v}_j) = \left(\sum_{k=1}^{\dim(V)} |v_{i,k} - v_{j,k}|^s \right)^{1/s} \quad (97)$$

- odległość euklidesową (szczególny przypadek odległości Minkowskiego dla $s=2$),

$$\text{dist}(\underline{v}_i, \underline{v}_j) = \sqrt{(\underline{v}_i - \underline{v}_j)^T (\underline{v}_i - \underline{v}_j)} \quad (98)$$

- odległość „Manhattan” (szczególny przypadek odległości Minkowskiego dla $s=1$)

$$\text{dist}(\underline{v}_i, \underline{v}_j) = \sum_{k=1}^{\dim(V)} |v_{i,k} - v_{j,k}| \quad (99)$$

Zastosowanie wymienionych zależności jest możliwe po odpowiednim przekształceniu przestrzeni wartości cech tak, aby przestrzeń ta mogła być rozpatrywana jako przestrzeń metryczna. Nie jest to zadanie proste, zwłaszcza wtedy, gdy rozpatrywana przestrzeń rozpięta jest nad cechami o nieporównywalnych wielkościach oraz gdy brak jest formalnych podstaw uzasadniających przyjęcie skal poszczególnych współrzędnych. W takiej sytuacji zaleca się normalizację przestrzeni wartości cech tak, aby zbiory wartości kolejnych współrzędnych posiadały zerową wartość średnią i jednostkowe odchylenie standardowe. Jednym ze

sposobów normalizacji przestrzeni wartości cech ilościowych jest wprowadzenie współczynników wagowych różnicujących poszczególne współrzędne [25].

Z porównania różnych postaci funkcji odległości [25] wynika, że w większości przypadków wartości tych funkcji rosną ze wzrostem liczby wymiarów przestrzeni, w której są one wyznaczone. W celu zmniejszenia wpływu liczby wymiarów przestrzeni wartości cech na wartości funkcji podobieństwa elementów można przeprowadzić skalowanie funkcji odległości przed zastosowaniem jej do określenia funkcji podobieństwa. Przykład takiego skalowania widać w zależności (94).

Bazując na przedstawionych wzorach (93) - (99) miarę jakości wyznaczanego lokalnego modelu odwrotnego proponuje się określać wg wzoru [29], [63]:

$$J(\underline{v}) = \frac{1}{1 + \alpha \text{dist}(\underline{v}, \underline{v}(\underline{s}(\underline{v})))}, \quad (100)$$

gdzie:

$\text{dist}(\bullet)$ - miara odległości wyznaczana zgodnie z (96) lub (98) w zależności od tego, czy rozpatrywana przestrzeń cech jest przestrzenią anizotropową, czy przestrzenią izotropową;

$J(\underline{v})$ - jakość wyznaczanego modelu odwrotnego, związana z punktem \underline{v} ;

\underline{v} - współrzędne wyróżnionego punktu w wielowymiarowej przestrzeni symptomów (rys. 20 - v_s);

$\underline{v}(\underline{s}(\underline{v}))$ - współrzędne punktu w wielowymiarowej przestrzeni symptomów wyznaczone na podstawie odwracania modelu, a następnie stosowania symulatora (rys. 20 - v_i);

α stała (czynnik skalujący zależny od liczby wymiarów rozpatrywanej przestrzeni symptomów).


Stała α w zależności (100) pełni bardzo ważną rolę. Zadaniem tej stałej jest uniezależnienie wartości wyznaczanej miary jakości od liczby wymiarów rozpatrywanej przestrzeni symptomów. Sposób wyznaczania wartości tej stałej zależy od tego, jak wyznaczana jest miara odległości. Na przykład, jeśli wyznaczana jest odległość „Manhattan”, zgodnie z zależnością (99), to wartość stałej α wyznacza się jako odwrotność liczby wymiarów; jeśli wyznaczana jest odległość euklidesowa, zgodnie z zależnością (98), to wartość stałej α wyznacza się jako pierwiastek odwrotności liczby wymiarów. Wartość miary $J(\underline{v})$ można uśredniać w wybranym otoczeniu rozpatrywanego punktu \underline{v} .

4.3.2. Metody badania rozmieszczenia danych w przestrzeniach wielowymiarowych

Badanie rozmieszczenia danych w przestrzeniach wielowymiarowych może być przeprowadzane na podstawie badań koncentracji przestrzennej. Metody badania koncentracji przestrzennej często stosowane są w zagadnieniach geograficznych do określenia stopnia skupienia dowolnych obiektów. Stosuje się je na przykład do określania koncentracji ludności na wybranym obszarze geograficznym [81]. Samo pojęcie koncentracji może być różnie definiowane. Czasami maksymalną koncentrację definiuje się jako:

1. Skupienie wszystkich obiektów w jednym punkcie. W takim ujęciu minimalna koncentracja oznacza maksymalny rozstęp między wszystkimi punktami, który zagwarantowany jest rozmiarami badanego obszaru.
2. Lokalizację wszystkich obiektów w najmniejszej jednostce przestrzennej. Wszystkie punkty znajdują się w jednym wyodrębnionym podobszarze rozpatrywanego obszaru bez względu na rozmieszczenie punktów w tym podobszarze. W takim ujęciu minimalna koncentracja oznacza proporcjonalny udział obiektów we wszystkich wyodrębnionych podobszarach rozpatrywanego obszaru.

Te dwie definicje nie są równoważne, co widać na rys 22. Oczywiście, metody badania koncentracji stosowane w geografii dotyczą zazwyczaj przestrzeni o niewielkiej liczbie wymiarów (najczęściej przestrzeni dwu- lub trójwymiarowych). Niektóre z tych metod można jednak uogólnić na większą liczbę wymiarów. Z metod stosowanych w geografii do badania koncentracji przedstawiono w niniejszej pracy dwie metody, a mianowicie: badanie koncentracji na podstawie wskaźnika Lorenza oraz badanie koncentracji z uwzględnieniem lokalizacji obiektów. Trzecia metoda, polegająca na losowaniu kolejnych podobszarów, jest oryginalną metodą, zaproponowaną przez autora.



Rys. 22. Przykłady różnie rozumianej maksymalnej koncentracji [81]

Fig. 22. Example of differently considered maximum concentration [81]

Podział obszaru przestrzeni wartości cech na podobszary

Do prowadzenia rozważań dotyczących badania koncentracji konieczne jest określenie sposobu podziału rozpatrywanego obszaru przestrzeni na podobszary. Rozważania będą

prowadzone dla cech ilościowych. N -wymiarowa przestrzeń wartości cech może być rozpięta na osiach, dla których wartości cech mogą przyjmować:

- wartości ciągłe z pewnego przedziału (np. wartość skuteczna amplitudy przemieszczeń drgań);
- wartości dyskretne z bardzo licznego zbioru wartości (np. wartości mierzonych drgań sygnału analogowego po kwantowaniu amplitudy dla potrzeb zapisania tego sygnału w postaci cyfrowej);
- wartości dyskretne z nielicznego zbioru wartości – w szczególnym przypadku cechy dwuwartościowe (np. cecha opisująca stan zaworu – zawór otwarty, zawór zamknięty).

Dodatkowo przestrzeń wartości cech może być rozpięta nad cechami o różnych rzędach wielkości. W takiej sytuacji (o czym wspomniano wcześniej) zaleca się normalizację przestrzeni wartości cech, tak aby wartości cech posiadały zerową wartość średnią i jednostkowe odchylenie standardowe. W dalszych rozważaniach zakłada się, że przestrzeń wartości cech jest przestrzenią izotropową lub znormalizowaną.

Zakłada się, że podział rozpatrywanego obszaru będzie wykonany na podobszary o równej objętości. Podziału takiego można dokonać w następujący sposób:

- dla cech o wartościach ciągłych zakres zmienności wartości każdej z rozpatrywanych cech dzieli się na k_i przedziałów ($i=1,2,\dots,N$; k_i może przyjmować dowolne wartości ze zbioru liczb naturalnych – $k_i \in N$);
- dla cech o wartościach dyskretnych z bardzo licznego zbioru wartości zakres zmienności wartości cech dzieli się na k_i przedziałów ($k_i \leq Lw_i$, gdzie Lw_i jest liczbą wartości dyskretnych, które może przyjmować i -ta cecha, $k_i \in N$);
- dla cech o wartościach dyskretnych z nielicznego zbioru wartości jako podział zakresu zmienności wartości cech przyjmuje się wartości tych cech, czyli $k_i = Lw_i$, gdzie Lw_i jest liczbą wartości dyskretnych, które może przyjmować i -ta cecha, $k_i \in N$).

W wyniku takiego podziału otrzyma się następującą liczbę podobszarów :

$$L = \prod_{i=1}^N k_i , \tag{101}$$

gdzie:

L - liczba uzyskanych podobszarów;


k_i - liczba przedziałów, na które dzieli się zakres zmienności i -tej cechy ($i = 1, 2, \dots, N$).

Rysunek 23 pokazuje przykład podziału rozpatrywanego obszaru na równe podobszary, przy czym rozpatrywane cechy V_1, V_2, V_3 są cechami o wartościach ciągłych z przedziałów $(V_{i \min}, V_{i \max})$.

Podziału dokonano dzieląc zakresy zmienności wartości cech w następujący sposób:

- dla cechy V_1 przyjmującej wartości z przedziału $\langle V_{1\min}, V_{1\max} \rangle$ przyjęto $k_1=2$;
- dla cechy V_2 przyjmującej wartości z przedziału $\langle V_{2\min}, V_{2\max} \rangle$ przyjęto $k_2=3$;
- dla cechy V_3 przyjmującej wartości z przedziału $\langle V_{3\min}, V_{3\max} \rangle$ przyjęto $k_3=2$.

Otrzymuje się w ten sposób $L=12$ podobszarów, które przyjmują kształty prostopadłościów.



Rys. 23. Przykład podziału rozpatrywanego obszaru przestrzeni cech o wartościach ciągłych dla $k_1=2$, $k_2=3$, $k_3=2$

Fig. 23. Example of partition of considered area of continuous features space for $k_1=2$, $k_2=3$, $k_3=2$


Rysunek 24 pokazuje przykład podziału rozpatrywanego obszaru na równe podobszary, przy czym cechy V_1 i V_2 są cechami o wartościach ciągłych, natomiast cecha V_3 jest cechą dwuwartościową. Podziału dokonano dzieląc zakresy zmienności wartości cech w następujący sposób:

- dla cechy V_1 przyjmującej wartości z przedziału $\langle V_{1\min}, V_{1\max} \rangle$ przyjęto $k_1=2$;
- dla cechy V_2 przyjmującej wartości z przedziału $\langle V_{2\min}, V_{2\max} \rangle$ przyjęto $k_2=3$;
- dla cechy V_3 przyjmującej wartości V_{31} i V_{32} przyjęto $k_3=2$.

Podobnie jak w poprzednim przykładzie otrzymuje się w ten sposób $L=12$ podobszarów, które przyjmują kształty prostokątów (prostopadłościów o wysokości $h=0$).

Podczas rozpatrywania przestrzeni wielowymiarowych, w ogólnym przypadku, podobszary będą przyjmować kształty wielowymiarowych kostek. W dalszej części pracy w celu

uproszczenia rozważań będą rozpatrywane przestrzenie, które rozpięte są nad cechami o wartościach ciągłych lub wartościach dyskretnych z bardzo licznego zbioru wartości. Uogólnienie tych metod na przestrzenie rozpięte nad cechami o nielicznym zbiorze wartości nie stwarza żadnych trudności.



Rys. 24. Przykład podziału rozpatrywanego obszaru przestrzeni cech o wartościach ciągłych (V_1 i V_2) i dyskretnych (V_3) dla $k_1=2, k_2=3, k_3=2$

Fig. 24. Example of partition of considered area of continuous features space (V_1 i V_2) and discrete features (V_3) for $k_1=2, k_2=3, k_3=2$

Badanie koncentracji na podstawie wskaźnika Lorenza

Krzywa koncentracji Lorenza opisana jest w [81]. Nadaje się ona do równoczesnego porównania rozkładu kumulacyjnego pary zjawisk. W przypadku badania przestrzennej koncentracji punktów na jednej osi prostokątnego układu współrzędnych odkłada się skumulowaną objętość podobszarów, a na drugiej - skumulowaną liczbę punktów znajdujących się w podobszarach.

Rozpatrywany obszar P N -wymiarowej przestrzeni cech dzieli się na L rozłącznych dowolnych podobszarów takich, których objętości spełniają następującą zależność:

$$VP = Vp_1 + Vp_2 + \dots + Vp_L \quad (102)$$

Liczbę punktów, znajdujących się w i -tym obszarze, oznacza się przez m_i , stąd:

$$M = \sum_{i=1}^L m_i, \quad (103)$$

gdzie: M – całkowita liczba punktów.

Koncentracja, w tym ujęciu, oznacza skupienie punktów w ramach mniejszej lub większej liczby podobzarów. W celu utworzenia szeregów kumulacyjnych liczby punktów znajdujących się w podobzarach i objętości podobzarów porządkuje się ciąg $\{g\}$ w sposób malejący:

$$g_1 \geq g_2 \geq \dots \geq g_L, \tag{104}$$

gdzie:

$$g_i = \frac{m_i}{Vp_i} \tag{105}$$

Daje to podstawę do wypisania poszczególnych wyrazów szeregu:

$$\begin{aligned} z(x_1) &= m_1 & x_1 &= Vp_1 \\ z(x_2) &= m_1 + m_2 & x_2 &= Vp_1 + Vp_2 \\ \vdots & & \vdots & \\ z(x_L) &= m_1 + m_2 + \dots + m_L = M & x_L &= Vp_1 + Vp_2 + \dots + Vp_L = VP \end{aligned} \tag{106}$$

Zestawienie takie umożliwia znalezienie dwóch dystrybuant empirycznych:

$$F(x_i) = \frac{z(x_i)}{M} \quad \text{i} \quad G(x_i) = \frac{x_i}{VP}, \tag{107}$$

gdzie:

$$F(x_L) = 1 \quad \text{i} \quad G(x_L) = 1 \tag{108}$$

Zestawiając pary liczb:

$$\{F(x_i), G(x_i)\}; \quad i = 1, 2, \dots, L \tag{109}$$

przenosi się je w postaci punktów na płaszczyznę prostokątną układu współrzędnych. Po złączeniu punktów odcinkami prostych otrzymuje się wielobok koncentracji, a po wygładzeniu – krzywą koncentracji Lorenza (rys. 25). Przy proporcjonalnym wzroście obu dystrybuant iloraz:

$$\frac{F(x_i)}{G(x_i)} = 1 \quad (\text{dla wybranego } x_i) \tag{110}$$

W takim przypadku krzywa pokrywa się z linią równomiernego rozdziału, czyli przekątną kwadratu. Gdy wszystkie punkty skoncentrowane są w jednym podobzarze, krzywa ma jeden skok. W celu wyznaczenia liczbowej miary koncentracji konieczne jest wprowadzenie pojęcia pola koncentracji – jest to pole zawarte między krzywą Lorenza a linią równomiernego podziału (rys. 25). Liczbową wartość miary koncentracji oblicza się [81]:

$$\eta = \frac{\text{pole koncentracji}}{\text{pole połowy kwadratu}}; \quad 0 \leq \eta < 1 \tag{111}$$

Przedział zmienności wartości miary koncentracji określony zależnością (111) jest półotwarty. Pełna koncentracja wymagałaby skupienia wszystkich rozpatrywanych punktów w jednym punkcie. W ogólnym przypadku wskaźnik ten określony jest wzorem:

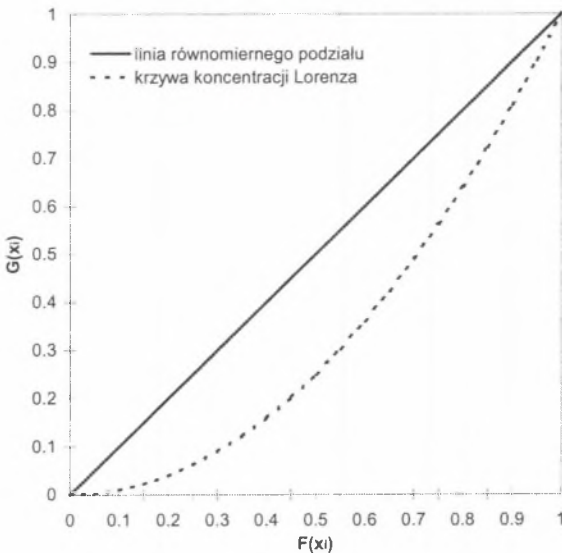
$$\eta = \frac{\int_0^1 [f(x) - g(x)] dx}{\int_0^1 g(x) dx}, \quad (112)$$

gdzie:

$f(x)$ - funkcja ciągła, przynajmniej dwukrotnie przedziałami różniczkowalna w przedziale $0 \leq x \leq 1$, opisująca krzywą koncentracji Lorenza;

$g(x)$ - funkcja ciągła, przynajmniej dwukrotnie przedziałami różniczkowalna w przedziale $0 \leq x \leq 1$, opisująca linię równomiernego podziału.

Koncentrację można obliczyć również poprzez maksymalną odległość pomiędzy funkcjami $f(x)$ i $g(x)$, tj. $\max |f(x) - g(x)|$.



Rys. 25. Przykład krzywej koncentracji Lorenza [81]

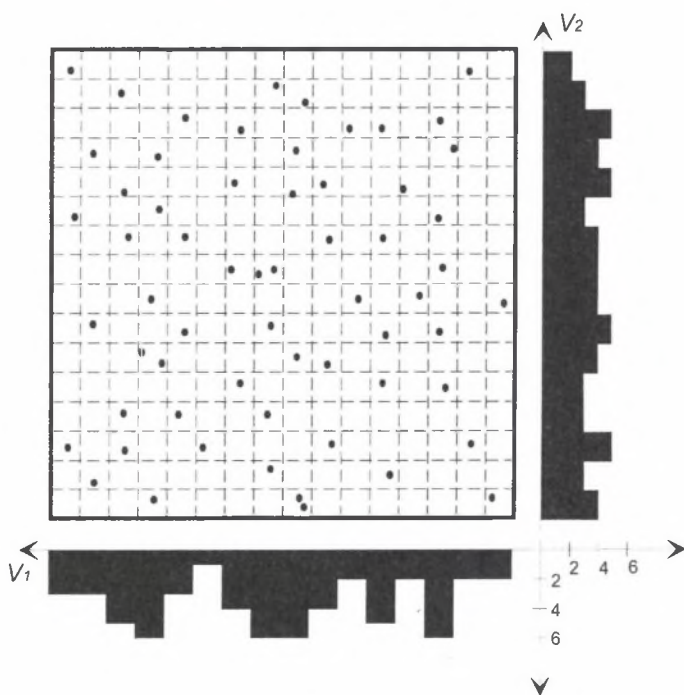
Fig. 25. Example of Lorenz's concentration curve [81]

Na wartość współczynnika koncentracji η ma wpływ jedynie liczba punktów znajdująca się w rozpatrywanych L podobszarach, a nie rozmieszczenie punktów w tych podobszarach, co według [81] jest niewątpliwą zaletą tej metody. Dla obu przykładów pokazanych na rys. 22

wartość miary koncentracji będzie taka sama $\eta=0$. Niewątpliwą zaletą tej metody jest to, że dwie krzywe Lorenza dadzą ten sam wskaźnik, pomimo że dotyczyć będą obszarów, w których punkty są w różnym stopniu skoncentrowane (na przykład jedna krzywa będzie miała „wybrzuszenie” w górnym rogu kwadratu, a druga – w dolnym). Słabą stroną tej analizy jest wpływ zmiany wielkości jednostki podziału rozpatrywanego obszaru na podobzary – rezultaty są nieporównywalne dla różnego rodzaju podziału na podobzary.

Badanie koncentracji z uwzględnieniem lokalizacji obiektów

Pierwszą czynnością wykonywaną podczas badania koncentracji z uwzględnieniem lokalizacji obiektów jest wykonanie rozkładów brzegowych dla poszczególnych wymiarów (osi). Sposób wykonania takich rozkładów zostanie opisany na przykładzie przestrzeni dwuwymiarowej. Zakres zmienności każdej z osi dzieli się na k_i przedziałów ($i=1,2,\dots,N$; N – liczba wymiarów rozpatrywanej przestrzeni), a następnie zlicza się punkty leżące w poszczególnych pionowych i poziomych „pasach”. Rysunek 26 pokazuje przykład rozkładów brzegowych gęstości punktów dla przestrzeni dwuwymiarowej, przy czym zakres zmienności wartości osi rozpatrywanej przestrzeni podzielono na taką samą liczbę przedziałów $k_1 = k_2 = 16$. W celu wykonania rozkładów brzegowych dla N wymiarów wykonuje się podział zmienności wartości dla każdej osi rozpatrywanej przestrzeni na k_i przedziałów ($i = 1, 2, \dots, N$).



Rys. 26. Rozkłady brzegowe gęstości punktów dla przestrzeni dwuwymiarowej

Fig. 26. Marginal distribution of density of points for two-dimensional space

Następnie wyznacza się dla poszczególnych rozkładów brzegowych ich wariancje według zależności:

$$\sigma_i^2 = \frac{\sum_{j=1}^{k_i} (l_{ij} - \bar{l}_i)^2}{k_i - 1}, \quad (113)$$

gdzie:

k_i - liczba przedziałów, na które podzielono wymiar i rozpatrywanej przestrzeni;

l_{ij} - liczba punktów znajdująca się w j -tym przedziale i -tego wymiaru (osi) rozpatrywanej przestrzeni;

\bar{l}_i - średnia liczba punktów wyznaczana dla i -tego wymiaru (osi) rozpatrywanej przestrzeni.

Wskaźnik, który pozwala mierzyć koncentrację, można wyznaczyć z zależności [81]:

$$\eta = \frac{1}{\sum_{i=1}^N \sigma_i^2} \quad (114)$$

Koncentracja w tym rozumieniu to miara statystyczna, za pomocą której bada się stopień skupienia zbioru punktów. Ponieważ wartość wskaźnika zawierającego się w przedziale $(0, \infty)$ utrudniała analizę, przekształcono go [81] w taki sposób, żeby po zmodyfikowaniu przyjmował wartości z domkniętego przedziału jednostkowego $(0 \leq \eta \leq 1)$. Aby to uzyskać, wystarczy sumę wariancji współrzędnych punktów podzielić przez sumę maksymalnych wariancji, jakie można osiągnąć w badanym obszarze dla poszczególnych wymiarów, czyli:

$$\eta = \frac{\sum_{i=1}^N \sigma_i^2}{\sum_{i=1}^N \sigma_{\max, i}^2} \quad (115)$$

Maksymalne wariancje rozkładów brzegowych dla poszczególnych wymiarów (osi) przestrzeni uzyskuje się, gdy wszystkie punkty znajdują się w jednym przedziale. Wariancje takie można wyznaczyć z zależności:

$$\sigma_{\max, i}^2 = \frac{(M - \bar{l}_i)^2 \sum_{j=1}^{k_i - 1} \bar{l}_i^2}{k_i - 1}, \quad (116)$$

gdzie:

M - ogólna liczba punktów;

k_i - liczba przedziałów, na które podzielono zakres zmienności wartości i -tego wymiaru (osi) rozpatrywanej przestrzeni;

\bar{l}_i - średnia liczba punktów wyznaczona dla i -tego wymiaru (osi).

W celu uproszczenia postaci ilorazu, a zatem samych obliczeń, można oprzeć się na największej wariancji

$$\sigma_{\max}^2 = \max\{\sigma_{\max,j}^2\} \quad (117)$$

i przyjąć:

$$\eta = \frac{\sum_{i=1}^N \sigma_i^2}{N\sigma_{\max}^2} \quad (118)$$

Wartość współczynnika koncentracji $\eta=1$ otrzymuje się, gdy punkty skoncentrują się w jednym podobszarze dowolnie położonym w badanym obszarze (bez względu na rozmieszczenie punktów w tym podobszarze) - wtedy wariancje rozkładów osiągną wartość maksymalną. Natomiast wartość współczynnika koncentracji $\eta=0$ otrzymuje się przy maksymalnym rozproszeniu rozpatrywanych punktów (w każdym podobszarze znajduje się taka sama liczba punktów); wtedy wariancje poszczególnych rozkładów brzegowych będą zerami.


Wariancje specyficznych rozkładów brzegowych, rozkładu skupionego w jednym punkcie i rozkładu jednostajnego są zależne od ogólnej liczby M punktów i liczby klas k_i rozkładów brzegowych. Niezależne są natomiast od liczby elementów podziału obszaru na podobszary, co stanowi dużą zaletę w stosunku do opisanej w poprzednim podrozdziale miary koncentracji opartej na krzywej Lorenza [81].

