

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

Damian Sławik

**Metody
badania wrażliwości
cech sygnałów
diagnostycznych**

Gliwice 2005

Recenzenci

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

Prof. dr hab. inż. Bogdan Żółtowski, Akademia Techniczno-Rolnicza w Bydgoszczy

Redaktor zeszytów

Wojciech Cholewa

Redaktor techniczny

Marek Wyleźoń

Projekt okładki

Wojciech Cholewa, Marek Wyleźoń

ISBN 83–916957–8–6

Wydawca

Katedra Podstaw Konstrukcji Maszyn

Wydział Mechaniczny Technologiczny

Politechnika Śląska

ul. Konarskiego 18a, 44-100 Gliwice

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

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

Od autora

Zeszyt ten został opracowany na podstawie mojej pracy doktorskiej, wykonanej pod kierunkiem prof. dra hab. inż. Wojciecha Cholewy. Publiczna obrona rozprawy odbyła się 27 września 2005 roku przed Komisją powołaną przez Radę Wydziału Mechanicznego Technologicznego. W opracowaniu zostały uwzględnione uwagi recenzentów rozprawy doktorskiej: prof. dra hab. Wojciecha Moczulskiego i prof. dra hab. inż. Bogdana Żółtowskiego.

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

Gliwice, listopad 2005

Damian Sławik

Część przeprowadzonych i opisanych w pracy badań realizowana była w ramach projektu promotorskiego KBN 8 T07B 030 27 pod tytułem „Metody badania wrażliwości cech sygnałów diagnostycznych” finansowanego przez Komitet Badań Naukowych.

Spis treści

Od autora	3
Wykaz ważniejszych oznaczeń	9
Rozdział 1. Wstęp	11
1.1. Cel rozprawy	15
1.2. Tezy	15
1.3. Zakres rozprawy	16
Rozdział 2. Definicje i pojęcia	19
2.1. Pojęcie cechy	19
2.1.1. Cechy stanu	20
2.1.2. Cechy sygnałów	20
2.1.3. Wartość cechy	21
2.1.4. Cechy ciągłe i dyskretne	21
2.1.5. Cechy punktowe i funkcyjne	21
2.1.6. Cechy uporządkowane i nieuporządkowane	21
2.1.7. Cechy jedno i wielowymiarowe	22
2.1.8. Cechy ilościowe i cechy jakościowe	22
2.1.9. Cechy dokładne i przybliżone	22
2.2. Stan obiektu	22
2.3. Klasy stanu	23
2.4. Obiekt i model	24
2.4.1. Rzeczywisty obiekt techniczny	24
2.4.2. Modele obiektów technicznych	26
2.4.3. Model diagnostyczny	28
Rozdział 3. Definicje wrażliwości	31
3.1. Wrażliwość w automatyce	31
3.2. Wrażliwość w metodach optymalizacji	33
3.3. Wrażliwość w badaniach modeli matematycznych	33
3.4. Wrażliwość w diagnostyce maszyn	34

Rozdział 4. Podział metod badania wrażliwości	39
4.1. Analiza wrażliwości – badania modelu	39
4.2. Analiza wrażliwości – badania obiektu rzeczywistego	40
4.3. Metody lokalne	40
4.4. Metody globalne	41
4.5. Metody matematyczne	41
4.6. Metody statystyczne	42
4.7. Metody graficzne	42
Rozdział 5. Metody badania wrażliwości diagnostycznej	43
5.1. Definicja wrażliwości	45
5.1.1. Uwzględnienie klas stanu	46
5.1.2. Uwzględnienie klasy stanu bazowego	47
5.2. Badanie wrażliwości – selekcja cech wrażliwych	48
5.2.1. Założenia	48
5.2.2. Miary zmienności wartości cech sygnałów	49
5.2.3. Wartość wrażliwości	50
5.2.4. Selekcja wrażliwych cech sygnałów	50
5.2.5. Podsumowanie	52
5.3. Badanie wrażliwości – metoda statystyczna	53
5.3.1. Założenia	54
5.3.2. Analiza zmienności wartości cech sygnałów	55
5.3.3. Miary zmienności wartości cech sygnałów	56
5.3.4. Wartość wrażliwości cząstkowej	57
5.3.5. Wartość wrażliwości grupowej	58
5.3.6. Wartość wrażliwości głównej	58
5.3.7. Selekcja wrażliwych cech sygnałów	59
5.3.8. Podsumowanie	60
Rozdział 6. Przykład zastosowania statystycznej metody badania wrażliwości – dane symulacyjne	63
6.1. Model rzeczywistego obiektu technicznego	63
6.2. Klasy stanu	65
6.3. Cechy sygnałów	66
6.4. Przykład zastosowania analizy wrażliwości	68
6.5. Testy jakości wybranych cech sygnałów	71
6.5.1. Identyfikacja modelu diagnostycznego	71
6.5.2. Sposób badania modelu diagnostycznego	72
6.5.3. Sposób opisu wyników badań	74
6.6. Omówienie wyników testów	75
6.6.1. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości	76

6.6.2. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech	78
6.6.3. Testy prowadzone metodą leave one out z zastosowaniem oraz bez zastosowania analizy wrażliwości	80
6.6.4. Testy prowadzone metodą leave one out z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech	82
6.7. Wnioski	84
Rozdział 7. Przykład zastosowania statystycznej metody badania wrażliwości – dane pomiarowe	87
7.1. Badany obiekt techniczny	87
7.2. Klasy stanu	88
7.3. Cechy sygnałów	90
7.4. Testy jakości wybranych cech sygnałów	91
7.4.1. Sposób badania modelu diagnostycznego	92
7.4.2. Sposób opisu wyników badań	93
7.5. Omówienie wyników testów	95
7.5.1. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości	95
7.5.2. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech	99
7.5.3. Testy prowadzone metodą leave one out z zastosowaniem oraz bez zastosowania analizy wrażliwości	104
7.5.4. Testy prowadzone metodą leave one out z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech	108
7.6. Wnioski	114
Rozdział 8. Podsumowanie i wnioski	117
8.1. Wnioski ogólne	118
8.2. Wnioski szczegółowe	119
8.3. Kierunki dalszych badań	119
Bibliografia	121
Streszczenie	128

Wykaz ważniejszych oznaczeń

b	zbiór stanów technicznych obiektu
b_i	stan techniczny obiektu
b_0	bazowy stan techniczny obiektu
B	zbiór klas stanu obiektu
B_i	klasa stanu obiektu
B_0	bazowa klasa stanu obiektu
c_i	cechy stanów lub sygnałów
c_i^j	i -ta cecha sygnału związana z j -tym stanem lub j -tą klasą stanu
s^j, S^j	wrażliwość określająca przydatność j -tej cechy sygnału w klasyfikacji stanów
s_i^j	<i>metoda selekcji cech</i> : drażliwość j -tej cechy sygnału na zmianę stanu (klasy stanu) z i -tego(ej) na inny(ą) <i>metoda statystyczna</i> : drażliwość grupowa określająca przydatność j -tej cechy sygnału w odróżnieniu i -tej klasy stanu od pozostałych klas stanu
$s_{i,k}^j$	wrażliwość cząstkowa określająca przydatność j -tej cechy sygnału w odróżnieniu i -tej od k -tej klasy stanu
S	macierz z wartościami drażliwości s_i^j , na której bazuje metoda selekcji cech drażliwych
S_{cz}^j	macierz z wartościami drażliwości cząstkowej $s_{i,k}^j$
S_{gr}^j	macierz z wartościami drażliwości grupowej s_i^j określonymi w statystycznej metodzie badania drażliwości
$w_i^{j,k}$	k -ta wartość i -tej cechy sygnału wyznaczona dla j -tej klasy stanu
w_i^j	wartość i -tej cechy sygnału wyznaczona dla j -tego stanu lub macierz wartości i -tej cechy sygnału wyznaczona dla j -tej klasy stanu
W	zbiór wartości cech sygnałów
W_i	wartości cech sygnałów w_i^j uszeregowane według stanów lub klas stanu
W^j	wartości cech sygnałów w_i^j uszeregowane według nazw cech
nam(...)	nazwa
val(...)	wartość

Rozdział 1

Wstęp

Obecnie obserwowany rozwój diagnostyki jest ściśle związany z rozwojem technik komputerowych. Szybko rosnące możliwości obliczeniowe, a także możliwości związane z przesyłem i rejestracją danych pozwalają obserwować jednocześnie wiele sygnałów, z których, w czasie rzeczywistym, można wyznaczać setki, a nawet tysiące cech sygnałów.

Same sygnały i/lub ich cechy są przez systemy diagnostyczne zazwyczaj archiwizowane. Powodów tego jest kilka, ale główne to chęć posiadania informacji o historii diagnozowanego obiektu w celu:

- poznania przyczyn ewentualnych niesprawności;
- zwiększenia sprawności systemu diagnostycznego związanej z trafnością stawianych diagnoz;
- późniejszego wykorzystania zarejestrowanych danych do budowy sprawniejszych i wydajniejszych systemów diagnostycznych.

Diagnozowane obiekty techniczne co pewien określony czas poddawane są przeglądowi i/lub przeprowadzany jest ich remont. Czas ten jest zazwyczaj zależny od wskazań systemu diagnostycznego, a czym jest on dłuższy przy bezawaryjnej pracy diagnozowanego obiektu tym koszty eksploatacji są niższe. Idealnym rozwiązaniem z tego względu byłoby zbudowanie systemu diagnostycznego charakteryzującego się stuprocentową trafnością diagnozy, który czas przeprowadzenia remontu określałby z dokładnością rzędu dni lub godzin.

Osoby przeprowadzające okresowy przegląd diagnozowanego obiektu są w stanie określić w sposób dokładny lub przybliżony jego stan techniczny. Może to być przykładowo ,obiekt sprawny' lub ,obiekt do remontu za trzy miesiące'. Łącząc te informacje z zarejestrowanymi sygnałami i/lub cechami sygnałów można podjąć się zadania ulepszenia istniejącego lub zbudowania nowego, lepszego systemu diagnostycznego.

Przystępując do budowy systemu diagnostycznego pojawia się pytanie: który z zarejestrowanych sygnałów i/lub która z wyznaczonych cech niesie najwięcej informacji o stanie badanego obiektu? Można podjąć próbę rozpatrzenia wszystkich cech, jednak może się to zakończyć niepowodzeniem. Powodów tego jest kilka:

1. Zbudowanie systemu uwzględniającego setki cech może być niewykonalne ze względu na rosnące szybciej od liczby cech nakłady obliczeniowe.

2. Uwzględnienie większej liczby cech wymaga wyznaczenia większej liczby parametrów modelu diagnostycznego, a do tego z kolei potrzeba większej liczby przykładów uczących, których wygenerowanie może być niemożliwe lub zbyt kosztowne.
3. System diagnostyczny, który na podstawie dużej ilości cech rozstrzyga o zaledwie kilku stanach może zbyt często dopasować się do danych uczących i stać się bezużyteczny ze względu na błędne jego działanie już w chwili pojawienia się na wejściu wartości cech tylko nieznacznie odbiegających od wzorcowych.

Poprawnym rozwiązaniem przedstawionego problemu jest redukcja liczby cech do kilku zawierających najwięcej informacji o stanie diagnozowanego obiektu. Można to zrobić na dwa sposoby:

1. Przekształcając duży zbiór cech pierwotnych na mniejszy zbiór cech kumulujących w sobie prawie całą informację zawartą w cechach przekształconych.
2. Usuwając, ze zbioru wyznaczanych cech, cechy zawierające najmniejszą ilość istotnych ze względów diagnostycznych informacji i porządkując pozostałe cechy wg ich przydatności w określeniu klasy stanu.

W pierwszym przypadku można skorzystać z metod zwanych wielowymiarowymi technikami eksploracyjnymi. Pozwalają one na identyfikację układów (zależności) występujących w wielowymiarowych zbiorach danych. Należy jednak pamiętać, że ich zastosowanie wymaga informacji o wszystkich poddawanych przekształceniom i/lub agregacji cechach. Do metod tych zaliczamy:

- analizę skupień (CA od ang. Cluster Analysis) obejmującą metody grupowania (np.: grupowanie metodą k-średnich, grupowanie hierarchiczne, łączenie dwuwymiarowe) oparte na miarach odległości lub regułach amalgamacji/wiązania [54, 71, 89];
- analizę czynnikową (FA od ang. Factor Analysis) bazującą na założeniu, że pewne grupy zmiennych losowych reprezentują zmienność tych samych czynników, czyli zmienne losowe w danej grupie są od siebie w pewnym stopniu zależne. Obejmuje ona analizę głównych składowych (PCA od ang. Principal Component Analysis) oraz analizę czynników głównych (PFA od ang. Principal Factor Analysis) [54, 59, 105];
- skalowanie wielowymiarowe (MDS od ang. MultiDimensional Scaling) za pomocą którego możemy zmniejszyć liczbę wymiarów i przedstawić istotne z punktu widzenia obserwatora zależności na łatwym w interpretacji wykresie dwuwymiarowym nazywanym też przestrzenią postrzegania lub mapą percepcyjną [57, 72, 105];
- analizę korelacji kanonicznej (CCA od ang. Canonical Correlation Analysis) pozwalającą określić zależności zachodzące pomiędzy zbiorami zmiennych objaśnianych i objaśniających poprzez przekształcenie zmiennych pierwotnych w nowe wektory zmiennych kanonicznych w taki sposób, aby korelacja między tymi zmiennymi była maksymalna [37, 98, 105];

- analizę dyskryminacyjną (DA od ang. Discriminatory Analysis), która jest wielowymiarową statystyczną metodą pozwalającą ocenić zróżnicowanie w badanych grupach klasyfikacyjnych. Określana za pomocą tej analizy funkcja dyskryminacyjna, jest liniową zależnością wartości badanego zbioru cech [50, 61, 86];
- analizę odpowiedniości (CA od ang. Correspondence Analysis) oraz jej wielowymiarowy odpowiednik (MCA od ang. Multiple Correspondence Analysis), które są opisowymi i eksploracyjnymi technikami analizy tablic dwudzielnych i wielodzielnych, zawierających pewne miary charakteryzujące zależności międzykolumnowe oraz międzywierszowe. Otrzymywane wyniki dostarczają informacji podobnych do tych uzyskiwanych za pomocą analizy czynnikowej i pozwalają na analizę struktury zmiennych jakościowych tworzących tablicę [54, 85, 88].

Druga grupa metod stosowana jest w przypadku, gdy nie mamy zamiaru przekształcać jednego zbioru cech na inny lecz chcemy go zredukować poprzez:

- odrzucenie cech nieistotnych z punktu widzenia statystycznego;
- wybór cech w pewien sposób skorelowanych z klasami stanu;
- selekcję cech umożliwiających uzyskanie najlepszego modelu diagnostycznego.

Do grupy tej zaliczamy między innymi:

- regresję krokową (SR od ang. Stepwise Regression) postępującą lub wsteczną polegającą na dołączaniu lub usuwaniu z listy zmiennych objaśniających (cech) uwzględnianych w modelu. W przypadku regresji krokowej postępującej dołączane są zmienne najbardziej istotne, a w przypadku regresji krokowej wstecznej z listy usuwane są zmienne, których pominięcie nie wpłynie znacząco na pogorszenie jakości budowanego modelu [24, 26, 102];
- drzewa klasyfikacyjne i regresyjne (C&RT od ang. Classification and Regression Trees) mogące znaleźć zastosowanie w przypadku, gdy chcemy odróżnić jedną klasę stanu od pozostałych i poszukujemy takich cech, dzięki którym można to zrobić w najbardziej efektywny sposób [3, 34, 54];
- analizę log-liniową (LLA od ang. Log-Linear Analysis) pozwalającą badać wielowymiarowe tabele wielodzielcze przy użyciu testów istotności. Możemy ją traktować podobnie jak analizę regresji rozszerzoną o możliwości związane z badaniem niezależnych oraz zależnych zmiennych jakościowych [31, 54, 105];
- analizę wariancji wielu zmiennych (MANOVA od ang. Multivariate ANalysis Of VAriance) pozwalającą odpowiedzieć na pytanie czy analizowany czynnik lub ich kombinacje wpływają w sposób istotny na badaną cechę [48, 53, 56, 59, 102];
- analizę kowariancji wielu zmiennych (MANACOVA od ang. Multivariate ANalysis of COVAriance) łączącą w sobie elementy analizy wariancji wielu zmiennych, korelacji i regresji. Podobnie jak analiza wariancji pozwala ona określić wpływ analizowanego czynnika lub ich kombinacji na badaną cechę [53, 59, 66, 102].

Wszystkie z przedstawionych metod pozwalają na optymalizację zbioru zmiennych zależnych pod kątem ilości zawartej w nich informacji o zmiennych niezależnych. Trudno

jednak za ich pomocą przypisać poszczególnym zmiennym zależnym pewnych wartości określających udziały zmiennych niezależnych w zmianach wartości zmiennych zależnych. Zaradzić temu można korzystając z metod analizy wrażliwości.

Analiza wrażliwości w swoim klasycznym ujęciu zajmuje się badaniem wpływu zmian wejść na zmiany wyjść obiektów. Wychodząc od źródeł, teorię wrażliwości opracowano badając układy automatycznej regulacji ze sprzężeniem zwrotnym, a samą wrażliwość wyznacza się korzystając z analizy pochodnych cząstkowych [18, 93]. Definicja wrażliwości w przypadku sterowania optymalnego [32] pozwala określić, jaki jest wpływ poszczególnych wielkości sterujących na osiąganą wartość wskaźnika jakości. Podobnie, w metodach optymalizacji analiza wrażliwości ma na celu określenie wpływu zmian parametrów projektowych na wartość funkcji celu. Przechodząc do analizy wrażliwości w badaniach modeli matematycznych można wyróżnić: metody matematyczne [5, 22, 39, 64, 95], statystyczne [1, 28, 38, 65, 74, 84] oraz graficzne [35, 60]. Metody te pozwalają na analizę zmian parametrów wyjściowych modeli dla założonych zakresów zmian ich parametrów wejściowych, a główny cel ich stosowania to uproszczenie i lepsze dopasowanie modeli matematycznych do modelowanych obiektów lub zjawisk.

Analiza wrażliwości diagnostycznej w odróżnieniu od klasycznej analizy wrażliwości ma na celu rozwiązywanie nieco odmiennego zadania:

1. Zamiast wejść i wyjść lub zmiennych niezależnych i zależnych mamy stany techniczne lub klasy stanu technicznego badanego obiektu oraz cechy sygnałów.
2. Stany lub klasy stanu badanych obiektów prawie zawsze mają charakter jakościowy (opisowy).
3. Wartości cech sygnałów mogą być zarówno ciągłe jak i dyskretne, nieuporządkowane, ilościowe oraz jakościowe.
4. Nie interesuje nas przekształcenie zbioru jednych cech na zbiór innych cech z tego względu, iż nie ułatwi to wyboru cech sygnałów, a pośrednio samych sygnałów diagnostycznych, których rejestracja jest najbardziej opłacalna ze względu na ładunek informacyjny jaki te cechy zawierają.
5. Wymagana jest możliwość analizy nie kilku, lecz dziesiątek, setek lub tysięcy cech sygnałów.
6. Dostępnych jest w najlepszym przypadku kilka przykładów (przeprowadzonych badań) dla każdego stanu (klasy stanu).

Wymagania stawiane metodom badania wrażliwości diagnostycznej sprawiają, iż klasyczne metody badania wrażliwości oraz metody optymalizacji zbioru zmiennych zależnych nie znajdują zastosowania. Pomimo tego, zadaniem opracowania efektywnej metody badania wrażliwości, zajmowano się już wielokrotnie. Jednymi z pierwszych tego typu prac były [8] i [36]. Nieco odmiennie podejście, bazujące w dużej mierze na analizie statystycznej oraz klasyfikacji i grupowaniu znajdziemy w [17, 41, 76–81, 91] oraz [94].