Badanie koncentracji metodą losowania kolejnych podobszarów

Bazą dla wyprowadzenia algorytmu badania koncentracji metodą losowania kolejnych podobszarów są metody określane w literaturze nazwą *Monte Carlo*. Opisy metod *Monte Carlo* można znaleźć między innymi w [75], [91]. Wyniki obliczeń otrzymanych przy użyciu metod *Monte Carlo* nie są wynikami dokładnymi; mają zawsze charakter przybliżony, co wynika z istoty tych metod, bazujących na pewnych operacjach losowych. Niemniej jednak metody te są chętnie stosowane. Znajdują szczególne zastosowania tam, gdzie nie są potrzebne dokładne wyniki ilościowe, a wystarczą jedynie wyniki przybliżone w celu zorientowania się, z jakim rzędem wielkości ma się do czynienia.

Zakłada się, że rozpatrywany będzie obszar P N -wymiarowej przestrzeni. Zakładając, że interesuje nas ocena równomierności rozmieszczenia danych w całym rozpatrywanym obszarze P , obszar ten należy podzielić na równe podobszary. Rysunek 27 pokazuje podział obszaru (ograniczonego liniami grubymi przerywanymi) na równe podobszary dla $k_1=k_2=5$, przy czym założono, że przestrzeń symptomów jest przestrzenią dwuwymiarową. Obszary zmienności dla poszczególnych wartości cech składowych zaznaczono linią grubą przerywaną. Współrzędne zaznaczonych punktów określono losowo. Proponowana metoda

polega na losowym wyborze podobszarów spośród L możliwych podobszarów (liczba podobszarów L wyznaczana jest zgodnie z zależnością (101)), a następnie sprawdzeniu, czy w wybranym podobszarze znajduje się wymagana liczba punktów.



Rys. 27. Przykład podziału obszaru na równe podobszary dla $k_1=k_2=5$ [63]

Fig. 27. Example of partion of area for equal regions for $k_1=k_2=5$ [63]

Zliczane są te podobszary, w których znajduje się wymagana liczba punktów. Miarę koncentracji można określić według następującej zależności:

$$\eta(q) = 1 - \frac{n(q)}{N}, \quad (119)$$

gdzie:

N - liczba losowań podobszarów;

$n(q)$ - liczba wylosowanych podobszarów w których znajduje się co najmniej q punktów.

$$n(q) = \sum_{\substack{j=1 \\ m_j \geq q}}^N 1, \quad (120)$$

gdzie:

m_j - liczba punktów znajdujących się w j -tym podobszarze ($j=1,2,\dots,L$);

q - założona wymagana liczba punktów w podobszarach.

Wartość miary koncentracji (119) zawarta jest w przedziale $0 \leq \eta \leq 1$. Aby rozpatrywana miara koncentracji odzwierciedlała rzeczywistą sytuację rozmieszczenia punktów, konieczne

jest odpowiednie przyjęcie wymaganej liczby punktów q znajdujących się w losowanych podobszarach. Złe przyjęcie liczby q prowadzi do błędnych wyników. Liczbę punktów q można wyznaczyć zgodnie z zależnością:

$$q = \begin{cases} \left[\frac{M}{L} \right] + 1 & \text{gdy } \left[\frac{M}{L} \right] < 1 \\ \left[\frac{M}{L} \right] & \text{gdy } \left[\frac{M}{L} \right] \geq 1 \end{cases}, \quad (121)$$

gdzie:

$[\]$ - oznacza cechę liczby;

M - całkowita liczba punktów;

L - liczba rozpatrywanych podobszarów.

Można się spodziewać, że zwiększenie liczby losowań będzie prowadzi do dokładniejszych wyników. Ponieważ jednak metoda ma charakter losowy, może okazać się, że wartość uzyskana na przykład dla $N=150$ losowań jest mniej dokładna niż dla $N=100$ losowań. Sprawą wymagającą rozstrzygnięcia jest określenie liczby losowań. Oszacowanie wartości liczby losowań N można przeprowadzić w zależności od liczby podobszarów, na które dzieli się obszar P . Liczbę N można obliczyć z zależności:


$$N = \frac{L}{l} \quad \text{dla } l=1,2,3,\dots \quad (122)$$

Wzrost liczby l powoduje zmniejszenie dokładności otrzymanych wyników miary koncentracji.

4.3.3. Globalna optymalizacja jakości modelu odwrotnego

Zakłada się, że po przeprowadzeniu procedury zmierzającej do globalnej optymalizacji jakości modelu szacowane wartości cech stanów otrzymanych w wyniku stosowania wyznaczonego lokalnego modelu odwrotnego dla dowolnych możliwych wartości cech sygnałów diagnostycznych będą poprawne. W przypadku takiej optymalizacji należy rozpatrywać całą przestrzeń rozpiętą nad możliwymi wartościami cech sygnałów diagnostycznych określonego obiektu badań. Rozpatrywana przestrzeń symptomów obejmuje zarówno wartości cech sygnałów diagnostycznych, świadczących o dobrym (idealnym) stanie technicznym rozpatrywanego obiektu (np. wartości drgań dla wirnika idealnie wyrównoważonego), jak i wartości cech sygnałów diagnostycznych, które świadczą o wyraźnej niesprawności badanego obiektu i nie pozwalają na dalszą jego eksploatację (np. bardzo duże drgania świadczące np. o bardzo dużych wartościach niewyważ przyłożonych na wirniku). Głównym celem globalnej optymalizacji jakości modelu odwrotnego jest dążenie do równomiernego wypełnienia danymi całego obszaru obejmującego wymienione dane w

przestrzeni symptomów. Działania zmierzające do takiej optymalizacji można wykonywać zgodnie ze schematem blokowym pokazanym na rysunku rys. 21.



Rys. 28. Przykładowe rozmieszczenie punktów w przestrzeni symptomów po globalnej optymalizacji jakości wyznaczanego modelu [63]

Fig. 28. Example of points distribution in the symptom space after the global quality optimisation of the determined model [63]

Dla potrzeb badania rozmieszczenia danych w przestrzeni symptomów można zastosować metody badania koncentracji opisane we wcześniejszych rozdziałach. W wyniku przeprowadzenia globalnej optymalizacji jakości modelu dane przykładowe będą rozmieszczone w przestrzeni w ten sposób, że prawie wszystkie podobszary będą zawierać tę samą liczbę przykładów. Rysunek 28 pokazuje przykładowe rozmieszczenie punktów po wykonaniu działań zmierzających do globalnej optymalizacji jakości modelu, gdzie założono, że przestrzeń symptomów jest przestrzenią dwuwymiarową. Nowe przykłady, które uzyskano w wyniku optymalizacji, przedstawiono jako punkty nie zaczernione.

Niewątpliwą zaletą globalnej optymalizacji jakości modelu odwrotnego jest uzyskanie modelu optymalnego pod względem jakości dla wszystkich możliwych wartości cech sygnałów diagnostycznych, które mogą wystąpić. Główną wadą takiego postępowania jest konieczność wykonania bardzo dużej liczby obliczeń. Zakłada się, że:

- $N=24$ – liczba cech składowych przestrzeni symptomów;
- $p=16000$ – liczba początkowych przykładów uzyskana w wyniku przeprowadzenia podstawowych badań symulacyjnych;
- $k=10$ – liczba przedziałów, na które dzieli się zakresy zmienności każdej z cech składowych obszarów.

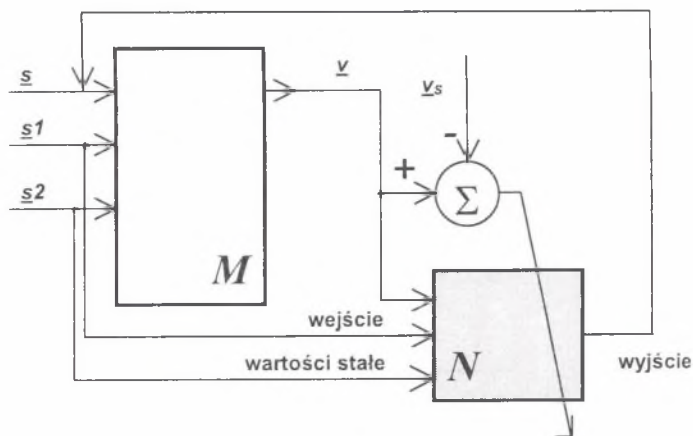
Dla tak przyjętych wartości liczba równych podobszarów, na które podzieli się rozpatrywany obszar, wynosić będzie $L=10^{24}$. Oznacza to, że doprowadzenie do sytuacji, w której w każdym podobszarze znalazłby się jeden przykład, wymagałoby dopisania $10^{24} - 16000$ przykładów, a na to nie można sobie pozwolić ze względu na długi czas obliczeń.

Należy postawić sobie następujące pytania:

- Czy konieczna jest globalna optymalizacja jakości modelu?
- Czy – być może – niektóre wartości symptomów nigdy nie wystąpią?

4.3.4. Lokalna optymalizacja jakości modelu odwrotnego

Bardziej efektywnym sposobem optymalizacji jakości wyznaczanego modelu odwrotnego będzie lokalna optymalizacja jakości modelu, związana z lokalnym modelem odwrotnym wyznaczanym dla wyróżnionego punktu w przestrzeni symptomów. Rysunek 29 pokazuje koncepcję wyznaczania lokalnych modeli odwrotnych oraz optymalizację ich jakości przez aktualizację zbioru przykładów.

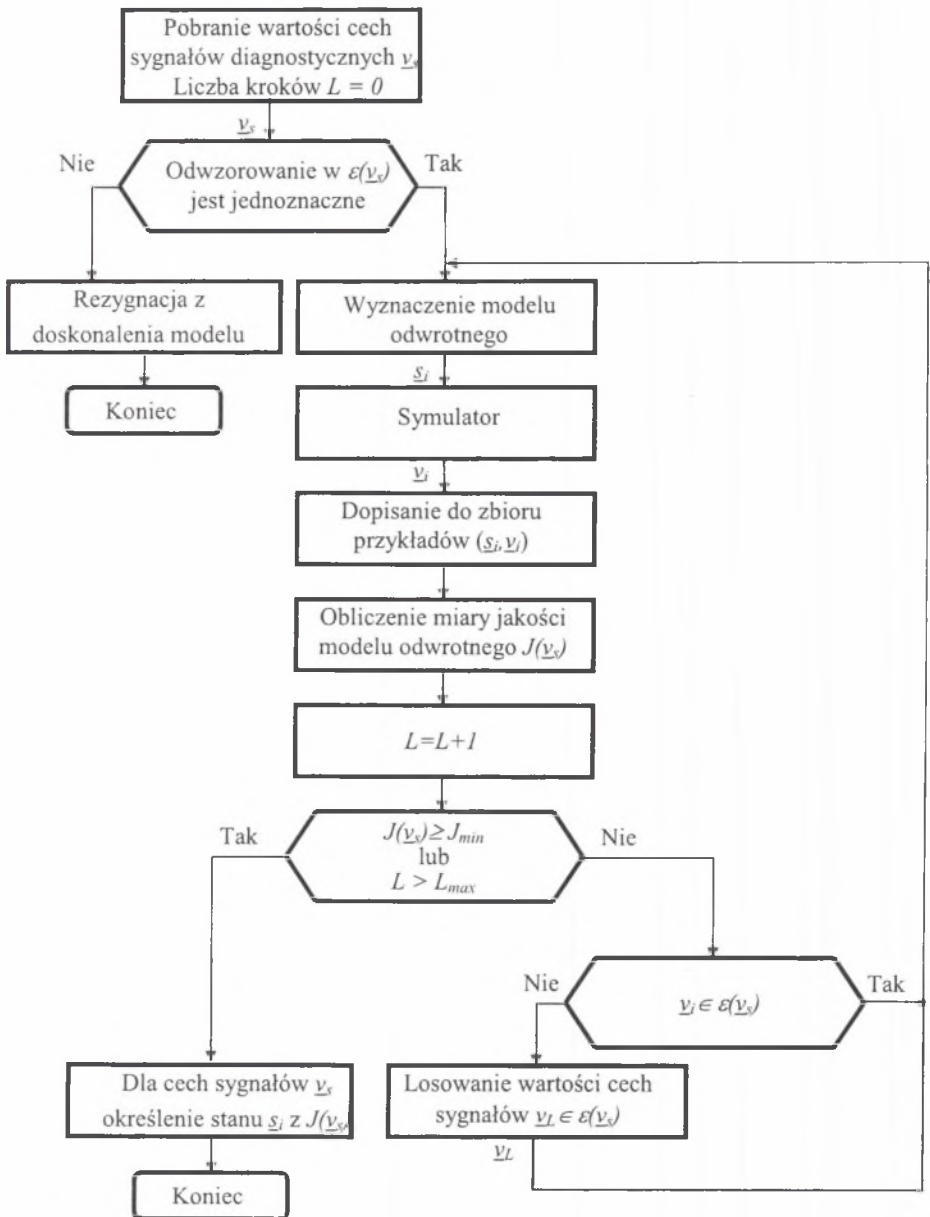


Rys. 29. Wyznaczanie lokalnego modelu odwrotnego N związanego z wyróżnionym punktem przestrzeni symptomów \underline{v}_s , dla którego wyznaczone będą odpowiadające mu wartości cech stanów (proponycja autora na podstawie rys. 7)

Fig. 29. Determination of local inverse model N connected with distinguished \underline{v}_s point of symptom space, for which corresponding values of state feature will be determined (the autor's proposal based on fig. 7)

Szczegółowa procedura zmierzająca do lokalnej optymalizacji jakości modelu może działać zgodnie z algorytmem pokazanym na rys. 30. Algorytm zmierza do optymalizacji jakości

lokalnego modelu odwrotnego, związanego z wyróżnionym punktem przestrzeni symptomów \underline{v}_s .




Rys. 30. Algorytm lokalnej optymalizacji jakości modelu odwrotnego

Fig. 30. Algorithm of local quality optimisation of inverse model

W pierwszym kroku dokonuje się oceny jednoznaczności odwzorowania w najbliższym otoczeniu rozpatrywanego punktu \underline{v}_s (otoczenie to może być określone np. przez liczbę najbliższych sąsiadów). W celu oceny jednoznaczności odwzorowania można zastosować metody badania jednoznaczności odwzorowania opisane w rozdziale Dodatek A. Po stwierdzeniu braku jednoznaczności odwzorowania dalsze działania są przerywane, co nie uniemożliwia budowy modelu odwrotnego, a jedynie ogranicza możliwość jego doskonalenia (element ten wymaga rozwinięcia w dalszych etapach prac związanych z rozwijaniem metod doskonalenia modeli odwrotnych). W przypadku stwierdzenia jednoznaczności odwzorowania podejmowane są działania adaptacyjnego sterowania badaniami symulacyjnymi.

Decyzja o przerwaniu dalszej optymalizacji jakości wyznaczanego modelu może być podjęta wtedy, gdy:

1. Uzyskano oczekiwaną jakość wyznaczanego modelu związanego z wyróżnionym w przestrzeni symptomów punktem \underline{v}_s .
2. Wykonano zadaną liczbę kroków. Ograniczenie dotyczące zadanej liczby powtórzeń wynikać może np. z czasu, który można przeznaczyć na doskonalenie modelu.



Rys. 31. Przykładowe rozmieszczenie punktów w przestrzeni symptomów po lokalnej optymalizacji jakości wyznaczanego modelu [63]

Fig. 31. Example of points distribution in the symptom space after the local quality optimisation of determined model [63]

W wyniku przeprowadzenia lokalnej optymalizacji jakości modelu dane przykładowe będą rozmieszczone w przestrzeni symptomów w postaci skupisk grupujących się wokół wyróżnionych punktów, dla których dokonywano optymalizacji jakości wyznaczanego modelu. Rysunek 31 pokazuje przykładowe rozmieszczenie punktów po wykonaniu działań zmierzających do lokalnej optymalizacji jakości modelu, gdzie założono, że przestrzeń

symptomów jest przestrzenią dwuwymiarową. Strzałki na rysunku wskazują punkty, dla których przeprowadzono optymalizację jakości modelu. Nowe przykłady, które uzyskano w wyniku optymalizacji jakości modelu, pokazano jako punkty nie zaczerpnięte. Widać, że nie wszystkie podobszary rozpatrywanej przestrzeni symptomów zostały równomiernie wypełnione.

Kwestią wymagającą rozstrzygnięcia jest określenie obszaru wokół punktu \underline{v}_s , w którym losowane są współrzędne symptomów \underline{v}_L . Obszar ten nie może być za duży, gdyż będzie to prowadzić do sytuacji, w której nowe przykłady uzupełniane będą „za daleko” od punktu \underline{v}_s (nie będzie aktualizowany zbiór najbliższych sąsiadów). Z drugiej jednak strony nie może on być również za mały. Mogą wystąpić przypadki, w których za każdym razem dla danych losowych będą występować ci sami najbliżsi sąsiedzi powodując wyznaczenie tych samych lub bardzo zbliżonych wartości stanów. Wydaje się, że rozsądne jest określenie tego obszaru w postaci wielowymiarowej kostki, której wymiary określone mogą być na podstawie współrzędnych najbliższego sąsiada rozpatrywanego punktu \underline{v}_s .

4.3.5. Podsumowanie

W tym rozdziale zaproponowano realizację adaptacyjnego sterowania procesem badań symulacyjnych na podstawie dwóch niezależnych metod:

- metody globalnej optymalizacji jakości modelu odwrotnego;
- metody lokalnej optymalizacji jakości modelu odwrotnego.

Podkreślono, że metoda globalnej optymalizacji jakości modelu odwrotnego jest metodą mało racjonalną głównie ze względu na długi czas obliczeń, natomiast zastosowanie metody lokalnej optymalizacji jakości może spowodować pojawienie się pewnych pułapek, np. przy niepoprawnym określeniu obszaru (obszar zbyt duży lub zbyt mały), w którym mogą być losowane wartości cech sygnałów diagnostycznych.

Adaptacyjne sterowanie procesem badań symulacyjnych może być również realizowane przy zastosowaniu obydwu metod. Jednym z rozwiązań jest:

- 1) W pierwszym kroku stosowanie metody globalnej optymalizacji jakości modelu. Optymalizacja ta może być przeprowadzana w pewnym obszarze, określonym przez współrzędne rozpatrywanego punktu \underline{v}_s (nie jest konieczne rozpatrywanie obszaru globalnego, który zawierałby wszystkie możliwe wartości cech sygnałów diagnostycznych).
- 2) W drugim kroku stosowanie metody lokalnej optymalizacji jakości modelu. Optymalizacja ta powinna być przeprowadzana w obszarze określonym przez współrzędne rozpatrywanego punktu \underline{v}_s (rozpatrywany obszar powinien być obszarem lokalnym, charakteryzującym się tym, że będzie mniejszy od obszaru rozpatrywanego w pierwszym kroku).

Opisane podejście jest jednym z możliwych szczególnych rodzajów zastosowania proponowanych metod doskonalenia diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów. Szczegółowe określenie kryteriów, po spełnieniu których możliwe byłoby przejście z korku pierwszego do drugiego, wymaga przeprowadzenia badań. Dlatego też kryterium takie nie jest szczegółowo dyskutowane.

5. Weryfikacja metody adaptacyjnego sterowania badaniami symulacyjnymi

W rozdziale 4.3.4 opisano zaproponowaną przez autora metodę adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającą do optymalizacji jakości wyznaczanego odwrotnego modelu diagnostycznego przez aktualizację zbioru przykładów. Przeprowadzenie weryfikacji proponowanej metody wymagało wykonania kilku działań:

- wyboru obiektu badań;
- odwzorowania zachowań dynamicznych obiektu za pomocą modelu numerycznego;
- zaplanowania eksperymentu weryfikującego metodę oraz przygotowania niezbędnych narzędzi pozwalających na realizację eksperymentu;
- przeprowadzenia eksperymentu.

Dla potrzeb weryfikacji zaproponowanej metody wybrano obiekt z klasy maszyn wirnikowych łożyskowanych ślizgowo, a mianowicie wirnik dwupodporowy, będący fragmentem stanowiska do badań drgań wałów, znajdującego się w laboratorium Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach.

Wybór obiektu podyktowany został następującymi względami:

- jest to obiekt o małej liczbie elementów, prostej postaci konstrukcyjnej, możliwy jest jego łatwy demontaż, można prowadzić identyfikację własności dynamicznych (np. identyfikację sztywności oraz tłumienia podpór łożyskowych);
- opisywane stanowisko znajduje się w laboratorium Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach, co umożliwiło przeprowadzenie czynnych eksperymentów diagnostycznych na tym stanowisku;
- istniała możliwość symulowania stanów rozpatrywanego obiektu za pomocą pakietu programów MESWIR [56], [58], [80] opracowanego w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku, służącego do modelowania między innymi wirników dwupodporowych;
- maszyna wirnikowa często kwalifikowana jest jako maszyna „krytyczna”, czyli taka, której uszkodzenie mogłoby zagrażać życiu i przynieść ogromne straty finansowe. Dotyczy to zwłaszcza dużych obiektów energetycznych. Poszukiwanie więc dla tego rodzaju obiektów nowych i bardziej użytecznych metod identyfikacji relacji diagnostycznych jest szczególnie zasadne.


Weryfikację metody prowadzono posługując się danymi uzyskanymi zarówno z eksperymentu numerycznego, jak i z pomiarów wykonanych na rozpatrywanym obiekcie. Opisany w

kolejnych podrozdziałach proces weryfikacji proponowanej metody adaptacyjnego sterowania badaniami symulacyjnymi jest przykładem pokazującym metodologię prowadzenia badań dotyczących generowania i doskonalenia diagnostycznych modeli odwrotnych.

5.1. Opis stanowiska

Głównym elementem stanowiska jest zestaw *RotorKit* firmy *Bently Nevada* [94], [95], pozwalający na prowadzenie czynnych eksperymentów diagnostycznych. Stanowisko umożliwia zmianę stanu technicznego i wywoływanie najczęściej występujących niesprawności maszyn wirnikowych, takich jak:

- niewyrównoważenie;
- przycieranie wirnika;
- nadmierne przeciążenie maszyn wirnikowych.



Rys. 32. Obiekt badań [112]

Fig. 32. Investigated object [112]

Uzupełnienie stanowiska łożyskiem hydrodynamicznym umożliwia badanie:

- niestabilności działania łożysk hydrodynamicznych (wir i bicz olejowy);
- wpływu warunków zasilania łożyska olejem na pracę łożyska (np. możliwość zmiany ilości oleju zasilającego i położenia wlotu oleju na obwodzie panewki).

Na rys. 32 pokazano rozpatrywany obiekt badań, który składa się z następujących głównych elementów [111], [112]:

- wał;
- dwie tarcze;
- dwie podpory łożyskowe z łożyskami ślizgowymi;
- silnik elektryczny połączony podatnym sprzęgłem z wałem ;
- rama wsporcza;
- układ do pomiarów chwilowej prędkości obrotowej oraz przemieszczeń drgań względnych.

Położenie podpór oraz tarcz na wale może być dowolnie zmieniane. Liczne nagwintowane otwory wykonane w tarczach umożliwiają wprowadzanie niewyrównoważenia.

W skład stanowiska wchodzi również łożysko hydrodynamiczne, które można zainstalować jako jedno z łożysk końcowych. Olej do łożyska podawany jest przez pompę, a ilość oleju jest płynnie regulowana.

Układ regulacji prędkości obrotowej silnika umożliwia płynną zmianę prędkości w zakresie od 0 do 10000 [obr./min]. Pomiarów można dokonywać przy zmieniającej się prędkości obrotowej wału ze stałym przyspieszeniem kątowym. Wartość przyspieszenia kąтового można zmieniać w zakresie od 0 do 3200 [obr/min²].

Pomiaru chwilowej wartości prędkości obrotowej dokonuje się za pomocą czujnika przemieszczeń względnych. Czujnik mierzy zmiany pola magnetycznego wywołane obracającą się tarczą osadzoną na wale silnika, na której obwodzie naciętych jest dwanaście rowków.


5.1.1. Układ pomiarowy

Stanowisko wyposażone jest w układ sześciu czujników przemieszczeń względnych, działających na zasadzie prądów wirowych wraz z układem zasilająco-demodulującym (rys. 33). Czujniki zamocowane w odpowiednich uchwytach umożliwiają otrzymanie sygnałów przemieszczeń wału w płaszczyźnie prostopadłej do osi wału. Stanowisko wyposażone jest w wysokiej klasy układ do akwizycji sygnałów SigLab [106],[107]. Sterowanie działaniem układu SigLab odbywa się za pomocą oprogramowania napisanego w wewnętrznym języku programowania środowiska Matlab [78] (jest to środowisko do wykonywania cyfrowych analiz sygnałów i innych obliczeń naukowo-technicznych oraz

prezentacji graficznych wyników analiz). Dane pomiędzy SigLabem a komputerem PC przysyłane są magistralą SCSI.

Układ akwizycji sygnałów SigLab zawiera:

- cztery 16-bitowe przetworniki sigma/delta A/C;
- dwa 16-bitowe przetworniki sigma/delta C/A;
- procesor sygnałowy Analog Device AD2105 DSP jako filtr antyaliasingowy, działający w rzeczywistej skali czasu;
- procesor sygnałowy do generowania dowolnych funkcji jako sygnałów wyjściowych;
- zmiennoprzecinkowy procesor sygnałów Texas Instruments TMS320C31 DSP.