Opracowanie takich metod badania wrażliwości diagnostycznej, co do których będzie istniała pewność, że wybierane przy ich użyciu cechy sygnałów będą zawierały prawie

całą informację o interesujących nas klasach stanu, może być pomocna w rozwiązywaniu zadań związanych m.in. z:

- wyszukiwaniem ze zbioru wszystkich wyznaczanych cech sygnałów takich cech, których wyznaczenie jest nieopłacalne ze względu na znikomą ilość zawartej w nich informacji o rozpatrywanych stanach lub klasach stanu;
- określeniem korzyści płynących z wyboru rozpatrywanych cech sygnałów w identyfikacji określonego stanu lub klasy stanu;
- wyszukiwaniem i/lub odrzucaniem cech sygnałów charakteryzujących się małą wrażliwością i zawierających te same informacje co bardziej wrażliwe cechy. Pozostawienie takich cech w zbiorze cech wrażliwych może pogorszyć jakość diagnozy.

1.1. Cel rozprawy

Celem pracy jest opracowanie metod badania wrażliwości pozwalających na wybór cech sygnałów najbardziej istotnych z punktu widzenia diagnostyki. Założono, że metody te można stosować w przypadku dyskretnej przestrzeni stanów oraz w przypadku ilościowych lub jakościowych wartości cech sygnałów, a budowane na podstawie wybranych cech modele diagnostyczne nie powinny być znacząco gorsze od modeli opracowanych na podstawie wszystkich wyznaczanych cech sygnałów.

1.2. Tezy

Mając na uwadze tytuł oraz cel rozprawy sformułowano następujące tezy:

1. Wrażliwość diagnostyczna może być stosowana, w procesie optymalizacji modeli diagnostycznych, jako kryterium wyboru uwzględnianych cech sygnałów.
2. Dla obiektów charakteryzujących się dyskretną przestrzenią stanów, możliwe jest definiowanie miar wrażliwości diagnostycznej, pozwalających na porządkowanie cech sygnałów diagnostycznych.

Poszukując dowodów na potwierdzenie lub odrzucenie przedstawionych tez można podjąć próbę odpowiedzi na pytania:

- Czy w diagnostyce maszyn możliwe i celowe jest zastosowanie metod badania wrażliwości?
- Czy z zastosowania metod badania wrażliwości mogą wyniknąć wymierne korzyści związane np. z uproszczeniem budowanych modeli diagnostycznych, bez obawy o jednoczesne pogorszenie się ich jakości?
- Czy możliwe jest opracowanie takich metod badania wrażliwości, które pozwolą na uzyskanie wiarygodnych wyników, w przypadku dyskretnej przestrzeni stanów i dyskretnych wartości cech sygnałów?

Odpowiedź twierdząca pozwoli przypuszczać, iż zastosowanie analizy wrażliwości będzie nie tylko możliwe, ale także opłacalne przy opracowywaniu nowych systemów diagnostycznych.

1.3. Zakres rozprawy

Praca obejmuje opis koncepcji wyznaczania miar wrażliwości cech sygnałów diagnostycznych oraz przykłady zastosowania, bazującej na tych miarach, analizy wrażliwości w diagnostyce obiektów technicznych.

Rozdział pierwszy obejmuje wstęp objaśniający przyczynę oraz konieczność stosowania analizy wrażliwości w selekcji cech sygnałów. Opisano w nim również pokrótce znane i stosowane metody selekcji i redukcji informacji. Rozdział ten zawiera cel oraz tezy rozprawy.

W rozdziale drugim przedstawiono definicje oraz pojęcia związane z diagnostyką maszyn oraz ze statystyką. Zrobiono to ze względu na występujące w tych definicjach i pojęciach różnice, w celu ich uściślenia. Drugim z celów tego rozdziału było usystematyzowanie metod badania wrażliwości, które w zależności od danych którymi dysponujemy, mogą w niektórych przypadkach znacznie między sobą się różnić.

Rozdział trzeci poświęcono pojęciu wrażliwości. Przedstawiono w nim definicje ogólne oraz te ściśle związane z takimi dziedzinami nauki jak: automatyka i teoria sterowania, metody optymalizacji, budowa modeli matematycznych oraz diagnostyka maszyn. W przypadku diagnostyki maszyn ze względu na przedmiot prowadzonych badań zostało przytoczonych najwięcej definicji.

W rozdziale czwartym zaproponowany został podział metod badania wrażliwości. W podziale tym uwzględniono m.in. rodzaj stosowanej metody badawczej, analizowaną przestrzeń cech sygnałów oraz stanów, a także przedmiot badań, którym może być zarówno dowolny obiekt techniczny, jak i jego model matematyczny.

Rozdział piąty poświęcono opisowi dwóch metod analizy wrażliwości diagnostycznej: metodzie selekcji wrażliwych cech sygnałów oraz metodzie statystycznej. Bazują one na dwóch metodach wyznaczania wartości wrażliwości diagnostycznej oraz na algorytmach selekcji wrażliwych cech sygnałów. Opisane metody wyznaczania wartości wrażliwości diagnostycznej to: metoda oparta na różnicach wartości cech sygnałów, w której wyznaczane są wartości wrażliwości dla wszystkich kombinacji cech sygnałów i stanów oraz metoda statystyczna, w której określone są wrażliwości cząstkowe, grupowe oraz główne.

W rozdziałach szóstym oraz siódmym przedstawiono przykłady zastosowania statystycznej metody badania wrażliwości. Dane, z których skorzystano, pochodziły z eksperymentu numerycznego prowadzonego na modelu turbosespołu 13K215 oraz z eksperymentu diagnostycznego prowadzonego na stanowisku *Rotor Kit*. Rozdziały szósty oraz siódmy zawierają opis: badanych obiektów, rozpatrywanych klas stanu, wyznaczanych cech sygnałów, sposobu prowadzenia badań oraz sposobu interpretacji uzyskanych wyników. Oprócz wspomnianych opisów w rozdziałach tych zawarto część uzyskanych wyników, przedstawiono ich interpretację oraz wnioski. Badania, których wyniki przed-

stawiono, obejmowały: opracowanie modelu diagnostycznego; przeprowadzanie klasyfikacji zarówno dla przypadku gdy stosowano analizę wrażliwości, jak i dla przypadku, gdy nie była ona stosowana; porównanie wyników klasyfikacji stanu, przeprowadzone za pomocą zidentyfikowanego modelu diagnostycznego. W rozdziale szóstym przedstawiono dodatkowo przykład zastosowania analizy wrażliwości dla wybranej cech sygnału diagnostycznego.

Rozdział ósmy zawiera podsumowanie oraz wnioski ogólne i szczegółowe. Dotyczą one przedstawionych tez pracy oraz przeprowadzonych badań.

Pracę zamyka wykaz bibliografii oraz streszczenie w języku polskim i angielskim.

Rozdział 2

Definicje i pojęcia

W opisach metod badania wrażliwości diagnostycznej zamieszczonych w kolejnych rozdziałach skorzystano z definicji i pojęć związanych z diagnostyką maszyn oraz ze statystyką. Ponieważ wspomniane definicje i pojęcia mogą w pewnych kwestiach różnić się między sobą konieczne jest ich uściślenie. Wymaga to wprowadzenia dodatkowych, opisanych w tym rozdziale ograniczeń i założeń.

Wprowadzone definicje i pojęcia oprócz ujednoczenia znaczenia niektórych słów lub wyrażeń, mają na celu usystematyzowanie metod badania wrażliwości, które w zależności od danych którymi dysponujemy, mogą niekiedy znacznie się między sobą różnić.

2.1. Pojęcie cechy

Znaczenie cechy interpretujemy jako pewną charakterystyczną właściwość, odróżniającą dany element, pojęcie, zjawisko od innych [99, 103, 106, 109]. W statystyce cechą nazywamy właściwość charakterystyczną jednostek informacyjnych (danych) pozwalającą wyodrębnić je z większych zbiorowości [103, 106]. Definicje te są zbliżone do siebie, jednak pierwsza z nich jest bardziej ogólna.

Cechy c_i zapisujemy za pomocą następującej pary [14]:

$$c_i = \langle \text{nam}(c_i), \text{val}(c_i) \rangle; \quad i = 1, 2, \dots, \quad (2.1)$$

gdzie: $\text{nam}(c_i)$ – nazwa lub indeks cechy,

$\text{val}(c_i)$ – wartość cechy, gdzie dla uproszczenia stosowany jest także zapis c_i .

Nazwa cechy powinna w sposób jednoznaczny identyfikować charakteryzowane przez cechę właściwości. Mając to na uwadze możemy wyróżnić pewne podzbiory obejmujące cechy związane z określonymi obszarami wiedzy. Przykładowo mogą to być cechy: stanu, sygnałów, konstrukcyjne, projektowe, ilościowe, jakościowe oraz inne dowolne grupy cech. W badaniach wrażliwości diagnostycznej obszar naszego zainteresowania stanowią będą cechy stanu oraz cechy sygnałów.

Dziedzina wartości cech może być różna, w zależności od rozpatrywanych elementów, pojęć lub zjawisk. Do podstawowych klas cech uwzględniających tą dziedzinę zaliczamy m.in. cechy ilościowe oraz jakościowe.

2.1.1. Cechy stanu

Podzbiór cech stanu stanowią cechy pozwalające odróżnić stan jednego obiektu od stanu drugiego obiektu lub stan jednego obiektu, który określono dla różnych chwil czasu. Przykładami takich cech mogą być: ‚rozosiowanie wałów silnika i maszyny wyrażone w milimetrach‘, ‚uszkodzenie powierzchni zęba nr X w kole nr Y maszyny nr Z‘, ‚możliwe uruchomienie (tak/nie)‘. Każda z tych cech charakteryzuje się innym poziomem szczegółowości zależnym od złożoności rozpatrywanych obiektów i/lub obszaru naszego zainteresowania.

2.1.2. Cechy sygnałów

Zgodnie z definicją, cechy sygnałów pozwalają odróżnić jeden sygnał od drugiego. W dziedzinie techniki pod pojęciem sygnału rozumiemy przebieg wielkości fizycznej zawierający wiadomość, którym przykładowo może być: zmodulowana fala radiowa [47, 103, 109]. W diagnostyce maszyn będą to np.: chwilowe wartości przemieszczeń pionowych zmierzone w wybranych punktach pomiarowych.

Do podstawowych cech sygnałów możemy zaliczyć miary statystyczne. Estymatory tych miar są zazwyczaj nieobciążone lub przynajmniej dopuszczalne [48]. Właściwość ta powoduje, że wartości cech zależą głównie od rzeczywistych różnic między sygnałami, a nie od zakłóceń jakie tym sygnałom zawsze towarzyszą.

Oprócz cech sygnałów wyznaczanych bezpośrednio często korzysta się z cech otrzymanych na drodze przekształceń funkcyjnych (filtracji). Przykładem mogą być cechy widma amplitudowego sygnału (składowe dla częstotliwości $1X$, $2X$). W węższym kontekście te cechy sygnałów nazywamy także cechami widmowymi lub cechami sygnałów w dziedzinie częstotliwości.

Nieco odmienną grupę cech sygnałów stanowią cechy wyznaczone dla więcej niż jednego przebiegu. Jedną z nich jest korelacja wzajemna, gdzie wyznaczone na podstawie niej cechy pozwalają odróżnić poszczególne pary sygnałów od siebie.

Przykładami (nazwami) cech sygnału, w zależności od kontekstu, mogą być:

- ‚wartość średnia przemieszczeń zmierzona w punkcie nr 1‘, gdy interesuje nas rozróżnienie sygnałów przemieszczeń pochodzących z różnych punktów pomiarowych;
- ‚wartość średnia przemieszczeń zmierzona w chwili t_0 ‘, gdy interesuje nas rozróżnienie sygnałów przemieszczeń zarejestrowanych w różnych chwilach czasu;
- ‚wartość średnia przemieszczeń zmierzona w punkcie nr 1 w chwili t_0 ‘, gdy interesuje nas rozróżnienie sygnałów przemieszczeń pochodzących z różnych punktów pomiarowych zarejestrowanych w różnych chwilach czasu.

W badaniach wrażliwości uwaga zostanie skupiona głównie na przypadkach, gdzie porównywane będą sygnały zarejestrowane dla różnych stanów badanego obiektu. Czas rejestracji samego zdarzenia dla nich nie jest istotny.

2.1.3. Wartość cechy

Jak wspomniano wcześniej uwzględniając dziedzinę cech można wyróżnić kilka ich podstawowych klas. W [16, 48] wyróżniono:

- cechy ciągłe oraz dyskretne;
- cechy punktowe oraz funkcyjne;
- cechy uporządkowane oraz nieuporządkowane;
- cechy jedno oraz wielowymiarowe;
- cechy ilościowe oraz jakościowe;
- cechy dokładne oraz przybliżone.

Ilość możliwych kombinacji jest ogromna, jednak istnieje możliwość zmiany klasy cech poprzez zastosowanie odpowiednich operacji [19–21, 62, 63, 82]. Przykładem może być zamiana cech ilościowych na jakościowe. Wiąże się to często z utratą części informacji, jednak zazwyczaj jest to najprostszy i najskuteczniejszy sposób przygotowania danych do dalszej analizy.

2.1.4. Cechy ciągłe i dyskretne

Cechy ciągłe mogą przyjmować wartości należące do zbioru liczb rzeczywistych. Wartości cech dyskretnych należą natomiast do zbioru dyskretnego tzn. zbioru skończonego lub przeliczalnego. Elementy zbioru dyskretnego można ponumerować kolejnymi liczbami naturalnymi. Przekształcenia cech ciągłych na dyskretne dokonujemy poprzez kwantyzację ich wartości.

2.1.5. Cechy punktowe i funkcyjne

Cechy funkcyjne są cechami, których zbiór wartości jest dany wykresem funkcji. Ich źródłem mogą być wszelkiego rodzaju sygnały analogowe pochodzące z czujników przemieszczeń, przyspieszeń, temperatury i innych. Cechy te, prawie zawsze, przekształca się na liniowy zbiór cech punktowych przy użyciu przetworników analogowo-cyfrowych. Możliwe jest także odwrotne przekształcenie z zastosowaniem przetworników cyfrowo-analogowych.

2.1.6. Cechy uporządkowane i nieuporządkowane

Pomiędzy wartościami cech uporządkowanych istnieje relacja uporządkowania [62]. Może być ona typu liniowego:

$$c_{\min} < c_1 < c_2 < \dots < c_{\max},$$

lub cyklicznego:

$$c_{\min} < c_1 < c_2 < \dots < c_{\max} = c_{\min}.$$

Relacja uporządkowania typu cyklicznego dotyczy np.: kąta w kartezjańskim układzie współrzędnych.

2.1.7. Cechy jedno i wielowymiarowe

Cechy jednowymiarowe charakteryzują się tym, iż dla jednej chwili czasu, ich wartością jest jedna zmienna (liczba, symbol). Wartości cech wielowymiarowych są natomiast krotkami tych zmiennych. W przypadku rozbicia cechy wielowymiarowej na cechy jednowymiarowe często następuje utrata informacji, czego przykładem może być wykres okręgu, do którego narysowania potrzebne są wartości współrzędnych x i y . Przy znajomości jedynie jednej z tych dwóch współrzędnych niemożliwe jest jego odtworzenie.

2.1.8. Cechy ilościowe i cechy jakościowe

Wartości przyjmowane przez cechy ilościowe należą do zbioru liczb rzeczywistych lub całkowitych. Oznacza to, że pomiędzy tymi wartościami istnieje relacja uporządkowania liniowego $c_{min} < c_1 < c_2 < \dots < c_{max}$. Przykładem takiej cechy ilościowej, której wartość odpowiada mierzonej wielkości fizycznej, może być: 'temperatura oleju w silniku'.

W przypadku, gdy wyznaczamy wartość cechy jakościowej, korzystamy ze zbioru wzorców (klas), między którymi nie istnieje żadna relacja uporządkowania. Określana wartość może być interpretowana jako identyfikator odpowiadającego cesze wzorca. Przykładem cechy jakościowej jest 'kolor samochodu'.

W niektórych przypadkach staje się celowe przekształcenie cechy jakościowej na ilościową. Możemy tego dokonać określając kierunek relacji uporządkowania liniowego między wszystkimi elementami zbioru wartości cech. Przykładem tego mogą być mapy kolorów, gdzie odpowiednim kolorom i ich odcieniom przyporządkowujemy wartości rzeczywiste lub całkowite.

Kolor, który jest cechą jakościową można również przekształcić na wielowymiarową cechę ilościową stosując odpowiednie mapy kolorów dla różnych jego składowych.

2.1.9. Cechy dokładne i przybliżone

Wartości cech dokładnych określone są precyzyjnie ($20[^\circ C]$), natomiast wartości cech przybliżonych mogą być uogólnieniem (około $20[^\circ C]$, blisko $20[^\circ C]$) lub uwzględnić dokładność pomiaru ($20 \pm 2[^\circ C]$).

2.2. Stan obiektu

W badaniach wrażliwości diagnostycznej zakładamy, że każdy elementarny stan obiektu będziemy oznaczali literą b_i ; $i = 1, 2, \dots$

Poszczególne stany b_i ; $i = 1, 2, \dots$ dotyczące np.: różnych obiektów lub jednego obiektu w różnych chwilach czasu rozróżniamy za pomocą cech stanu c_j ; $j = 1, 2, \dots$. Oznacza to, że każde dwa stany uznamy za różne, jeżeli wartość choć jednej charakteryzującej je cechy stanu będzie różna.

Zbiór stanów b zawiera wszystkie stany określone kombinacjami rozpatrywanych wartości cech stanu:

$$b \subset \{b_i(\text{val}(c_1), \text{val}(c_2), \dots)\}; \quad i = 1, 2, \dots \quad (2.2)$$

2.3. Klasy stanu

Badając dowolny obiekt ograniczamy zbiór wyznaczanych cech stanu do cech nas interesujących, których wartość jesteśmy w stanie określić. Przykładowo takimi cechami mogą być:

- $c_1 = \langle \text{'przycieranie'}, \{\text{TAK}; \text{NIE}\} \rangle$;
- $c_2 = \langle \text{'mimośród [mm]'}, \{0,0; 0,1; 0,2\} \rangle$.

Zmniejszając liczbę cech stanu do dwóch (c_1, c_2) oraz ograniczając liczbę przyjmowanych przez te cechy wartości, zmniejszamy liczbę rozróżnialnych stanów do sześciu. Dla przyjętych wartości cech stanu są to stany b_i należące do zbioru stanów b :

$$b \subset \{b_1(\text{TAK}; 0,0), b_2(\text{TAK}; 0,1), \dots, b_6(\text{NIE}; 0,2)\}. \quad (2.3)$$

Mając dany zbiór stanów b możemy utworzyć podzbiory stanów charakteryzujące się pewnymi szczególnymi wartościami cech stanu. Podzbiory te będziemy nazywali klasami stanu.

W badaniach wrażliwości diagnostycznej klasy stanu obiektu będziemy oznaczali literą B_i , gdzie: $i = 0, 1, 2, \dots, N$ lub $i = 1, 2, \dots, N$. Indeks $i = 0$ rezerwujemy tutaj dla klasy stanu bazowego, która może, ale nie musi być uwzględniana w poszczególnych definicjach wrażliwości.

Przykładowym stanem bazowym obiektów rzeczywistych może być dowolny stan związany z: normalnymi warunkami działania, maksymalną wydajnością, najmniejszym zużyciem (największą niezawodnością) lub innymi określanymi indywidualnie parametrami. Badając wrażliwość diagnostyczną i mając do dyspozycji modele numeryczne pojawia się trudność przy określaniu stanu bazowego. Można ją łatwo ominąć w przypadku modeli mających swojego odpowiednika w obiekcie rzeczywistym poprzez przyjęcie w modelu podobnych parametrów do tych występujących w rzeczywistości. W przypadku, gdy model numeryczny nie posiada swojego odpowiednika w obiekcie rzeczywistym można przyjąć kryterium minimalizujące np. siły, które w odpowiadającym mu obiekcie rzeczywistym mogłyby prowadzić do zniszczeń.

Klasy stanu, zgodnie z przytoczoną definicją, tworzymy uwzględniając wartości cech stanu. Dla przykładowych cech c_1 oraz c_2 mogą to być:

- stan dobry $B_0 = \{b_1(\text{NIE}; 0,0)\}$;
- tylko przycieranie $B_1 = \{b_2(\text{TAK}; 0,0)\}$;
- tylko mimośród $B_2 = \{b_3(\text{NIE}; 0,1), b_4(\text{NIE}; 0,2)\}$;
- przycieranie i mimośród $B_3 = \{b_5(\text{TAK}; 0,1), b_6(\text{TAK}; 0,2)\}$.