Rys. 33. Układy pomiarowe stanowiska badawczego

Fig. 33. Measuring systems of the investigation stand

Sterowanie układem SigLab odbywa się za pomocą oprogramowania wspomagającego proces akwizycji i analizy sygnałów (działającego w środowisku Matlab), składającego się, między innymi, ze współdziałających modułów:

- oscyloskopu;
- generatora sygnałów;
- analizatora widma.

Kolejnym elementem wyposażenia stanowiska badawczego jest przenośny miernik TK83 [50], który pozwala na pomiar:

- prędkości obrotowej wału;
- wartości przyspieszeń drgań składowych 1X, 2X oraz ich faz;

- wartości prędkości drgań składowych 1X , 2X oraz ich faz;
- wartości przemieszczeń drgań składowych 1X, 2X oraz ich faz.

Dla potrzeb prowadzonych badań pomiary przeprowadzano w dwóch płaszczyznach w okolicach podpór łożyskowych (rys. 32). W obu płaszczyznach mierzono przemieszczenia drgań w kierunku poziomym i pionowym.

5.1.2. Podstawowe dane techniczne stanowiska

Wał:

- średnica $D = 10$ [mm];
- długość $L = 580$ [mm].

Rozpiętość podpór wirnika: $l = 480$ [mm].

Panewki łożysk: masa $m_{p1} = m_{p2} = 12$ [g].

Tarcze:

- średnica $D_t = 75$ [mm];
- grubość $g = 25.5$ [mm];
- masa $m = 805$ [g];
- moment bezwładności tarczy z otworami względem osi obrotu $I_w = 0.5005$ [g m²].

W obu tarczach na średnicy 59.5 [mm] wykonanych jest 16 otworów umożliwiających wprowadzanie niewyrównoważenia:

- masy niewyrównoważenia m_{nw1} i m_{nw2} mogą przyjmować wartości od 0.2 [g] do 2 [g] z krokiem co 0.2 [g];
- promień niewyrównoważenia $r_{nw1} = r_{nw2} = 29.75$ [mm];
- kąty fazowe przyłożenia niewyrównoważenia mogą zmieniać się co 22.5[°].

Sztywność oraz tłumienie podpór łożysk wyznaczono eksperymentalnie [68], [112]. Panewki łożysk są mocowane w obudowach łożysk za pomocą gumowych pierścieni. Sztywność wyznaczono na podstawie uzyskanego eksperymentalnie wykresu przemieszczeń wału w podporze w funkcji reakcji podpory. Wyznaczone sztywności utwierdzeń panewek łożysk dla obu podpór w kierunku poziomym i pionowym są równe $\lambda_{11} = \lambda_{22} = 0.24 \cdot 10^6$ [N/m]. Tłumienie utwierdzeń panewek jest silnie nieliniowe w funkcji wartości amplitudy przemieszczeń drgań promieniowych panewki. Na podstawie logarytmicznego dekrementu tłumienia wyznaczone zostały tłumienia obu podpór łożysk (dla przemieszczeń o amplitudzie 100 [μm]) w kierunku poziomym i pionowym. Tłumienia te są równe i wynoszą $A_{11} = A_{22} = 10^5$ [Ns/m].

5.2. Model układu

Obiekt rzeczywisty, rozpatrywany pod względem zachowań dynamicznych, odwzorowany został za pomocą liniowego modelu teoretycznego i zespołu programów wchodzących w skład systemu MESWIR [56], [58], [80], opracowanego w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku. System programów MESWIR służy do analizy dynamiki wielopodporowych wirników łożyskowanych ślizgowo z zastosowaniem metody elementów skończonych MES.

5.2.1. Model numeryczny

Oddziaływania dynamiczne zachodzące w układach typu: linia wirników – łożyska ślizgowe – podpory – fundament, opisać można za pomocą liniowego bądź nieliniowego modelu teoretycznego [53]. W obu przypadkach z uwagi na fakt, iż są to układy wielomasowe i niesymetryczne, modele te są złożone [58] (uwaga ta odnosi się zwłaszcza do opisu nieliniowego).

Przy założeniu, że przemieszczenia względne czopów i panwi w łożyskach są dostatecznie małe, zasadne jest stosowanie w ograniczonym zakresie modeli liniowych. Liniowy opis przyjętego obiektu jest szczególnie istotny ze względu na badania związane z weryfikacją proponowanej metody (odwracanie modelu i doskonalenie modelu odwrotnego). Trajektorie drgań wymuszonych dowolnych węzłów układu (elipsy drgań) mogą być opisane przez cztery współczynniki A, B, C, D według schematu zaproponowanego w [58]:

$$\begin{aligned}x &= A \sin \tau + B \cos \tau \\y &= C \sin \tau + D \cos \tau,\end{aligned}\tag{123}$$

gdzie:

- $\tau = \omega \cdot t$ - bezwymiarowy czas;
- x - składowa pozioma elipsy drgań [m];
- y - składowa pionowa elipsy drgań [m].

W przypadku modelu nieliniowego niemożliwy jest opis trajektorii drgań w postaci (123). Konieczne staje się wówczas poszukiwanie cech opisujących trajektorie nieliniowe. Z uwagi na konieczność generowania setek lub tysięcy danych oraz zdecydowanie dłuższy czas obliczeń w przypadku opisu nieliniowego stosowanie modelu nieliniowego może powodować bariery nie do przekroczenia ze względu na możliwości obliczeniowe sprzętu komputerowego nawet o zaawansowanej technologii [55]. Z drugiej strony opis nieliniowy [55] stwarza jakościowo nowe możliwości analizy oddziaływań dynamicznych zachodzących w złożonych maszynach wirnikowych, co może być szczególnie istotne w diagnostyce tego rodzaju obiektów technicznych.

Biorąc pod uwagę fakt, że model będzie stosowany dla potrzeb weryfikacji proponowanej metody doskonalenia odwrotnych modeli diagnostycznych, można stwierdzić, że opis liniowy jest opisem wystarczającym.

Analiza liniowa zagadnień dynamiki wielopodporowych wirników łożyskowych ślizgowo nie eliminuje konieczności analizy nieliniowej w zagadnieniach kinetostatyki [57]. Opis teoretyczny układu mechanicznego, będącego sprzężeniem linii wirników, podpór i fundamentu, wymagał opracowania systemu komputerowego łączącego liniowe człony dynamiczne z nieliniowymi członami kinetostatycznymi. System taki o nazwie MESWIR [56], [58], [80], został opracowany w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku.

System komputerowy MESWIR składa się z zespołu kilku programów, z których do opisu przyjętego obiektu zastosowano [41]:

- Program KINWIR–D – realizuje obliczenia z zakresu kinetostatyki układu. Dla zadanych obciążeń zewnętrznych (ciężaru wirnika) i prędkości obrotowej wirnika program, poprzez iteracyjne przybliżenia, wyznacza położenia środków czopów w łożyskach. Obliczenia kinetostatyczne mają charakter silnie nieliniowy. Efektem tych obliczeń są współczynniki sztywności i tłumienia filmu smarnego, właściwe dla danej prędkości obrotowej wirnika i położenia równowagi statycznej środka czopa w łożyskach.
- Program DYNWIR–W – realizuje właściwe obliczenia dynamiczne w zakresie liniowym, tzn. oparte na założeniu, że drgania wymuszone czopów w łożyskach są na tyle małe, iż można przyjąć stałość współczynników sztywności i tłumienia w analizowanym obszarze luzów.


Program DYNWIR–W dla wybranych węzłów podaje wartości czterech współczynników A, B, C, D (wyznaczane zgodnie z zależnością (123)), które opisują wszystkie parametry elipsy drgań (półosie elipsy i opóźnienie fazowe) [58].

Programy KINWIR–D oraz DYNWIR–W zostały odpowiednio zmodyfikowane [58], [80] dla celów związanych z odwracaniem modelu. Modyfikacja ta umożliwia automatycznie generowanie danych wejściowych i uruchamianie tych programów przez specjalny program sterujący START.BAT [80].

5.2.2. Dyskretyzacja wirnika układu


Dla celów badań przyjęto konfigurację stanowiska określającą położenie podpór łożyskowych, tarcz i płaszczyzn pomiarowych, pokazaną na rys. 34.

Rysunek 35 pokazuje schemat dyskretyzacji obiektu, numerację węzłów i przyjęte odległości pomiędzy węzłami, natomiast rys. 36 i rys. 37 pokazują przyjęte układy współrzędnych.



Rys. 34. Wymiary montażowe stanowiska badawczego [112]

Fig. 34. Assembly dimensions of the investigated stand [112]




Rys. 35. Schemat dyskretyzacji wirnika stanowiska laboratoryjnego i numeracja węzłów [112]

Fig. 35. Schematic diagram for discretisation of laboratory rotor and the node numeration [112]

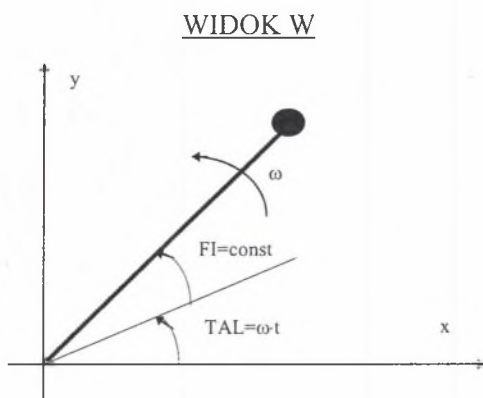
W przyjętej numeracji poszczególne węzły oznaczają:

- węzły nr 4 i 18 – odpowiednio podpora łożyskowa nr 1 i nr 2;
- węzły nr 8 i 12 – środki tarcz wirnika;
- węzły nr 6 i 16 – miejsca pomiaru drgań względnych czopa w dwu wzajemnie prostopadłych kierunkach (pionowym i poziomym) czujnikami przemieszczeń względnych dla łożyska nr 1 i nr 2.



Rys. 36. Przyjęty dla stanowiska układ współrzędnych prostokątnych (na podstawie [58])

Fig. 36. Established rectangular co-ordinate system for the stand (on the basis of [58])



Rys. 37. Przyjęty dla stanowiska układ współrzędnych dla przemieszczeń węzłów (na podstawie [58])


Fig. 37. Established co-ordinate system for stand for the nodal displacement (on the basis of [58])

5.2.3. Zakres weryfikacji doświadczalnej przyjętego modelu

Weryfikacja przyjętego modelu polegała na badaniu zgodności charakterystyk amplitudowych oraz fazowych w funkcji prędkości obrotowej, otrzymanych w wyniku pomiarów na stanowisku badawczym z charakterystykami uzyskanymi w wyniku stosowania modelu.


Ze względu na cel badań (przyszłe odwrócenie modelu, które ma umożliwić identyfikację różnych stanów niewyrównoważenia) istotne jest rozpatrywanie badanego obiektu dla częstotliwości bliskiej częstotliwości jednego z rezonansów (rozpatrywanie co najmniej trzech prędkości obrotowych wirnika: dla prędkości odpowiadających częstotliwościom poniżej, w okolicach oraz poza rezonansem [41]). W układzie wprowadzono stan niewyrównoważenia przykładając na tarczy nr 1 oraz tarczy nr 2 masę niewyrównoważenia 0.8 [g] pod kątami odpowiednio 90 [°] oraz 0 [°].

W płaszczyznach pomiarowych rejestrowano wartości przemieszczeń drgań oraz fazy tych drgań składowej 1X w kierunkach poziomym i pionowym dla prędkości obrotowej wirnika w zakresie 800-8000 [obr./min]. Na rys. 38 pokazano przebieg amplitudy przemieszczenia drgań, a na rys. 39 przebieg fazy przemieszczenia drgań w funkcji prędkości obrotowej. Pokazane charakterystyki wykonano dla przemieszczenia drgań składowej 1X sygnałów zarejestrowanych w kierunku poziomym w płaszczyźnie pomiarowej w pobliżu podpory łożyskowej nr 1 (rys. 34). Na podstawie przeprowadzonej analizy charakterystyk amplitudowych i fazowych w funkcji prędkości obrotowej postanowiono badać obiekt dla prędkości obrotowych, odpowiadających częstotliwościom w okolicach drugiego rezonansu. Powodem tego jest rzadko występująca w rzeczywistych obiektach wyjątkowo duża wartość dobroci układu [116] dla pierwszego rezonansu. Dalsze badania ograniczono do rozpatrywania układu dla prędkości obrotowych, odpowiadających częstotliwościom w okolicach drugiego rezonansu – w zakresie prędkości obrotowych 4000-8000 [obr./min].



Rys. 38. Przebieg amplitudy przemieszczeń drgań składowej 1X mierzonych w kierunku poziomym w płaszczyźnie pomiarowej w pobliżu podpory łożyskowej nr 1 [68]

Fig. 38. Run of amplitude of 1X component of vibration displacements measured near bearings no 1 in horizontal direction in measurement plane [68]



Rys. 39. Przebieg fazy przemieszczeń drgań składowej 1X mierzonych w kierunku poziomym w płaszczyźnie pomiarowej w pobliżu podpory łożyskowej nr 1 [68]


Fig. 39. Run of phase of 1X component of vibration displacement measured near bearing no 1 in horizontal direction in measurement plane [68]

5.2.4. Wyniki badań i wnioski

Na rysunkach (rys. 40 i rys. 41) porównano charakterystyki przebiegów amplitud i faz przemieszczeń drgań w funkcji prędkości obrotowej badanego obiektu z charakterystykami otrzymanymi za pomocą modelu. Przebiegi oznaczone na rysunkach jako „Model 1” zostały wyznaczone w wyniku stosowania modelu dla wartości sztywności i tłumienia podpór łożyskowych wyznaczonych doświadczalnie (rozdział 5.1.2).


W celu lepszego dopasowania modelu do obiektu skorygowano wartości sztywności i tłumienia w podporach do wartości: $\lambda_{11} = \lambda_{22} = 0.198 \cdot 10^6$ [N/m] oraz $A_{11} = A_{22} = 77$ [Ns/m]. Przebiegi otrzymane w wyniku stosowania modelu dla skorygowanych wartości sztywności i tłumienia podpór oznaczono na rysunkach jako „Model 2”.

Biorąc pod uwagę, że zastosowano model liniowy, uzyskane dopasowanie modelu do badanego obiektu uznano za wystarczające.



Rys. 40. Porównanie przebiegu amplitudy przemieszczeń drgań obiektu z przebiegami wyznaczonymi przez model numeryczny (dla prędkości 4000-8000 [obr./min]) [68]

Fig. 40. Comparison of run of amplitude of vibration displacement of object with runs computed by numerical model (for speed 4000-8000 [rpm]) [68]



Rys. 41. Porównanie przebiegu fazy przemieszczeń drgań obiektu z przebiegami wyznaczonymi przez model numeryczny (dla prędkości 4000-8000 [obr./min]) [68]

Fig. 41. Comparison of run of phase of vibration displacement of object with runs computed by numerical model (for speed 4000-8000 [rpm]) [68]

5.3. Generowanie i doskonalenie odwrotnych modeli diagnostycznych

5.3.1. Uwagi ogólne

W rozdziale 4. szczegółowo opisano metody doskonalenia modeli odwrotnych przez adaptacyjne sterowanie procesem badań symulacyjnych. Zaproponowano dwie metody optymalizacji jakości wyznaczanego modelu odwrotnego:

- metoda optymalizacji jakości globalnego modelu odwrotnego;
- metoda optymalizacji jakości lokalnego modelu odwrotnego.

Główną wadą metody optymalizacji jakości modelu globalnego jest konieczność wykonania bardzo dużej liczby obliczeń oraz dopisywanie do podstawowego zbioru takich przykładów, które być może nigdy nie będą potrzebne. Wad tych nie posiada metoda optymalizacji jakości modelu lokalnego. Jest ona związana z wyróżnionym obszarem w rozpatrywanej przestrzeni symptomów, który może być wyznaczony na podstawie danych otrzymanych w wyniku pomiarów wartości cech sygnałów diagnostycznych na rzeczywistym obiekcie. Weryfikacji poddany będzie algorytm adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającymi do optymalizacji jakości lokalnego modelu odwrotnego (szczegółowy opis w rozdziale 4.3.4). Wyznaczane modele odwrotne będą modelami wyznaczanymi lokalnie i optymalizacja jakości dotyczyć będzie takich właśnie modeli. Metoda lokalnej optymalizacji jakości modelu odwrotnego nie wymaga badania rozmieszczenia danych w przestrzeniach wielowymiarowych.

Założono, że generowanie modeli odwrotnych oraz ich doskonalenie należy przeprowadzić zgodnie z opisaną w rozdziale 4. koncepcją w środowisku o rozproszonych zasobach za pomocą dwóch współdziałających autonomicznych procesów:

1. Proces wyznaczania wartości cech sygnałów diagnostycznych opisujących zadane stany modelowanego obiektu na podstawie wartości cech stanów (modelowanie z zastosowaniem zbioru programów wchodzących w skład systemu MESWIR [56], [58], [80] znajdującego się w Instytucie Maszyn Przepływowych PAN w Gdańsku). Dla uproszczenia w dalszym opisie proces ten będzie oznaczony jako proces **A**;
2. Proces wyznaczania stanów modelowanego obiektu na podstawie wartości cech sygnałów diagnostycznych opisujących te stany (identyfikacja modelu odwrotnego na podstawie posiadanego zbioru przykładów). Proces ten realizowany był w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach. W celu uproszczenia w dalszym opisie proces ten będzie oznaczony jako proces **B**.

Proces generowania modeli odwrotnych

Aby możliwe było generowanie modeli odwrotnych w środowisku o rozproszonych zasobach, niezbędne stało się opracowanie (opisane kroki wykonano w ramach pakietu projektów badawczych 8T10B 057 09 p.01 oraz 8T10B 057 08 p.02) [37]:

- programu pozwalającego na wyznaczanie wartości cech sygnałów diagnostycznych, opisujących zadane stany modelowanego obiektu [56], [58], [80];
- programu służącego do uruchamiania zadań (oprogramowania symulacyjnego) na odległym komputerze [35];
- sposobu przechowywania i zarządzania zbiorem przykładów ze względu na przewidywaną licznosc tego zbioru [23];
- programu realizującego proces gromadzenia wyników obliczeń symulacyjnych [36];
- programu realizującego proces adaptacyjnego uzupełniania istniejącego zbioru przykładów dla potrzeb doskonalenia wyznaczanego modelu odwrotnego [62];
- metody sterowania procesem transmisji danych [37].

Ze względu na przewidywaną licznosc zbioru przykładów opracowano relacyjną bazę danych [23] w środowisku umożliwiającym gromadzenie i obsługę bardzo dużej liczby danych. Zastosowano system relacyjnych baz danych MS SQL Server 6.5 [83], działający w środowisku WINDOWS NT Server 4.0. System ten pozwala na wykonywanie skomplikowanych operacji wielu użytkownikom na dużej liczbie danych przy użyciu prostych poleceń języka SQL, a także umożliwia dostęp do danych z poziomu różnych aplikacji.

W związku z zaistniałymi potrzebami związanymi z przepływem danych wyłoniły się pytania [37]:

- *Jak uruchamiać zadania w systemie, w którym realizowany jest proces A z poziomu systemu realizującego proces B?*
- *Jak pobierać wyniki przeprowadzonych obliczeń z systemu, w którym realizowany jest proces A i umieszczać je w relacyjnej bazie danych znajdującej się w systemie realizującym proces B?*

Różnorodność protokołów TCP/IP, na których została oparta sieć Internet, umożliwia prowadzenie badań w obliczeniowym środowisku rozproszonym. Jednym z protokołów do obsługi odległego systemu komputerowego jest protokół TELNET [92], [104]. Oprogramowanie oparte na tym protokole w prosty sposób umożliwia użytkownikowi pracę na odległym komputerze, natomiast do przesyłania (kopiowania) wyników obliczeń z odległego systemu komputerowego można zastosować protokół transmisji danych o nazwie FTP [93].

Sterowanie procesem transmisji danych powinno zapewnić odpowiednią kolejność zadań wykonywanych w sposób zautomatyzowany. Wymaganie to jest spowodowane dużą

różnorodnością zadań do wykonania oraz długim czasem potrzebnym do weryfikacji proponowanej metody adaptacyjnego sterowania badaniami symulacyjnymi. Do sterowania procesem transmisji danych można zastosować tzw. *semafony* (flagi), których określone stany odpowiadają działaniom już wykonywanym lub do wykonania. Ustalenie tych wartości oraz prawidłowe przestawianie nastaw semaforów pozwalają na nieprzerwaną pracę w środowisku rozproszonym narzędzi programowych, wspomagających proces generowania modeli diagnostycznych.

W celu przeprowadzenia pełnego procesu generowania modeli odwrotnych oraz ich doskonalenia przez aktualizację zbioru przykładów należy [37]:

1. Zgromadzić podstawowy zbiór przykładów:

- zbiór ten można otrzymać w wyniku:
 - ⇒ przeprowadzenia podstawowych badań symulacyjnych dla wybranych stanów rozpatrywanego obiektu;
 - ⇒ przeprowadzenia pomiarów w ramach czynnego eksperymentu diagnostycznego dla wybranych stanów rozpatrywanego obiektu;
- podstawowy zbiór przykładów zapisać w relacyjnej bazie danych znajdującej się w ośrodku **B**.

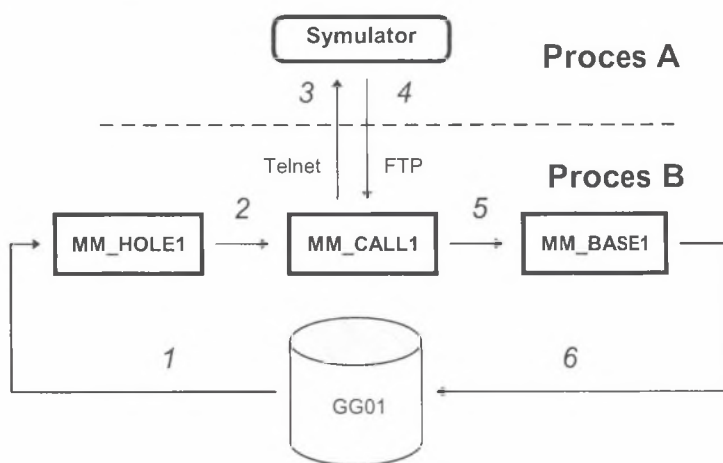
2. Przeprowadzić uzupełniające badania symulacyjne:

- na podstawie podstawowego zbioru przykładów oraz danych testowych przygotować odpowiednie zadanie do wykonania z zastosowaniem oprogramowania symulacyjnego znajdującego się w ośrodku **A**;
- przy użyciu semaforów uruchomić z ośrodka **B** przygotowane zadanie;
- po wykonaniu zadania pobrać z ośrodka **A** plik, zawierający wyniki obliczeń i zapisać go na dysku znajdującym się w ośrodku **B**;
- przestawić nastawy semaforów, tak aby kolejne działania dotyczyły wpisania skopiowanych wyników obliczeń symulacyjnych do relacyjnej bazy danych;
- pobrać zawartość pliku z wynikami obliczeń symulacyjnych i umieścić je w relacyjnej bazie danych;
- przestawić nastawy semaforów, tak aby kolejne działania dotyczyły ponownego przygotowania zadania do wykonania;
- po stwierdzeniu, że otrzymano już wystarczającą jakość wyznaczanego modelu odwrotnego lub wykonano zadaną liczbę kroków, cały proces generowania modeli odwrotnych należy zakończyć.

Procesy przepływu danych, jak i procesy generowania modeli odwrotnych zostały zaprojektowane, uruchomione i przetestowane w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach w ramach prac związanych z realizacją pakietu projektów

badawczych finansowanych przez Komitet Badań Naukowych 8T10B 057 09 p.01 oraz 8T10B 057 08 p.02. Procesy te wspomagane były poprzez opracowany, przy użyciu kompilatora Microsoft Visual C++ 4.0 [82], pakiet programów działających w środowisku WINDOWS NT 4.0 oraz WINDOWS 95. W skład tego pakietu wchodzi następujące programy:

- MM_HOLE1 [62] – program do przygotowywania odpowiednich zadań, które wykonane są z zastosowaniem symulatora;
- MM_CALL1 [35] – program do zdalnego uruchamiania zadań oraz do kopiowania pliku zawierającego wyniki obliczeń symulacyjnych;
- MM_BASE1 [36] – program do przenoszenia do bazy danych GG01 treści pliku zawierającego wyniki przeprowadzonych obliczeń [23].



Rys. 42. Kolejność wykonywania zadań w procesie generowania oraz doskonalenia diagnostycznych modeli odwrotnych [37]

Fig. 42. Sequence of realisation of tasks in the generation and improvement process of inverse diagnostic models [37]

Opracowany pakiet programów został uruchomiony w ośrodku **B**, natomiast oprogramowanie symulacyjne niezbędne do wyznaczania przykładów uruchomiono na komputerze znajdującym się w ośrodku **A**. Dodatkowo (w czasie testowania oraz badań weryfikacyjnych) relacyjna baza danych znajdowała się w ośrodku **B**.