Inne przykłady klas stanu to: ‚stan dobry’ i ‚mimośród i/lub przycieranie’. W skrajnym przypadku można dla każdego stanu utworzyć osobną klasę.

Podsumowując można zauważyć, że istotne z punktu widzenia diagnostyki jest to, iż poszczególne stany lub klasy stanu mogą być powiązane relacjami uporządkowania, tzn. mogą tworzyć zbiór:

- uporządkowany

$$B = \{,brak\ rozosiowania', ,małe\ rozosiowanie', ,duże\ rozosiowanie'\};$$

- nieuporządkowany

$$B = \{,stan\ dobry', ,rozosiowanie', ,przycieranie'\};$$

- częściowo uporządkowany

$$B = \{,stan\ dobry', ,małe\ rozosiowanie', ,duże\ rozosiowanie', ,przycieranie'\}.$$

2.4. Obiekt i model

W badaniach wrażliwości rozpatrywane mogą być:

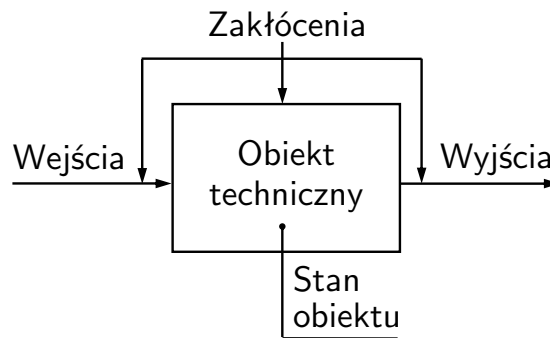
- rzeczywiste, działające obiekty techniczne, z których możemy zbierać informację o parametrach ich pracy, ich stanie technicznym oraz o wynikach ich działania;
- modele, które dla zadanego wektora stanu i/lub zadanych wartości wejściowych pozwalają na generowanie interesujących nas informacji (np.: sygnałów diagnostycznych).

Rozróżnianie obiektów rzeczywistych i modeli wydaje się być właściwe z kilku względów. Po pierwsze badania wrażliwości diagnostycznej dotyczą tylko obiektu rzeczywistego lub tylko modelu. Nie interesuje nas natomiast porównanie obiektu rzeczywistego z modelem w celu np. lepszego dopasowania modelu i/lub jego weryfikacji. Po drugie, w przypadku modelu, cechy sygnałów można wyznaczyć dla dowolnych wartości wektora stanu. W przypadku obiektów rzeczywistych, cechy sygnałów wyznaczane są najwyżej dla kilkudziesięciu różnych stanów.

2.4.1. Rzeczywisty obiekt techniczny

Dowolny obiekt techniczny można przedstawić jako działający system z wyszczególnionymi wejściami, wyjściami oraz stanem (rys. 2.1).

W systemie tym szczególnie interesującą, ze względów diagnostycznych, jest informacja o stanie obiektu. Niestety, nie zawsze jest ona dostępna w trakcie jego pracy. Często określenie stanu wymaga zatrzymania maszyny, jej demontażu oraz przeprowadzenia specjalistycznych badań. Przeprowadzenie badań niestety może mieć wpływ na stan badanego obiektu. Przykładem jest zmiana takiej wartości cechy stanu jak siła rozciągająca w śrubie z 1500[N] na 1550[N], po ponownym jej zakręceniu. Nie bez znaczenia pozostają także zmiany wartości cech stanu, następujące w sposób ciągły, w trakcie działania maszyny, będące normalnym zjawiskiem towarzyszącym jej eksploatacji.



Rys. 2.1. Obiekt techniczny.

Zmiany te, jeżeli następują w sposób losowy, można przypisać zakłóceniom stanu badanego obiektu.

Oprócz zakłóceń oddziałujących w sposób pośredni na wyjścia poprzez stan, w diagnostyce mamy do czynienia także z zakłóceniami bezpośrednio oddziałującymi na wejścia oraz wyjścia badanego obiektu.

Na wejścia każdego obiektu technicznego składają się zasilanie oraz sterowanie. Zasilanie obejmuje zarówno dostarczany strumień energii, jak i materiał, który w maszynie ulega przekształceniu. Przez strumień energii rozumiemy energię elektryczną, mechaniczną przekazywaną przez wał wejściowy maszyny lub też mechaniczną przekazywaną przez dowolne medium, jakim jest przykładowo przegrzana para wodna w turbinie parowej. Materiałem, który ulega przekształceniu, może być zarówno surowiec naturalny, półfabrykat jak i sama energia zamieniana na inny jej rodzaj w maszynach energetycznych.

Na wyjściu dowolnego obiektu technicznego znajdujemy produkt lub przetworzoną energię oraz procesy resztkowe, z czego procesy resztkowe dotyczą zjawisk termicznych, tarciovych, wibroakustycznych oraz elektrycznych.

Procesy resztkowe, a zwłaszcza zjawiska wibroakustyczne, mogą być traktowane jako źródło informacji o stanie badanego obiektu. Przemawia za tym to, iż nasilenie drgań lub wzrost temperatury towarzyszy zazwyczaj nasilonemu zużyciu lub też uszkodzeniu. Kolejnym powodem, dla którego procesy resztkowe można traktować jako dobre nośniki informacji o stanie obiektu, jest możliwość ich rejestrowania w trakcie pracy maszyny często bez konieczności jej demontażu. Przykładem jest pomiar temperatury lub drgań łożyska.

W przypadku niektórych zjawisk związanych z procesami resztkowymi możliwe jest zbieranie o nich informacji w sposób niewymagający fizycznego kontaktu z badaną maszyną. Przykładem tego są pomiary: emisji akustycznej za pomocą mikrofonów, przemieszczeń z zastosowaniem technik laserowych, czy też temperatury z zastosowaniem technik termowizyjnych.

Wszystkie dane dotyczące zarówno wejść jak i wyjść mogą być opisane za pomocą wielkości zmieniających się w czasie. Można je więc traktować jako sygnały diagno-

styczne (rys. 2.2). Dotyczy to zarówno wejść, gdzie będziemy rejestrowali np. natężenie prądu zasilającego, jak i wyjść, gdzie jedną z wielu mierzonych wartości może być wartość przemieszczeń interesującego nas punktu pomiarowego.



Rys. 2.2. Wyznaczanie cech sygnałów.

W badaniach wrażliwości diagnostycznej poszukiwane są cechy niosące największą ilość informacji o stanie badanego obiektu. Mając to na uwadze przyjęto, iż wszystkie rejestrowane sygnały dotyczące zarówno wejść jak i wyjść będą poddawane dodatkowej obróbce polegającej na wyznaczeniu cech sygnałów. Dodatkowym argumentem przemawiającym za takim postępowaniem jest to, że cechy sygnałów są często estymatorami nieobciążonymi, minimalizującymi wpływ wszelkiego rodzaju zakłóceń i zwiększającymi stosunek sygnału do szumu.

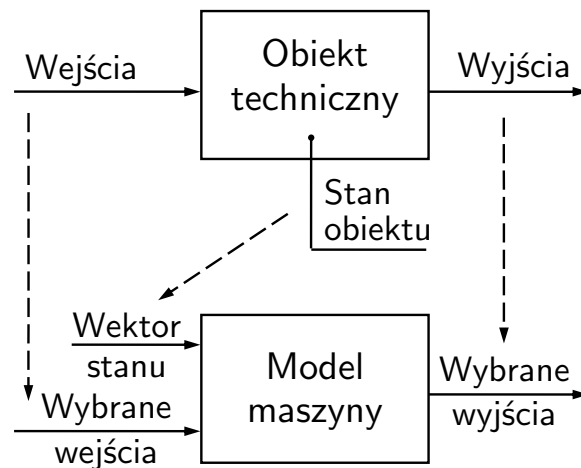
2.4.2. Modele obiektów technicznych

W diagnostyce, główne zadanie jakie ma spełniać model maszyny, polega zazwyczaj na możliwie wiernym odzwierciedleniu sposobu i zasad funkcjonowania modelowanego obiektu technicznego. W trakcie opracowywania takiego modelu, pozwalającego m.in. na analizę oraz śledzenie sposobów zachowania się rzeczywistego obiektu w różnych warunkach działania, bazuje się głównie na prawach i aksjomatach fizyki. Te prawa i aksjomaty dotyczą zarówno równowagi sił i momentów, bilansów energii, równań przepływów, jak i zależności geometrycznych [6, 7, 16, 49, 58, 87, 99, 100].

Posiadając taki model możemy podjąć się zadania wnioskowania o samym obiekcie. Oznacza to, że na podstawie wiadomości o wejściach obiektu, przy założeniu interesujących nas wartości wektora stanu możemy określić interesujące nas wyjścia (rys. 2.3).

W modelach matematycznych w odróżnieniu od obiektów rzeczywistych uwzględnia się tylko wybrane, interesujące nas wejścia. Pomijane są natomiast wejścia, których zmiany uznaje się za nieistotne lub wejścia, które nie będą uwzględniane w modelu ze względu na wprowadzone uproszczenia.

Zastępując rzeczywisty obiekt modelem matematycznym następuje także ograniczenie liczby uwzględnianych cech stanu do cech określonych za pomocą wektora stanu.



Rys. 2.3. Model maszyny.

Ograniczenie takie dotyczy również wyjść, gdzie poszczególne wyjścia mogą być wyznaczone za pomocą różnych, specjalnie zbudowanych do tego celu modeli.

Wektor stanu określający parametry modelu możemy w dowolny sposób modyfikować. Nie można tego samego powiedzieć o poszczególnych wartościach cech stanu rzeczywistego obiektu, gdzie zmiana jednej wartości cechy stanu pociągać może za sobą, zmiany wartości innych cech. Należy także uwzględnić tutaj opisany wcześniej wpływ demontażu lub samego działania maszyny na zmiany wartości cech stanu, które stanowią o jej stanie.

Zakłócenia w przypadku modeli można wprowadzać w dowolnym miejscu. Pozwala to traktować modele matematyczne jak rzeczywiste obiekty techniczne, w których takie zakłócenia zawsze występują, niezależnie od dokładności ich wykonania. Podejście takie ma także pewne wady. W przypadku stosowania większych wartości zakłóceń utracona zostaje powtarzalność wyników badań. Dotyczy to szczególnie nieliniowych modeli oraz rzeczywistych obiektów technicznych.

Każdemu modelowi fizycznemu, który opisuje rzeczywisty obiekt techniczny, odpowiada mniej lub bardziej złożony model matematyczny. Modelem matematycznym obiektu mechanicznego są najczęściej równania różniczkowe lub całkowe. Opierają się one zazwyczaj na bilansie energetycznym, materiałowym lub równaniach procesów fizyko-chemicznych.

Modelowane, rzeczywiste układy mechaniczne są z zasady układami nieliniowymi. Na występujące w nich nieliniowości mają wpływ: własności reologiczne materiału, występowanie luzów, nieliniowy charakter sił tłumiących i charakterystyk sprężystych elementów. Uwzględnienie nieliniowości w równaniach różniczkowych może powodować trudności w ich rozwiązaniu. Często, aby takich trudności uniknąć, wykorzystywane są odpowiednie procedury linearyzacji zawężające zakres stosowalności budowanych modeli. Rozpatrywanie układów jako liniowych jest jednak czasami celowe, z tego względu, iż istnieje duża klasa obiektów mechanicznych, które z dopuszczalną dla praktycznych

zastosowań dokładnością mogą być przez nie reprezentowane.

Znanych jest wiele sposobów w jaki można tworzyć modele obiektów, a wybór sposobu ich budowy zdeterminowany jest prawie zawsze zakresem ich stosowania. Do podstawowych, najczęściej identyfikowanych zaliczamy modele [101]: strukturalne, funkcjonalne, ideowe, analityczne, topologiczne i inne.

Model obiektu z założenia ma umożliwić wnioskowanie o samym obiekcie. Sposobem na zagwarantowanie tego jest najczęściej zapewnienie podobieństwa strukturalnego, polegającego na zachowaniu wspólnych cech budowy wewnętrznej modelu i modelowanego obiektu oraz na zachowaniu zależności, jakie występują pomiędzy strukturą, a funkcją obiektu.

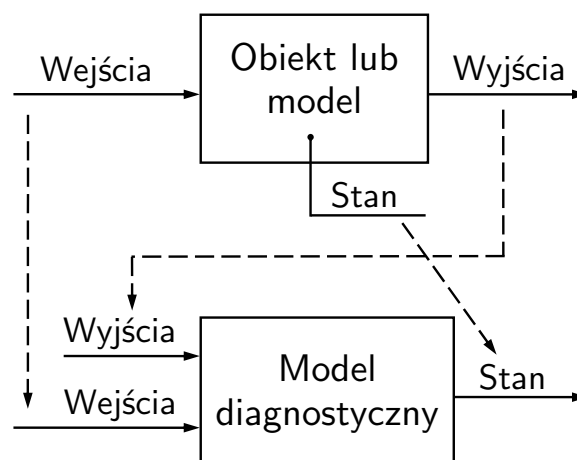
Wnioskowanie o obiekcie na podstawie modelu umożliwia także podobieństwo funkcjonalne. W przypadku modeli funkcjonalnych można wnioskować o zależnościach przyczynowo-skutkowych, jakie w modelowanym obiekcie występują, chociaż nie dają one możliwości wnioskowania o jego strukturze.

Podsumowując, sposób w jaki modele obiektów są budowane i stosowane zależy od stawianych tym modelom wymagań odnośnie zakresu ich stosowalności i jakości uzyskiwanych wyników.

2.4.3. Model diagnostyczny

Dla danego stanu oraz wejść zarówno w przypadku modeli jak i obiektów rzeczywistych generowane są wyjścia. Wyznaczenie ich nie jest jednak głównym celem z punktu widzenia diagnostyki maszyn. Celem tym jest określenie stanu badanego obiektu lub modelu.

Narzędziem pomocnym w rozwiązaniu tak postawionego zadania są modele diagnostyczne, które na podstawie informacji o wejściach oraz wyjściach pozwalają określić interesujący nas stan (rys. 2.4).



Rys. 2.4. Model diagnostyczny (na podstawie [14]).

Modele diagnostyczne mogą charakteryzować się różnym poziomem złożoności oraz mniej lub bardziej otwartą strukturą, która w wielu przypadkach porównywana jest do czarnej skrzynki o nieznannej zawartości. Wg [14, 15] modele te są relacjami pomiędzy cechami sygnałów diagnostycznych, a cechami stanu obiektu identyfikowanymi na podstawie wyników eksperymentu lub symulacji.

Do celów budowy modeli diagnostycznych korzysta się z narzędzi opartych na wiedzy zaczerpniętej z wielu dziedzin. Możemy tutaj wymienić [14, 15]:

- statystykę matematyczną i analizę regresji;
- teorię układów uczących 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.

Jak można zauważyć wszystkie wymienione narzędzia bazują na wiedzy dotyczącej rzeczywistych obiektów. Wiedza ta jest zazwyczaj pozyskiwana w trakcie badań diagnostycznych lub eksploatacyjnych. Jej źródłem mogą być także badania prowadzone na modelach obiektów.

Badając wrażliwość zakładamy, że wejścia oraz wyjścia obiektu lub modelu są jednocześnie wejściami modelu diagnostycznego. Będziemy je opisywali za pomocą cech sygnałów. Uwzględniając to wyszczególniamy następujące ich grupy:

- cechy określające warunki działania obiektu, związane z wejściami (np.: prędkość obrotowa wału wejściowego, kąt otwarcia zaworu):
 - cechy, których wartości nie ulegają zmianom, lub których zmiany są wynikiem zakłóceń losowych;
 - cechy, których zmiany nie wpływają w sposób znaczący na wyjścia obiektu;
 - cechy wrażliwe, których zmiany w sposób znaczący wpływają na wyjścia obiektu;
- cechy opisujące skutki działania obiektu, związane z jego wyjściami. Są one określane poprzez pomiar lub symulację (np.: cechy punktowe sygnałów wibroakustycznych):

- cechy, których wartości nie ulegają zmianom, lub których zmiany są wynikiem zakłóceń losowych;
- cechy, których zmiany nie zależą od zmian stanu;
- cechy wrażliwe na zmianę stanu, trudne do oszacowania i pomiaru;
- cechy wrażliwe, których zmiany przynajmniej częściowo zależą od zmian stanu.

Nie wszystkie z przedstawionych grup cech sygnałów mogą zawierać informację pozwalającą określić stan badanego obiektu lub modelu. Wiele z nich jest pomijanych ze względu na trudności związane z ich wyznaczeniem. Pozostałe cechy można podzielić na dwie podstawowe grupy, którymi są: cechy wrażliwe oraz cechy niewrażliwe. Określenie tego do której grupy należą poszczególne cechy nie jest niestety zadaniem prostym i wymaga zastosowania specjalnych narzędzi ze szczególnym uwzględnieniem metod statystycznych.

Rozdział 3

Definicje wrażliwości

Jednoznaczna definicja wrażliwości, możliwa do zastosowania we wszystkich dziedzinach, w których pojęcie „wrażliwości” jest używane, niestety nie istnieje.

Według „Popularnego słownika języka polskiego” [30], „wrażliwość” jest rzeczownikiem pochodzącym od przymiotnika „wrażliwy”. Przymiotnik wrażliwy ma dwa znaczenia. Pierwsze to: „łatwo, szybko, silnie reagujący na coś”, zaś drugie: „podatny na wpływy z zewnątrz, mało odporny”.

Oprócz tej definicji wrażliwości, stosowanej w życiu codziennym, można zetknąć się z definicjami ukierunkowanymi na różne dziedziny nauki. W dziedzinie ekonomii „Leksykon biznesu” [69] podaje definicję „wrażliwości na zmiany”. Definicja ta dotyczy wrażliwości firm na zmiany zachodzące na rynku. Medycyna, która jest bardzo szeroką dziedziną, posługuje się pojęciami: wrażliwości bakterii na antybiotyki, siatkówki oka na światło, skóry na bodźce, itp.

Wszystkie przytoczone definicje wrażliwości zostały przyjęte w celu określenia wpływu pewnych czynników fizycznych, psychologicznych lub finansowych na badany obiekt. Obiektem tym może być zarówno człowiek, maszyna jak i rynek finansowy.

Ze względu na interesujący nas problem wrażliwości w dziedzinie diagnostyki, nasza uwaga skupi się głównie na definicjach wrażliwości wywodzących się z automatyki, metod optymalizacji i innych pokrewnych dziedzin. Definicje te odnoszą się najczęściej do wyznaczania wrażliwości na podstawie wejść i wyjść modeli matematycznych.

3.1. Wrażliwość w automatyce

Klasyczna teoria wrażliwości wywodzi się z automatyki, a dokładniej z badań układów automatycznej regulacji ze sprzężeniem zwrotnym. Zakłada ona, iż poddając analizie pochodne cząstkowe można określić wpływ, jaki na odpowiedź układów regulacji mają zmiany wartości ich parametrów. Ujmuje to następująca zależność [18]:

$$S_{ij}(t) = \frac{\partial y_i(t)}{\partial a_j(t)}, \quad (3.1)$$

gdzie: $S_{ij}(t)$ – wrażliwość układu;
 $y_i(t)$ – sygnał wyjściowy;

$a_j(t)$ – parametr układu.

Pozwala ona wyznaczyć wrażliwość układów automatycznej regulacji, a tym samym ustalić takie wartości parametrów a_j , dla których analizowany układ jest stabilny.

Stosując analizę wrażliwości w automatyce można badać wpływ nieskończenie małych zmian parametrów badanego układu, na sygnały wyjściowe. Postawione zostaje jednak wymaganie możliwości ciągłej zmiany wartości parametrów układu lub inaczej, wymagana jest ciągła przestrzeń stanów.

W książce A. Wierzbickiego pod tytułem „Modele i wrażliwość sterowania” [93] podano dwie definicje wrażliwości. Pierwsza z definicji dotyczy wrażliwości modelu matematycznego i ujmuje ją jako:

„Oszacowanie przyrostów zmiennych modelu matematycznego spowodowanych zmianami samego modelu.”