Rysunek 42 pokazuje kolejność wykonywanych działań programów wchodzących w skład opracowanego pakietu.

5.3.2. Charakterystyka zadania diagnostycznego

Zadanie diagnostyczne polegało na identyfikacji stanu niewyrównoważenia wirnika rozpatrywanego stanowiska badawczego. Głównym powodem wyboru tego typu niesprawności (niewyrównoważenia) jest fakt, że niewyrównoważenie jest powszechną przyczyną drgań w maszynach wirnikowych [7], [74], [89], [116]. Dla układów liniowych amplituda drgań spowodowanych niewyrównoważeniem jest proporcjonalna do wielkości niewyrównoważenia oraz kwadratu prędkości obrotowej wirnika. Zbyt duża amplituda drgań wirnika spowodowana stanem niewyrównoważenia może z kolei prowadzić do innych niesprawności, takich jak: przycieranie wirnika o uszczelnienia, precesja przeciwbieżna, zniszczenie łożysk.

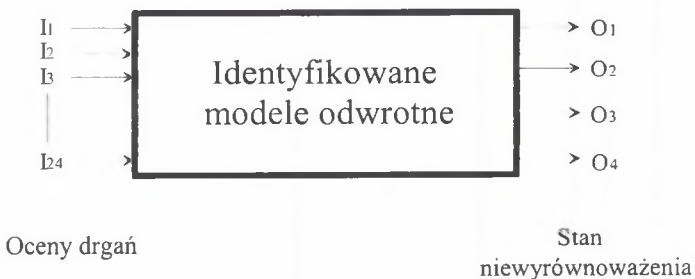
Parametrami modelu opisującego analizowany układ były następujące cechy obiektu:

- wartości przykładanych niewyważ $NW1$ i $NW2$ odpowiednio na tarczach nr 1 i nr 2;
- wartości kątów fazowych przykładanych niewyważ $FI1$ i $FI2$;
- prędkość obrotowa wirnika.

Wszystkie pozostałe dane dotyczące postaci geometrycznej wirnika, łożysk, sztywności podpór, warunków pracy były stałe i odpowiadały parametrom, dla których przeprowadzany był eksperyment.

Jako dane wyjściowe z wyznaczanych modeli odwrotnych (rys. 43) rozpatrywano wartości przykładanych niewyważ oraz wartości faz przykładanych niewyważ w rozpatrywanych płaszczyznach (przykładanych na tarczach nr 1 i nr 2 – rys. 32). Otrzymano w ten sposób 4 wyjścia (2+2), gdzie:

- 2 – wartości niewyważ przykładanych w rozpatrywanych płaszczyznach;
- 2 – wartości faz niewyważ przykładanych w rozpatrywanych płaszczyznach.



Rys. 43. Wejścia i wyjścia identyfikowanych modeli odwrotnych

Fig. 43. Inputs and outputs of identified inverse models

Jako dane wejściowe do wyznaczanych modeli odwrotnych (rys. 43) rozpatrywano oceny przemieszczeń drgań, które reprezentowane były dla każdego węzła pomiarowego w postaci

czterech współczynników A, B, C, D, opisanych zależnością (123). W przypadku symulacji wartości te były określone bezpośrednio przez model numeryczny. Natomiast w przypadku pomiarów mierzono amplitudę i fazę przemieszczeń drgań składowej 1X w kierunku poziomym i pionowym, a następnie obliczono współczynniki A, B, C, D zgodnie z zależnością (123). Otrzymano w ten sposób 24 wejścia (4-2-3), gdzie:

- 4 – liczba wartości współczynników (A, B, C, D) dla jednego punktu pomiarowego;
- 2 – liczba rozpatrywanych węzłów. Przyjęto, iż dla celów weryfikacji zaproponowanej metody adaptacyjnego sterowania badaniami symulacyjnymi wystarczy rozpatrywanie trajektorii dwóch charakterystycznych węzłów układu, a mianowicie węzły o numerach 6 i 16 – rys. 35;
- 3 – liczba prędkości kątowych wału, dla których wyznaczono oceny drgań (zgodnie z propozycją zawartą w [41], [58] rozpatrywano prędkości odpowiadające częstotliwościom poniżej, w pobliżu oraz powyżej częstotliwości rezonansowej).

Uznano, że rozpatrywana przestrzeń symptomów V nie jest przestrzenią o zbyt dużej liczbie cech (wymiarów). Z tego powodu nie jest konieczne stosowanie algorytmów zmierzających do ograniczania liczby cech (rozdział 3).

5.3.3. Podstawowy zbiór przykładów

Plan badań zmierzających do otrzymania podstawowego zbioru przykładów opracowano na podstawie [41], [58].

Usytuowanie niewyważ wzdłuż wirnika

Przyjęto, że niewyważi NW1, NW2 będą mogły być kolejno przykładane w węzłach, w których zamocowane są tarcze, a mianowicie w węzłach 8 i 12 (rys. 35).

Wartości niewyważ

Wartości przykładanych niewyważ przyjęto według następujących kryteriów:

- 1) Wartości niewyważ powinny być na tyle duże, aby po przyłożeniu najmniejszej niewyważi wartości cech rejestrowanych sygnałów ulegały zmianie.
- 2) Wartości niewyważ powinny być na tyle małe, aby układ znajdował się w zakresie drgań liniowych ze względu na przyjęte założenie o odwzorowaniu zachowań dynamicznych badanego obiektu za pomocą modelu liniowego.

Przyjęto trzy wartości niewyważ (iloczynu masy niewyrównoważenia „mnw” i promienia „rnw”):

- $mnw \times rnw = 0.0006 \text{ [kg]} \times 0.02975 \text{ [m]} = 0.00001785 \text{ [kgm]}$;
- $mnw \times rnw = 0.0010 \text{ [kg]} \times 0.02975 \text{ [m]} = 0.00002975 \text{ [kgm]}$;
- $mnw \times rnw = 0.0016 \text{ [kg]} \times 0.02975 \text{ [m]} = 0.00004760 \text{ [kgm]}$.

Każda z dwóch niewy wag NW1 oraz NW2 mogła przyjmować jedną z trzech przedstawionych wartości tworząc następujące kombinacje:

NW1	NW2
0.00001785	0.00001785
0.00001785	0.00002975
0.00001785	0.00004760
0.00002975	0.00002975
0.00002975	0.00004760
0.00004760	0.00004760

Aby ułatwić odczyt w identyfikatorze zbiorów wynikowych wprowadzono wartości względne niewy wag. Przyjęto wartość bazową równą 0.00002975, co oznacza, że powyższe kombinacje w zapisie względnym były w postaci:

NW1	NW2
0.6	0.6
0.6	1.0
0.6	1.6
1.0	1.0
1.0	1.6
1.6	1.6

Kąty fazowe niewy wag

Założono, że kąty fazowe F11, F12 wektorów niewy wag NW1, NW2 będą się zmieniały co 90 [°], a to oznacza, iż każdy z nich mógł przyjmować 4 wartości (0, 90, 180, 270 [°]).

Prędkości obrotowe

Podstawowy zbiór przykładów generowano dla trzech wybranych charakterystycznych prędkości obrotowych wirnika (rys. 40), a mianowicie:

- $n = 5500$ [obr./min] – odpowiada częstotliwości poniżej częstotliwości rezonansowej;
- $n = 6300$ [obr./min] – odpowiada częstotliwości w okolicach częstotliwości rezonansowej;
- $n = 7200$ [obr./min] – odpowiada częstotliwości powyżej częstotliwości rezonansowej.

Sztywność dynamiczna oraz tłumienie utwierdzeń zewnętrznych panwii

Przyjęto następujące stałe wartości skorygowanych współczynników sztywności dynamicznej podpór, które zostały określone [68], [112] w wyniku „strojenia” modelu z obiektem (rozdział 5.2.4):

- dla podpory nr 1 $\lambda_{11} = \lambda_{22} = 0.198 \cdot 10^6$ [N/m];
- dla podpory nr 2 $\lambda_{11} = \lambda_{22} = 0.198 \cdot 10^6$ [N/m].

Przyjęto następujące stałe wartości skorygowanych współczynników tłumienia podpór, które zostały określone [68], [112] w wyniku „strojenia” modelu z obiektem (rozdział 5.2.4):

- dla podpory nr 1 $\Lambda_{11} = \Lambda_{22} = 77$ [Ns/m];
- dla podpory nr 2 $\Lambda_{11} = \Lambda_{22} = 77$ [Ns/m].

Wyniki

Ze względu na cel dalszych badań dla tych samych cech stanów zgromadzono trzy niezależne zbiory przykładów:

- 1) Przykłady uzyskane w wyniku stosowania modelu numerycznego.
- 2) Przykłady uzyskane w wyniku pomiarów przeprowadzonych na rozpatrywanym stanowisku w ramach czynnego eksperymentu diagnostycznego.
- 3) Przykłady uzyskane w wyniku stosowania modelu numerycznego, a następnie dodania do otrzymanych danych szumu.

Obliczenia oraz pomiary przeprowadzane były dla każdej kombinacji, jaką tworzyć mogły dwie „wędrujące” po promieniach tarcz niewywagi o różnych wartościach i kątach fazowych, dla każdej prędkości obrotowej wirnika i każdego zestawu pozostałych parametrów. Przyjmując zaproponowany zestaw parametrów tworzących dane do obliczeń, otrzymano 144 różne przypadki niewyrównoważenia, które stanowiły podstawowy zbiór przykładów.

W przypadku badań symulacyjnych dla rozpatrywanych węzłów otrzymano trajektorie drgań, które opisane były przez cztery współczynniki A, B, C, D, wyznaczone zgodnie z zależnością (123). Natomiast w przypadku pomiarów mierzono amplitudę i fazę przemieszczeń drgań składowej 1X w kierunku poziomym i pionowym (węzły o numerach 6 i 16 – 35). Następnie stosując zadanie aproksymacji obliczono współczynniki A, B, C, D.

Otrzymane dane zapisano w bazie danych GG01 [23] z odpowiednimi identyfikatorami, pozwalającymi na rozróżnienie, do którego zbioru przykładów one należą.

5.3.4. Dane testowe

W celu weryfikacji metody adaptacyjnego sterowania badaniami symulacyjnymi konieczne jest posiadanie odpowiedniego zbioru danych testowych. Można użyć wybranych zestawów danych spośród tych, które znajdują się już w podstawowym zbiorze przykładów. Wybór jednak tych danych nie pozwoliłby na „pełną” weryfikację metody. Zdecydowano, że dane testowe dotyczyć będą stanów niewyrównoważenia, które nie znajdują się w podstawowym zbiorze przykładów (zbiór przykładów podstawowych oraz zbiór danych testowych były zbiorami rozłącznymi). W pierwszym kroku określono, dla jakich stanów badanego obiektu były określane wartości odpowiadających im symptomów (wyznaczonych zarówno w wyniku stosowania modelu numerycznego, jak i w wyniku pomiarów wykonanych w ramach czynnego eksperymentu diagnostycznego). Stany te określono na podstawie posiadanego już podstawowego zbioru przykładów. Podstawowy zbiór przykładów otrzymany jest dla pewnych założonych dyskretnych wartości cech stanów (określone wartości niewyważ oraz wartości faz tych niewyważ, jakie mogą być przyjmowane w rozpatrywanych płaszczyznach).

Na podstawie tych wartości określono zakresy zmienności rozpatrywanych cech stanów. Następnie losowo wybierano w rozpatrywanych płaszczyznach przykładania niewy wag wartości niewy wag (spośród rozpatrywanego zbioru możliwych względnych wartości niewy wag 0.8, 1.0, 1.2, 1.4) oraz wartości faz tych niewy wag (spośród rozpatrywanego zbioru możliwych wartości 45, 135, 225, 315 [°]). Rozpatrywane wartości niewy wag oraz faz przykładanych niewy wag określono przy założeniu, że losowane wartości nie powinny przyjmować wartości dyskretnych, równych wartościom, które przyjmowano wcześniej dla podstawowego zbioru przykładów, oraz wartości znajdujących się w ich najbliższym otoczeniu.

Tablica I

Wartości niewy wag oraz faz tych niewy wag dla przykładów testowych [113]

Lp.	Tarcza pierwsza		Tarcza druga	
	NW1	FN1	NW2	FN2
1	0.8	225	0.8	315
2	1.0	225	1.2	315
3	0.8	45	1.4	315
4	1.2	225	1.0	135
5	0.8	45	0.6	45
6	0	–	1.2	225
7	1.4	135	0.8	45
8	0.8	315	1.4	135
9	1.2	315	0.8	45
10	0	–	1.2	45
11	1.4	135	0	–
12	1.2	315	1.4	315
13	0.8	225	1.2	225
14	0.8	225	0.8	45
15	1.2	315	1.4	225

Podobnie jak w przypadku podstawowego zbioru przykładów zbiór danych testowych otrzymano w wyniku stosowania modelu numerycznego oraz pomiarów na rozpatrywanym obiekcie. Otrzymane dane testowe zapisane zostały w bazie danych GG01 [23] z odpowiednimi identyfikatorami, pozwalającymi na rozróżnienie, które dane pochodzą z symulacji, a które z pomiarów. Tablica I zawiera wartości niewy wag oraz faz tych niewy wag przyjęte dla przykładów testowych [113].

5.3.5. Uzupełniające badania symulacyjne

Eksperyment weryfikujący metodę adaptacyjnego sterowania procesem badań symulacyjnych obejmował następujące działania (algorytm opisany w rozdziale 4.3.4 – rys. 30):

- wybór przykładowych danych testowych;

- ocenę jednoznaczności odwzorowania w najbliższym otoczeniu danych testowych;
- w przypadku uzyskania zadowalającej oceny jednoznaczności odwzorowania uzupełnienie podstawowego zbioru przykładów nowymi danymi otrzymanymi w wyniku stosowania procedury adaptacyjnego sterowania badaniami symulacyjnymi.

Opisane działania powtarzano dla kolejnych danych testowych. Warunkami przerywania procesu adaptacyjnego sterowania badaniami symulacyjnymi było:

- uzyskanie zadowalającej wartości miary jakości wyznaczanych odwrotnych modeli lokalnych (tzn. $J(\nu) \geq 0.99$) lub
- wykonanie zadanej liczby kroków – dopisanie co najwyżej 200 nowych przykładów do podstawowego zbioru przykładów (liczbę 200 przykładów wynika z ograniczeń czasowych).

Miara jakości wyznaczanych modeli $J(\nu)$ wyznaczana była zgodnie z zależnością (100), przy czym odległość występująca w tej zależności $dist(\bullet)$ obliczano zgodnie z zależnością (99). Czynniki skalujące α wyznaczono jako odwrotność liczby wymiarów rozpatrywanej przestrzeni symptomów, czyli $\alpha = 1/24$.

Przeprowadzono trzy niezależne eksperymenty:

- 1) Eksperyment dla zbioru przykładów oraz zbioru danych testowych uzyskanych w wyniku stosowania modelu numerycznego.
- 2) Eksperyment dla zbioru przykładów oraz zbioru danych testowych uzyskanych w wyniku pomiarów na badanym obiekcie.
- 3) Eksperyment dla zbioru przykładów oraz zbioru danych testowych uzyskanych w wyniku stosowania modelu numerycznego oraz generatora szumu.

Uzupełnione nowe przykłady (w ramach każdego eksperymentu) były brane pod uwagę w kolejnych obliczeniach. Z badań algorytmów interpolacji dla potrzeb adaptacyjnego sterowania badaniami symulacyjnymi (Dodatek B) wynika, że najlepiej nadającymi się algorytmami wielowymiarowej interpolacji są algorytmy W12 i W13. Zdecydowano się na stosowanie algorytmu W13. Jako dane wzorcowe dla algorytmu W13 przyjęto dane znajdujące się w najbliższym otoczeniu danych testowych. Rozpatrywane najbliższe otoczenie danych testowych było otoczeniem ruchomym i zależnym od przyjętej liczby najbliższych sąsiadów. Aby układ równań, który wyznacza się w trakcie obliczeń (realizowanych zgodnie z algorytmem W13), był rozwiązywalny, wymagana jest liczba co najmniej tylu danych, ile jest wejść do wyznaczanego modelu. Identyfikowane modele odwrotne posiadały 24 wejścia. Zdecydowano się na uwzględnianie 27 najbliższych sąsiadów. Działania takie (określanie otoczenia przez liczbę najbliższych sąsiadów) podyktowane były nieznaną rozmieszczenia punktów w przestrzeni symptomów.

Jednoznaczność odwzorowania określano w najbliższym otoczeniu danych testowych (określonym przez 27 najbliższych sąsiadów danych testowych) i oceniano przez badanie

liczby najbliższych sąsiadów (Dodatek A) zgodnie z zależnością (139). Wartości oceny jednoznaczności odwzorowania wyznaczano po przyjęciu, że otoczenie $\varepsilon(\underline{x}_i)$ oraz otoczenie $\varepsilon(\underline{y}_i)$ określane było przez liczbę 5 najbliższych sąsiadów.

Średni czas potrzebny na wykonanie działań związanych z wyznaczaniem nowego przykładu i jego zapisanie w bazie danych wynosił około 5 min. Szczególnie czasochłonne były zadania wykonywane przez program MM_CALL1. Istotną rolę odgrywa czas przesyłania danych przez sieć *Internet* na trasie Gliwice – Gdańsk – Gliwice. Wyraźne zmniejszenie czasu potrzebnego na transmisję danych można było zauważyć w godzinach nocnych, co wynika ze zdecydowanie mniejszego obciążenia sieci *Internet*. Swój udział, w czasie wykonywanych działań, ma również program MM_HOLE1 – głównie procedura wyznaczająca najbliższych sąsiadów rozpatrywanych danych testowych w wielowymiarowej przestrzeni symptomów, co wynika z liczności rozpatrywanego zbioru przykładów.

5.3.6. Wyniki otrzymane dla danych pochodzących z symulacji

Otrzymane wyniki zestawiono w tablicach (tablica II, tablica III), które zawierają szacowane względne wartości niewy wag oraz faz tych niewy wag w poszczególnych płaszczyznach przed oraz po uzupełnieniu zbioru przykładów. W kolejnych wierszach dla każdego przykładu testowego podano:

- oczekiwane (dane) względne wartości przykładanych niewy wag oraz faz tych niewy wag (wiersz o nazwie *Oczekiwane*);
- wyznaczone na podstawie podstawowego zbioru przykładów względne wartości przykładanych niewy wag oraz faz tych niewy wag szacowane przez model odwrotny (wiersz o nazwie *Przed*) oraz ocenę jednoznaczności odwzorowania dla poszczególnych wyjść (wiersz o nazwie *OJO*);
- wyznaczone na podstawie podstawowego oraz uzupełnianego zbioru przykładów (po zakończeniu działań związanych z uzupełnianiem zbioru przykładów) względne wartości przykładanych niewy wag oraz faz tych niewy wag szacowane przez model odwrotny (wiersze o nazwie *Etap I* i/lub *Etap II*) oraz ocenę jednoznaczności odwzorowania dla poszczególnych wyjść (wiersz o nazwie *OJO*).

Kolejne kolumny w tablicach (tablica II, tablica III) oznaczają:

- *DT* – numer danych testowych;
- *Opis* – opis wierszy;
- *MJ* – miara jakości wyznaczanego lokalnego modelu odwrotnego związana z danymi testowymi (obliczana wg (100));
- *NW1* – względne wartości niewy wag przykładanych w płaszczyźnie nr 1;
- *NW2* – względne wartości niewy wag przykładanych w płaszczyźnie nr 2;
- *FN1* – fazy niewy wag przykładanych w płaszczyźnie nr 1;

- *FN2* – fazy niewywag przykładowych w płaszczyźnie nr 2;
- *LNP* – liczba dopisanych nowych przykładów, po dopisaniu których osiągnięto założoną wartość miary jakości (≥ 0.99) lub wykonano założoną maksymalną liczbę kroków (200);
- *LNS* - liczba określająca, ilu spośród rozpatrywanych dwudziestu siedmiu najbliższych sąsiadów (wyznaczonych dla poszczególnych danych testowych na podstawie podstawowego i uzupełnionego zbioru przykładów) należy do zbioru przykładów wyznaczonego w wyniku przeprowadzenia uzupełniających badań symulacyjnych. Liczba (podana w kolumnie o nazwie *LNS*) wynosząca 27 oznacza, że wszyscy nowi najbliżsi sąsiedzi należą do zbioru przykładów wyznaczonego w wyniku przeprowadzenia uzupełniających badań symulacyjnych. Oznacza to, że nastąpiło oczekiwane zagęszczenie danych w najbliższym sąsiedztwie danych testowych.

Po zakończeniu pierwszego etapu obliczeń, w którym założono, że wykonanych będzie maksymalnie 200 kroków, niezadowolająco szacowane przez wyznaczony model odwrotny były 4 przypadki (dane testowe nr 4, 6, 10 i 12). Po wykonaniu drugiego etapu obliczeń, w którym uwzględniano dane uzyskane z pierwszego etapu obliczeń, uzyskano rozwiązania (uznane za zadowolające) we wszystkich przypadkach.

Weryfikowany algorytm adaptacyjnego sterowania badaniami symulacyjnymi (rozdział 4.3.4 – rys. 30) zawiera pętlę, w której występuje losowanie wartości symptomów. Analizując pliki, w których zapisany został „śląd” działania procedury, dane testowe można podzielić na trzy grupy:

- 1) Dane testowe, dla których „dojście” do rozwiązania nie wymagało bądź wymagało niewielkiej liczby losowań wartości cech sygnałów diagnostycznych (losowanie wartości cech sygnałów diagnostycznych występowało do 30% wykonanej liczby kroków).
- 2) Dane testowe, dla których „dojście” do rozwiązania wymagało wykonania większej liczby losowań wartości cech sygnałów diagnostycznych (losowanie wartości cech sygnałów diagnostycznych występowało od 30% do 60 % wykonanej liczby kroków).
- 3) Dane testowe, dla których „dojście” do rozwiązania wymagało wykonania dużej liczby losowań wartości cech sygnałów diagnostycznych (losowanie wartości cech sygnałów diagnostycznych występowało powyżej 60% wykonanej liczby kroków).

Najliczniejszą grupę stanowiły przykłady z grupy drugiej.

Dla przedstawionych trzech grup wybrano po dwóch ich reprezentantów i tak:

- dla grupy pierwszej dane testowe nr 7 i nr 15;
- dla grupy drugiej dane testowe nr 1 i nr 3;
- dla grupy trzeciej dane testowe nr 9 i nr 10.