Przyrosty zmiennych modelu wyznacza się najczęściej stosując przybliżenie różniczkowe lub też oszacowanie typu Lipschitza. Ogólnie mówiąc, wyznaczanie wrażliwości polega na stosowaniu różnorodnych technik różniczkowania modeli matematycznych zależnych od stopnia skomplikowania struktury tych modeli.

Druga z przytoczonych definicji wrażliwości dotyczy układów sterowania, a jej wyznaczenie polega na badaniu wpływu zmian jednego modelu na zachowanie się drugiego modelu. Służy ona głównie do analizy zachowania się regulatorów we współdziałaniu z procesem rzeczywistym.

W dziedzinie jaką jest automatyka spotykamy się również z definicją wrażliwości sterowania optymalnego [32]. Korzystając z niej można określić, które elementy zbioru wielkości sterujących mają niewielki wpływ na osiąganą wartość wskaźnika jakości Q . Sam wskaźnik jakości Q jest funkcją wszystkich wielkości wejściowych układu regulacji:

$$Q = Q(u_1, u_2, \dots, u_n; z_1, z_2, \dots, z_k), \quad (3.2)$$

gdzie: u_1, u_2, \dots, u_n – są wielkościami sterującymi (nastawianymi);

z_1, z_2, \dots, z_k – są wielkościami niesterowanymi (zakłóceniami).

Funkcja ta przyjmuje ekstremum, jeżeli wszystkie jej pochodne cząstkowe względem wielkości nastawianych u_i będą zerowe:

$$\frac{\partial Q}{\partial u_i} = 0 \quad \text{dla} \quad i = 1, 2, \dots, n. \quad (3.3)$$

Mając określony wskaźnik jakości Q można wyrazić zależność na wrażliwość sterowania optymalnego za pomocą następującej różnicy:

$$\Delta Q = \max_{\mathbf{u}} Q - \max_{\mathbf{u}^i} Q, \quad (3.4)$$

gdzie: \mathbf{u}^i – zbiór \mathbf{u} bez elementu u_i .

Stosując tą zależność może się okazać, że część wielkości wejściowych jest nieistotna dla sterowania optymalnego lub inaczej rozwiązanie optymalne dopuszcza dowolność tych wielkości wejściowych. W licznych przypadkach, gdy występuje sprzężenie zwrotne, również niektóre wartości wyjściowe mogą okazać się mało istotne.

3.2. Wrażliwość w metodach optymalizacji

Analiza wrażliwości w metodach optymalizacji pozwala określić wpływ zmian wartości parametrów projektowych $\bar{p} = [p_1, \dots, p_k]$ na wartości zmiennych stanu. Zmiennymi stanu w przypadku wytrzymałości materiałów mogą być: przemieszczenia \bar{u} , odkształcenia $\bar{\varepsilon}$ i naprężenia $\bar{\sigma}$.

$$S_u = \frac{\delta u}{\delta p}. \quad (3.5)$$

Zamiast zmiennych stanu można rozpatrywać pewne parametry projektowe od nich zależne $J = J(\bar{u}, \bar{\varepsilon}, \bar{\sigma})$. Równanie wrażliwości przyjmuje wtedy postać:

$$S_J = \frac{\delta J}{\delta p}. \quad (3.6)$$

W przypadku metod optymalizacji analiza wrażliwości pozwala nie tylko na ocenę wpływu zmian parametrów projektowych na zmienne stanu lub charakterystyki od nich zależne. Pozwala ona także na analizę wpływu obcinania i zaokrąglania wartości liczbowych w trakcie obliczeń numerycznych. Wpływ ten można określić poprzez wprowadzenie bardzo małego zakłócenia w parametrach projektowych i wykonanie dodatkowych obliczeń.

3.3. Wrażliwość w badaniach modeli matematycznych

Przeglądając literaturę związaną z zastosowaniem analizy wrażliwości w badaniach modeli matematycznych można się spotkać z następującą definicją [73]:

„Wartość wrażliwości jest oceną tego, w jakim stopniu niepewność na wyjściu modelu jest zależna od poszczególnych źródeł niepewności na wejściu modelu.”

Bazująca na tej definicji miara wrażliwości dla kolejnych wejść opisana jest zależnością [9, 75]:

$$S_X = \frac{\text{Var}_X[E(Y|X)]}{\text{Var}(Y)}, \quad (3.7)$$

gdzie: Y – zmienne wyjściowe;

X – zmienne wejściowe;

$E(Y|X)$ – wartość oczekiwana Y dla zadanej wartości X .

W bardziej szczegółowym ujęciu, przy zastosowaniu metody Sobola [9] wartości wrażliwości dla poszczególnych wejść wyznaczamy z równania:

$$S(i_1, \dots, i_n) = \frac{V(i_1, \dots, i_n)}{V}, \quad (3.8)$$

gdzie: V i $V(i_1, \dots, i_n)$ oznaczają odpowiednio wariancję całkowitą oraz cząstkową.

3.4. Wrażliwość w diagnostyce maszyn

W publikacji Cz. Cempla oraz M. Golec [8] została przedstawiona widmowa miara wrażliwości $S_{D_i}^{a_j}$. Nazywano ją *bezwymiarowym współczynnikiem wrażliwości estymaty D_i na zmianę jej argumentu a_j* i opisano następującą zależnością:

$$\frac{\Delta D_i(G_1, \dots, G_n, f_1, \dots, f_n, \Delta f_1, \dots, \Delta f_n, \Delta a_j)}{D_i(G_1, \dots, G_n, f_1, \dots, f_n, \Delta f_1, \dots, \Delta f_n)} = \frac{\Delta a_j}{a_j} \cdot S_{D_i}^{a_j}, \quad (3.9)$$

$$\left| \frac{\Delta a_j}{a_j} \right| \ll 1; \quad a_j = G_k; f_k; \Delta f_k \quad \text{dla} \quad j = k = 1, 2, \dots, n,$$

gdzie: $\frac{\Delta D_i}{D_i}$ – względny przyrost miary widmowej D_i procesu drganiowego spowodowany zmianą j -tego argumentu a_j ;

$\frac{\Delta a_j}{a_j}$ – względny przyrost j -tego argumentu a_j ;

$G_k, f_k, \Delta f_k$ – estymaty widmowe: wartości amplitud, częstotliwości środkowe oraz szerokości połówkowe składowych elementarnych widma gęstości mocy.

Określeniem miar wrażliwości diagnostycznej zajęto się również w pracach [76,91,94]. Dotyczyły one badania wrażliwości cech sygnałów w dziedzinie: częstotliwości, czasu oraz cech wzajemnych sygnałów. Przedstawione w nich definicje i algorytmy badania wrażliwości miały umożliwić znalezienie odpowiedzi na pytanie:

Które sygnały należy mierzyć i jakie ich cechy należy wyznaczyć aby móc określić aktualny stan techniczny badanego obiektu technicznego bez ingerencji w jego strukturę?

Definicja wrażliwości przytoczona w pierwszej z wymienionych publikacji [76] jest następująca:

„Wrażliwością S wartości cech W , opisujących obiekt S , na działanie czynnika lub grupy czynników B , będziemy nazywali względną zmianę wartości cech W , opisujących obiekt A , pod wpływem tego, czy czynnik lub czynniki B działają, czy też nie działają na obiekt A .”

Można ją przedstawić w postaci zależności:

$$S(W(A|B)) = W(A|B) - W(A|\neg B), \quad (3.10)$$

gdzie: „-” – operator różnicy lub ilorazu indywidualnie zdefiniowany dla wartości cech, mogących być: liczbami, zbiorami liczb, jak i każdymi innymi obiektami (np.: kolorami) lub zbiorami tych obiektów;

A – badany obiekt;

B – czynnik lub grupa czynników;

$A|B$ – czynnik lub grupa czynników B działa na obiekt A ;

$A|\neg B$ – czynnik lub grupa czynników B nie działa na obiekt A ;

$W(A|B)$ – wartości cech W opisujących obiekt A , na który działa czynnik lub czynniki B ;

$W(A|\neg B)$ – wartości cech W opisujących obiekt A , na który nie działa czynnik lub czynniki B ;

$S(W(A|B))$ – wrzażliwość S wartości cech W opisujących obiekt A , na który działa czynnik lub czynniki B .

W przedstawionym równaniu wartość bezwzględna wrzażliwości S lub jej odpowiednik dla cech nie będących liczbami, określa wielkość wpływu czynnika lub czynników B na wartości cech W opisujących obiekt A . Określa także czy wartości cech W opisujących obiekt A wzrosły „+” czy też zmały „-”. W przypadku ciągłego działania czynnika B można wyodrębnić pewne poziomy jego oddziaływania B_1, B_2, \dots, B_n i dla każdego z tych poziomów wyznaczać wrzażliwość. Wrzażliwość tę wyznaczamy przyjmując poziom oddziaływania czynnika B_0 za bazowy:

$$S(W(A|B_i)) = W(A|B_i) - W(A|B_0); \quad i = 1, 2, \dots, n. \quad (3.11)$$

Należy dodać, iż funkcja $f(\dots)$ zdefiniowana dla wrzażliwości wartości cech opisujących obiekt A , z działającymi osobno, na ten obiekt, elementarnymi czynnikami $\{b_1, b_2, \dots, b_n\} \in B$, nie musi być równa funkcji $g(\dots)$ zdefiniowanej dla wrzażliwości wartości cech opisujących obiekt A z działającymi jednocześnie, na ten obiekt, elementarnymi czynnikami b_1, b_2, \dots, b_n :

$$f(S(W(A|\{b_1\})), S(W(A|\{b_2\})), \dots, S(W(A|\{b_n\}))) \neq g(S(W(A|\{b_1, b_2, \dots, b_n\}))). \quad (3.12)$$

W omawianej publikacji [76] oprócz przytoczonej definicji wrzażliwości przedstawiono metodę badania wrzażliwości diagnostycznej cech funkcyjnych sygnałów. Cechy te rozpatrywano jako zbiory cech punktowych, a sama metoda wyznaczania wrzażliwości oparta jest na analizie wariacyjnej modelu stałego dla danych ortogonalnych opartego na klasyfikacji krzyżowej [67]. Można ją stosować w przypadku, gdy na badany obiekt działają dwa czynniki, z których jeden przyjmuje wartości nominalne, a drugi dyskretne liniowe. Wyznaczane wartości cech sygnałów, dla których jest wyznaczana wrzażliwość, muszą przyjmować wartości rzeczywiste.

Praca dotycząca badania wrzażliwości cech sygnałów w dziedzinie czasu [91] zawiera następującą definicję wrzażliwości:

„Wrzażliwość diagnostyczna cech sygnału wibroakustycznego to ilościowa lub jakościowa ocena względnej zmiany wartości cechy sygnału wibroakustycznego będącego skutkiem zmiany stanu technicznego diagnozowanego obiektu.”

Definicja ta jest niejako zawężeniem wcześniejszej definicji wrzażliwości do cech jakimi są cechy sygnałów wibroakustycznych i czynnika działającego na obiekt jakim jest niesprawność (zmiana stanu technicznego).

Bazując na tej definicji, autor opracował i pokazał trzy różne metody wyznaczania wrzażliwości diagnostycznej. Pierwsze dwie metody dotyczą cech punktowych. Różnią się one tym, iż jedna z nich bazuje na analizie wariacyjnej modelu stałego opartego na

klasyfikacji krzyżowej i wielokrotnych przedziałach ufności Tukeya, a druga polega na porównywaniu zakresów wartości badanej cechy dla różnych wartości czynników działających na badany obiekt. Metodę opartą na klasyfikacji krzyżowej i przedziałach ufności można stosować w przypadku, gdy czynnik działający na badany obiekt przyjmuje wartości dyskretne, a wartości wyznaczanych cech przyjmują wartości rzeczywiste. Drugą metodę, można stosować przy wyznaczaniu wrażliwości dla wartości cech sygnałów przyjmujących wartości rzeczywiste, w przypadku, gdy czynniki działające na badany obiekt przyjmują wartości nominalne. Trzecia metoda opracowana do celów badania wrażliwości diagnostycznej funkcyjnych cech sygnałów wibroakustycznych oparta jest na algorytmach klasyfikacji i grupowania. Uzależnia ona wartość wrażliwości od średnich odległości zbiorów wartości cech funkcyjnych wyznaczonych dla poszczególnych nominalnych wartości czynników działających na badany obiekt.

W artykule dotyczącym badania wrażliwości cech wzajemnych sygnałów [94] znajdziemy następującą definicję wrażliwości:

„Wrażliwość diagnostyczną wybranej cechy wzajemnej par sygnałów wibroakustycznych określa stopień z jakim zmienia się wartość tej cechy na skutek zmiany stanu badanego obiektu technicznego.”

Dla tej definicji wartość wrażliwości uzależniona jest od różnic występujących między wartością cechy wyznaczonej dla rozpatrywanego stanu, a wartościami cech wyznaczonymi dla pozostałych stanów. Jeżeli różnice są znaczące dla badanego stanu, oznacza to, iż cechy są wrażliwe na ten stan. W przeciwnym przypadku badane cechy są niewrażliwe. Zaproponowana metoda pozwala na badanie wrażliwości cech funkcyjnych opisanych za pomocą wartości rzeczywistych wyznaczonych dla nominalnych wartości stanów badanego obiektu.

Ciekawą pozycją dotyczącą metod badania wrażliwości cech sygnałów diagnostycznych jest praca zbiorowa pod redakcją W. Cholewy i J. Kicińskiego [17]. Zaprezentowane zostało w niej kilka metod badania wrażliwości. Wybór poszczególnych metod uzależniony jest od rodzaju wartości przyjmowanych przez cechy stanu oraz cechy sygnałów analizowanego modelu lub obiektu technicznego. Wszystkie zaprezentowane w tejże pracy metody bazują na następującej definicji wrażliwości diagnostycznej [17]:

„Wrażliwość cechy sygnału diagnostycznego jest ilościową lub jakościową miarą jej względnej zmiany, obserwowanej jako skutek niewielkiej zmiany stanu technicznego diagnozowanego obiektu.”

Definicję tą można przedstawić jako następującą zależność:

$$S(q_i) = \frac{\partial p(q_i, \bar{q}_{-i})}{\partial q_i}; \quad \bar{q}_{-i} = \{q_1, q_2, \dots, q_n\} \setminus q_i, \quad (3.13)$$

gdzie: $p(\dots)$ – cecha sygnału diagnostycznego będąca funkcją interesującej nas cechy stanu q_i oraz innych cech stanu \bar{q}_{-i} , którymi nie jesteśmy zainteresowani.

Ze względu na brak możliwości uwzględnienia wszystkich występujących w zależności (3.13) cech stanu, a tym samym określenia ich wpływu na wyznaczone wartości

cech sygnałów, można przyjąć uproszczoną jej postać:

$$S(q) = \frac{\partial p(q)}{\partial q}. \quad (3.14)$$

W praktyce, gdy nie są znane zależności funkcyjne, a jedynie rzeczywiste wartości cech, równanie (3.14) przyjmuje postać równania różnicowego:

$$S(q) = \frac{\Delta p(q)}{\Delta q}. \quad (3.15)$$

Często zdarza się, że wartości cechy stanu lub cech sygnałów stanowią zbiór uporządkowany wartości jakościowych, np.:

$$\begin{aligned} \text{val}(p) &= \{,mały', ,średni', ,duży'\}; \\ \text{val}(q) &= \{,mały', ,średni', ,duży'\}. \end{aligned} \quad (3.16)$$

W takich przypadkach, w [17], proponowane jest zastosowanie rangowej analizy korelacyjnej [48], pozwalającej określić poziom zgodności uporządkowanych szeregów wartości. Poziom ten może być utożsamiany z wartością wrażliwości i stanowić jej miarę. Dotyczy to także cech ilościowych, które można w posty sposób przekształcić w cechy jakościowe, a tym samym stosować rangową analizę korelacyjną do wyznaczania wrażliwości rzeczywistych wartości cech stanu lub cech sygnałów.

Rozdział 4

Podział metod badania wrażliwości

Zajmując się badaniem wrażliwości nasuwa się pytanie, w jaki sposób uszeregować i uporządkować metody badania wrażliwości, aby w sposób możliwie wierny odzwierciedlić naturalne relacje zachodzące między tymi metodami. Pierwszą z możliwości jest podział na:

- metody badania wrażliwości stosowane w przypadku modeli;
- metody badania wrażliwości stosowane w przypadku obiektów rzeczywistych.

Zarówno w przypadku badania wrażliwości modeli, jak i badania wrażliwości obiektów rzeczywistych, można określić zakres badań wprowadzając podział metod na [74]:

- metody lokalne;
- metody globalne.

Kolejną z możliwości wyszczególnienia pewnych grup w metodach badania wrażliwości jest ich podział ze względu na sposób przeprowadzania analizy [33]. Wyróżniamy tutaj:

- metody matematyczne;
- metody statystyczne;
- metody graficzne.

Rozróżniając powyższe grupy metod można łatwiej i lepiej zrozumieć metody badania wrażliwości i znaleźć spośród nich te, które są najbardziej odpowiednie do rozwiązania postawionego zadania. Ze względu na to, iż badanie wrażliwości można stosować jako dodatek do technik modelowania lub metod diagnostyki, najlepiej do badań modeli deterministycznych nadają się metody matematyczne. W przypadku, gdy badamy modele zidentyfikowane na podstawie danych statystycznych, modele bazujące na sieciach Bayesa lub też rzeczywiste obiekty, zalecane jest stosowanie statystycznych metod badania wrażliwości.

4.1. Analiza wrażliwości – badania modelu

Modele mogą być budowane zarówno jako narzędzia służące do symulacji zjawisk fizycznych jak i do symulacji działania obiektów fizycznych. Jeżeli chodzi o modele to

uwagę skupimy głównie na modelach obiektów technicznych. Opisują one związki zachodzące pomiędzy wejściami, wyjściami oraz stanem modelowanego obiektu [62].

Główną cechą wyróżniającą wszelkiego rodzaju modele jest możliwość generowania za ich pomocą wartości wyjściowych dla dowolnych, mieszczących się w dopuszczalnym zakresie wartości wejściowych. Zaletą ta pozwala nam na uwzględnienie w badaniach wrażliwości wszystkich kombinacji wartości wejściowych. Wadą modeli są natomiast ograniczenia związane z tym, iż za ich pomocą można wyznaczać tylko te wyjścia, do wyznaczania których modele te zostały zbudowane.

4.2. Analiza wrażliwości – badania obiektu rzeczywistego

Prowadzenie badań na rzeczywistych obiektach technicznych, w odróżnieniu od prowadzenia takich samych badań na modelach, wymaga znacznych nakładów finansowych, zależnych od kosztu samego obiektu i niezbędnego do badań oprzyrządowania. W przypadku badań diagnostycznych można wyróżnić m.in. eksperyment czynny oraz bierny.

Eksperyment czynny podobnie jak badania symulacyjne pozwala wyznaczyć przestrzeń wartości wyjściowych dla wszystkich kombinacji wartości wejściowych. Należy jednak uwzględnić fakt, iż zakresy tych wartości są znacznie bardziej ograniczone, niż ma to miejsce w przypadku badania modeli, z powodów czysto technicznych, specyficznych dla badanego obiektu technicznego. Kolejnym czynnikiem, który należy uwzględnić w badaniach, są zmieniające się cyklicznie i/lub losowo wartości wejściowe, które z założenia powinny być stałe. Przykładem może być wartość prędkości obrotowej wału wejściowego maszyny roboczej, która nawet przy najlepszych układach regulacji oscyluje wokół założonej wartości, nawet wtedy, gdy warunki działania maszyny są ustalone.

Eksperyment bierny charakteryzuje się tym, iż nie ingerujemy w parametry obiektów technicznych dla celów prowadzonego eksperymentu. Otrzymywane tym sposobem wyniki badań dostarczają nam informacji o wartościach wyjściowych otrzymanych dla wąskiego zakresu zmian wartości wejściowych. Wartości wejściowe zmieniają się przy tym jedynie w „bezpiecznych” zakresach dla normalnych warunków działania badanego obiektu.