Otrzymane wyniki dla danych testowych nr 1 - nr 8

DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
1	Oczekiwane		0.800	0.800	225.000	315.000	50	26
	Przed	0.776	0.770	0.760	185.390	56.500		
	<i>OJO</i>		0.386	0.271	0.586	0.421		
	Etap I	0.993	0.800	0.800	224.690	315.800		
	<i>OJO</i>		0.764	0.643	0.379	0.629		
2	Oczekiwane		1.000	1.200	225.000	315.000	139	27
	Przed	0.854	0.720	1.150	194.690	349.200		
	<i>OJO</i>		0.393	0.329	0.593	0.500		
	Etap I	0.990	1.000	1.210	225.390	316.100		
	<i>OJO</i>		0.664	0.393	0.436	0.450		
3	Oczekiwane		0.800	1.400	45.000	315.000	96	26
	Przed	0.655	0.790	0.600	87.800	45.300		
	<i>OJO</i>		0.436	0.336	0.464	0.507		
	Etap I	0.998	0.800	1.400	45.000	314.800		
	<i>OJO</i>		0.486	0.571	0.507	0.386		
4	Oczekiwane		1.200	1.000	225.000	135.000	200	27
	Przed	0.642	1.530	0.980	274.590	243.390		
	<i>OJO</i>		0.429	0.386	0.664	0.664		
	Etap I	0.791	1.190	0.310	234.890	109.500		
	Etap II	0.991	1.190	1.010	224.990	133.800		
	<i>OJO</i>		0.729	0.721	0.664	0.729	235	
5	Oczekiwane		0.800	0.600	45.000	45.000	36	27
	Przed	0.833	0.620	0.770	12.800	12.500		
	<i>OJO</i>		0.393	0.157	0.529	0.421		
	Etap I	0.995	0.800	0.590	44.000	43.300		
	<i>OJO</i>		0.443	0.486	0.536	0.457		
6	Oczekiwane		0.000	1.200	0.000	225.000	200	27
	Przed	0.690	0.530	0.950	4.600	305.990		
	<i>OJO</i>		0.386	0.321	0.529	0.493		
	Etap I	0.553	0.560	1.020	3.200	19.290		
	Etap II	0.993	0.000	1.210	93.600	224.800		
	<i>OJO</i>		0.436	0.550	0.650	0.679	284	
7	Oczekiwane		1.400	0.800	135.000	45.000	78	27
	Przed	0.814	1.430	0.600	169.490	260.990		
	<i>OJO</i>		0.307	0.314	0.650	0.550		
	Etap I	0.991	1.400	0.800	135.000	43.890		
	<i>OJO</i>		0.557	0.543	0.629	0.407		
8	Oczekiwane		0.800	1.400	315.000	135.000	154	27
	Przed	0.610	1.490	0.970	8.500	98.700		
	<i>OJO</i>		0.371	0.343	0.621	0.543		
	Etap I	0.992	0.798	1.410	314.890	135.560		
	<i>OJO</i>		0.829	0.950	0.921	0.814		

Tablica III

Otrzymane wyniki dla danych testowych nr 9 - nr 15

DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
9	Oczekiwane		1.200	0.800	315.000	45.000		
	Przed	0.658	0.680	0.600	274.390	185.090		
	<i>OJO</i>		<i>0.343</i>	<i>0.300</i>	<i>0.521</i>	<i>0.500</i>		
	Etap I	0.979	1.190	0.760	314.890	46.400	200	26
	<i>OJO</i>		<i>0.414</i>	<i>0.500</i>	<i>0.429</i>	<i>0.407</i>		
10	Oczekiwane		0.000	1.200	0.000	45.000		
	Przed	0.670	1.380	0.740	243.490	204.390		
	<i>OJO</i>		<i>0.407</i>	<i>0.343</i>	<i>0.543</i>	<i>0.493</i>		
	Etap I	0.616	1.390	0.660	243.990	170.990	200	
	Etap II	0.998	0.000	1.200	249.190	44.790	342	25
<i>OJO</i>		<i>0.729</i>	<i>0.571</i>	<i>0.479</i>	<i>0.664</i>			
11	Oczekiwane		1.400	0.000	135.000	0.000		
	Przed	0.573	0.700	0.900	155.300	19.100		
	<i>OJO</i>		<i>0.336</i>	<i>0.357</i>	<i>0.586</i>	<i>0.493</i>		
	Etap I	0.997	1.400	0.000	135.200	16.000	49	25
	<i>OJO</i>		<i>0.450</i>	<i>0.593</i>	<i>0.664</i>	<i>0.543</i>		
12	Oczekiwane		1.200	1.400	315.000	315.000		
	Przed	0.630	0.760	0.900	34.000	94.900		
	<i>OJO</i>		<i>0.393</i>	<i>0.143</i>	<i>0.493</i>	<i>0.457</i>		
	Etap I	0.755	0.870	1.020	23.000	48.200	200	
	Etap II	0.996	1.200	1.400	315.320	314.690	313	22
<i>OJO</i>		<i>0.429</i>	<i>0.571</i>	<i>0.671</i>	<i>0.686</i>			
13	Oczekiwane		0.800	1.200	225.000	225.000		
	Przed	0.863	0.670	1.090	275.690	276.290		
	<i>OJO</i>		<i>0.393</i>	<i>0.143</i>	<i>0.493</i>	<i>0.457</i>		
	Etap I	0.995	0.820	1.230	225.190	225.390	31	25
	<i>OJO</i>		<i>0.536</i>	<i>0.543</i>	<i>0.736</i>	<i>0.743</i>		
14	Oczekiwane		0.800	0.800	225.000	45.000		
	Przed	0.600	1.370	0.580	244.790	145.100		
	<i>OJO</i>		<i>0.336</i>	<i>0.357</i>	<i>0.607</i>	<i>0.471</i>		
	Etap I	0.994	0.800	0.800	225.190	45.500	134	27
	<i>OJO</i>		<i>0.700</i>	<i>0.614</i>	<i>0.493</i>	<i>0.771</i>		
15	Oczekiwane		1.200	1.400	315.000	225.000		
	Przed	0.402	1.490	1.200	270.390	278.590		
	<i>OJO</i>		<i>0.386</i>	<i>0.314</i>	<i>0.550</i>	<i>0.507</i>		
	Etap I	0.993	1.190	1.400	314.990	224.990	130	27
	<i>OJO</i>		<i>0.657</i>	<i>0.514</i>	<i>0.771</i>	<i>0.793</i>		

W celu umożliwienia graficznej prezentacji poszukiwania rozwiązania przez doskonalony model odwrotny dla poszczególnych danych testowych rozpatrywane cechy stanu (NW1, NW2, FN1, FN2) przekształcono w nowe cechy:


$$s_1 = NW1 \cdot \sin(FN1) \quad (124)$$

$$s_2 = NW2 \cdot \sin(FN2) \quad (125)$$

Przy założeniu, że maksymalna wartość niewyważ przyjmowana przez cechy NW1 i NW2 wynosi 1.6 wartości cech s_1 oraz s_2 zawarte będą w przedziale $\langle -1.6, 1.6 \rangle$ (założenie to wynika z faktu, że maksymalna wartość niewyważ, jakie mogły przyjmować cechy NW1 i NW2 dla podstawowego zbioru przykładów wynosiła 1.6). Dla rozpatrywanych danych testowych na rysunkach (rys. 44 – rys. 49) pokazano przebieg procesu poszukiwania rozwiązania przez doskonalony model odwrotny. Na rysunkach po lewej stronie pokazano trajektorię dochodzenia do rozwiązania w pełnym zakresie zmienności cech s_1 oraz s_2 ($\langle -1.6, 1.6 \rangle$) przy założeniu, że początek układu współrzędnych (punkt o współrzędnych (0, 0)) znajduje się w środku układu współrzędnych. Natomiast skalę prawego wykresu dobrano tak, aby pokazać całą trajektorię w możliwie największym powiększeniu bez zniekształceń. Na rysunkach zastosowano następujące oznaczenia:



- '+' - poszukiwane rozwiązanie;
- 'o' - wartości szacowane przez model odwrotny wyznaczone na bazie podstawowego zbioru przykładów;
- '•' - wartości szacowane przez model odwrotny wyznaczone na bazie podstawowego oraz uzupełnianego zbioru przykładów (po zakończeniu procedury zagęszczania danych).

Natomiast na rysunkach (rys. 50 – rys. 52) pokazano miary jakości wyznaczanych modeli odwrotnych w funkcji liczby dopisanych nowych przykładów.





Rys. 44. Poszukiwanie rozwiązania przez doskonalony model odwrotny dla danych testowych nr 7

Fig. 44. Search of solution by improved inverse model for test data no. 7





Rys. 45. Poszukiwanie rozwiązania przez doskonały model odwrotny dla danych testowych nr 15

Fig. 45. Search of solution by improved inverse model for test data no. 15





Rys. 46. Poszukiwanie rozwiązania przez doskonały model odwrotny dla danych testowych nr 1

Fig. 46. Search of solution by improved inverse model for test data no. 1





Rys. 47. Poszukiwanie rozwiązania przez doskonały model odwrotny dla danych testowych nr 3

Fig. 47. Search of solution by improved inverse model for test data no. 3




Rys. 48. Poszukiwanie rozwiązania przez doskonalony model odwrotny dla danych testowych nr 9

Fig. 48. Search of solution by improved inverse model for test data no. 9




Rys. 49. Poszukiwanie rozwiązania przez doskonalony model odwrotny dla danych testowych nr 10

Fig. 49. Search of solution by improved inverse model for test data no. 10





Rys. 50. Wykresy miary jakości wyznaczanego modelu odwrotnego w funkcji liczby dopisanych nowych przykładów (dane testowe nr 7 i nr 15)

Fig. 50. Diagram of quality measure of identified inverse model versus number of new updated data (test data no. 7 and no. 15)



Rys. 51. Wykresy miary jakości wyznaczanego modelu odwrotnego w funkcji liczby dopisanych nowych przykładów (dane testowe nr 1 i nr 3)

Fig. 51. Diagram of quality measure of identified inverse model versus number of new updated data (test data no 1 and no 3)



Rys. 52. Wykresy miary jakości wyznaczanego modelu odwrotnego w funkcji liczby dopisanych nowych przykładów (dane testowe nr 9 i nr 10)

Fig. 52. Diagram of quality measure of identified inverse model versus number of new updated data (test data no 9 and no 10)

Analizując pokazane wyniki (tablica II, tablica III oraz rys. 44 – rys. 52) można wyciągnąć następujące wnioski:

- Dla wszystkich rozpatrywanych grup danych testowych wartości miary jakości nie rosną monotonicznie ze wzrostem liczby dopisanych nowych przykładów. Obserwując zmiany miary jakości na pewnych krótkich odcinkach można dojść do wniosku, że dopisywanie nowych przykładów nie poprawia, a wręcz pogarsza jakość wyznaczanego modelu - wynika to bezpośrednio ze stosowanych algorytmów wielowymiarowej interpolacji. Obserwując jednak zmiany miary jakości w całym prezentowanym zakresie widać, że miara jakości rośnie osiągając wartości bliskie jedności.

- Im większa liczba losowań w procesie doskonalenia modeli odwrotnych przez aktualizację zbioru przykładów, tym większa liczba fluktuacji podczas poszukiwania rozwiązania przez doskonalony model odwrotny oraz większa liczba fluktuacji na wykresie miary jakości w funkcji liczby dopisanych nowych przykładów.
- Wartości ocen jednoznaczności odwzorowania wyznaczanych dla przykładów ze zbioru podstawowego oraz uzupełnianego prawie w większości przypadków rosną względem wartości ocen jednoznaczności odwzorowania wyznaczanych dla przykładów ze zbioru podstawowego.
- Dla danych testowych, dla których proces dochodzenia do rozwiązania wymagał mniejszej liczby losowań, można zauważyć wyraźny kierunek dochodzenia do rozwiązania (np. rys. 44 i rys. 45), natomiast dla danych testowych dla których proces dochodzenia do rozwiązania wymagał większej liczby losowań, kierunek dochodzenia do rozwiązania jest zakłócony (rys. 48 i rys. 49).
- Dla wszystkich danych testowych widać, że po zakończeniu uzupełniających badań symulacyjnych najbliżsi sąsiedzi wyznaczeni dla tych danych na podstawie podstawowego i uzupełnionego zbioru przykładów w większości należą do zbioru przykładów uzyskanego w wyniku przeprowadzenia uzupełniających badań symulacyjnych (tablica II, tablica III - kolumna o nazwie *LNS* - w większości przypadków liczba ta jest bliska lub równa 27).

5.3.7. Wyniki otrzymane dla danych pochodzących z pomiarów

Otrzymane wyniki zestawiono w tablicach (tablica IV, tablica V, tablica VI), które zawierają szacowane względne wartości niewywg oraz faz tych niewywg w poszczególnych płaszczyznach przed oraz po uzupełnieniu zbioru przykładów. Znaczenie kolejnych wierszy i kolumn w tablicach - patrz rozdział 5.3.6.

Po wykonaniu pierwszego etapu obliczeń, w którym założono, że wykonanych będzie maksymalnie 200 kroków, dla żadnego przykładu spośród danych testowych nie otrzymano zadowalającej wartości miary jakości wyznaczonego modelu. Dla wszystkich danych testowych poszukiwanie rozwiązania wymagało wykonania dużej liczby losowań wartości cech sygnałów diagnostycznych (losowanie wartości cech sygnałów diagnostycznych występowało powyżej 90% wykonanej liczby kroków).

Analizując pokazane wyniki (tablica IV, tablica V, tablica VI) można wyciągnąć następujące wnioski:

- Dla większości danych testowych (z wyjątkiem danych testowych o numerach 12 i 15) wartości miary jakości modeli wyznaczanych na podstawie podstawowego zbioru przykładów pochodzącego z pomiarów są niższe niż wartości miary jakości modeli wyznaczanych na podstawie podstawowego zbioru przykładów pochodzącego z symulacji (patrz rozdział 5.3.6).

Otrzymane wyniki dla danych testowych nr 1 - nr 6

DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
1	Oczekiwane		0.800	0.800	225.000	315.000	400	2
	Przed	0.612	0.790	0.480	150.300	22.900		
	<i>OJO</i>		<i>0.360</i>	<i>0.380</i>	<i>0.587</i>	<i>0.640</i>		
	Etap I	0.612	0.790	0.480	150.300	22.900		
	Etap II	0.599	0.870	0.430	162.200	7.700		
	<i>OJO</i>		<i>0.420</i>	<i>0.413</i>	<i>0.473</i>	<i>0.493</i>		
2	Oczekiwane		1.000	1.200	225.000	315.000	400	4
	Przed	0.549	0.780	1.190	192.290	43.600		
	<i>OJO</i>		<i>0.353</i>	<i>0.266</i>	<i>0.733</i>	<i>0.640</i>		
	Etap I	0.514	0.790	1.150	192.290	44.800		
	Etap II	0.526	0.778	1.194	192.285	43.608		
	<i>OJO</i>		<i>0.313</i>	<i>0.433</i>	<i>0.606</i>	<i>0.466</i>		
3	Oczekiwane		0.800	1.400	45.000	315.000	400	0
	Przed	0.524	0.170	1.610	10.100	226.390		
	<i>OJO</i>		<i>0.300</i>	<i>0.246</i>	<i>0.786</i>	<i>0.513</i>		
	Etap I	0.524	0.170	1.610	10.100	226.390		
	Etap II	0.524	0.170	1.610	10.100	226.390		
	<i>OJO</i>		<i>0.300</i>	<i>0.246</i>	<i>0.786</i>	<i>0.513</i>		
4	Oczekiwane		1.200	1.000	225.000	135.000	400	0
	Przed	0.531	0.720	0.100	301.490	57.100		
	<i>OJO</i>		<i>0.326</i>	<i>0.273</i>	<i>0.746</i>	<i>0.493</i>		
	Etap I	0.531	0.720	0.100	301.490	57.100		
	Etap II	0.531	0.720	0.100	301.490	57.100		
	<i>OJO</i>		<i>0.326</i>	<i>0.273</i>	<i>0.746</i>	<i>0.493</i>		
5	Oczekiwane		0.800	0.600	45.000	45.000	400	15
	Przed	0.816	0.700	0.600	14.300	25.000		
	<i>OJO</i>		<i>0.426</i>	<i>0.366</i>	<i>0.513</i>	<i>0.446</i>		
	Etap I	0.530	0.310	2.650	222.200	343.790		
	Etap II	0.366	1.870	2.930	270.790	39.000		
	<i>OJO</i>		<i>0.466</i>	<i>0.466</i>	<i>0.426</i>	<i>0.453</i>		
6	Oczekiwane		0.000	1.200	0.000	225.000	400	3
	Przed	0.632	0.560	0.660	22.800	280.390		
	<i>OJO</i>		<i>0.353</i>	<i>0.353</i>	<i>0.580</i>	<i>0.486</i>		
	Etap I	0.611	0.710	0.670	42.100	260.190		
	Etap II	0.625	0.569	0.658	22.771	280.397		
	<i>OJO</i>		<i>0.273</i>	<i>0.293</i>	<i>0.560</i>	<i>0.386</i>		

Otrzymane wyniki dla danych testowych nr 7 - nr 12


DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
7	Oczekiwane		1.400	0.800	135.000	45.000	400	2
	Przed	0.511	0.350	0.210	342.390	319.090		
	<i>OJO</i>		<i>0.486</i>	<i>0.280</i>	<i>0.486</i>	<i>0.426</i>		
	Etap I	0.317	0.763	2.254	126.057	170.509		
	Etap II	0.530	0.467	0.236	257.891	195.023		
	<i>OJO</i>		<i>0.466</i>	<i>0.460</i>	<i>0.426</i>	<i>0.453</i>		
8	Oczekiwane		0.800	1.400	315.000	135.000	400	0
	Przed	0.408	1.060	1.480	267.690	159.500		
	<i>OJO</i>		<i>0.333</i>	<i>0.280</i>	<i>0.606</i>	<i>0.420</i>		
	Etap I	0.408	1.060	1.480	267.690	159.500		
	Etap II	0.408	1.060	1.480	267.690	159.500		
	<i>OJO</i>		<i>0.333</i>	<i>0.280</i>	<i>0.606</i>	<i>0.420</i>		
9	Oczekiwane		1.200	0.800	315.000	45.000	400	0
	Przed	0.506	0.700	1.470	16.900	58.700		
	<i>OJO</i>		<i>0.340</i>	<i>0.280</i>	<i>0.666</i>	<i>0.393</i>		
	Etap I	0.506	0.700	1.470	16.900	58.700		
	Etap II	0.506	0.700	1.470	16.900	58.700		
	<i>OJO</i>		<i>0.340</i>	<i>0.280</i>	<i>0.666</i>	<i>0.393</i>		
10	Oczekiwane		0.000	1.200	0.000	45.000	400	0
	Przed	0.601	0.270	1.120	183.890	328.090		
	<i>OJO</i>		<i>0.406</i>	<i>0.286</i>	<i>0.546</i>	<i>0.480</i>		
	Etap I	0.601	0.270	1.120	183.890	328.090		
	Etap II	0.601	0.270	1.120	183.890	328.090		
	<i>OJO</i>		<i>0.406</i>	<i>0.286</i>	<i>0.546</i>	<i>0.480</i>		
11	Oczekiwane		1.400	0.000	135.000	0.000	400	0
	Przed	0.500	1.350	0.380	100.900	35.700		
	<i>OJO</i>		<i>0.280</i>	<i>0.366</i>	<i>0.600</i>	<i>0.446</i>		
	Etap I	0.500	1.350	0.380	100.900	35.700		
	Etap II	0.500	1.350	0.380	100.900	35.700		
	<i>OJO</i>		<i>0.280</i>	<i>0.366</i>	<i>0.600</i>	<i>0.446</i>		
12	Oczekiwane		1.200	1.400	315.000	315.000	400	17
	Przed	0.810	0.550	0.650	285.790	272.390		
	<i>OJO</i>		<i>0.426</i>	<i>0.266</i>	<i>0.480</i>	<i>0.400</i>		
	Etap I	0.387	0.250	0.160	166.900	171.69		
	Etap II	0.604	0.711	0.878	221.452	243.563		
	<i>OJO</i>		<i>0.586</i>	<i>0.446</i>	<i>0.440</i>	<i>0.340</i>		

Otrzymane wyniki dla danych testowych nr 13 - nr 15

DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
13	Oczekiwane		0.800	1.200	225.000	225.000	400	10
	Przed	0.860	0.460	0.830	338.990	326.390		
	<i>OJO</i>		<i>0.393</i>	<i>0.266</i>	<i>0.400</i>	<i>0.440</i>		
	Etap I	0.485	1.400	1.950	145.400	319.990		
	Etap II	0.521	1.125	1.632	156.920	298.192		
	<i>OJO</i>		<i>0.513</i>	<i>0.386</i>	<i>0.393</i>	<i>0.360</i>		
14	Oczekiwane		0.800	0.800	225.000	45.000	400	0
	Przed	0.515	0.550	1.300	176.990	53.100		
	<i>OJO</i>		<i>0.406</i>	<i>0.346</i>	<i>0.620</i>	<i>0.513</i>		
	Etap I	0.515	0.550	1.300	176.990	53.100		
	Etap II	0.515	0.550	1.300	176.990	53.100		
	<i>OJO</i>		<i>0.406</i>	<i>0.346</i>	<i>0.620</i>	<i>0.513</i>		
15	Oczekiwane		1.200	1.400	315.000	225.000	400	2
	Przed	0.433	1.010	1.110	54.400	169.000		
	<i>OJO</i>		<i>0.286</i>	<i>0.206</i>	<i>0.806</i>	<i>0.626</i>		
	Etap I	0.615	1.800	0.870	206.090	209.590		
	Etap II	0.628	1.589	0.967	197.724	186.822		
	<i>OJO</i>		<i>0.306</i>	<i>0.346</i>	<i>0.700</i>	<i>0.540</i>		

- Dla połowy danych testowych nie nastąpiło oczekiwane zagęszczenie danych w ich najbliższym obszarze (patrz kolumna o nazwie *LNS* w tablicach: tablica IV, tablica V, tablica VI). Wykonanie dla każdej z tych danych testowych czterystu losowań wartości cech sygnałów diagnostycznych nie spowodowało aktualizacji zbioru ich najbliższych sąsiadów.
- Dla danych testowych, dla których uzyskano stosunkowo dużą liczbę nowych sąsiadów (patrz kolumna o nazwie *LNS* w tablicach: tablica IV, tablica V, tablica VI - dane testowe o numerach 5, 12, 13) nie we wszystkich przypadkach nastąpił oczekiwany wzrost wartości miary jakości wyznaczanych modeli lecz jej spadek.
- Obserwując wykresy (rys. 53) wartości miary jakości w funkcji dopisanych nowych danych można zaobserwować, że zmiany wartości miary jakości występują w niewielu miejscach na wykresach. Powodem takiej postaci wykresów jest to, że niewiele spośród losowanych wartości cech sygnałów diagnostycznych spowodowało aktualizację zbioru najbliższych sąsiadów danych testowych.
- Dla danych testowych, dla których nastąpiło zagęszczenie danych w ich najbliższym obszarze, uległy zmianie wartości miar jednoznaczności odwzorowania wyznaczanych na podstawie podstawowego oraz uzupełnianego zbioru przykładów w stosunku do wartości

miar uzyskanych na podstawie podstawowego zbioru przykładów. Dla niektórych przykładów miara ta rośnie, dla innych maleje.




Rys. 53. Wykresy miary jakości wyznaczonego modelu odwrotnego w funkcji liczby dopisanych nowych przykładów (dane testowe nr 2 i nr 12)

Fig. 53. Diagram of quality measure of identified inverse model versus number of new updated data (test data no. 2 and no. 12)

Na uzyskanie takich wyników najprawdopodobniej miały wpływ następujące czynniki:

- 1) Dla danych pochodzących z pomiarów pojawił się dość znaczny szum pomiarowy, który nie występował w przypadku danych pochodzących z symulacji.



Rys. 54. Wpływ szumu na otrzymane wyniki

Fig. 54. Effect of noise on the obtained results

- 2) Rozpatrywany obiekt pod względem zachowań dynamicznych odwzorowano za pomocą modelu liniowego. Rozpatrywany obiekt jest silnie nieliniowy, co widać na rysunkach (rys. 40 i rys. 41). Stosowanie modelu liniowego znacznie skraca czas obliczeń, co ze względu na postawiony cel badań, jakim była weryfikacja proponowanej metody doskonalenia odwrotnych modeli diagnostycznych, było niezmiernie istotne. Należy jednak

pamiętać, że odwzorowanie zachowań dynamicznych obiektu za pomocą modelu liniowego wprowadziło „dodatkowy” szum do danych. Na rysunku (rys. 54) pokazano dane, dla których dodano stałą wartość szumu o takim samym znaku. Rozpatrywana przestrzeń symptomów jest przestrzenią jednowymiarową, jednak już można zauważyć, że dane uzyskane w wyniku odwracania modelu, a następnie stosowania symulatora znajdują się poza obszarem wyznaczania lokalnego modelu odwrotnego. Następuje więc aktualizacja danych, które jednak nie są brane pod uwagę w trakcie identyfikacji kolejnych modeli odwrotnych (dane znajdują się poza rozpatrywanym obszarem obowiązywania modelu lokalnego). Eksperymenty prezentowane w pracy przeprowadzane były dla wielowymiarowych przestrzeni symptomów (rozpatrywano przestrzeń 24 wymiarową), co, jak można przypuszczać, zwiększa możliwość wystąpienia tego typu trudności. Istnieje jednak możliwość zabezpieczenia się przed taką sytuacją przez np. dobór innego (w tym przypadku większego) obszaru, w którym wyznacza się model odwrotny.

5.3.8. Wyniki otrzymane dla danych pochodzących z symulacji z szumem

Wyniki, które otrzymano dla danych pochodzących z pomiarów, skłoniły autora do przeprowadzenia jeszcze jednego eksperymentu. W eksperymencie tym podstawowy zbiór przykładów oraz dane testowe pochodziły z symulacji, ale z uwzględnieniem celowo wprowadzonego szumu. Dla uzyskanych z symulacji współczynników A, B, C, D obliczono amplitudę oraz fazę składowej przemieszczeń drgań 1X w kierunku poziomym oraz pionowym w rozpatrywanych węzłach. W kolejnym kroku wprowadzono szum. Do obliczonych wartości amplitud przemieszczeń drgań dodano (lub odjęto) wartość 4 [μm], natomiast do faz dodano (lub odjęto) wartość 1 [°]. Znak szumu (+/-) określano losowo.

Tablica VII

Otrzymane wyniki dla danych testowych nr 1 – nr 2

DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
1	Oczekiwane		0.800	0.800	225.000	315.000	400	25
	Przed	0.477	1.175	1.012	144.673	340.328		
	<i>OJO</i>		0.326	0.253	0.753	0.493		
	Etap I	0.729	1.190	0.720	123.900	6.060		
	Etap II	0.840	0.700	0.590	169.300	53.300		
	<i>OJO</i>		0.386	0.500	0.433	0.480		
2	Oczekiwane		1.000	1.200	225.000	315.000	400	19
	Przed	0.626	0.560	0.853	208.385	61.119		
	<i>OJO</i>		0.320	0.280	0.840	0.540		
	Etap I	0.438	0.130	1.210	220.390	231.390		
	Etap II	0.681	0.580	1.880	208.990	7.5000		
	<i>OJO</i>		0.293	0.420	0.440	0.426		

Otrzymane wyniki dla danych testowych nr 3 - nr 9


DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
3	Oczekiwane		0.800	1.400	45.000	315.000	400	23
	Przed	0.669	0.689	1.092	98.677	220.000		
	<i>OJO</i>		<i>0.306</i>	<i>0.300</i>	<i>0.700</i>	<i>0.626</i>		
	Etap I	0.640	1.150	1.070	130.200	294.790		
	Etap II	0.739	0.800	1.530	183.990	267.690		
	<i>OJO</i>		<i>0.273</i>	<i>0.433</i>	<i>0.500</i>	<i>0.386</i>		
4	Oczekiwane		1.200	1.000	225.000	135.000	400	21
	Przed	0.553	0.851	1.047	269.452	214.801		
	<i>OJO</i>		<i>0.360</i>	<i>0.313</i>	<i>0.760</i>	<i>0.606</i>		
	Etap I	0.336	0.390	1.912	273.630	225.889		
	Etap II	0.228	2.170	1.720	121.140	62.900		
	<i>OJO</i>		<i>0.260</i>	<i>0.333</i>	<i>0.313</i>	<i>0.280</i>		
5	Oczekiwane		0.800	0.600	45.000	45.000	400	23
	Przed	0.871	0.802	0.688	34.665	5.340		
	<i>OJO</i>		<i>0.333</i>	<i>0.133</i>	<i>0.466</i>	<i>0.440</i>		
	Etap I	0.626	0.810	1.510	108.700	304.690		
	Etap II	0.852	0.640	0.721	30.856	25.691		
	<i>OJO</i>		<i>0.266</i>	<i>0.260</i>	<i>0.273</i>	<i>0.280</i>		
6	Oczekiwane		0.000	1.200	0.000	225.000	400	22
	Przed	0.663	0.712	1.174	62.858	245.440		
	<i>OJO</i>		<i>0.393</i>	<i>0.333</i>	<i>0.546</i>	<i>0.486</i>		
	Etap I	0.308	2.140	1.520	78.300	152.100		
	Etap II	0.415	1.930	1.120	127.700	126.600		
	<i>OJO</i>		<i>0.300</i>	<i>0.286</i>	<i>0.340</i>	<i>0.293</i>		
7	Oczekiwane		1.400	0.800	135.000	45.000	400	24
	Przed	0.701	0.807	1.292	91.868	38.402		
	<i>OJO</i>		<i>0.320</i>	<i>0.353</i>	<i>0.673</i>	<i>0.593</i>		
	Etap I	0.217	1.280	1.990	312.000	148.80		
	Etap II	0.513	0.082	0.727	234.121	69.753		
	<i>OJO</i>		<i>0.406</i>	<i>0.460</i>	<i>0.406</i>	<i>0.553</i>		
8	Oczekiwane		0.800	1.400	315.000	135.000	400	25
	Przed	0.718	1.497	1.509	15.436	81.814		
	<i>OJO</i>		<i>0.340</i>	<i>0.380</i>	<i>0.616</i>	<i>0.490</i>		
	Etap I	0.514	1.630	1.980	40.800	2.400		
	Etap II	0.632	1.532	0.998	10.218	22.430		
	<i>OJO</i>		<i>0.253</i>	<i>0.340</i>	<i>0.300</i>	<i>0.300</i>		
9	Oczekiwane		1.200	0.800	315.000	45.000	400	20
	Przed	0.794	0.798	1.422	13.496	80.482		
	<i>OJO</i>		<i>0.313</i>	<i>0.340</i>	<i>0.673</i>	<i>0.546</i>		
	Etap I	0.628	0.679	0.548	280.782	319.810		
	Etap II	0.443	0.773	1.892	227.588	154.648		
	<i>OJO</i>		<i>0.300</i>	<i>0.353</i>	<i>0.293</i>	<i>0.413</i>		

Otrzymane wyniki dla danych testowych nr 10 - nr 15

DT	Opis	MJ	NW1	NW2	FN1	FN2	LNP	LNS
10	Oczekiwane		0.000	1.200	0.000	45.000	400	22
	Przed	0.909	0.511	1.021	155.123	74.575		
	<i>OJO</i>		<i>0.400</i>	<i>0.333</i>	<i>0.566</i>	<i>0.500</i>		
	Etap I	0.891	0.591	0.982	135.020	92.138		
	Etap II	0.911	0.515	1.051	151.328	71.832		
	<i>OJO</i>		<i>0.246</i>	<i>0.200</i>	<i>0.286</i>	<i>0.313</i>		
11	Oczekiwane		1.400	0.000	135.000	0.000	400	20
	Przed	0.865	1.083	0.855	166.201	278.187		
	<i>OJO</i>		<i>0.326</i>	<i>0.380</i>	<i>0.646</i>	<i>0.466</i>		
	Etap I	0.870	1.121	0.732	154.243	315.00		
	Etap II	0.883	1.238	0.632	145.321	321.089		
	<i>OJO</i>		<i>0.386</i>	<i>0.500</i>	<i>0.433</i>	<i>0.480</i>		
12	Oczekiwane		1.200	1.400	315.000	315.000	400	13
	Przed	0.856	0.667	0.428	308.798	316.858		
	<i>OJO</i>		<i>0.393</i>	<i>0.140</i>	<i>0.506</i>	<i>0.426</i>		
	Etap I	0.782	0.821	1.129	25.832	51.717		
	Etap II	0.872	0.918	1.325	213.010	254.172		
	<i>OJO</i>		<i>0.300</i>	<i>0.253</i>	<i>0.226</i>	<i>0.246</i>		
13	Oczekiwane		0.800	1.200	225.000	225.000	400	8
	Przed	0.671	0.810	0.983	33.600	332.862		
	<i>OJO</i>		<i>0.306</i>	<i>0.120</i>	<i>0.520</i>	<i>0.466</i>		
	Etap I	0.541	1.497	0.721	31.891	201.328		
	Etap II	0.347	2.158	0.667	27.934	171.683		
	<i>OJO</i>		<i>0.226</i>	<i>0.220</i>	<i>0.273</i>	<i>0.233</i>		
14	Oczekiwane		0.800	0.800	225.000	45.000	400	25
	Przed	0.947	0.691	0.945	207.979	54.375		
	<i>OJO</i>		<i>0.346</i>	<i>0.340</i>	<i>0.633</i>	<i>0.460</i>		
	Etap I	0.873	0.732	0.845	182.321	311.823		
	Etap II	0.841	0.754	0.832	189.345	331.845		
	<i>OJO</i>		<i>0.253</i>	<i>0.360</i>	<i>0.426</i>	<i>0.406</i>		
15	Oczekiwane		1.200	1.400	315.000	225.000	400	16
	Przed	0.691	0.966	0.900	18.432	206.082		
	<i>OJO</i>		<i>0.306</i>	<i>0.286</i>	<i>0.740</i>	<i>0.640</i>		
	Etap I	0.723	0.991	1.024	20.954	207.540		
	Etap II	0.758	1.123	0.965	25.012	203.21		
	<i>OJO</i>		<i>0.280</i>	<i>0.922</i>	<i>0.950</i>	<i>0.872</i>		

Na podstawie tak określonych wartości amplitud oraz faz składowej IX przemieszczeń drgań obliczono nowe współczynniki A, B, C, D. Wyniki otrzymane dla rozpatrywanych danych zestawiono w tablicach (tablica VII, tablica VIII, tablica IX).

Po wykonaniu pierwszego etapu obliczeń, w którym założono (podobnie jak w poprzednich eksperymentach), że wykonanych będzie maksymalnie 200 kroków, dla żadnego przykładu danych testowych nie otrzymano zadowalającej wartości miary jakości wyznaczanego modelu. Dla wszystkich danych testowych poszukiwanie rozwiązania wymagało wykonania dużej liczby losowań wartości cech sygnałów diagnostycznych (losowanie wartości cech sygnałów diagnostycznych występowało powyżej 90% wykonanej liczby kroków).



Rys. 55. Wykres miary jakości wyznaczanego modelu odwrotnego w funkcji liczby dopisanych nowych przykładów oraz poszukiwanie rozwiązania przez doskonalony model odwrotny dla danych testowych nr 1

Fig. 55. Diagram of quality measure of identified inverse model versus number of new updated data and search of solution by improved inverse model for test data no. 1

Analizując pokazane wyniki (tablica VII, tablica VIII, tablica IX) można wyciągnąć następujące wnioski:

- Dla większości danych testowych wartości miary jakości modeli wyznaczanych na podstawie podstawowego zbioru przykładów pochodzącego z symulacji z szumem są wyższe niż wartości miary jakości modeli wyznaczanych na podstawie podstawowego zbioru przykładów pochodzącego z pomiarów (patrz rozdział 5.3.7).
- Dla wszystkich danych testowych widać, że po zakończeniu uzupełniających badań symulacyjnych najbliżsi sąsiedzi wyznaczeni dla tych danych na podstawie podstawowego i uzupełnionego zbioru przykładów w większości pochodzą ze zbioru przykładów wyznaczonych w wyniku przeprowadzenia uzupełniających badań symulacyjnych (tablica VII, tablica VIII, tablica IX - kolumna o nazwie *LNS*). Otrzymano w ten sposób wynik lepszy niż dla danych pochodzących z pomiarów, jednocześnie gorszy niż dla danych pochodzących z symulacji.

- Pomimo aktualizacji zbioru najbliższych sąsiadów danych testowych nie dla wszystkich danych testowych nastąpił wzrost miary jakości modelu wyznaczanego na podstawie podstawowego i uzupełnionego zbioru przykładów.
- Duża wartość miary jakości wyznaczanego modelu nie gwarantuje dojścia do poprawnego rozwiązania, na co główny wpływ ma wprowadzony szum. Pomimo stosunkowo dużej jakości wyznaczanego modelu wartości szacowanych niewy wag oraz faz tych niewy wag znacznie się różnią od wartości oczekiwanych (tablica - dane testowe nr 10 i nr 14).
- Wartości ocen jednoznaczności odwzorowania wyznaczanych na podstawie podstawowego oraz uzupełnianego zbioru przykładów prawie we wszystkich przypadkach maleją względem wartości ocen jednoznaczności odwzorowania wyznaczanych na podstawie podstawowego zbioru przykładów. Świadczy to o tym, że nowe dane wprowadzają niejednoznaczność odwzorowania, czego można było się spodziewać (dla tych samych wartości cech stanów wartości cech sygnałów diagnostycznych są różne dla danych z szumem i bez szumu).

5.3.9. Podsumowanie

Otrzymane wyniki potwierdzają, że możliwe jest doskonalenie diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów. Wyniki wykazały również formalną poprawność zaproponowanej w pracy metody doskonalenia diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów. W przypadku eksperymentu weryfikującego proponowaną metodę dla danych otrzymanych w wyniku przeprowadzenia obliczeń numerycznych uzyskano stuprocentową sprawność tej metody. Wyniki otrzymane dla danych pochodzących z pomiarów wyraźnie wskazują, że powodzenie operacji doskonalenia modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów w dużej mierze zależy od dokładności dopasowania modelu do rzeczywistego obiektu.

Wyniki eksperymentu, w którym dane otrzymano w wyniku przeprowadzenia obliczeń numerycznych wraz z szumem, wyraźnie wskazują, jak duży wpływ na otrzymanie poprawnych wyników ma szum znajdujący się w danych. Jednym ze sposobów zabezpieczenia się przed tak dużym wpływem szumu na jakość wyznaczanych modeli odwrotnych wydaje się być w przyszłości rozpatrywanie zamiast dokładnych wartości cech, klas wartości cech. Można podjąć również próby przekształcenia wartości cech ilościowych (które były rozpatrywane w pracy) w cechy jakościowe. Można przypuszczać, że stosowanie klas wartości cech bądź cech jakościowych spowoduje pewne uodpornienie się metody na szum pomiarowy, który występuje w rzeczywistych układach oraz ewentualne niedokładności dopasowania modelu do rzeczywistego obiektu. Uwaga ta dotyczy rozpatrywania zarówno cech sygnałów diagnostycznych, jak i cech stanów.

W proponowanej metodzie adaptacyjnego sterowania badaniami symulacyjnymi występuje losowanie wartości cech sygnałów diagnostycznych. Podczas realizacji eksperymentów losowanie wartości cech sygnałów diagnostycznych przeprowadzano w najbliższym

otoczeniu danych testowych (najbliższe otoczenie określano na podstawie wartości cech sygnałów diagnostycznych najbliższego sąsiada danych testowych). Ze względu na duży udział czynnika losowego w przeprowadzonych eksperymentach wydaje się zasadne podjęcie prób opracowania strategii losowania wartości cech sygnałów diagnostycznych. Strategie te miałyby doprowadzić do losowania wartości cech sygnałów diagnostycznych w takich miejscach przestrzeni symptomów, aby aktualizacja zbioru przykładów prowadziła w jak najkrótszym czasie do optymalizacji jakości wyznaczanych modeli. Strategie takie mogłyby bazować na analizie rozkładu danych w przestrzeni symptomów w najbliższym otoczeniu rozpatrywanych danych testowych.

6. Podsumowanie

W monografii omówiono metody umożliwiające doskonalenie modeli pozwalających na wnioskowanie o stanie technicznym obiektu na podstawie obserwowanych symptomów. Opisano metodę umożliwiającą wyznaczenie i doskonalenie rozpatrywanych modeli, nazywanych modelami odwrotnymi (modele te wyznaczone są w wyniku odwracania znanych i zweryfikowanych doświadczalnie teoretycznych modeli obiektów, które pozwalają na wyznaczanie technikami numerycznymi obserwowanych symptomów jako skutków zadawanych stanów technicznych). Szczegółowo zostały omówione takie zagadnienia, jak:

- *Metody identyfikacji modeli relacji.* Jakość wyznaczanego modelu zależy między innymi od postaci modelu. Na podstawie przeglądu literatury opisano algorytmy pozwalające na wyznaczanie odwrotnych modeli globalnych oraz lokalnych, ze szczególnym uwzględnieniem tych drugich, wyznaczanych przez stosowanie algorytmów wielowymiarowej interpolacji. Pokazano również zalety modeli dopasowywanych lokalnie w porównaniu z modelami globalnymi.
- *Metody pozwalające na wybór liczby i rodzaju wejściowych cech modelu.* Istotny wpływ na jakość wyznaczanych modeli ma odpowiedni wybór liczby i rodzaju wejściowych cech modelu, ponieważ jakość wyznaczanego modelu nie może być lepsza od jakości danych uczących, na podstawie których został on wyznaczony. Błędem może być również uwzględnianie nadmiernej liczby cech, które mogą prowadzić do pogorszenia jakości wyznaczanego modelu odwrotnego. Omówiono pojęcie cechy oraz ogólnie sformułowano zagadnienie wyboru cech. Na podstawie badań literaturowych dokonano przeglądu wybranych metod wyboru cech ze względu na rozpatrywane zadanie wyznaczania modelu odwrotnego. W takim ujęciu metody wyboru cech podzielono na trzy grupy (metody uwzględniające wartości cech sygnałów diagnostycznych, metody uwzględniające klasy wartości cech stanów i metody uwzględniające wartości cech stanów). Opisano również dwie metody wyboru cech wejściowych modeli proponowane przez autora. Pierwsza z nich bazuje na jakości wyznaczanych modeli odwrotnych, natomiast druga bazuje na badaniu niejednoznaczności odwzorowania przestrzeni symptomów w przestrzeń stanów.
- *Planowanie badań symulacyjnych.* Zakładając, że diagnostyczny model odwrotny wyznaczany jest na bazie przykładów danych uczących (wyznaczonych przez model obiektu lub uzyskanych z pomiarów w wyniku przeprowadzenia czynnego eksperymentu diagnostycznego) opisujących zadane stany rozpatrywanego obiektu oraz odpowiadające tym stanom wartości cech sygnałów diagnostycznych, istotna jest jakość tych przykładów. Od przykładów zależy powodzenie operacji odwracania modelu oraz jakość wyznaczonego modelu odwrotnego. Opisano sposób 2-etapowego planowania badań symulacyjnych (podstawowe i uzupełniające badania symulacyjne). Następnie przedstawiono istotę zaproponowanego przez autora adaptacyjnego sterowania badaniami

symulacyjnymi, zmierzającego do poprawy jakości wyznaczanego modelu odwrotnego. Szczególną uwagę poświęcono możliwości sterowania badaniami symulacyjnymi, zmierzającymi do poprawy jakości lokalnego modelu odwrotnego, związanego z wyróżnionym punktem w wielowymiarowej przestrzeni symptomów. Współrzędne wyróżnionego punktu w wielowymiarowej przestrzeni symptomów mogą być określane w wyniku pomiarów wartości cech sygnałów diagnostycznych na rzeczywistym obiekcie.

Opisano również przeprowadzone eksperymenty mające na celu weryfikację proponowanej metody doskonalenia diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów. Wyznaczano modele odwrotne, pozwalające na określenie stanu niewyrównowazenia rozpatrywanego obiektu z klasy maszyn wimikowych na podstawie ocen drgań mierzonych w pobliżu opraw łożyskowych. Uzyskane wyniki wskazały formalną poprawność zaproponowanej metody doskonalenia diagnostycznych modeli odwrotnych przez odpowiednią aktualizację zbioru przykładów.

W pracy wskazano również na możliwość realizacji niezbędnych obliczeń w rozproszonych systemach komputerowych - operacja odwracania modelu realizowana była w Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach, natomiast obliczenia symulacyjne były przeprowadzane w Instytucie Maszyn Przepływowych Polskiej Akademii Nauk w Gdańsku. Rozpatrywanie rozproszonego środowiska obliczeniowego uzasadnione jest również względami praktycznymi. Opisywane metody postępowania mogą być stosowane do oceny stanu technicznego dużych turbozespołów, których modele numeryczne mogą być realizowane na komputerach w wybranych ośrodkach badawczych, podczas gdy dane określające aktualne symptomy mogą być wyznaczane w sąsiedztwie obiektu (w elektrowni).

Rozpatrywany model numeryczny obiektu był modelem liniowym, wprawdzie bardzo złożonym, ale dającym w efekcie trajektorie przemieszczeń dynamicznych wyłącznie w postaci elips. Zamodelowanie bardziej złożonych stanów (np. niewyrównowazenia i/lub rozosiowania) nie było możliwe za pomocą rozpatrywanego modelu liniowego. Uwzględnianie w przyszłości modelu nieliniowego pozwoli na zamodelowanie o wiele większego zbioru możliwych stanów. Rozpatrywane w monografii dane uczące określone były w wyniku przeprowadzenia obliczeń numerycznych oraz pomiarów w ramach czynnego eksperymentu diagnostycznego. W dalszych badaniach można stosować również dane uczące otrzymane z pomiarów w wyniku biernego eksperymentu diagnostycznego.

Można wyróżnić pewne główne kierunki dalszych prac związanych z zagadnieniami dotyczącymi wyznaczania i doskonalenia diagnostycznych modeli odwrotnych:

- 1) Doskonalenie zaproponowanej metody adaptacyjnego sterowania badaniami symulacyjnymi, głównie skierowane na opracowywanie strategii losowania wartości cech sygnałów diagnostycznych w przestrzeni symptomów, zmierzających do skracania czasu potrzebnego na optymalizację jakości wyznaczanych modeli odwrotnych.
- 2) Zbadanie przydatności opisywanej koncepcji modeli lokalnych dla potrzeb odwracania modeli nieliniowych.

- 3) Poszukiwanie nowych cech sygnałów diagnostycznych oraz określenie algorytmów wyznaczania ich wartości, obejmujących zarówno cechy pozwalające na opis trajektorii wyznaczanych w wyniku zastosowania modeli nieliniowych, jak i cechy umożliwiające opis wielowymiarowych sygnałów diagnostycznych.
- 4) Próba zastosowania przybliżonych modeli odwrotnych, będących wynikiem wprowadzenia przybliżonych wartości cech sygnałów diagnostycznych oraz wynikiem zastępowania cech ilościowych wprowadzanymi nowymi cechami jakościowymi.
- 5) Definiowanie struktury baz danych, przeznaczonych do przechowywania zarówno wartości cech rozpatrywanych obiektów, jak i przykładów danych uczących (uzyskanych zarówno w wyniku symulacji, jak i pomiarów na rzeczywistym obiekcie) oraz określanie zasad zarządzania takimi bazami.

Można przypuszczać, że rozpatrywanie modeli nieliniowych wprowadzi anizotropię rozpatrywanych przestrzeni stanów i symptomów, co w znacznym stopniu komplikuje procedurę odwracania modeli, konieczne staje się stosowanie procedur zmierzających do normalizacji przestrzeni wartości cech.

Autor wyraża nadzieję, że powyższe zagadnienia stanowiąc będą przedmiot dalszych badań, a zamieszczone w pracy metody, techniki, uzyskane wyniki oraz wskazane kierunki dalszych możliwych prac zadanie to znacznie ułatwią.

Dodatki

Dodatek A

Oceny jednoznaczności odwzorowania


W Katedrze Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach podjęto próbę definiowania miar pozwalających na badanie jednoznaczności odwzorowania na postawie danych punktowych. Opisane w dalszej części rozdziału oceny jednoznaczności odwzorowania są wynikiem prac prowadzonych nad tym zagadnieniem w KPKM, w których uczestniczył autor. Opisane miary są ocenami heurystycznymi i jako tako w większości przypadków prowadzą do zadowalających wyników, choć nie zawsze. Na podstawie przeglądu dostępnej literatury przyjęto, że w przypadku braku miar dokładnych istnieje możliwość zastosowania ocen heurystycznych.

Rozpatrywane w pracy modele odwrotne identyfikowane były na podstawie danych, uzyskanych w wyniku stosowania modelu M (rys. 2) oraz na podstawie danych uzyskanych w wyniku pomiarów przeprowadzonych w ramach czynnego eksperymentu diagnostycznego na rozpatrywanym obiekcie badań (rys. 32). Na wstępie pracy zwrócono uwagę na to, że w zastosowaniach związanych z diagnostyką techniczną brak jest podstaw do przyjmowania założenia o istnieniu jednoznacznego odwzorowania pomiędzy wejściem i wyjściem tych modeli (rys. 3). Z przeprowadzonych badań [67] wynika, iż zawsze wtedy, gdy jest to możliwe, należy zrezygnować z ogólnych modeli relacji i dążyć do poszukiwania modelu odwzorowania, ponieważ modele takie są bardziej dokładne niż ogólne modele relacji.

W [41] w celu uniknięcia konieczności każdorazowego sprawdzania możliwości wyznaczenia modelu za pomocą wszystkich znanych metod oraz uniknięcia potrzeby przedwczesnego podejmowania decyzji o rezygnacji z poszukiwania modelu odwzorowania wprowadzono miary stopnia jednoznaczności odwzorowania.


A.1. Kryteria ogólne

Rysunek 56 i rys. 57 zawierają przykłady relacji określonych dla wszystkich wartości zmiennej niezależnej w rozpatrywanym przedziale $[0.1; 0.9]$. Pierwszy przykład (rys. 56) ilustruje odwzorowanie, gdzie każdej wartości zmiennej niezależnej odpowiada jedna i tylko jedna wartość zmiennej zależnej (jednoznaczność). Drugi przykład (rys. 57) nie jest przykładem odwzorowania jednoznacznego (nie jest to funkcja), ponieważ wartościom zmiennej niezależnej z przedziału $[0.5; 0.7]$ odpowiada więcej niż jedna wartość zmiennej zależnej. Cechą szczególną przykładów (rys. 56 i rys. 57) jest to, że rozpatrywane relacje określone zostały *gęsto*, tzn. dla wszystkich wartości zmiennej niezależnej w rozpatrywanym przedziale. Cecha ta umożliwiła wykrywanie obszaru, w którym relacja nie jest odwzorowaniem jednoznacznym.



Rys. 56. Przykład odwzorowania [41]


Fig. 56. Example of mapping [41]



Rys. 57. Przykład relacji [41]

Fig. 57. Example of relation [41]

Dane uczące (16), dla których poszukiwane są modele, nie są danymi określonymi *gęsto*. Rysunek 58 pokazuje dyskretną wersję relacji określonej *gęsto* (rys. 57). Dyskretny charakter tych danych utrudnia w znacznym stopniu poszukiwanie obszaru, w którym relacja nie jest odwzorowaniem jednoznacznym.



Rys. 58. Przykład relacji [41]

Fig. 58. Example of relation [41]

Wyróżnić można co najmniej dwa rodzaje niejednoznaczności odwzorowania:

- odwzorowanie niejednoznaczne pierwszego rodzaju („mniej groźne” dla potrzeb odwracania) – odwzorowanie jednej wartości cechy stanu w więcej niż jedną wartość cechy sygnału diagnostycznego;
- odwzorowanie niejednoznaczne drugiego rodzaju („bardziej groźne” dla potrzeb odwracania) – odwzorowanie różnych wartości cechy stanu w tę samą wartość cechy sygnału diagnostycznego.

Niejednoznaczność odwzorowania pierwszego rodzaju może być spowodowana np. niedokładnościami pomiarów wartości cech sygnałów diagnostycznych. Kolejne pomiary wykonane dla takiego samego stanu mogą różnić się wartościami.