4.3. Metody lokalne

Stosując lokalne metody badania wrażliwości możemy określić wpływ każdego z wejść obiektu lub modelu na jego wyjście. Metody te charakteryzują się tym, iż w jednej chwili możemy badać wpływ zmian jednego tylko wejścia przyjmując pozostałe za niezmiennie i ustalając je na interesującym nas poziomie. Rezultatem badania lokalnej wrażliwości są szeregi pochodnych cząstkowych, po jednym dla każdego wejścia, opisujące szybkość zmian wartości na wyjściu w stosunku do szybkości zmian wartości na wejściu. Metody

te można stosować zarówno w przypadku badania wrażliwości modeli jak i badania wrażliwości obiektów technicznych. Ponadto są one jednymi z nielicznych metod, jakie mogą służyć do badań wrażliwości w przypadku eksperymentu biernego.

Inna definicja metod lokalnych, z której nie będziemy korzystać w trakcie badań wrażliwości, zakłada istnienie wielowymiarowej przestrzeni, w której wartości wejściowe i wyjściowe stanowią punkty. Interesujący nas punkt tej przestrzeni oraz jego najbliższe otoczenie (sąsiednie punkty) są traktowane jako dane lokalne służące do badań przy użyciu metod lokalnych.

4.4. Metody globalne

W przypadku globalnych metod badania wrażliwości, efektem zmian wartości wejściowych jest zmiana kształtu funkcji gęstości prawdopodobieństwa wartości wyjściowych. W odróżnieniu od metod lokalnych wartości na wszystkich wejściach mogą zmieniać się jednocześnie, w dopuszczalnych dla nich zakresach. Wymaga to zazwyczaj zastosowania specjalnych metod doboru wartości wejściowych, gdzie przykładem jednej z nich może być metoda Monte Carlo.

Globalne metody badania wrażliwości pozwalają otrzymywać rozwiązania bardziej ogólne niż w przypadku metod lokalnych. Ich zastosowanie wiąże się jednak z analizą ogromnej liczby kombinacji wpływu zmian wartości wejściowych na zmiany wartości poszczególnych wyjść modeli lub obiektów.

Do globalnych statystycznych metod badania wrażliwości możemy zaliczyć metody bazujące na: analizie wariancji, znormalizowanych oraz cząstkowych współczynnikach korelacji rangowej, a także na metodzie FAST (od ang. Fourier Amplitude Sensitivity Test) [74, 75].

Jakość wyników otrzymywanych przy pomocy statystycznych, globalnych metod badania wrażliwości lub inaczej „względna stabilność analizy wrażliwości”, w dużej mierze zależy od użytego do analizy zbioru danych. Jest to powodem tego, iż globalne metody badania wrażliwości mogą znaleźć zastosowanie jedynie w przypadku badań modeli oraz w przypadku czynnego eksperymentu diagnostycznego.

4.5. Metody matematyczne

Wrażliwość, w przypadku metod matematycznych, jest oceniana na podstawie zmian wielkości obserwowanych na wejściach oraz wyjściu modelu lub obiektu. Wymaga to najczęściej wygenerowania, zbioru danych wyjściowych dla rozpatrywanego zakresu danych wejściowych.

W niektórych przypadkach matematyczne metody badania wrażliwości mogą być pomocne przy ocenie najbardziej istotnych wejść modelu, których zmiana ma największy wpływ na wartości wyjściowe. Można je stosować także do: weryfikacji, walidacji oraz identyfikacji najbardziej wrażliwych wejść modelu, które w pierwszej kolejności powinny

być brane pod uwagę przy generowaniu zbiorów danych dotyczących np. analizowanego obiektu lub procesu i uwzględniane podczas dalszych badań.

Do metod matematycznych zaliczamy między innymi: analizę przegięć (breakeven analysis), analizę różnic wartości wejściowych i wyjściowych w skali logarytmicznej, a także wyznaczanie pochodnych.

4.6. Metody statystyczne

Badanie wrażliwości przy użyciu metod statystycznych polega na wykonaniu szeregu symulacji lub przeprowadzeniu czynnego eksperymentu diagnostycznego. W badaniach tych wartości wejściowe wyznacza się metodami statystycznymi pamiętając o dopuszczalnych ich zakresach zdeterminowanych stosowalnością modelu lub możliwościami zmian parametrów obiektu. Mając dane wartości wejściowe wyznaczane lub generowane są wartości wyjściowe. Otrzymane dane poddaje się następnie analizie. W zależności od przyjętej metody badania wrażliwości można przeprowadzić analizę jednego lub większej ilości wejść i wyjść, które dodatkowo mogą zmieniać się w czasie. Można także uwzględniać wszelkiego rodzaju interakcje zachodzące pomiędzy poszczególnymi wejściami i wyjściami.

W metodach statystycznych do wyznaczania rozpatrywanego zbioru wartości wejściowych są stosowane między innymi: metoda Monte Carlo oraz metoda kwadratów łańciskich. Wyznaczając wrażliwość można natomiast skorzystać z kilku metod analizy danych opatrych na: analizie wariancyjnej, korelacyjnej, wyznaczaniu powierzchni odpowiedzi, testach wrażliwości FAST oraz testach bazujących na wzajemnych indeksach zależności (MII od ang. Mutual Information Index) [74, 75].

4.7. Metody graficzne

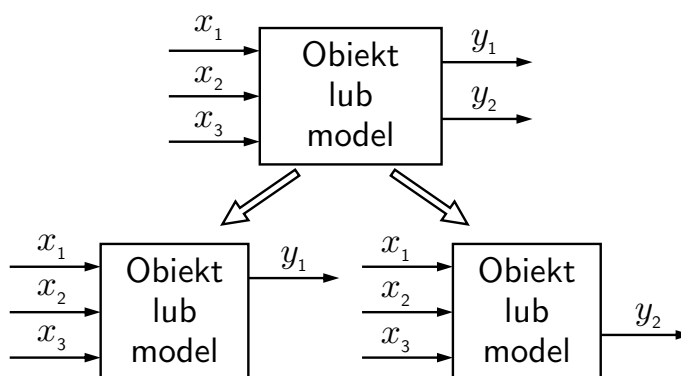
W graficznych metodach wrażliwość przedstawiana jest za pomocą wykresów, map lub powierzchni. Najczęściej stosowane są one do wizualnego przedstawienia zmienności wyjść spowodowanych zmianami na wejściach.

Metody graficzne znajdują zastosowanie przede wszystkim we wstępnej ocenie modelu lub obiektu przed podjęciem dalszych badań. Mogą zostać użyte również jako dopełnienie metod matematycznych oraz statystycznych, głównie w celu lepszego przedstawienia oraz łatwiejszego zrozumienia uzyskanych wyników.

Rozdział 5

Metody badania wrażliwości diagnostycznej

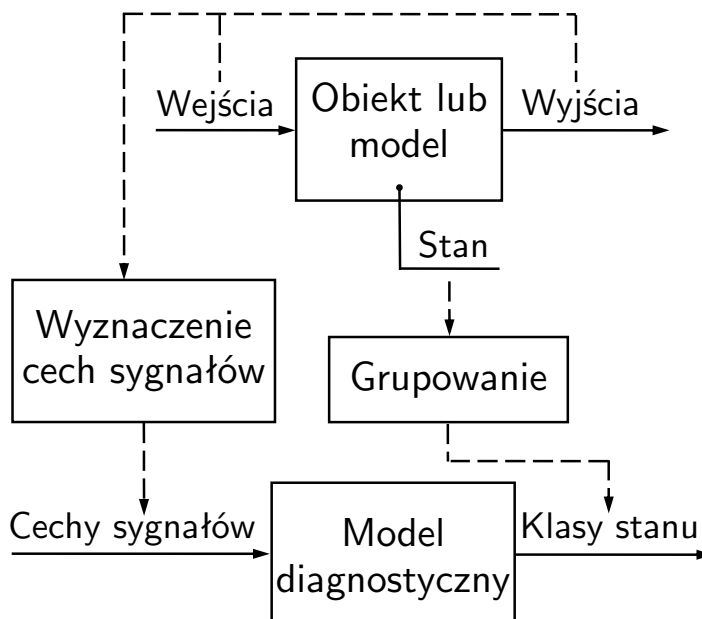
Klasyczne, nie związane z diagnostyką, metody badania wrażliwości pozwalają określić, które wejścia badanych obiektów lub modeli mają znaczący wpływ na ich wyjścia. Metody te dotyczące m.in.: automatyki, budowy modeli matematycznych, czy też zadań optymalizacji pozwalają na analizę wpływu więcej niż jednego wejścia na jedno lub kilka wyjść badanego obiektu lub modelu. Gdy istnieje więcej niż jedno wyjście zazwyczaj traktuje się je w badaniach wrażliwości jako niezależne i rozpatruje osobno (rys. 5.1).



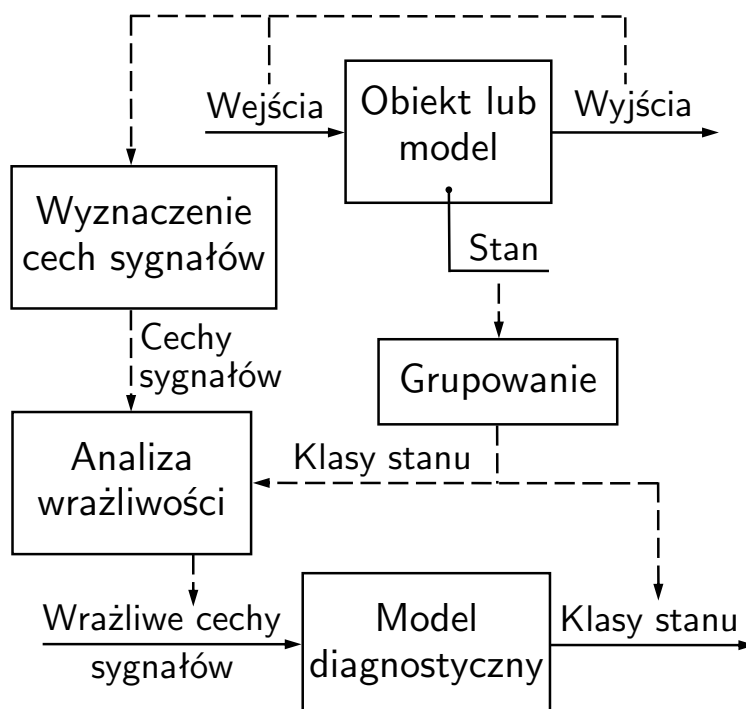
Rys. 5.1. Badanie wrażliwości obiektu lub modelu.

Analiza wrażliwości diagnostycznej w odróżnieniu od klasycznej analizy wrażliwości ma na celu rozwiązanie nieco odmiennego zadania. Nie mamy tutaj wielu niezależnych wejść obiektu i zależnych od nich wyjść, z których każde możemy rozpatrywać osobno, lecz mamy (rys. 5.2, 5.3):

- wejścia modelu diagnostycznego związane z niezależnymi wejściami badanego obiektu;
- wyjścia badanego obiektu, na które nie mamy wpływu, rozpatrywane jako wejścia modelu diagnostycznego;
- stan zaklasyfikowany do jednej lub kilku zdefiniowanych klas stanu.



Rys. 5.2. Identyfikacja modelu diagnostycznego bez udziału analizy wrażliwości.



Rys. 5.3. Identyfikacja modelu diagnostycznego z zastosowaniem analizy wrażliwości.

Przyglądając się definicjom wrażliwości, które nie dotyczą diagnostyki, zauważymy, że uwzględniane są jedynie wejścia oraz wyjścia modeli lub obiektów, a pomijany jest ich stan. Podejście takie jest niemożliwe w diagnostyce, gdzie właśnie stan jest źródłem naszego zainteresowania, a jego określenie ma zasadnicze znaczenie w procesie diagnozo-

wania. Podsumowując można stwierdzić, że informacja o stanie jest konieczna do budowy modeli diagnostycznych.

Rysunki 5.2 i 5.3 przedstawiają sposób identyfikacji modelu diagnostycznego na podstawie informacji dostarczonych przez obiekt techniczny lub jego model. Pierwszym z przyjętych założeń, pokazanym na tych rysunkach, jest wymóg stosowania cech sygnałów jako nośników informacji o interesujących nas wejściach i wyjściach. Stosowanie wspomnianych cech pozwala pozyskać dodatkowe informacje z rozpatrywanych sygnałów nie powodując jednoczesnej utraty informacji (wartość chwilowa sygnału także może być wartością cechy).

Drugie założenie przedstawione na rysunkach dotyczy określenia klas stanu. Aby je wyznaczyć wymagane jest przeprowadzenie operacji grupowania na zbiorze rozpatrywanych stanów. Można to wykonać w sposób uwzględniający cechy stanu stanowiące kryterium planowania eksperymentu. Przykładem utworzonych z użyciem tego kryterium klas stanu mogą być: 'stan dobry', 'przycieranie', 'niewyważenie', 'pęknięcie', itd. W przypadku, gdy nie chcemy redukować liczby rozpatrywanych stanów, można dla każdego z nich utworzyć odrębną klasę stanu. Może to mieć miejsce np. w badaniach diagnostycznych, gdzie dla każdej niesprawności przeprowadzony zostaje jeden eksperyment.

Rysunek 5.3 przedstawia, w jaki sposób, budując model diagnostyczny, uwzględniać wyniki analizy wrażliwości. Wskazywane za pomocą tej analizy wrażliwe cechy sygnałów, w odróżnieniu od cech sygnałów otrzymywanych bezpośrednio z obiektu technicznego lub modelu, mogą ułatwić budowę modeli diagnostycznych redukując liczbę uwzględnianych cech.

5.1. Definicja wrażliwości

Zgodnie z tym co powiedziano wcześniej klasyczne metody badania wrażliwości znajdują zastosowanie w przypadku rzeczywistych obiektów lub ich modeli, gdzie przedmiotem zainteresowania jest wpływ zmian wartości wejściowych na zmiany wyjść. W przypadku modeli diagnostycznych, gdzie podstawowym celem jest określenie stanu, zastosowanie znajduje analiza wrażliwości diagnostycznej.

Chcąc badać wrażliwość diagnostyczną należy rozpocząć od jej zdefiniowania. W diagnostyce maszyn próby takie podejmowane już były wielokrotnie, a treść przytaczanych definicji w głównej mierze zależy od specyfiki rozwiązywanych zadań. Definicje wrażliwości z jakimi możemy się zetknąć różnią się nieco w szczegółach, jednak istota znaczenia wrażliwości pozostaje niezmienną. Najbardziej ogólną definicją, uwzględniającą specyfikę diagnostyki wydaje się być ta, którą przytoczono poniżej.

Wrażliwością s_i^j , wartości cech sygnałów W^j , na zmianę stanu z b_i na inny stan, nazywamy względną zmianę wartości cech sygnałów W^j wynikającą ze zmiany tego stanu.

Definicję tą można przedstawić w postaci zależności:

$$s_i^j = \frac{\sum_k V(W^j(b_i), W^j(b_k))}{V_{ref}(W^j(b_1), W^j(b_2), \dots)}; \quad b_1, b_2, \dots \in b; \quad (5.1)$$

$$k \neq i; \quad k = 1, 2, \dots,$$

gdzie: b – zbiór stanów;

b_i – rozpatrywany stan;

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

$V(W^j(b_i), W^j(b_k))$ – wartość miary zmienności V cechy sygnału W^j wynikająca ze zmiany stanu z b_i na stan b_k ;

$V_{ref}(W^j(b_1), W^j(b_2), \dots)$ – wartość skalująca sumaryczną wartość miar zmienności $\sum_k V(W^j(b_i), W^j(b_k))$ do interesującego nas przedziału na podstawie informacji o wartościach cech sygnału $W^j(b_i)$; $i = 1, 2, \dots$

Szerszego omówienia wymaga tutaj pojęcie zbioru wartości cech sygnałów W . Zbiór ten zawiera następujące wartości cech:

$$c_i^j = c_j(b_i); \quad i = 1, 2, \dots; \quad j = 1, 2, \dots, \quad (5.2)$$

gdzie: indeks górny j dotyczy kolejnych, wyznaczanych cech sygnałów c_j ;

indeks dolny i opowiada stanom b_i , dla których poszczególne cechy są wyznaczone.

Mając to na uwadze przykładowa cecha sygnału może odpowiadać wartości średniej sygnału przyspieszeń wyznaczonej dla maszyny, w której nastąpiło uszkodzenie łożyska.

Zbiór wartości cech sygnałów W zawiera podzbiory W^j . Podzbiory te z kolei zawierają wartości j -tej cechy sygnału:

$$W^j = \{w_i^j\} = \{c_j(b_i)\} = \{c_j(b_1), c_j(b_2), \dots\}; \quad i = 1, 2, \dots, \quad (5.3)$$

wyznaczone dla stanów b_i .

5.1.1. Uwzględnienie klas stanu

W przedstawionej definicji wartość wrażliwości określana jest na podstawie informacji o zbiorze stanów badanego obiektu oraz informacji o wartościach cech sygnałów odpowiadających poszczególnym stanom. Może to być niewystarczające, w przypadku, gdy grupę stanów uznamy za podobną pomijając np. jedną z cech stanu. Jeżeli tak postąpimy, to interesować nas będzie wpływ, jaki na wartości cech sygnałów mają zmiany stanów: ze stanów należących do grupy stanów podobnych na stany należące do innej grupy. Sposobem na rozwiązanie tego problemu jest uwzględnienie w definicji wrażliwości pojęcia klasy stanu.

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

Definicję tą można przedstawić w postaci poniższej zależności:

$$s_i^j = \frac{\sum_k V(W^j(B_i), W^j(B_k))}{V_{ref}(W^j(B_1), W^j(B_2), \dots)}; \quad B_1, B_2, \dots \in B; \quad (5.4)$$

$$k \neq i; \quad k = 1, 2, \dots,$$

gdzie: B – zbiór klas stanu;

B_i – rozpatrywana klasa stanu, do której może należeć jeden lub więcej stanów;

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

$V(W^j(B_i), W^j(B_k))$ – wartość miary zmienności V cechy sygnału W^j wynikająca ze zmiany klasy stanu z B_i na klasę stanu B_k ;

$V_{ref}(W^j(B_1), W^j(B_2), \dots)$ – wartość skalująca sumaryczną wartość miar zmienności $\sum_k V(W^j(B_i), W^j(B_k))$ do interesującego nas przedziału na podstawie informacji o wartościach cech sygnału $W^j(B_i)$; $i = 1, 2, \dots$

Podobnie jak wcześniej, zbiór wartości cech sygnałów W zawiera podzbiory W^j :

$$W^j = \{w_i^j\} = \{c_j(B_i)\} = \{c_j(B_1), c_j(B_2), \dots\}; \quad i = 1, 2, \dots, \quad (5.5)$$

gdzie: $w_i^j = c_j(B_i)$ nie oznacza już pojedynczej wartości cechy, lecz jest zbiorem wartości cechy sygnału c_j wyznaczonym dla stanów należących do klasy stanu B_i .

5.1.2. Uwzględnienie klasy stanu bazowego

Dla dowolnego obiektu technicznego możemy wyróżnić szereg stanów bazowych, związanych np. z jego prawidłowym działaniem. Stany te tworzą klasę stanu bazowego B_0 . Pozostałe stany związane z występowaniem niesprawności mogą tworzyć kolejne klasy B_i ; $i = 1, 2, \dots$, odpowiadające przykładowo niewyważeniu lub przycieraniu.

Uwzględniając klasę stanu bazowego treść definicji wrażliwości będzie następująca:

Wrażliwością s_i^j , wartości cech sygnałów W^j , na zmianę klasy stanu z bazowego B_0 na inną B_i , nazywamy względną zmianę wartości cech sygnałów W^j wynikającą ze zmiany tej klasy stanu.

Definicję tą można przedstawić w postaci zależności:

$$s_i^j = \frac{V(W^j(B_0), W^j(B_i))}{V_{ref}(W^j(B_0), W^j(B_1), \dots)}; \quad B_0, B_1, \dots \in B; \quad i \neq 0, \quad (5.6)$$

gdzie: B_0 – klasa stanu bazowego;

$V(W^j(B_0), W^j(B_i))$ – wartość miary zmienności V cechy sygnału W^j wynikająca ze zmiany klasy stanu z bazowego B_0 na klasę stanu B_i .