Niejednoznaczność odwzorowania drugiego rodzaju może być spowodowana kilkoma przyczynami:

- wybór nieodpowiedniej wielkości mierzonej jako cechy sygnału diagnostycznego (mała wrażliwość cechy sygnału diagnostycznego, której wartości nie ulegają zmianie lub ulegają zmianie w bardzo małym zakresie przy odpowiednio dużych zmianach wartości cech stanu);
- zmiany wartości cech stanu występują w bardzo małym stopniu, co nie wpływa na zmiany wartości cech sygnałów diagnostycznych;
- zmiany wartości cech stanu występujące w bardzo dużym stopniu mogą powodować powstanie tych samych (lub zbliżonych) wartości cech sygnałów diagnostycznych (np. dla kilku różnych stanów niewyrównoważenia wirnika można otrzymać takie same wartości cech sygnałów diagnostycznych).

Przyjmując kryteria oceny jednoznaczności odwzorowania należy pamiętać, że dotyczyć one mają danych wielowymiarowych. Kryteria takie mogą być określane na podstawie porównania odległości par odpowiadających sobie punktów odpowiednio w przestrzeniach wartości wejść i przestrzeniach wartości wyjść modelu (zmiennie niezależne i zmiennie zależne).

W [41] zaproponowano następujące ogólne kryteria badania jednoznaczności odwzorowania:

- dla relacji będących odwzorowaniami jednoznaczными małymi odległościami punktów w przestrzeni wejść odpowiadać powinny małe odległości tych punktów w przestrzeni wyjść,
- dla relacji będących odwzorowaniami wieloznacznymi małymi odległościami punktów w przestrzeni wejść odpowiadać mogą duże odległości tych punktów w przestrzeni wyjść,
- badanie odległych punktów w przestrzeni wejść nie stanowi podstawy do orzekania o jednoznaczności odwzorowania.

Niedogodnością powyższych warunków jest stosowanie niedokładnych określeń: *mała odległość*, *duża odległość* oraz potrzeba rozpatrywania przestrzeni wejść i przestrzeni wyjść jako przestrzeni metrycznych, w których zdefiniowano pojęcie odległości. W celu uniknięcia kłopotów występujących podczas definiowania odległości w przestrzeniach, które rozpięte są nad cechami o różnych wielkościach fizycznych (np. temperatura i prędkość drgań), stosować można odpowiednią normalizację wartości tych cech [25].

W [41] podjęto próbę zdefiniowania miar pozwalających na oceny jednoznaczności odwzorowania bazujące na badaniu odległości w przestrzeni wejść i wyjść. Odległości w przestrzeni wejść i wyjść mogą być badane za pomocą histogramów ich łącznego rozkładu. Można w tym celu zastosować również badanie lokalnych odchyłeń oraz badanie liczby najbliższych sąsiadów. W kolejnych podrozdziałach będą opisane definicje wymienionych miar [41]. Prezentowane w dalszej części pracy miary były badane pod kątem poprawności oceniania jednoznaczności odwzorowania i zostały sformułowane następujące wnioski [67]:

- opisane miary są ocenami heurystycznymi i jako takie w większości przypadków prowadzą do zadowalających wyników, choć nie zawsze;
- badanie jednoznaczności odwzorowania jest możliwe;
- dla zaproponowanych miar jednoznaczności odwzorowania trudno jest znaleźć granice (progi), które pozwalałyby na jednoznaczne klasyfikowanie stopnia niejednoznaczności odwzorowania;
- za pomocą wprowadzonych miar jednoznaczności odwzorowania możliwe jest (w większości przypadków) rozstrzygnięcie, czy dane są odwzorowane jednoznacznie;
- w celu zastosowania zaproponowanych miar jakości odwzorowania należy dobrać odpowiednie wartości parametrów (np. liczba najbliższych sąsiadów), dla których zaproponowane miary najlepiej różnicują przypadki niejednoznaczności odwzorowania.

A.2. Badanie histogramów łącznego rozkładu

Prezentowane w tym podrozdziale rozważania zaproponowano w [39]. Histogramy łącznego rozkładu pozwalają na badanie związków występujących pomiędzy odległościami elementów wejść i wyjść modelu. W celu określenia podstawowego parametru histogramu, jakim są rozmiary elementarnej jego komórki, wyznacza się (lub przyjmuje arbitralnie) zakresy zmian wartości wejść i wyjść:

$$dist_{\max}(\{\underline{x}\}) = \max_{i=1}^{N-1} \max_{j=i+1}^N \left(dist(\underline{x}_i, \underline{x}_j) \right) \quad (126)$$

$$dist_{\max}(\{\underline{y}\}) = \max_{i=1}^{N-1} \max_{j=i+1}^N \left(dist(\underline{y}_i, \underline{y}_j) \right) \quad (127)$$

Po przyjęciu tych zakresów ustalane są szerokości odpowiednich przedziałów (rozmiary komórek histogramu):

$$SP(\{\underline{x}\}) = \frac{dist_{\max}(\{\underline{x}\})}{Lp_x} \quad (128)$$

$$SP(\{\underline{y}\}) = \frac{dist_{\max}(\{\underline{y}\})}{Lp_y}, \quad (129)$$



gdzie:

Lp_x - liczba przedziałów (klas) rozróżnianych wartości wejść;

Lp_y - liczba przedziałów (klas) rozróżnianych wartości wyjść.

Rysunek 59 pokazuje przykłady histogramów łącznego rozkładu, w których zaznaczono komórki o niezerowych wartościach. Ze względu na to, że badanie odległych elementów (punktów) w przestrzeni wejść nie stanowi postawy do orzekania o jednoznaczności

odzworowania, pokazane zostały na histogramach wyłącznie początkowe przedziały dla odległości wejść.



Rys. 59. Przykłady histogramów wyznaczonych dla odzworowań:
a) jednoznacznych, b) wieloznacznych [39]

Fig. 59. Examples of histograms determined for:
a) one-to-one mapping, b) not one-to-one mapping [39]

Podstawą wnioskowania o rodzaju odzworowania są następujące stwierdzenia:

- dla relacji będących odzworowaniami jednoznacznymi małym odległościom elementów (punktów) w przestrzeni wejść odpowiadać powinny małe odległości w przestrzeni wyjść (rys. 59a);
- dla relacji będących odzworowaniami wieloznacznymi małym odległościom elementów (punktów) w przestrzeni wejść odpowiadać mogą duże odległości tych punktów w przestrzeni wyjść, czego przykład pokazano na rys. 59b.

W celu umożliwienia ilościowej oceny charakteru rozkładu wprowadzona została miara jednoznaczności odzworowania (*MJO*) [39]:

$$MJO = \frac{\sum_{i=1}^{l_i} \sum_{j=1}^{l_j} A_{i,j} w_{i,j}}{\sum_{i=1}^{l_i} \sum_{j=1}^{l_j} A_{i,j}} \quad (130)$$

$$w_{i,j} = \begin{cases} +1 & \text{dla } i \geq j \\ -1 & \text{dla } i < j \end{cases} \quad (131)$$

gdzie:

- A_i - liczba jednoczesnych wystąpień w i -tym przedziale odległości elementów w przestrzeni wejść oraz j -tym przedziale odległości elementów w przestrzeni wyjść;
- l_i - liczba rozpatrywanych przedziałów histogramu dla odległości elementów w przestrzeni wejść;
- l_j - liczba rozpatrywanych przedziałów histogramu dla odległości elementów w przestrzeni wyjść.

Wartość miary (130) zawarta jest w przedziale $\langle -1, 1 \rangle$. Interpretacja wartości tej miary jest następująca:

- wartość równa zero oraz wartość bliska zero od strony dodatniej oznacza, że odwzorowanie jest jednoznaczne;
- wartość ujemna może oznaczać, że odwzorowanie jest wieloznaczne;
- wartość dodatnia może oznaczać, że odwzorowanie jest jednoznaczne, z tym że im wartość ta jest bliższa 1, tym liczba klas różnych wartości wejść jest mniejsza.

Linia podwójna (rys. 60) ogranicza z prawej strony fragment histogramu łącznego rozkładu, dla którego wyznacza się wartość MJO (130). Jest to granica ruchoma i brak jest jednoznacznych kryteriów ustalania jej miejsca na histogramie.

-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	+1
-1	-1	-1	-1	-1	-1	-1	-1	-1	+1	+1
-1	-1	-1	-1	-1	-1	-1	-1	+1	+1	+1
-1	-1	-1	-1	-1	-1	-1	+1	+1	+1	+1
-1	-1	-1	-1	-1	+1	+1	+1	+1	+1	+1
-1	-1	-1	+1	+1	+1	+1	+1	+1	+1	+1
-1	-1	+1	+1	+1	+1	+1	+1	+1	+1	+1
-1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1
+1	+1	+1	+1	+1	+1	+1	+1	+1	+1	+1

Rys. 60. Rozkład wartości wag (131) [39]

Fig. 60. Distribution of weights (131) [39]

A.3. Badanie lokalnych odchyień

Prezentowane w tym podrozdziale rozważania zaproponowano w [21]. Podstawowym kryterium jednoznaczności odwzorowania jest stwierdzenie, że małym odległościom punktów w przestrzeni wejść odpowiadają małe odległości punktów w przestrzeni wyjść. Miarą stopnia spełnienia tego kryterium dla wyjścia y_h może być [21]:

$$q_h = 1 - \sqrt{\frac{1}{N s_h^2} \sum_{n=1}^N s_h^2(n)} \quad (132)$$

lub

$$q_h = 1 - \sqrt{\frac{\sum_{n=1}^N J(n) s_h^2(n)}{s_h^2 \sum_{n=1}^N J(n)}} \quad (133)$$

gdzie s_h^2 jest ogólnym (globalnym) odchyleniem kwadratowym wyjścia y_h :

$$s_h^2 = \frac{1}{N} \sum_{n=1}^N (y_{n,h} - \bar{y}_h)^2 \quad (134)$$

$$\bar{y}_h = \frac{1}{N} \sum_{n=1}^N y_{n,h} \quad (135)$$

dla wartości wyjść $y_{n,h}$ ze zbioru danych (10), zawierającego N danych oraz gdzie $s_h^2(n)$ jest lokalnym odchyleniem kwadratowym wyjścia y_h w ruchomym otoczeniu $\mathcal{E}(\underline{x}_n)$ kolejnych wyjść \underline{x}_n :

$$s_h^2(n) = \frac{1}{J(n)} \sum_{\underline{x}_j \in \mathcal{E}(\underline{x}_n)} (y_{j,h} - \bar{y}_h(n))^2 \quad (136)$$

$$\bar{y}_h(n) = \frac{1}{J(n)} \sum_{\underline{x}_j \in \mathcal{E}(\underline{x}_n)} y_{j,h} \quad (137)$$

$$J(n) = \sum_{\underline{x}_j \in \mathcal{E}(\underline{x}_n)} 1 \quad (138)$$

dla wartości wejść \underline{x}_j i odpowiadających im wyjść $y_{j,h}$ ze zbioru danych (10). Liczbę elementów $J(n)$ ruchomego otoczenia $\mathcal{E}(\underline{x}_n)$ określa (138). W większości przypadków dla odwzorowań jednoznacznych wartości tej miary są bliskie wartości 1. Im wartość miary jest bliższa zeru, tym większy może być „stopień” niejednoznaczności odwzorowania. Wyznaczane wartości q_h wg (132) i (133) zależą od przyjętej definicji ruchomego otoczenia $\mathcal{E}(\underline{x}_n)$ (rozdział 2.2).

A.4. Badanie liczby najbliższych sąsiadów

Prezentowane w tym podrozdziale rozważania zaproponowano w [21]. Podczas wyznaczania wartości stopnia jednoznaczności odwzorowania (132) uwzględniane są wartości wyjść $y_{n,h}$, co może prowadzić do niezadowalających wyników, zwłaszcza wtedy, gdy rozpatrywane wyjścia charakteryzują się dużą dynamiką zmian. Postępowaniem alternatywnym jest rozpatrywanie ruchomego otoczenia $\mathcal{E}(\underline{x}_n)$ wartości wejścia \underline{x}_n oraz ruchomego otoczenia $\mathcal{E}(\underline{y}_n)$ wartości odpowiadającego mu wyjścia $\underline{y}_n = \underline{y}(\underline{x}_n)$. Miarą stopnia jednoznaczności odwzorowania jest [21]:

$$q_h = \frac{1}{N} \sum_{n=1}^N \left(\frac{\sum_{\underline{x}_j \in \mathcal{E}(\underline{x}_n) \wedge \underline{y}_j \in \mathcal{E}(\underline{y}_n)} 1}{\sum_{\underline{x}_j \in \mathcal{E}(\underline{x}_n)} 1} \right) \quad (139)$$

Wadą metod związanych z badaniem najbliższych sąsiadów jest wysoka złożoność obliczeniowa tych metod. W większości przypadków dla odwzorowań jednoznacznych (tak jak w poprzednim przypadku) wartości tej miary są bliskie wartości 1. Im wartość miary jest bliższa zero, tym większy może być „stopień” niejednoznaczności odwzorowania.

Dodatek B


Badanie skuteczności algorytmów interpolacji dla potrzeb adaptacyjnego sterowania badaniami symulacyjnymi

B.1. Zakres badań

W rozdziale tym zaprezentowano badania dotyczące przydatności przedstawionych w pracy algorytmów interpolacji w przestrzeniach wielowymiarowych (rozdział 2.2) dla potrzeb adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającymi do doskonalenia wyznaczania lokalnych modeli odwrotnych. W celu łatwiejszej interpretacji wyników badania przeprowadzono dla jednowymiarowych przestrzeni symptomów V i stanów S . Prezentowane badania przeprowadzono dla odwzorowania przestrzeni stanów w przestrzeń symptomów w postaci funkcji sigmoidalnej danej następującą zależnością:

$$v(s_i) = \frac{1}{1 + e^{-s_i + 10}} \quad (140)$$

Funkcja sigmoidalna pokazuje przykład odwzorowania, które dla równomiernie rozmieszczonych punktów w przestrzeni stanów S nie gwarantuje równomiernego rozmieszczenia odpowiadających im punktów w przestrzeni symptomów V (rys. 61).



Rys. 61. Przykład odwzorowania przestrzeni stanów w przestrzeń symptomów

Fig. 61. Example of mapping of state space into symptom space


B.2. Rozpatrywane przypadki

Badania zostały przeprowadzone dla trzech wybranych przypadków rozmieszczenia danych z podstawowego zbioru przykładów oraz danych testowych, a mianowicie:

1. Dane z podstawowego zbioru przykładów (liczącego 10 przykładów) równomiernie rozmieszczone w przestrzeni stanów oraz dane testowe znajdujące się w środku obszaru o najmniejszej liczbie danych w przestrzeni symptomów (rys. 62);
2. Dane z podstawowego zbioru przykładów (liczącego 10 przykładów) równomiernie rozmieszczone w przestrzeni stanów oraz dane testowe nie znajdujące się w środku obszaru o najmniejszej liczbie danych w przestrzeni symptomów (rys. 63);
3. Dane z podstawowego zbioru przykładów (liczącego 6 przykładów) rozmieszczone nierównomiernie w przestrzeni stanów oraz dane testowe nie znajdujące się w środku obszaru o najmniejszej liczbie danych w przestrzeni symptomów (rys. 64).


Badaniom poddano opisane w pracy cztery algorytmy interpolacji w przestrzeniach wielowymiarowych, a mianowicie:

- 1) algorytm W11 (szczegółowy opis w rozdziale 2.2.1);
- 2) algorytm W12 (szczegółowy opis w rozdziale 2.2.2);
- 3) algorytm W13 (szczegółowy opis w rozdziale 2.2.3);
- 4) algorytm interpolacji za pomocą kombinacji funkcji wykładniczych – algorytm ten dalej oznaczono jako KFW (szczegółowy opis w rozdziale 2.2.4).




Rys. 62. Ilustracja przypadku numer 1

Fig. 62. Illustration of case no. 1



Rys. 63. Ilustracja przypadku numer 2

Fig. 63. Illustration of case no. 2



Rys. 64. Ilustracja przypadku numer 3

Fig. 64. Illustration of case no. 3

Ze względu na występowanie w algorytmie dotyczącym adaptacyjnego sterowania badaniami symulacyjnymi (rys. 30) pętli, w której następuje losowanie wartości cech sygnałów diagnostycznych, testowanie polegało na dziesięciokrotnym uruchomieniu procedur

działających zgodnie z rozpatrywanymi algorytmami dla przedstawionych trzech przypadków rozmieszczenia elementów zbioru danych podstawowych oraz danych testowych. Napisane zostały procedury w języku programowania Matlab [78], działające zgodnie z rozpatrywanymi algorytmami. Ustalono, że decyzja o przerwaniu procesu uzupełniania zbioru przykładów nowymi przykładami podjęta zostanie na podstawie:

- osiągnięcia założonej wartości miary jakości wyznaczanego modelu odwrotnego $J(v_s) \geq 0.98$ lub
- osiągnięcia zadanej liczby kroków (wykonanie maksymalnie 100 kroków).

Miara jakości wyznaczanych modeli $J(v_s)$ wyznaczana była zgodnie z zależnością (100), przy czym odległość występująca w tej zależności $dist(\bullet)$ obliczano zgodnie z zależnością (98). Czynniki skalujące α wyznaczono jako pierwiastek odwrotności liczby wymiarów rozpatrywanej przestrzeni symptomów, czyli $\alpha = 1$.

Rozpatrywany obszar obejmujący dane wzorcowe dla wyznaczania modeli interpolacyjnych ograniczony był liczbą najbliższych sąsiadów (przyjęto arbitralnie że rozpatrywanych będzie 5-ciu najbliższych sąsiadów). Liczba rozpatrywanych najbliższych sąsiadów była stała podczas prowadzenia badań.

B.3. Otrzymane wyniki

Wyniki dla rozpatrywanych przypadków rozmieszczenia danych zostały zestawione w tablicach (tablica X, tablica XI, tablica XII). Otrzymane średnie arytmetyczne wartości liczby kroków oraz średnie arytmetyczne wartości uzyskanych miar jakości wyznaczanych modeli odwrotnych dla poszczególnych przypadków rozmieszczenia danych zestawiono w tablicy (tablica XIII). Wyraźnie widać, że najlepsze wyniki (najmniejsza średnia liczba kroków, po której uzyskano zadowalające rozwiązanie i największa wartość miary jakości wyznaczanego modelu) otrzymano dla algorytmów W12 oraz W13. Analizując otrzymane wyniki można zauważyć, że algorytm W12 i W13 dają podobne wyniki we wszystkich rozpatrywanych przypadkach. Natomiast algorytmy W11 i KFW dają różne wyniki dla rozpatrywanych przypadków, co świadczy o pewnej „wrażliwości” tych algorytmów na sposób rozmieszczenia danych podstawowych i testowych.

Na rysunkach (rys. 65 – rys. 68) pokazano przykładowe rozmieszczenia danych uzyskanych w wyniku stosowania algorytmu adaptacyjnego sterowania badaniami symulacyjnymi, zmierzającego do optymalizacji jakości modelu odwrotnego. Na rysunkach tych zastosowano następujące oznaczenia:

‘o’ - zbiór danych podstawowych;

‘+’ - zbiór danych uzupełnionych;

‘◇’ - dane testowe.

Wyniki badania algorytmów dla rozmieszczenia danych nr 1

Algorytm		W11	W12	W13	KFW
1	Liczba kroków	30	5	5	1
	Miara jakości	0.9832	0.9975	0.9943	1
2	Liczba kroków	20	1	4	1
	Miara jakości	0.9817	0.9946	0.9960	1
3	Liczba kroków	28	5	4	1
	Miara jakości	0.9987	0.9916	0.9924	1
4	Liczba kroków	76	9	5	1
	Miara jakości	0.9806	0.9960	0.9911	1
5	Liczba kroków	100	7	4	1
	Miara jakości	0.7822	0.9996	0.9910	1
6	Liczba kroków	67	3	4	1
	Miara jakości	0.9958	0.9925	0.9920	1
7	Liczba kroków	100	5	5	1
	Miara jakości	0.9683	0.9984	0.9964	1
8	Liczba kroków	22	5	4	1
	Miara jakości	0.9841	0.9966	0.9950	1
9	Liczba kroków	55	5	2	1
	Miara jakości	0.9994	0.9975	0.9915	1
10	Liczba kroków	100	4	3	1
	Miara jakości	0.8707	0.9962	0.9984	1
Śr.	Liczba kroków	59.8	4.9	4	1
	Miara jakości	0.9544	0.9960	0.9938	1

Wyniki badania algorytmów dla rozmieszczenia danych nr 2



Algorytm		W11	W12	W13	KFW
1	Liczba kroków	100	4	5	100
	Miara jakości	0.8696	0.9958	0.9994	0.9241
2	Liczba kroków	100	9	10	100
	Miara jakości	0.8696	0.9998	0.9966	0.8698
3	Liczba kroków	100	12	7	100
	Miara jakości	0.8695	0.9982	0.9996	0.8698
4	Liczba kroków	100	5	5	100
	Miara jakości	0.8695	0.9995	0.9995	0.8698
5	Liczba kroków	100	8	5	100
	Miara jakości	0.8695	0.9940	0.9945	0.8698
6	Liczba kroków	100	5	7	100
	Miara jakości	0.8696	0.9936	0.9999	0.8698
7	Liczba kroków	100	6	4	100
	Miara jakości	0.8696	0.9957	0.9963	0.8698
8	Liczba kroków	100	5	5	100
	Miara jakości	0.8695	0.9977	0.9947	0.8698
9	Liczba kroków	100	5	5	100
	Miara jakości	0.8695	0.9982	0.9993	0.8698
10	Liczba kroków	100	7	5	100
	Miara jakości	0.8694	0.9986	0.9913	0.8698
Śr.	Liczba kroków	100	6.6	5.8	100
	Miara jakości	0.8695	0.9971	0.9971	0.8752

Wyniki badania algorytmów dla rozmieszczenia danych nr 3

Algorytm		W11	W12	W13	KFW
1	Liczba kroków	8	6	5	100
	Miara jakości	0.9925	0.9933	0.9998	0.7242
2	Liczba kroków	59	2	6	12
	Miara jakości	0.9985	0.9944	0.9956	0.9816
3	Liczba kroków	22	3	5	100
	Miara jakości	0.9962	0.9946	0.9942	0.9752
4	Liczba kroków	12	5	6	100
	Miara jakości	0.9898	0.9995	0.9938	0.7242
5	Liczba kroków	7	4	7	100
	Miara jakości	0.9862	0.9984	0.9958	0.9296
6	Liczba kroków	8	5	6	100
	Miara jakości	0.9989	0.9912	0.9991	0.9627
7	Liczba kroków	8	5	6	100
	Miara jakości	0.9850	0.9988	0.9982	0.9505
8	Liczba kroków	22	5	6	100
	Miara jakości	0.9985	0.9937	0.9936	0.7241
9	Liczba kroków	11	6	6	100
	Miara jakości	0.9816	0.9932	0.9974	0.7242
10	Liczba kroków	100	7	6	100
	Miara jakości	0.9510	0.9952	0.9979	0.7242
Śr.	Liczba kroków	25.7	4.8	5.9	91.2
	Miara jakości	0.9878	0.9952	0.9965	0.8420



Zestawienie otrzymanych wyników dla poszczególnych przypadków

Algorytm		W11	W12	W13	KFW
Przypadek numer 1	Liczba kroków	59.8	4.9	4.0	1
	Miara jakości	0.9544	0.9960	0.9938	1
Przypadek numer 2	Liczba kroków	100	6.6	5.8	100
	Miara jakości	0.8695	0.9971	0.9971	0.8752
Przypadek numer 3	Liczba kroków	25.7	4.8	5.9	91.2
	Miara jakości	0.9878	0.9952	0.9965	0.8420





Rys. 65. Przykładowe rozmieszczenie danych uzyskane dla algorytmu W11

Fig. 65. Example distribution of the obtained data for W11 algorithm





Rys. 66. Przykładowe rozmieszczenie danych uzyskane dla algorytmu W12

Fig. 66. Example distribution of the obtained data for W12 algorithm



Rys. 67. Przykładowe rozmieszczenie danych uzyskane dla algorytmu W13
 Fig. 67. Example distribution of the obtained data for W13 algorithm



Rys. 68. Przykładowe rozmieszczenie danych uzyskane dla algorytmu KFW
 Fig. 68. Example distribution of the obtained data for KFW algorithm

B.4. Wnioski

Analizując pokazane rysunki można stwierdzić, że algorytmy W12 i W13 prowadzą do uzyskania danych rozmieszczonych równomiernie „po obu stronach” danych testowych, czego nie gwarantują algorytmy W11 i KFW. Przeprowadzone badania wyraźnie uwidaczniają pewne wady algorytmów W11 i KFW. Na dokładność obliczeń tych algorytmów istotny wpływ ma rozmieszczenie danych – dane rozmieszczone równomiernie prowadzą do dokładnych wyników. Można się spodziewać, że w przypadku rozpatrywania wielowymiarowych przestrzeni wady tych algorytmów uwidoczną się jeszcze bardziej.

Literatura

1. Bartoszewicz J.: *Wykłady ze statystyki matematycznej*. PWN, Warszawa 1989.
2. Batko W., Gabiec M.: *Eliminacja zaburzeń w systemach monitorujących z wykorzystaniem sieci neuronowych*. II Krajowa Konferencja Naukowo-Techniczna „Diagnostyka procesów przemysłowych”, s.71-76, Łagów, 8-11 września 1997.
3. Będkowski L.: *Elementy diagnostyki technicznej*. WAT, Warszawa 1991.
4. Bogusławski A., Drobnik S., Elsner W.: *Phase correlated Karman vortex street in moving cylinder wake.*, Modelling and Design in Fluid-Flow Machinery 1997, Proceedings pp. 377-382.
5. Bone D.: *Adaptive multidimensional interpolation using regularized linear splines*. SPIE Vol. 1902, Nonlinear Image Processing IV (1993), pp.243-253.
6. Carlotto M.J.: *Nonlinear mapping algorithm and applications for multidimensional data analysis*. Journal of Visual Communication and Image Representation, Vol. 5, No. 2, June, pp.127-138,1994.
7. Cempel Cz.: *Podstawy wibroakustycznej diagnostyki maszyn*. WNT, Warszawa 1982.
8. Cempel Cz.: *Diagnostyka wibroakustyczna maszyn*. PWN, Warszawa 1989.
9. Cholewa W.: *Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych*. Zeszyty Naukowe Politechniki Śląskiej, s. Mechanika z.79, Gliwice 1983.
10. Cholewa W.: *Szkieletowy System Doradczy MAS. Dokumentacja użytkownika*. KPKM Gliwice, 1993. Zeszyt RMT6081 (maszynopis - Dokumentacja Systemu MAS, Tom I).
11. Cholewa W.: *Generator Sieci Neuronalnych MAS_NN. Dokumentacja użytkownika*. KPKM Gliwice, 1993. Zeszyt RMT6100 (maszynopis - Dokumentacja Systemu MAS, Tom II).
12. Cholewa W.: *Projekt szkieletowego systemu doradczego przeznaczonego do dozoru eksploatacyjnego i diagnostyki turbozespołu*. Materiały Ogólnopolskiego Seminarium *Wibrodiagnostyka turbozespołów energetycznych*. Gdańsk 1994, s.25-49.
13. Cholewa W.: *Wybrane klasy modeli danych*. Zeszyty Naukowe Politechniki Śląskiej, s. Mechanika z.121, Gliwice 1995, s.62-70.
14. Cholewa W.: *Uncertain decision tables as a tool for knowledge acquisition*. Second International Workshop on Learning in Intelligent Manufacturing Systems. Budapest 20-21.04.95. p.628-654.
15. Cholewa W.: *O stosowaniu sieci neuronalnych*. III Krajowa Konferencja „Diagnostyka techniczna urządzeń i systemów”, Szczyrk 1995. Materiały, tom 4 s.69-78. Wyd. Instytut Techniczny Wojsk Lotniczych.

16. Cholewa W.: *Unilateral Diagnostic Models*. 2nd International Conference on Acoustical and Vibratory Surveillance Methods and Diagnostic Techniques. Senlis 10-12.10.95. Proceedings vol.2, p.805-815.
17. Cholewa W.: *Diagnostics and Artificial Intelligence*. [w:] "Metody i techniki diagnostyki technicznej", red.: J. Korbicz, Lubuskie Towarzystwo Naukowe, Zielona Góra 1995, s.7-15.
18. Cholewa W.: *Dynamiczne systemy doradcze w diagnostyce technicznej*. Kongres Diagnostyki Technicznej, Gdańsk 1996, T.1, s.57-84.
19. Cholewa W.: *Real-Time Expert Systems for Technical Diagnostics*. 15th IMACS World Congress on Scientific Computation, Modelling and Applied Mathematics. Berlin 1997, Vol.6, p.715-720.
20. Cholewa W.: *Diagnostyka symulacyjna*. Problemy Eksploatacji 4/97 (27), s.13-23.
21. Cholewa W.: *Metody identyfikacji modeli relacji*. Rozdział 4 [w:] *Diagnostyka Techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
22. Cholewa W., Chrzanowski P.: *Cechy jakościowe i ilościowe*. Rozdział 12 w *Diagnostyka Techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
23. Cholewa W., Chrzanowski P., Klimek A.: *Relacyjna baza danych GG01. Dokumentacja programisty*. Zeszyt Katedry PKM: RMT6286, Gliwice 1996.
24. Cholewa W., Czogała E.: *Podstawy systemów ekspertowych*. Prace Instytutu Biocybernetyki i Inżynierii Biomedycznej PAN, 28, Warszawa 1989.
25. Cholewa W., Kaźmierczak J.: *Diagnostyka techniczna maszyn - Przetwarzanie cech sygnałów*. Skrypt Politechniki Śląskiej nr 1693, Gliwice 1992.
26. Cholewa W., Kaźmierczak J.: *Data Processing and Reasoning in Technical Diagnostics*. WNT, Warszawa 1995.
27. Cholewa W., Kiciński J.: *Metody identyfikacji reguł dla diagnostycznych systemów doradczych*. Sympozjon "Modelowanie w mechanice", Wisła 1996.
28. Cholewa W., Klimek A.: *Oprogramowanie do identyfikacji modeli częściowo jednostronnych za pomocą sieci neuronalnych*. Dokumentacja programisty i użytkownika. Zeszyt Katedry PKM: RMT6265, Gliwice 1996.
29. Cholewa W., Klimek A.: *Planowanie badań symulacyjnych*. Rozdział 14 [w:] *Diagnostyka Techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
30. Cholewa W., Pedrycz W.: *Systemy doradcze*. Skrypt Politechniki Śląskiej nr 1447, Gliwice 1987.

31. Cholewa W., Solipiwo A.: *Optymalizacja przestrzeni cech w wibroakustycznych badaniach diagnostycznych*. Materiały VII Szkoły Diagnostyki: Wnioskowanie diagnostyczne, Poznań - Rydzyna 1985, s185-192.
32. Cholewa W., White M.F.: *Inverse modelling in rotordynamics for identification of unbalance distribution*. Machine Vibration. (1993) 2, 157-167.
33. Cholewa W., White M.F.: *Application of neural networks for inverting of vibration models*, Zeszyty Naukowe Politechniki Śląskiej, s. Mechanika z.116, Gliwice 1994.
34. Cholewa W., White M.: *Inverse vibration modelling for diagnosis of unbalance in machinery*. 15th International Congress on Acoustics, Trondheim 26-30.06.1995. Proceedings, p.503-506.
35. Chrzanowski P.: *Program MM_CALL1 (wersja .01)*. Dokumentacja programisty, Zeszyt Katedry PKM: RMT6282, Gliwice 1996.
36. Chrzanowski P.: *Program MM_BASE1 (wersja .01)*. Dokumentacja programisty, Zeszyt Katedry PKM: RMT6283. Gliwice 1996.
37. Chrzanowski P., Klimek A.: *Sterowanie procesem transmisji danych*. Zeszyt Katedry PKM: RMT6281, Gliwice 1996.
38. Chrzanowski P, Klimek A.: *Generowanie modeli odwrotnych*. Rozdział 13 [w:] *Diagnostyka Techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
39. Chrzanowski P, Klimek A.: *Badanie histogramów łącznego rozkładu*. Rozdział 4.5.1.1 [w:] *Diagnostyka techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
40. *Diagnostyka maszyn. Zasady ogólne. Przykłady zastosowań*, red.: Cempel Cz., Tomaszewski F. MCNEMT, Radom 1992.
41. *Diagnostyka techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
42. Dietrych J.: *System i konstrukcja*. WNT, Warszawa 1985.
43. Drobnik S., Elsner W.: *Analiza trendów i prognozowanie symptomów stanu w systemie ciągłego nadzoru turbozespołu.*, Kongres Diagnostyki Technicznej KDT'96, Gdańsk 1996, Tom II, s.211-218.
44. Drobnik S., Elsner W. i inni: *Oprogramowanie do prezentacji i prognozowania stanu technicznego turbozespołów*. III Konferencja nt. Problemy Badawcze Energetyki Ciepłej, Warszawa 2-5 grudnia 1997r, materiały konferencyjne tom I s.183-192.
45. *Encyklopedia PWN*, Warszawa 1997.
46. Gallant Stephen I.: *Neural Network Learning and Expert Systems*. A Bradford Book, The MIT Press, Massachusetts 1993. ISBN 0-262-07145-2.

47. Gollub G.H., Van Loan C.F.: *Matrix Computations*. Hopkins University Press, Baltimore 1989.
48. Grębosz J.: *Symfonia C++*. Programowanie w języku C++ orientowane obiektowo. Tom I,II,III. Oficyna Kallimach, Kraków 1993.
49. Hertz J., Krogh A., Palmer R.G.: *Introduction to the theory of neural computation*. Addison-Wesley, Redwood City 1992.
50. *Handheld Balance Master 2 - TK83 - User Guide*, Materiały firmy Bently Nevada Corporation, Minden USA, 1994.
51. Kaźmierczak J.: *Zastosowanie liniowych modeli procesów losowych do prognozowania w diagnostyce maszyn*. Zeszyty Naukowe Politechniki Śląskiej, s. Mechanika z.95, Gliwice 1989.
52. Khanna T.: *Foundations of Neural Networks*. Addison-Wesley, Reading 1990.
53. Kiciński J.: *Funkcje modeli symulacyjnych w diagnostyce technicznej*. Materiały III Krajowej Konferencji "Diagnostyka techniczna urządzeń i systemów" DIAG'95 - Szczyrk 10 - 13 X 1995.
54. Kiciński J.: *Metody symulacyjnego pozyskiwania relacji diagnostycznych i możliwości ich wykorzystania w budowie systemu nadzoru drganiowego nowej generacji*. Przegląd Mechaniczny, Nr 1-2/95, s.5 - 10.
55. Kiciński J.: *Symptomy diagnostyczne turbozespołów energetycznych określone metodą komputerowej i analogowej symulacji ich defektów*. Materiały Ogólnopolskiego Seminarium „Wibrodiagnostyka turbozespołów energetycznych.” IMP PAN, Gdańsk 1994, s.51-92.
56. Kiciński J., Krawczuk M.: *Algorytm i system programów komputerowych MESWIR do analizy drgań giętnych swobodnych i wymuszonych ułożyskowanych wirników turbozespołów energetycznych*. Wyd. IMP PAN Nr arch. 168/90, Gdańsk 1990.
57. Kiciński J., Materny P.: *Modelowanie oddziaływań dynamicznych złożonych układów wirnik-podpory*. Zeszyty Naukowe IMP PAN, Nr 378/1325/92, Gdańsk 1992.
58. Kiciński J., Materny P., Drozdowski R., Markiewicz A.: *Pozyskiwanie relacji diagnostycznych metodą badań symulacyjnych. Część I. Raport nr 311/95*. Instytut Maszyn Przepływowych PAN, Gdańsk 1995.
59. Klimek A.: *Zastosowanie sieci neuronalnych w diagnostycznym systemie doradczym, wspomagającym interpretację trajektorii*. Proceedings of the 3-rd International Scientific Conference Achievements in the Mechanical and Material Engineering. PAN, Gliwice 1994, s 183-192.

60. Klimek A.: *Ograniczanie zbioru cech opisujących drgania wału turbosespołu*. III Krajowa Konferencja „Diagnostyka techniczna urządzeń i systemów”, Szczyrk, 1995, tom 3, s.125-132.
61. Klimek A.: *Iteracyjne doskonalenie odwrotnych modeli diagnostycznych*. Kongres Diagnostyki Technicznej KDT'96, Gdańsk 1996, tom II, s.351-356.
62. Klimek A.: *Program MM_HOLE1 (wersja .01). Dokumentacja programisty*. Zeszyt Katedry PKM: RMT6284, Gliwice 1996.
63. Klimek A.: *Dynamiczna aktualizacja zbioru przykładów dla generowania diagnostycznego modeli odwrotnych*. II Krajowa Konferencja Naukowo-Techniczna: 8-11 września, 1997, Łągow k. Zielonej Góry, „Diagnostyka procesów przemysłowych”, materiały konferencyjne s.207-212.
64. Klimek A.: *Dynamiczne programowanie zakresu badań symulacyjnych*. I Krajowa Konferencja: Metody i systemy komputerowe w badaniach naukowych i projektowaniu inżynierskim, 25-26.XI.1997 Kraków - materiały konferencyjne s.143-150.
65. Klimek A.: *Identyfikacja relacji diagnostycznych przez odwracanie modeli obiektów*. XXXVII Sympozjon: „Modelowanie w mechanice”, Wisła, luty 1998, Zeszyty Naukowe Katedry Mechaniki Stosowanej -z.6, s 175-180, Gliwice 1998.
66. Klimek A.: *Metody doskonalenia diagnostycznych modeli odwrotnych*. III Krajowa Konferencja Naukowo-Techniczna: 7-10 września, 1998, Jurata, „Diagnostyka procesów przemysłowych”, materiały konferencyjne s.79 - 84.
67. Klimek A.: *Badanie jednoznaczności odwzorowania*. Rozdział 5.4 [w:] *Diagnostyka Techniczna, Odwrotne modele diagnostyczne*, red.: Cholewa W., Kiciński J., Wydawnictwo Politechniki Śląskiej, Gliwice 1997.
68. Klimek A., Wysogład B.: *Model stanowiska do badań drgań wałów i jego eksperymentalna weryfikacja*, XXXVII Sympozjon: „Modelowanie w mechanice”, Wisła, luty 1998, Zeszyty Naukowe Katedry Mechaniki Stosowanej -z.6, s 181-186, Gliwice 1998.
69. Korbicz J.: *Sztuczne sieci neuronowe*. AOW, Warszawa 1994.
70. Korbicz J.: *Metody sztucznej inteligencji w diagnostyce technicznej. Przegląd struktur i technik*. Kongres diagnostyki technicznej, materiały konferencyjne, tom II, s.373-380.
71. Kostka P.: *Badanie wrażliwości cech sygnałów diagnostycznych*. III Krajowa Konferencja Naukowo-Techniczna: 7-10 września, 1998, Jurata, „Diagnostyka procesów przemysłowych”, materiały konferencyjne s.85 - 90.
72. Krzyżanowski J., Kiciński J.: *Komputerowy inteligentny system diagnostyki turbosespołów energetycznych*. Ogólnopolskie Seminarium nt. „Wibrodiagnostyka turbosespołów energetycznych”, Wydawnictwo IMP PAN, Gdańsk 1994, s.3-23.

73. Krzyżanowski J., Cempel Cz., Cholewa W., Drobnik St., Kiciński J., Orłowski Z.: *Systemy diagnostyki turbozespołów energetycznych nowej generacji*. Przegląd Mechaniczny 1-2'95, s.16-19.
74. Łączkowski R.: *Wyważanie elementów wirujących*, Wydawnictwa Naukowo-Techniczne, Warszawa 1979.
75. Majchrzak E., Mochnacki B.: *Metody numeryczne - Podstawy teoretyczne, aspekty praktyczne i algorytmy*. Wydawnictwo Politechniki Śląskiej, Gliwice 1994.
76. Mańczak K.: *Technika planowania eksperymentu*. WNT, Warszawa 1976.
77. Masters T.: *Practical Neural Network Recipes in C++*. Academic Press, San Diego 1993.
78. *MATLAB Reference Guide*. The MathWorks Inc., Natick 1992.
79. *MATLAB Neural Network TOOLBOX ver.2.0a*. The MathWorks Inc., Natick 1995.
80. Materny P., Kicińska A.: *Opis programu START.BAT w wersji zmodernizowanej*, oprac. wew. Instytut Maszyn Przepływowych PAN, nr arch. 3/96, Gdańsk 1995.
81. *Metody ilościowe i modele w geografii*. Praca zbiorowa pod red. Z. Chojnackiego, PWN, Warszawa 1997.
82. Microsoft Visual C++ 4.0 - *Language manual*. Microsoft Corporation 1994-1995.
83. Microsoft SQL Server 6.5 Books OnLine - Microsoft Corporation 1992-1996.
84. Moczulski W.: *Metody pozyskiwania wiedzy dla potrzeb diagnostyki maszyn*. Zeszyty Naukowe Politechniki Śląskiej, s. Mechanika z.130, Gliwice 1997.
85. Moczulski W.: *Inductive Learning in Design: A Method and Case Study Concerning Design of Antifriction Bearing Systems*. W: Michalski R.S., Bratko I.: Kubat M. (red) *Methods and applications of Machine Learning, Data Mining and Knowledge Discovery*, John Wiley & Sons 1997.
86. Moczulski W.: *Indukcyjne pozyskiwanie wiedzy diagnostycznej dla złożonej struktury drzewa stanów*. III Krajowa Konferencja Naukowo-Techniczna: 7-10 września, 1998, Jurata, Diagnostyka Procesów Przemysłowych, Materiały Konferencyjne s.145 - 154.
87. Morel J.: *Drgania maszyn i diagnostyka ich stanu technicznego*. Polskie Towarzystwo Diagnostyki Technicznej, Warszawa 1992.
88. Morrison D.F.: *Wielowymiarowa analiza statystyczna*. PWN, Warszawa 1990.
89. Parszewski Z.: *Drgania i dynamika maszyn*. WNT, Warszawa 1982.
90. Powell M. J. D.: *A Review of Methods for Multivariable Interpolation at Scattered Data Points*. W: Duff I. S., Watson G. A.: *The State of the Art in Numerical Analysis*, Clarendon Press, Oxford 1997; s.283-309.

91. Press W.H., Teukolsky S.A., Vetterling W.T., Flannery B.P.: *Numerical Recipes in C*. Cambridge University Press, Cambridge 1992.
92. RFC 854 - Telnet Protocol. Postel and Reynolds 1985.
93. RFC 959 - FTP. <http://www.cis.ohio-state.edu/htbin/rfc>.
94. *Rotor Kit*. Materiały firmy Bently Nevada Corporation, Mindem USA, 1994.
95. *Rotor Kit, Oil Whirl/Whip Option*. Materiały firmy Bently Nevada Corporation, Mindem USA, 1994.
96. Shepard D.: *A two-dimensional interpolation function for irregularly-spaced data*. Proceedings of the 23rd National Conference ACM, Brandon Systems Press Inc., Princeton, p.517-524, 1991.
97. Shepherd T.J., Broomhead D.S.: *Nonlinear signal processing using radial basis functions*. SPIE Vol. 1348, Advanced Signal-Processing Algorithm, Architectures and Implementations, pp.51-61, 1990.
98. Słownik wyrazów obcych. PWN, Warszawa 1980.
99. Sobczak W., Malina W.: *Metody selekcji informacji*. WNT, Warszawa 1978.
100. Sokołowski A.: *Nadzorowanie stanu ostrza skrawającego z zastosowaniem sieci neuronowych*. Rozprawa doktorska. Politechnika Śląska, Gliwice 1994.
101. Solipiwo A.: *Metoda optymalizacji zbioru cech sygnałów diagnostycznych w badaniach maszyn*. Rozprawa doktorska. Politechnika Śląska, Gliwice 1986.
102. Stark R.M., Nicholls R.L.: *Matematyczne podstawy projektowania inżynierskiego*. PWN, Warszawa 1979.
103. *Statistica. User's Manual*. StatSoft, Tulsa 1994.
104. Stevens R. W.: *TCP/IP Illustrated Volume 1. The Protocols*. ADDISON-WESLEY PUBLISHING COMPANY. May'94.
105. Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa 1993.
106. Timofiejczuk A., Wysogład B.: *Instrukcja użytkownika stanowiska Rotor Kit*. Zeszyt Katedry PKM: RMT6347, Gliwice 1996.
107. Timofiejczuk A., Wysogład B.: *Instrukcja użytkownika analizatora SigLab 20-43*. Zeszyt Katedry PKM: RMT6348, Gliwice 1996.
108. Volk W.: *Statystyka stosowana dla inżynierów*. WNT, Warszawa 1973.
109. Wróblewski J.: *Finding minimal reducts using genetic algorithm*. <http://www.ipipan.waw.pl/libr/library.htm>

110. Wysogład B.: *Metody reprezentacji drgań wałów maszyn wirnikowych w diagnostycznych bazach danych*. Zeszyty Naukowe Politechniki Śląskiej, s. Mechanika z.126, Gliwice1996.
111. Wysogład B.: *Instrukcja obsługi stanowiska do badań drgań wałów i symulacji niesprawności maszyn wirnikowych*. Zeszyt Katedry PKM: RMT6395, Gliwice 1997.
112. Wysogład B.: *Mikrostanowisko do badań drgań wałów. Parametryzacja dla potrzeb symulacji komputerowej*. Zeszyt Katedry PKM: RMT6349, Gliwice 1997.
113. Wysogład B.: *Mikrostanowisko do badań drgań wałów. Zbiór wyników pomiarów drgań w warunkach stacjonarnych*. Zeszyt Katedry PKM: RMT6375, Gliwice 1997.
114. Xue-Shu Xie, Yan Lu: *Optimization control of fast turbine valve*. Proceedings of the 32nd Conference on Decision and Control, San Antonio, Texas, December 1993.
115. Żółtowski B.: *Podstawy diagnostyki maszyn*. Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej, Bydgoszcz 1996.
116. Żółtowski B., Ćwik Z.: *Leksykon diagnostyki technicznej*. Wydawnictwo Uczelniane Akademii Techniczno-Rolniczej, Bydgoszcz 1996.

Metody doskonalenia odwrotnych modeli diagnostycznych

Streszczenie

Celem niniejszej pracy było opracowanie i zweryfikowanie metod umożliwiających doskonalenie modeli pozwalających na wnioskowanie o stanie technicznym obiektu na podstawie obserwowanych symptomów. Opisano metodę pozwalającą na wyznaczenie i doskonalenie rozpatrywanych modeli, nazywanych modelami odwrotnymi, w wyniku odwracania znanych i zweryfikowanych doświadczalnie teoretycznych modeli obiektów, które umożliwiają wyznaczanie technikami numerycznymi obserwowanych symptomów jako skutków zadawanych stanów technicznych.

W pracy rozpatrywane były trzy kierunki doskonalenia rozpatrywanych modeli:

1. - *przez wybór postaci modelu* - zwrócono szczególną uwagę na stosowanie lokalnych modeli odwrotnych wyznaczanych za pomocą algorytmów wielowymiarowej interpolacji;
2. - *przez wybór liczby i rodzaju cech wejściowych modelu* - dokonano przeglądu wybranych metod wyboru cech ze względu na rozpatrywane zadanie wyznaczania modelu odwrotnego;
3. - *przez odpowiednią aktualizację zbioru przykładów*.

Trzeciemu kierunkowi doskonalenia rozpatrywanych modeli poświęcono szczególną uwagę. Podkreślono, że doskonalenie globalnego modelu odwrotnego jest nieracjonalne z powodu konieczności rozpatrywania wielowymiarowych przestrzeni symptomów oraz stanów. Pokazano oryginalny algorytm adaptacyjnego sterowania badaniami symulacyjnymi, zmierzający do doskonalenia lokalnych modeli odwrotnych skutecznie wyznaczanych za pomocą algorytmów wielowymiarowej interpolacji. Dla potrzeb weryfikacji zaproponowanej metody adaptacyjnego sterowania badaniami symulacyjnymi rozpatrywano także mikrostanowisko pomiarowe. Otrzymane wyniki potwierdzają możliwość doskonalenia diagnostycznych modeli przez odpowiednią aktualizację zbioru przykładów. Obliczenia w ramach wykonanych badań prowadzono w rozproszonym środowisku obliczeniowym. Opracowane metody postępowania mogą być stosowane do oceny stanu technicznego dużych turbozespołów, których modele numeryczne mogą być realizowane na komputerach w wybranych ośrodkach badawczych, podczas gdy dane określające aktualne wartości cech sygnałów diagnostycznych mogą być wyznaczane w sąsiedztwie obiektu.

Methods of improvement of inverse diagnostic models

Summary

The purpose of dissertation was elaboration and verification of methods enabling improvement of models allowing for diagnostic inference (determination states of machines on the ground of observed symptoms). Also, a method to define and improve such models was described throughout the course of work. The models of interest are the so-called inverse diagnostic models. They can be identified given a set of experimentally verified models of investigated objects. Clearly, the inversion is based on a set of state-to-symptom examples.

In this work the author has considered three ways of improvement of the models by:

1. determining an explicit (analytical) form of the models;
2. investigating specific properties of input data sets;
3. updating a set of examples.

The latter, in the author's opinion, deserves a particular attention and needs to be treated as such; improving diagnostic models by means of the global approach is very unlikely to succeed. Instead, a local model may serve as a reasonable and elegant alternative. The original algorithm of adaptation control of simulation enabling for improvement of inverse diagnostic models by updating set of examples was also presented. For the purpose of verification method for adaptive control of simulating the behaviour of a rotor system was considered. Obtained results confirm possibility of improvement of inverse diagnostic models by updating set of examples. Investigation were carried out in distributed environment what is very practical. The numerical models could be developed by the research team whereas real-life symptoms could come from the object, e.g. turbine/generator set in a power plant.