Z definicji tej można korzystać w przypadku, gdy naszym zadaniem jest detekcja uszkodzeń. Bazując na niej można poszukiwać cech sygnałów, których zmiany wynikające ze zmian klasy stanu bazowego na inną są największe.

5.2. Badanie wrażliwości – selekcja cech wrażliwych

Badania diagnostyczne maszyn oraz badania symulacyjne wiążą się zawsze z określonymi kosztami oraz podlegają ograniczeniom czasowym. Ze względu na te koszty oraz ograniczenia przeprowadzana jest często minimalna, wymagana liczba prób lub symulacji. Liczba ta zależy od:

- liczby rozpatrywanych klas stanu (można obserwować zmiany jednej lub kilku cech stanu tworząc dla każdej kombinacji ich wartości odrębną klasę stanu);
- liczby replikacji (pomiarów lub symulacji przeprowadzonych dla każdej klasy stanu).

W badaniach diagnostycznych w pierwszej kolejności stosowanym zabiegiem minimalizacji liczby prób jest redukcja liczby pomiarów do jednej dla każdej klasy stanu. Może to być uzasadnione tym, że eksperyment prowadzony jest na jednym obiekcie, a co za tym idzie odchylenie standardowe cech sygnałów wyznaczanych dla poszczególnych klas stanu powinno być małe. Mamy zatem sytuację, gdzie każdą klasę stanu reprezentuje jeden stan.

5.2.1. Założenia

Przystępując do analizy wrażliwości diagnostycznej zakładamy, że posiadamy informacje na temat:

- zbioru stanów $b = \{b_0, b_1, \dots, b_n\}$, uwzględnianych w badaniach, gdzie stan b_0 przyjmujemy jako stan bazowy;
- zbioru cech sygnałów $c = \{c_1, c_2, \dots, c_m\}$, dla których ma zostać określona wrażliwość.

Każdy ze stanów przypisujemy do innej klasy stanu. Robimy tak ze względu na to, iż zakładamy, że są one różne i będziemy chcieli mieć możliwość ich rozpoznania.

$$B_i = \{b_i\}; \quad i = 0, 1, 2, \dots, n, \quad (5.7)$$

gdzie: B_0 jest klasą stanu bazowego.

Otrzymane wartości cech sygnałów można uszeregować według wyznaczonej cechy sygnału:

$$W^j = [c_j(B_0) \quad c_j(B_1) \quad \dots \quad c_j(B_n)]; \quad j = 1, 2, \dots, m, \quad (5.8)$$

lub też według klas stanu, dla których cechy te zostały one wyznaczone:

$$W_i = [c_1(B_i) \quad c_2(B_i) \quad \dots \quad c_m(B_i)]; \quad i = 0, 1, 2, \dots, n. \quad (5.9)$$

Podsumowując, posiadamy wszystkie dane potrzebne do przeprowadzenia analizy wrażliwości:

- zbiór klas stanu: $B = \{B_0, B_1, B_2, \dots, B_n\}$,
gdzie: B_0 jest klasą stanu bazowego;
- zbiór wartości cech sygnałów: $W = \{W^1, W^2, \dots, W^m\}$;
 $W^j = \{w_0^j, w_1^j, w_2^j, \dots, w_n^j\}$.

5.2.2. Miary zmienności wartości cech sygnałów

Pierwszym etapem analizy wrażliwości jest wyznaczenie miary zmienności wartości cech sygnałów $V(W^j(B_0), W^j(B_i))$. Mając na uwadze to, iż dla każdej klasy stanu realizowane jest jedno badanie lub symulacja, przyjęto, że miarą tą będzie zmiana (różnica) wartości cech sygnałów Δw_i^j wynikająca ze zmiany klasy stanu bazowego B_0 na klasę stanu B_i . Wyznaczamy ją korzystając z następującej zależności:

$$\Delta w_i^j = w_i^j - w_0^j. \quad (5.10)$$

Różnice można wyznaczyć w prosty sposób dla rzeczywistych lub naturalnych wartości cech sygnałów, które dają się uporządkować w szeregu rosnącym lub malejącym. W przypadku cech sygnałów, których wartość zmienia się w sposób cykliczny takich jak np.: fazy składowych widma lub w przypadku cech jakościowych, różnicę proponuje się zastąpić innymi miarami odległościowymi.

1. Cechy ilościowe uporządkowane cyklicznie.

Miarą odległościową w przypadku np.: fazy składowych widma, może być wartość funkcji sinus, którą wyznaczamy dla różnic porównywanych kątów. Korzystamy przy tym z zależności:

$$\Delta w_i^j = \sin(w_i^j - w_0^j); \quad i = 1, 2, \dots, n. \quad (5.11)$$

2. Cechy jakościowe.

Jeżeli jesteśmy w stanie określić relację uporządkowania dla zbioru wartości cech jakościowych, to także możemy poszczególnym wartościom przypisać liczby porządkowe. Miarą odległościową w takim przypadku może być różnica wartości tych liczb przypisanych do dwóch rozpatrywanych wartości cech jakościowych:

$$\Delta w_i^j = \text{indeks}(w_i^j) - \text{indeks}(w_0^j); \quad i = 1, 2, \dots, n. \quad (5.12)$$

Po wyznaczeniu wartości miary zmienności $V(W^j(B_0), W^j(B_i))$ pozostaje kwestia wyznaczenia wartości skalującej $V_{ref}(W^j(B_0), W^j(B_1), \dots)$, dla każdej j -tej cechy sygnału. Naturalną miarą najlepiej nadającą się do tego celu jest wariancja wartości wyznaczonych różnic cech sygnałów. Szacujemy ją korzystając z zależności:

$$\text{var}(\Delta W^j) = \frac{1}{n} \sum_{i=1}^n (\Delta w_i^j - \Delta \bar{W}^j)^2; \quad (5.13)$$

$$\Delta \bar{W}^j = \frac{1}{n} \sum_{i=1}^n \Delta w_i^j; \quad (5.14)$$

$$\Delta W^j = \{\Delta w_1^j, \Delta w_2^j, \dots, \Delta w_n^j\}. \quad (5.15)$$

Otrzymana wartość wariancji oraz uprzednio wyznaczone wartości miar odległościowych Δw_i^j są liczbami rzeczywistymi, chociaż cechy sygnałów mogły być zarówno cechami jakościowymi jak i ilościowymi.

5.2.3. Wartość wrażliwości

Omówione metody określania miary zmienności cech sygnałów są podstawą do wyznaczenia wartości wrażliwości. Wyznaczamy ją zgodnie z podaną definicją dla wszystkich kombinacji elementów zbioru cech sygnałów i zbioru klas stanu. Ostatecznie wartość wrażliwości s_i^j po dodatkowym wyeliminowaniu wpływu przesunięcia wartości Δw_i^j względem zera wynosi:

$$s_i^j = \frac{\Delta w_i^j - \Delta \bar{W}^j}{\text{var}(\Delta W^j)}; \quad (5.16)$$

$$\Delta W^j = \{\Delta w_1^j, \Delta w_2^j, \dots, \Delta w_n^j\}. \quad (5.17)$$

Otrzymane wartości wrażliwości s_i^j zapisujemy w formie macierzy:

$$S = [s_i^j]_{m \times n} = [s_{j,i}]_{m \times n}; \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, m, \quad (5.18)$$

gdzie: wiersze odpowiadają kolejnym cechom sygnałów c_j ; $j = 1, 2, \dots, m$;

kolumny odpowiadają kolejnym klasom stanu B_i ; $i = 1, 2, \dots, n$.

Podstawowym celem analizy wrażliwości obok określenia wartości wrażliwości jest wskazanie cech sygnału najbardziej przydatnych w diagnozowaniu stanu badanych obiektów lub modeli. Zadanie to realizujemy przeprowadzając selekcję wrażliwych cech sygnałów.

5.2.4. Selekcja wrażliwych cech sygnałów

Bazując na wyznaczonej macierzy S zawierającej wartości wrażliwości $s_{j,i}$ możemy zająć się poszukiwaniami cech sygnału niosących największą ilość informacji o stanie badanego obiektu lub modelu. Algorytmy, które mają służyć takim poszukiwaniom, powinny spełniać pewne zalecenia w sposób jednoznaczny określające stawiane im zadania polegające m.in. na tym, że:

1. Wybierane cechy sygnału powinny charakteryzować się możliwie jak największą wrażliwością.
2. Wartość wybranej cech sygnału, wrażliwej na jedną z klas stanu powinna być znacząco różna od wartości tej cechy wyznaczonej dla innych klas stanu.
3. Jeżeli wartość wybranej cech sygnału nie jest znacząco różna dla dwóch lub więcej klas stanu to uznajemy, że klasy te są nierozróżnialne przy uwzględnieniu wyłącznie tej cechy.

Uwzględniając powyższe zalecenia proponowane są algorytmy sel1 (rys. 5.4) oraz sel2 (rys. 5.5) selekcji wrażliwych cech sygnałów. Algorytmy te poprzez wybór najbardziej interesujących nas ze względów diagnostycznych cech sygnałów umożliwiają jednocześnie wskazać i odrzucić cechy, które nie zawierają żadnej istotnej informacji o rozpatrywanych klasach stanu.

1. Znajdujemy maksymalną absolutną wartość wrażliwości $s_{x,y} = \max_{j,i} |s_{j,i}|$.
2. Na podstawie wartości $s_{x,y}$ za najbardziej wrażliwą na zmianę klasy stanu z bazowego B_0 na B_y uznajemy cechę c_x .
3. Odrzucamy klasy stanu których rozpoznanie jest utrudnione, ze względu na otrzymywane dla nich, podobne wartości cech.
 - (a) Znajdujemy wartości $s_{x,i}$; $i = 1, 2, \dots, n$, bliskie wartości $s_{x,y}$, np.: $s_{x,i} > 0,5 \cdot s_{x,y}$.
 - (b) Jeżeli znajdziemy wartości $s_{x,i}$; $i = 1, 2, \dots, n$ spełniające powyższy warunek to usuwamy z macierzy S odpowiadające tym wartościom kolumny (klasy stanów).
4. Usuwamy wiersz i kolumnę macierzy S odpowiadającą wartości $s_{x,y}$.
5. Przechodzimy do punktu 1 i powtarzamy algorytm dopóki nie usuniemy z macierzy S wszystkich kolumn i/lub wierszy.

Rys. 5.4. Algorytm sel1 wyboru cech wrażliwych.

1. Określamy nierównomierność rozkładu wartości wrażliwości $\hat{s}_j = f(s_{j,i})$ (5.21-5.24) dla poszczególnych wierszy macierzy S .
2. Znajdujemy maksymalną wartość nierównomierności rozkładu wartości wrażliwości $\hat{s}_x = \max_j(\hat{s}_j)$.
3. Na podstawie wartości \hat{s}_x za najbardziej wrażliwą na zmianę klasy stanu z bazowego B_0 na inną klasę stanu uznajemy cechę c_x .
4. Określamy indeks kolumny y w wierszu x macierzy S , dla której wartość bezwzględna cechy jest największa $s_{x,y} = \max_i |s_{x,i}|$.
5. Odrzucamy klasy stanu których rozpoznanie jest utrudnione, ze względu na otrzymywane dla nich, podobne wartości cech.
 - (a) Znajdujemy wartości $s_{x,i}$; $i = 1, 2, \dots, n$, bliskie wartości $s_{x,y}$, np.: $s_{x,i} > 0,5 \cdot s_{x,y}$.
 - (b) Jeżeli znajdziemy wartości $s_{x,i}$; $i = 1, 2, \dots, n$ spełniające powyższy warunek to usuwamy z macierzy S odpowiadające tym wartościom kolumny (stany).
6. Usuwamy z macierzy S wiersz i kolumnę odpowiadającą wartości $s_{x,y}$.
7. Przechodzimy do punktu 1 i powtarzamy algorytm dopóki nie usuniemy z macierzy S wszystkich kolumn i/lub wierszy.

Rys. 5.5. Algorytm sel2 wyboru cech wrażliwych.

W obu algorytmach do określenia klas stanu, których rozpoznanie może być utrudnione ze względu na podobne, odpowiadające im wartości cech sygnałów, zaproponowano następujące kryterium:

$$s_{j,i} > 0,5 \cdot s_{j,y}. \quad (5.19)$$

Jest ono zdefiniowane globalnie dla wszystkich cech sygnałów. Można go jednak określić indywidualnie, w zależności od tego czy badane wartości cech sygnałów są: rzeczywiste, całkowite, jakościowe lub inne.

$$s_{j,i} > k_j \cdot s_{j,y}. \quad (5.20)$$

Miara nierównomierności rozkładu wartości wrażliwości (nierównomierność) na którą powołujemy się w drugim algorytmie (rys. 5.5) pozwala określić, w jakim stopniu wartości wrażliwości otrzymane dla poszczególnych klas stanu różnią się pomiędzy sobą. Powszechnie stosowaną do tego celu miarą jest odchylenie standardowe. Jej zastosowanie jednak, w przypadku znormalizowanych wartości (wariancja = 1), jest niemożliwe. Ponieważ interesuje nas głównie to, w jakim stopniu wartości skrajne różnią się od pozostałych, proponowane są takie miary nierównomierności jak:

1. Wartość maksymalna absolutna:

$$A = \max_i |a_i|. \quad (5.21)$$

Wartość ta może być z powodzeniem stosowana ze względu na przeprowadzoną wcześniej normalizację. Jej zastosowanie w algorytmie sel2 (rys. 5.5) powoduje że otrzymywane wyniki mogą być zgodne z wynikami otrzymywanymi za pomocą algorytmu sel1 (rys. 5.4).

2. Wartość międzyszczytowa:

$$A = \max_i(a_i) - \min_i(a_i). \quad (5.22)$$

3. Średnia odległość wartości maksymalnej absolutnej od pozostałych wartości:

$$A = \frac{\sum_i |a_i \pm \max_j |a_j||}{(n-1)}; \quad i, j = 1, 2, \dots, n. \quad (5.23)$$

Znak występujący w równaniu (,+' lub ,-') zależy od znaku wartości a_j .

4. Minimalna odległość wartości maksymalnej absolutnej od pozostałych wartości:

$$A = \min_i |a_i \pm \max_j |a_j||; \quad i, j = 1, 2, \dots, n. \quad (5.24)$$

5.2.5. Podsumowanie

Wyznaczając wartość wrażliwości, a następnie dokonując selekcji cech sygnałów za pomocą zaproponowanych algorytmów można spełnić szereg oczekiwań stawianych cechom mającym służyć budowie modeli diagnostycznych.

Oczekiwania te dotyczą m.in.:

- Wyboru cech, charakteryzujących się największą wrażliwością, których zmiany wynikające ze zmian klasy stanu z bazowego B_0 na inny są największe.
- Wskazania klas stanu, których rozróżnienie za pomocą dowolnej cechy sygnału, spośród zbioru wyznaczanych cech, jest trudne lub wręcz niemożliwe.
- Odrzucenia cech sygnałów skorelowanych z innymi charakteryzującymi się większą wrażliwością cechami, których uwzględnienie nie wnosiłoby żadnych nowych informacji o klasach stanu. Dostarczana przez takie cechy nadmiarowość informacji, w przypadku, gdy informacja ta okazałaby się obciążona błędem, mogłaby spowodować spadek jakości opracowanego na ich podstawie modelu diagnostycznego.

5.3. Badanie wrażliwości – metoda statystyczna

W trakcie prowadzenia eksperymentu diagnostycznego rozpatrywany obiekt techniczny może być wielokrotnie demontowany, szczegółowo badany i ponownie montowany. Każda taka ingerencja ma pewien wpływ na niektóre cechy stanu, uważane czasami za nieistotne. Czy tak jest w istocie, można stwierdzić przeprowadzając analizę statystyczną. Aby przeprowadzenie takiej analizy było możliwe wymagane jest wykonanie więcej niż jednego pomiaru dla każdej z uwzględnianych w badaniach klasy stanu.

Praktyką stosowaną w badaniach diagnostycznych jest określenie zbioru stanów technicznych związanych np. z różnymi niesprawnościami badanego obiektu. Dla każdego z tych stanów rejestrowane są sygnały, które następnie poddaje się odpowiedniej obróbce mającej na celu wyznaczenie cech sygnałów. W trakcie badań pomiędzy poszczególnymi pomiarami związanymi z rozpatrywanym zbiorem stanów dokonuje się często pomiarów dla stanów, które można zaklasyfikować jako ‚wzorcowe‘, ‚bazowe‘ lub ‚sprawne‘. Głównym powodem takiego postępowania jest sprawdzenie powtarzalności otrzymywanych wyników.

Decyzję o tym czy otrzymane wyniki pomiarów są porównywalne, a więc można na ich podstawie przeprowadzać wnioskowanie, podejmuje się po porównaniu kilku lub kilkunastu cech sygnałów. Jeżeli ich wartości są podobne uznaje się, że powtarzalność wyników zostaje zachowana. Nie oznacza to oczywiście, że powtarzalność jest zachowana dla wszystkich cech sygnałów.

Najczęściej spotykaną przyczyną braku powtarzalności wyników są zmiany cech stanu. Mogą one występować z kilku powodów, do których można zaliczyć m.in.:

- odmienne wartości cech konstrukcyjnych uzyskane przy kolejnych operacjach montażu badanego obiektu;
- zmiany cech geometrycznych, będące wynikiem normalnej pracy obiektu technicznego, do których zaliczamy np.: zużycie okładzin ciernych. Praca obiektu z wprowadzonym uszkodzeniem może skutkować przyspieszonym zużyciem lub zniszczeniem jego elementów składowych;

- zmiany cech materiałowych związane np.: ze zmęczeniem materiału, ze zmianą struktury materiału w wyniku uderzenia, starzeniem, itp.

Wymienione powyżej zmiany cech konstrukcyjnych, geometrycznych oraz materiałowych mogą być następstwem wcześniej wprowadzanych do badanego układu niesprawności. Przykładem tego mogą być niewielkie odkształcenia plastyczne będące wynikiem chwilowych przeciążeń. Zmian takich należy w jak największym stopniu unikać, ale nie zawsze jest to możliwe.

Pomocnym narzędziem w analizie cech sygnałów zawierających składnik, zależny często od subtelnych i nieznanych zmian cech stanu jest analiza statystyczna. Bazująca na niej analiza wrażliwości może posłużyć do budowy sprawniejszych modeli diagnostycznych poprzez odrzucenie na wstępie cech, dla których powtarzalność jest niewystarczająca.

W przypadku modeli maszyn analiza wrażliwości oparta na analizie statystycznej może umożliwić wyeliminowanie ze zbioru rozpatrywanych cech sygnału takich cech, których zmiany w głównej mierze zależą od zmian mało interesujących nas wartości wektora stanu.

5.3.1. Założenia

Przystępując do analizy wrażliwości diagnostycznej bazującej na analizie statystycznej, zakładamy, że posiadamy informacje na temat:

- zbioru klas stanu $B = \{B_0, B_1, \dots, B_N\}$ uwzględnianych w badaniach, gdzie klasę stanu B_0 przyjmujemy jako klasę stanu bazowego;
- zbioru cech sygnałów $c = \{c_1, c_2, \dots, c_m\}$, dla których ma zostać określona wrażliwość.

Pomiędzy poszczególnymi klasami stanu B_i ; $i = 0, 1, \dots, N$ nie występuje żadna relacja uporządkowania oraz każda klasa stanu B_i reprezentowana jest przez więcej niż jeden stan:

- $B_0 = \{b_{0.1}, b_{0.2}, \dots, b_{0.n_0}\}$;
- $B_1 = \{b_{1.1}, b_{1.2}, \dots, b_{1.n_1}\}$;
- ...
- $B_N = \{b_{N.1}, b_{N.2}, \dots, b_{N.n_N}\}$.

Mając określone klasy stanu B_i ; $i = 0, 1, 2, \dots, N$, wyznaczamy dla każdego stanu wartości $w_i^{j,k}$; $k = 1, 2, \dots, n_i$ kolejnych cech sygnałów c_j ; $j = 1, 2, \dots, m$:

$$w_i^{j,k} = c_j(b_{i,k}); \quad i = 0, 1, 2, \dots, N; \quad j = 1, 2, \dots, m; \quad k = 1, 2, \dots, n_i. \quad (5.25)$$

Wartości te można zapisać w formie wierszowych lub kolumnowych n_i elementowych macierzy:

$$w_i^j = c_j(B_i) = [w_i^{j,1} \ w_i^{j,2} \ \dots \ w_i^{j,n_i}]^T; \quad i = 0, 1, 2, \dots, N; \quad j = 1, 2, \dots, m. \quad (5.26)$$

Otrzymane macierze z wartościami cech sygnałów porządkujemy następnie według wyznaczonej cechy sygnału:

$$W^j = [c_j(B_0) \quad c_j(B_1) \quad \dots \quad c_j(B_N)]; \quad j = 1, 2, \dots, m \quad (5.27)$$

lub też według klas stanu, dla których cechy te zostały wyznaczone:

$$W_i = [c_1(B_i) \quad c_2(B_i) \quad \dots \quad c_m(B_i)]; \quad i = 0, 1, 2, \dots, N. \quad (5.28)$$

Tym sposobem otrzymujemy wszystkie dane wymagane do przeprowadzenia analizy wrażliwości. Są nimi:

- zbiór klas stanu: $B = \{B_0, B_1, B_2, \dots, B_N\}$,
gdzie: B_0 jest klasą stanu bazowego;
- zbiór wartości cech sygnałów: $W = \{W^1, W^2, \dots, W^m\}$;
 $W^j = \{w_0^j, w_1^j, w_2^j, \dots, w_N^j\}$.

5.3.2. Analiza zmienności wartości cech sygnałów

Jak już wspomniano istotne w badaniach diagnostycznych jest określenie tego, czy wartości cech sygnałów wyznaczone dla poszczególnych klas stanu charakteryzują się wystarczającą powtarzalnością. Innymi słowy interesuje nas to, czy zmienność wartości cech sygnałów zależy chociaż w niewielkim stopniu od klas stanu dla których je wyznaczono.

Dobrze znanym i powszechnie do tego celu stosowanym narzędziem jest analiza wariancji. Przeprowadzenie jej wymaga jednak spełnienia podstawowego założenia, które mówi, że rozkład wartości cech wyznaczonych dla poszczególnych klas stanu musi być normalny z taką samą wariancją.

Do celów diagnostyki, gdzie nie chcemy zakładać postaci rozkładów statystycznych analizowanych wartości cech sygnałów, lepszymi wydają się być metody rangowe. Metodą najbardziej odpowiednią do tego celu wydaje się być nieparametryczny test Kruskalla-Wallisa.

Analizę wariancji lub test Kruskalla-Wallisa przeprowadzamy niezależnie dla każdej cechy sygnału c_j ; $j = 1, 2, \dots, m$, a rozpoczynamy od umieszczenia wartości tej cechy w tabeli 5.1.

Korzystając z tabeli 5.1 i traktując poszczególne jej kolumny jak grupy, w przypadku analizy wariancji wyznaczamy statystykę testową F Snedecora i weryfikujemy hipotezę zerową o równości grup [4, 27, 29, 48, 67, 83]. W przypadku testu Kruskalla-Wallisa wyznaczamy rangi, wyznaczamy statystykę testową T oraz podobnie jak dla analizy wariancji przeprowadzamy weryfikację hipotezy zerowej o równości grup [48, 53, 56].

W każdej z tych metod odrzucenie hipotezy zerowej oznacza, iż rozpatrywana cecha sygnału c_j zawiera informację pozwalającą odróżnić od siebie stany należące do przynajmniej dwóch, spośród wszystkich klas stanu. Oznacza to także, że informacja taka może być niewystarczająca do poprawnego zaklasyfikowania dowolnego, rozpatrywanego stanu.

Tab. 5.1. Wartości j -tej cechy sygnału.

Nr próby	Klasy stanu			
	B_0	B_1	...	B_N
1	$w_0^{j,1}$	$w_1^{j,1}$...	$w_N^{j,1}$
2	$w_0^{j,2}$	$w_1^{j,2}$...	$w_N^{j,2}$
...
n_i	w_0^{j,n_i}	w_1^{j,n_i}	...	w_N^{j,n_i}
Liczba obserwacji n_i	n_0	n_1	...	n_N

Przyjęcie hipotezy zerowej oznacza małą przydatność rozpatrywanej cechy do celów diagnostyki. Cechę taką można pominąć ponieważ nie wnosi ona żadnych istotnych informacji o jakimkolwiek stanie badanego obiektu lub modelu.

Drugim etapem analizy zmienności wartości cech sygnałów są porównania wielokrotne średnich w grupach oraz procedury testowe Bonferroniego lub Tukeya-Scheffègo [4, 27, 29, 48, 67], w wyniku których ustalane są przedziały ufności. Nieparametrycznym odpowiednikiem tych testów są porównania wielokrotne rozkładów wartości cech poszczególnych par grup za pomocą testów Kruskalla-Wallisa lub za pomocą rangowego odpowiednika testu F Friedmana [48, 53, 56].

Wynikiem porównań wielokrotnych jest informacja o tym, czy różnice pomiędzy poszczególnymi parami grup (zbiorami wartości cech sygnałów) są na tyle duże, że można powiedzieć, iż grupy te są rozdzielne. Informacja ta jest zawarta w przedziałach ufności określonych niezależnie dla każdej pary grup (pary klas stanu):

$$\langle \Delta w_{i,k}^{-j}, \Delta w_{i,k}^{+j} \rangle; \quad i, k = 0, 1, 2, \dots, N; \quad j = 1, 2, \dots, m. \quad (5.29)$$

Wspomniane przedziały ufności bez względu na przyjętą metodę ich wyznaczania wymagają określenia poziomu istotności α . Odnosi się to także do testów na równość grup. Zmieniając wartość poziomu istotności można tak sterować wartościami przedziałów, a pośrednio wartościami wrażliwości, aby cechy mniej przydatne w rozpoznaniu klas stanu charakteryzowały się wrażliwością mniejszą od maksymalnej. Algorytmy sel3 (rys. 5.6) oraz sel4 (rys. 5.7) opisujące takie rozwiązanie przedstawiono w rozdziale 5.3.7. Standardowo dla układów mechanicznych można przyjąć $\alpha = 0,001$.

5.3.3. Miary zmienności wartości cech sygnałów

W odróżnieniu od analizy wrażliwości opartej na różnicach między wartościami cech (rozdział 5.2) wyznaczonymi dla dowolnego stanu i stanu bazowego tutaj uwzględniamy różnice między wszystkimi kombinacjami grup wartości cech sygnałów.

Miary zmienności wartości cech sygnałów $V(W^j(B_i), W^j(B_k))$, które chcemy wyznaczyć zawierają informacje o tym jaki wpływ zmiany klas stanu wywierają na zmiany

cech sygnałów. Informację tą można zapisać w postaci jednej wartości. Można także zapisać ją za pomocą przedziału wartości, które wyznaczono w poprzednim podpunkcie:

$$\Delta w_{i,k}^j = \langle \Delta w_{i,k}^{-j}, \Delta w_{i,k}^{+j} \rangle; \quad i, k = 0, 1, 2, \dots, N; \quad j = 1, 2, \dots, m. \quad (5.30)$$

Tak określona miara zmienności wartości cech sygnałów opisuje zmiany cech sygnałów, jakie występują przy zmianie klasy stanu z B_i na inną, którą w tym przypadku jest B_k .

5.3.4. Wartość wrażliwości cząstkowej

Po określeniu miary zmienności, w kolejnym kroku dla każdej pary grup wyznaczamy wartość wrażliwości. Przyjęto, że będzie to wrażliwość cząstkowa:

$$s_{i,k}^j = \frac{V(W^j(B_i), W^j(B_k))}{V_{ref}(W^j(B_0), W^j(B_1), \dots, W^j(B_N))}; \quad B_0, B_1, \dots, B_N \in B; \quad k \neq i. \quad (5.31)$$

Oprócz wrażliwości cząstkowej wprowadzone zostaną także wrażliwość grupowa oraz wrażliwość całkowita.

Określając miarę zmienności $V(W^j(B_i), W^j(B_k))$ przyjęto założenie, iż w przypadku gdy dwie porównywane grupy wartości cech sygnałów będą istotnie między sobą się różniły, to jej bezwzględna maksymalna wartość będzie równa jedności. Znak tej wartości uzależniono od położenia przedziałów ufności $\Delta w_{i,k}^j$. W przypadku, gdy różnice między grupami wartości cech sygnałów byłyby zbyt małe, aby można je było jednoznacznie rozdzielić, wartości miary zmienności $V(W^j(B_i), W^j(B_k))$ przyjęto odpowiednio mniejsze.

We wzorze (5.31) na wartość wrażliwości $s_{i,k}^j$, jako wartość skalującą $V_{ref}(W^j(B_0), W^j(B_1), \dots, W^j(B_N))$ przyjęto maksymalną bezwzględną wartość, jaką może przyjmować miara zmienności $V(W^j(B_i), W^j(B_k))$. Będzie ona w przypadku wrażliwości cząstkowej równa jedności.

Uwzględniając powyższe założenia oraz bazując na miarach zmienności $\Delta w_{i,k}^j$, wartości wrażliwości cząstkowej wyznaczamy korzystając z zależności:

$$s_{i,k}^j = \begin{cases} 1, & \text{jeżeli: } \text{sign}(\Delta w_{i,k}^{-j}) = \text{sign}(\Delta w_{i,k}^{+j}) = 1; \\ -1, & \text{jeżeli: } \text{sign}(\Delta w_{i,k}^{-j}) = \text{sign}(\Delta w_{i,k}^{+j}) = -1; \\ \frac{\Delta w_{i,k}^{-j} + \Delta w_{i,k}^{+j}}{|\Delta w_{i,k}^{-j}| + |\Delta w_{i,k}^{+j}|}, & \text{jeżeli: } \text{sign}(\Delta w_{i,k}^{-j}) \neq \text{sign}(\Delta w_{i,k}^{+j}); \end{cases} \quad (5.32)$$

$$i = 0, 1, 2, \dots, N - 1; \quad k = i + 1, i + 2, \dots, N; \quad j = 1, 2, \dots, m.$$

Tak otrzymane wartości wpisujemy w macierz, której elementy diagonalne są zerowe:

$$S_{cz}^j = [s_{i,k}^j]_{(N+1) \times (N+1)}; \quad s_{k,i}^j = -s_{i,k}^j; \quad s_{i,i}^j = 0. \quad (5.33)$$

5.3.5. Wartość wrażliwości grupowej

Wyznaczone wartości wrażliwości cząstkowej $s_{i,k}^j$ zawierają informacje o tym, czy dana j -ta cecha sygnału umożliwi rozróżnienie dwóch rozpatrywanych klas stanu (i oraz k). Chcąc określić w jakim stopniu j -ta cecha sygnału pozwala odróżnić i -tą klasę stanu od pozostałych N klas stanu wprowadzamy wrażliwość grupową:

$$s_i^j = \frac{\sum_k V(W^j(B_i), W^j(B_k))}{V_{ref}(W^j(B_0), W^j(B_1), \dots, W^j(B_N))}; \quad B_0, B_1, \dots, B_N \in B; \quad (5.34)$$

$$k = 0, 1, \dots, i-1, i+1, \dots, N.$$

Miary zmienności $V(W^j(B_i), W^j(B_k))$, podobnie jak w przypadku wrażliwości cząstkowej, określamy na podstawie porównań par grup wartości cech sygnałów.

Jako wartość skalującą $V_{ref}(W^j(B_0), W^j(B_1), \dots, W^j(B_N))$ przyjęto maksymalną sumaryczną wartość miar zmienności $\sum_k V(W^j(B_i), W^j(B_k))$. W przypadku wrażliwości grupowej jest ona równa N .

Ostatecznie, po uwzględnieniu miar zmienności oraz wartości skalującej, wartość wrażliwości grupowej wyznaczana jest za pomocą następującej zależności:

$$s_i^j = \frac{\sum_k |s_{i,k}^j|}{N}; \quad j = 1, 2, \dots, m; \quad (5.35)$$

$$i = 0, 1, 2, \dots, N; \quad k = 0, 1, \dots, i-1, i+1, \dots, N.$$

Wartości te można wpisać w $N + 1$ elementowe macierze wierszowe:

$$S_{gr}^j = [s_i^j]_{1 \times (N+1)}. \quad (5.36)$$

5.3.6. Wartość wrażliwości głównej

Określenie wartości wrażliwości (głównej) jest podstawowym celem podejmowanych we wcześniejszych podpunktach działań. Za jej pomocą można określić to, które cechy sygnałów zawierają największą ilość informacji o interesujących nas klasach stanu B_0, B_1, \dots, B_N .

Podobnie jak poprzednio wartość wrażliwości wyznaczamy określając miary zmienności $V(W^j(B_i), W^j(B_k))$ oraz korzystając z zależności:

$$s^j = \frac{\sum_i \sum_k V(W^j(B_i), W^j(B_k))}{V_{ref}(W^j(B_0), W^j(B_1), \dots, W^j(B_N))}; \quad B_0, B_1, \dots, B_N \in B; \quad (5.37)$$

$$i = 0, 1, 2, \dots, N; \quad k = 0, 1, \dots, i-1, i+1, \dots, N.$$

Sumaryczną miarę zmienności $\sum_i \sum_k V(W^j(B_i), W^j(B_k))$ wyznaczamy korzystając z informacji o przedziałach ufności wyznaczonych dla wszystkich par grup wartości j -tej cechy sygnału. Miara ta określa zatem, jak bardzo grupy cech sygnałów odpowiadające poszczególnym klasom stanu są zróżnicowane.

Wartość skalująca $V_{ref}(W^j(B_0), W^j(B_1), \dots, W^j(B_N))$ podobnie jak w przypadku wrażliwości cząstkowej i grupowej jest równa maksymalnej wartości sumy miar zmienności $\sum_i \sum_k V(W^j(B_i), W^j(B_k))$, która w tym przypadku wynosi $N(N+1)$.

Ostatecznie wartość wrażliwości wyznaczamy korzystając z zależności:

$$S^j = s^j = \frac{\sum_i \sum_k |s_{i,k}^j|}{N(N+1)} = \frac{\sum_i |s_i^j|}{N+1}; \quad j = 1, 2, \dots, m; \quad (5.38)$$

$$i = 0, 1, 2, \dots, N; \quad k = 0, 1, \dots, i-1, i+1, \dots, N.$$

Wyznaczone maksymalne wartości wrażliwości S^j ; $j = 1, 2, \dots, m$ wskazują cechy sygnałów, których zmiany wynikające ze zmiany klasy stanu są największe. Cechy te oprócz największej wartości wrażliwości mogą charakteryzować się tym, że będą skorelowane z innymi, posiadającymi również dużą wrażliwość cechami.

5.3.7. Selekcja wrażliwych cech sygnałów

Bazując na wyznaczonych wartościach wrażliwości głównej S^j oraz grupowej S_i^j możemy zająć się poszukiwaniami cech sygnałów, które niosą najwięcej informacji o stanie badanego obiektu lub modelu. Uwzględnić należy tutaj fakt, iż dwie lub większa liczba skorelowanych ze sobą cech sygnałów z dużym prawdopodobieństwem wnosi tyle samo informacji o klasie stanu co jedna z tych cech rozpatrywana z osobna.

Algorytmy mające służyć takim poszukiwaniom powinny uwzględniać wymienione poniżej założenia:

1. Wybierane cechy sygnałów powinny charakteryzować się możliwie jak największą wrażliwością główną.
2. Wartości wybranej cechy sygnału, pomocnej w rozpoznaniu jednej lub kilku klas stanu, nie powinny być skorelowane z wartościami, wybieranych po niej, cech sygnałów.
3. Jeżeli wartości rozpatrywanej cechy sygnału są skorelowane z wartościami wcześniej wybranych cech, to cechę tą odrzucamy unikając tym samym redundancji informacji.
4. Jeżeli wartość wrażliwości cząstkowej dla jednej z grup przy maksymalnej przyjętej wartości α (np.: $\alpha = 0,05$), dla wszystkich rozpatrywanych cech sygnałów jest mniejsza od jedności, to klasa stanu odpowiadająca tej grupie może zostać uznana jako trudna do rozróżnienia za pomocą rozpatrywanego zbioru cech sygnałów.

Uwzględniając powyższe zalecenia zaproponowano algorytmy sel3 (rys. 5.6) oraz sel4 (rys. 5.7) służące do selekcji wrażliwych cech sygnałów. Algorytmy te oprócz umożliwienia nam wyboru najbardziej interesujących ze względów diagnostycznych cech, pozwalają odrzucić te cechy, które nie zawierają żadnej istotnej informacji o rozpatrywanych klasach stanu. Odrzucane są także cechy sygnałów zawierające informacje pokrywające się z informacją zawartą we wcześniej wybranych cechach.

W algorytmie sel4 (rys. 5.7) brany pod uwagę jest współczynnik korelacji rangowej. Może to być współczynnik korelacji Spearmana lub współczynnik τ Kendalla.

1. Zakładamy poziom istotności $\alpha = 0,05$.
2. Wyznaczamy wartości wrażliwości S^j ; $j = 1, 2, \dots, m$.
3. Jeżeli $\max_j(S^j) = 1$ to zmniejszamy wartość α o około 50% i powracamy do punktu 2. W przeciwnym przypadku:
 - (a) Jeżeli wartość $\alpha = 0,05$ i wartości wrażliwości cząstkowej S_y^j wyznaczone dla jednej z grup odpowiadającej klasie stanu B_y , dla wszystkich rozpatrywanych cech sygnałów c^j ; $j = 0, 1, 2, \dots, m$, jest mniejsza od jedności:

$$\max_j S_y^j < 1; \quad j = 0, 1, 2, \dots, m, \quad (5.39)$$
 to klasę stanu B_y uznajemy za trudną do rozróżnienia za pomocą dostępnego zbioru cech sygnałów.
 - (b) Przechodzimy dalej.
4. Dla kolejnych klas stanu B_i :
 - (a) Wybieramy cechę sygnału c^x , dla której wartość wrażliwości S_i^j jest największa $S_i^x = \max_j(S_i^j)$.
 - (b) Ze zbioru cech sygnałów c usuwany wybraną cechę c^x .
 - (c) Jeżeli wybrano wystarczającą liczbę cech (np. dwie cechy na każdą klasę stanu) dla rozpatrywanej klasy stanu B_i to przechodzimy dalej. W przeciwnym przypadku przechodzimy do punktu 4a.
5. Jeżeli wybrano cechy dla wszystkich klas stanu to kończymy algorytm. W przeciwnym przypadku przechodzimy do punktu 4.

Rys. 5.6. Algorytm sel3 wyboru cech wrażliwych.

5.3.8. Podsumowanie

Wyznaczenie wartości wrażliwości oraz selekcja cech sygnałów za pomocą zaproponowanego algorytmu sel3 może ułatwić budowę modeli diagnostycznych poprzez rozwiązanie szeregu zadań związanych między innymi z:

- Wyborem cech, charakteryzujących się największą wrażliwością główną, których wartości wyznaczone dla poszczególnych klasy stanu istotnie się między sobą różnią.
- Wyborem cech, charakteryzujących się największą wrażliwością grupową, których wartości wyznaczone dla jednej z klasy stanu istotnie różnią się od wartości wyznaczonych dla pozostałych klas stanu.

1. Zakładamy poziom istotności $\alpha = 0,05$.
2. Wyznaczamy wartości wrażliwości S^j ; $j = 1, 2, \dots, m$.
3. Jeżeli $\max_j(S^j) = 1$ to zmniejszamy wartość α o około 50% i powracamy do punktu 2. W przeciwnym przypadku:

(a) Jeżeli wartość $\alpha = 0,05$ i wartości wrażliwości cząstkowej S_y^j wyznaczone dla jednej z grup, odpowiadającej klasie stanu B_y , dla wszystkich rozpatrywanych cech sygnałów c^j ; $j = 0, 1, 2, \dots, m$, jest mniejsza od jedności:

$$\max_j S_y^j < 1; \quad j = 0, 1, 2, \dots, m, \quad (5.40)$$

to klasę stanu B_y uznajemy za trudną do rozróżnienia za pomocą dostępnego zbioru cech sygnałów.

(b) Przechodzimy dalej.

4. Wybieramy cechę sygnału c^x , dla której wartość wrażliwości S^j jest największa $S^x = \max_j(S^j)$.
5. Ze zbioru cech sygnałów c usuwany cechy, których wartości wrażliwości grupowej są skorelowane z wartościami wrażliwości grupowej wybranej w poprzednim punkcie cechy sygnału. Innymi słowy spełniony jest warunek:

$$\text{współczynnik_korelacji_rangowej}(S_i^x, S_i^j) = 1; \quad i = 0, 1, 2, \dots, N \quad (5.41)$$

6. Jeżeli wybrano wystarczającą liczbę cech sygnałów kończymy działanie. W przeciwnym przypadku powracamy do punktu 4.

Rys. 5.7. Algorytm sel4 wyboru cech wrażliwych.

- Wskazaniem klas stanu, których rozróżnienie za pomocą rozpatrywanych cech sygnałów jest trudne lub wręcz niemożliwe.
- Odrzuceniem cech sygnałów skorelowanych z innymi charakteryzującymi się większą wrażliwością cechami, których uwzględnienie nie wnosiłoby żadnych nowych informacji o klasach stanu.

Rozdział 6

Przykład zastosowania statystycznej metody badania wrażliwości – dane symulacyjne

Najlepszym sposobem weryfikacji opracowanej metody badania wrażliwości jest jej zastosowanie w praktyce. Aby to było możliwe potrzebne są dane symulacyjne lub dane otrzymane z badań rzeczywistego obiektu technicznego. Posiadając takie dane można zbudować model diagnostyczny. Można to zrobić na dwa sposoby:


1. Ograniczając najpierw zbiór cech sygnałów za pomocą analizy wrażliwości, a następnie stosując wybrane, wrażliwe cechy do budowy modelu diagnostycznego (rys. 5.3).
2. Budując model diagnostyczny na podstawie całego, dostępnego zbioru cech sygnałów (rys. 5.2).

Teoretycznie modele diagnostyczne posiadające większą liczbę wejść (punkt 2), a zatem posiadające więcej parametrów powinny charakteryzować się lepszą sprawnością, częściej klasyfikując poprawnie stan obiektu lub modelu. W praktyce tylko część cech może zawierać istotne dla celów diagnostycznych informacje, zaś pozostałe cechy, nie zawierając żadnych ważnych informacji, mogą wprowadzać do modelu diagnostycznego jedynie szum. Czy tak jest w istocie i czy ograniczenie liczby cech nie pogorszy jakości budowanych modeli diagnostycznych można się przekonać dokonując porównań wyników klasyfikacji przeprowadzonych za pomocą tych modeli.

Weryfikację przydatności opracowanej metody badania wrażliwości rozpoczynamy od badań na danych symulacyjnych.

6.1. Model rzeczywistego obiektu technicznego

W ramach prac prowadzonych w IMP PAN powstał model numeryczny [2, 40–44, 55, 70, 92] turbozespołu 13K215 (rys. 6.1). Uwzględnia on wzajemnie, sprzężone wymuszenia aerodynamiczne, mechaniczne oraz elektryczne, jakie w takim obiekcie występują.



Rys. 6.1. Schemat turbosespołu 13K215 [44].

Wchodzące w skład modelu numerycznego oprogramowanie umożliwia [44]:

- wyznaczenie temperatury oleju w poszczególnych łożyskach, w oparciu o ich diatermiczny model (program KINWIN-60);
- analizę zagadnień kinetostatyki wielopodporowych i wielomasowych wirników opartą na izotermicznym modelu łożyska (program KINWIN-I-LEW);
- analizę zagadnień kinetostatyki wielopodporowych i wielomasowych wirników opartą na koncepcji quasi diatermicznego modelu łożyska (kombinacja programów KINWIN-60 oraz KINWIN-I-LEW);
- obliczenia nieliniowych, sprzężonych form drgań giętno-wzdłużno-skrętnych z imperfekcjami typu pęknięcia wału i rozosiowania elementów z możliwością wprowadzania dodatkowych obciążeń takich jak siły: poprzeczne, wzdłużne oraz momenty skrętne, oraz z możliwością: badania imperfekcji typu przekoszenia panwi, uwzględnienia kieszeni lewarowych i zmian ciśnienia lewarowego (program NLDW-LEW-75);
- obliczenia nieliniowych, sprzężonych form drgań giętno-wzdłużno-skrętnych z uwzględnieniem quasi diatermicznego łożyska (kombinacja programów KINWIN-60, KINWIN-I-LEW oraz NLDW-LEW-75).

Dostrojenie modelu numerycznego do modelowanego turbosespołu przeprowadzono na podstawie danych zarejestrowanych przez system diagnostyczny DT200 [13], co opisano w [44]. Wynikiem tego było określenie wektora stanu dla tzw. „przypadku bazowego”. Uzyskane dla tego przypadku wyniki teoretyczne okazały się na tyle podobne do wyników eksploatacyjnych, że model numeryczny można było uznać za odpowiedni do celów symulacji defektów oraz do budowy modeli diagnostycznych.

6.2. Klasy stanu

Udostępnione przez IMP PAN dane zawierają wyniki obliczeń symulacyjnych przeprowadzonych dla:

- stanu bazowego [44] – jeden stan;
- przekoszeń panwi [55] – 28 stanów związanych z 2-oma różnymi kątami przekoszenia, 2-oma płaszczyznami oraz 7-mioma łożyskami, w których to przekoszenie wystąpiło;
- przemieszczeń pojedynczych podpór [70] – 56 stanów związanych z 2-oma różnymi wartościami przemieszczeń 7-miu podpór, w 4-ech różnych kierunkach;
- przemieszczeń par podpór [70] – 32 stany związane jednoczesnymi przemieszczeniami podpór nr 5 oraz nr 6 w 4-ech różnych kierunkach;
- pęknięć wału [2] – 96 stanów związanych z pęknięciami w 2-óch różnych punktach dla 4-rech przypadków obwodowego umiejscowienia pęknięć oraz 12-tu wartości ich głębokości.

Spośród opisanego zbioru dostępnych stanów, do celów weryfikacji statystycznej metody badania wrażliwości, wybrano stany związane z niesprawnościami występującymi w poszczególnych podporach łożyskowych. Postanowiono przy tym odrzucić stany związane z wystąpieniem więcej niż jednej niesprawności jednocześnie. Dodatkowo, ponieważ jednym z podstawowych zadań każdego systemu diagnostycznego jest odróżnienie stanu utożsamianego z poprawnym działaniem badanego obiektu od dowolnego innego stanu, w badaniach uwzględniono stan bazowy. Ostatecznie stany brane pod uwagę w badaniach to:

- stan bazowy;
- przekoszenia panwi;
- przemieszczenia pojedynczych podpór.

Chcąc na podstawie dostępnych danych zbudować model diagnostyczny (rys. 5.3, 5.2) stany te pogrupowano i wyodrębniono 8 klas stanu mając na uwadze lokalizację przekoszeń łożysk oraz przemieszczeń podpór:

B_0 : stan bazowy;

B_1 : przekoszenie łożyska lub przemieszczenie w podporze nr 1;

B_2 : przekoszenie łożyska lub przemieszczenie w podporze nr 2;

... ;

B_7 : przekoszenie łożyska lub przemieszczenie w podporze nr 7.

Klasę stanu bazowego B_0 reprezentuje jeden stan. Każda z pozostałych klas stanu B_i ; $i = 1, 2, \dots, 7$ reprezentowana jest przez stany związane z:

- dwoma różnymi wartościami przemieszczeń i -tej podpory, w czterech różnych kierunkach (8 stanów dla każdej z klas B_i);

- dwoma różnymi kątami przekoszenia i -tego łożyska w dwóch różnych płaszczyznach (4 stany dla każdej z klas B_i).

Daje to w sumie 12 stanów dla każdej z klas stanu B_i ; $i = 1, 2, \dots, 7$:

- $B_0 = \{b_{0.1}\}$;
- $B_1 = \{b_{1.1}, b_{1.2}, \dots, b_{1.12}\}$;
- $B_2 = \{b_{2.1}, b_{2.2}, \dots, b_{2.12}\}$;
- ... ;
- $B_7 = \{b_{7.1}, b_{7.2}, \dots, b_{7.12}\}$.

Klasy te tworzą zbiór klas stanu $B = \{B_0, B_1, \dots, B_7\}$.

6.3. Cechy sygnałów

Z zestawu wyników obliczeń udostępnionych przez IMP PAN do badań wybrano sygnały przemieszczeń czopów względem panwi. Postąpiono tak ze względu na to, iż fizyczne przeprowadzanie takich pomiarów nie nastrocza większych trudności. Mając to na uwadze, dla każdego stanu rozpatujemy 14 sygnałów, które zarejestrowano w 7-miu punktach pomiarowych (podporach) dla kierunków przemieszczeń zgodnych z kierunkami osi x oraz y .

Wszystkie sygnały próbkowane są co $1/144$ obrotu wału, w czasie 12 kolejnych obrotów. Daje to w sumie $12 \times 144 + 1 = 1729$ dyskretnych wartości na sygnał. Przy stałej prędkości obrotowej $3000[\text{obr}/\text{min}]$ (częstotliwości próbkowania $7200[\text{Hz}]$) czas realizacji tych sygnałów wynosi $0,24[\text{s}]$.

Celem badań jest sprawdzenie przydatności metody badania wrażliwości, w wyborze cech sygnałów niosących najwięcej informacji istotnych ze względów diagnostycznych. Wymagane do wykonania tego zadania cechy można wyznaczyć korzystając z opisanych wcześniej sygnałów. Zrobiono to otrzymując dla każdego węzła łożyskowego 75 następujących punktowych cech sygnałów [12]:

1. Cechy wyznaczone na podstawie sygnałów przemieszczeń względnych w kierunku osi x , osi y oraz cechy wyznaczone dla trajektorii centralnej r :
 - wartość średnia absolutna: $x_{AVE}, y_{AVE}, r_{AVE}$;
 - wartość skuteczna: $x_{RMS}, y_{RMS}, r_{RMS}$;
 - wartość szczytowa absolutna: $x_{PEAK}, y_{PEAK}, r_{PEAK}$;
 - wartość szczytowa dodatnia: $x_{PEAK+}, y_{PEAK+}, r_{PEAK+}$;
 - wartość szczytowa ujemna: $x_{PEAK-}, y_{PEAK-}, r_{PEAK-}$;
 - wartość międzyszczytowa: $x_{P-P}, y_{P-P}, r_{P-P}$;
 - współczynnik kształtu: K_x, K_y, K_r ;
 - współczynnik szczytu: C_x, C_y, C_r ;

- współczynnik impulsowości: I_x, I_y, I_r ;
 - kurtoza: Ku_x, Ku_y, Ku_r ;
 - współczynnik asymetrii (skośność): S_x, S_y, S_r ;
 - składowa widma amplitudowego o częstotliwości 0,25X: $a_x^{0.25}, a_y^{0.25}, a_r^{0.25}$;
 - składowa widma amplitudowego o częstotliwości 0,33X: $a_x^{0.33}, a_y^{0.33}, a_r^{0.33}$;
 - składowa widma amplitudowego o częstotliwości 0,5X: $a_x^{0.5}, a_y^{0.5}, a_r^{0.5}$;
 - składowa widma amplitudowego o częstotliwości 1X: a_x^1, a_y^1, a_r^1 ;
 - składowa widma amplitudowego o częstotliwości 2X: a_x^2, a_y^2, a_r^2 ;
 - składowa widma amplitudowego o częstotliwości 3X: a_x^3, a_y^3, a_r^3 ;
 - składowa widma amplitudowego o częstotliwości 4X: a_x^4, a_y^4, a_r^4 ;
 - składowa widma amplitudowego wiru olejowego w zakresie częstotliwości $0,38 \div 0,46X$: $a_x^{0.42}, a_y^{0.42}, a_r^{0.42}$;
 - faza składowej widma amplitudowego o częstotliwości 1X: $\varphi_x^1, \varphi_y^1, \varphi_r^1$;
 - faza składowej widma amplitudowego o częstotliwości 2X: $\varphi_x^2, \varphi_y^2, \varphi_r^2$;
 - faza składowej widma amplitudowego o częstotliwości 3X: $\varphi_x^3, \varphi_y^3, \varphi_r^3$;
 - faza składowej widma amplitudowego o częstotliwości 4X: $\varphi_x^4, \varphi_y^4, \varphi_r^4$.
2. Dodatkowe cechy punktowe wyznaczone dla trajektorii centralnej r :
 - maksymalne promieniowe przemieszczenie wału: S_{\max} ;
 - maksymalna podwójna amplituda promieniowych drgań względnych: S_{P-P}^{\max} .
 3. Cechy punktowe wyznaczone dla trajektorii niecentralnej r_n :
 - promień środka trajektorii liczony w układzie biegunowym: r_0 ;
 - kąt obrotu promienia r_0 środka trajektorii: φ_0 .
 4. Cechy wzajemne przemieszczeń w kierunku osi x oraz osi y :
 - stopień okresowości trajektorii: $ReRzz$;
 - okres trajektorii: T_1 .

Podobnie jak zbiór klas stanu definiujemy zbiór cech sygnałów $c = \{c_1, c_2, \dots, c_m\}$. Jeżeli uwzględnić cechy wyznaczone dla wszystkich podpór zawiera on łącznie $m = 525$ różnych cech.

Przykładową nazwą $\text{nam}(c_j)$ cechy sygnału c_j jest „wartość skuteczna sygnału przemieszczeń względnych podpory nr 1 w kierunku osi x' ”. W nazwie tej cechy zawarta jest informacja pozwalająca określić zarówno sposób jej wyznaczenia jak i miejsce oraz sposób rejestracji sygnału, na podstawie którego cecha ta została wyznaczona.

Mając określone klasy stanu B_i ; $i = 0, 1, 2, \dots, 7$ oraz zbiór cech sygnałów c , dla każdego stanu wyznaczamy wartości $w_i^{j,k}$ kolejnych cech sygnałów c_j ; $j = 1, 2, \dots, m$:

$$w_i^{j,k} = c_j(b_{i,k}); \quad i = 0, 1, 2, \dots, 7; \quad j = 1, 2, \dots, m; \quad k = 1, 2, \dots, n_i, \quad (6.1)$$

gdzie: n_i jest liczbą stanów reprezentujących i -tą klasę stanu.

Wyznaczone wartości zapisujemy w formie wierszowych lub kolumnowych n_i elementów macierzy:

$$w_i^j = c_j(B_i) = [w_i^{j,1} \quad w_i^{j,2} \quad \dots \quad w_i^{j,n_i}]^T; \quad i = 0, 1, 2, \dots, 7; \quad j = 1, 2, \dots, m. \quad (6.2)$$

Otrzymane macierze z wartościami cech sygnałów następnie porządkujemy według wyznaczanych cech sygnałów:

$$W^j = [c_j(B_0) \quad c_j(B_1) \quad \dots \quad c_j(B_7)]; \quad j = 1, 2, \dots, m. \quad (6.3)$$

Informacje o grupach wartości cech sygnałów W^j ; $j = 1, 2, \dots, m$, tworzących zbiór wszystkich wyznaczanych wartości cech:

$$W = \{W^1, W^2, \dots, W^m\}; \quad W^j = \{w_0^j, w_1^j, w_2^j, \dots, w_7^j\}, \quad (6.4)$$

wraz z informacją o klasach stanu:

$$B = \{B_0, B_1, B_2, \dots, B_7\}, \quad (6.5)$$

pozwalają zidentyfikować model diagnostyczny. Można to zrobić przeprowadzając najpierw analizę wrażliwości (rys. 5.3) lub wykorzystując do tego celu wszystkie wyznaczone cechy (rys. 5.2).

6.4. Przykład zastosowania analizy wrażliwości

Badanie wrażliwości rozpoczynamy od określenia zbioru klas stanu oraz zbioru cech sygnałów. Zbiór klas stanu zgodnie z przyjętym we wstępie tego rozdziału założeniem zawiera 8 klas:

$$B = \{B_0, B_1, B_2, \dots, B_7\}. \quad (6.6)$$

Zbiór cech sygnałów obejmuje cechy związane z sygnałami przemieszczeń czopa względem panwi ($m = 525$ cechy):

$$W = \{W^1, W^2, \dots, W^m\}; \quad W^j = \{w_0^j, w_1^j, w_2^j, \dots, w_7^j\}. \quad (6.7)$$

Wymaganą do testów statystycznych wartość α przyjęto na poziomie $\alpha = 0,3\%$.

Mając dane zbiory cech sygnałów i klas stanu przeprowadzamy testy Kruskalla-Wallisa oraz wyznaczamy wrażliwości cząstkowe, grupowe, a także główne. Robimy to niezależnie dla każdej cechy sygnału c_j ; $j = 1, 2, \dots, m$, a rozpoczynamy od umieszczenia wartości rozpatrywanej j -tej cechy w tabeli 6.1.

Cechą wybraną do zobrazowania toku postępowania przy wyznaczaniu wrażliwości jest: „wartość średnia absolutna sygnału przemieszczeń względnych czopa mierzonego w kierunku osi x na podporze nr 1' ($x_{AVE}(1)$).

Tab. 6.1. Wartości cechy $x_{AVE}(1) \times 10^{-6}[\text{m}]$.

Nr próby	Klasy stanu							
	B_0	B_1	B_2	B_3	B_4	B_5	B_6	B_7
1	24,16	22,92	24,36	23,80	24,29	24,49	24,15	24,46
2		43,13	24,62	21,98	24,34	25,00	23,87	24,92
3		24,44	22,33	24,33	24,16	24,14	24,50	24,13
4		24,98	33,73	24,43	23,27	23,92	25,00	23,78
5		8,94	9,34	21,78	20,60	24,74	22,89	25,34
6		0,27	10,70	13,40	14,55	24,15	19,10	26,84
7		9,80	11,07	17,88	22,83	23,04	24,90	22,80
8		6,98	0,29	9,79	17,97	18,36	24,55	21,58
9		11,32	14,25	20,52	23,50	23,68	24,48	24,78
10		16,76	11,34	22,83	23,82	23,75	23,94	24,00
11		11,32	14,25	20,52	23,50	23,20	24,48	24,78
12		16,76	16,31	22,83	23,82	23,75	23,94	24,00
Liczba obserwacji n_i	$n_0 = 1$	$n_1 = 12$	$n_2 = 12$	$n_3 = 12$	$n_4 = 12$	$n_5 = 12$	$n_6 = 12$	$n_7 = 12$

Tab. 6.2. Przedziały ufności dla rang cechy $x_{AVE}(1)$.

i	k	$\Delta w_{i,k}^{-1}$	$\Delta w_{i,k}^{+1}$
1	2	-68,1	129,6
1	3	-67,6	130,1
1	4	-71,9	125,7
1	5	-81,0	116,6
1	6	-91,0	106,6
1	7	-98,6	99,1
...
6	7	-46,3	31,1
6	8	-48,1	29,4
7	8	-40,5	37,0

Korzystając z tabeli 6.1 i traktując poszczególne jej kolumny jak grupy, wyznaczamy rangi, a następnie posługując się testem Kruskalla-Wallisa wyznaczamy statystykę testową T i przeprowadzamy weryfikację hipotezy zerowej o równości grup dla przyjętego poziomu istotności $\alpha = 0,3\%$.

Ze względu na otrzymaną za pomocą testu Kruskalla-Wallisa p -wartość równą $0,117\%$, mniejszą od $\alpha = 0,3\%$, hipoteza zerowa o równości grup zostaje odrzucona na korzyść hipotezy alternatywnej. Oznacza to, że celowe jest przeprowadzenie porównań wielokrotnych rozkładów wartości cech dla poszczególnych par grup. Tak jak poprzednio

porównania przeprowadzamy korzystając z testu Kruskala-Wallisa.

Wynikiem przeprowadzonych porównań wielokrotnych jest informacja o przedziałach ufności dla rozpatrywanej cechy $x_{AVE}(1)$ ($j=1$):

$$\langle \Delta w_{i,k}^{-j}, \Delta w_{i,k}^{+j} \rangle; \quad i, k = 0, 1, 2, \dots, 7. \quad (6.8)$$

Porównania te wykonujemy niezależnie dla każdej pary klas stanu (tab. 6.2).

Na podstawie wyznaczonych przedziałów zgodnie z równaniami (5.32) i (5.33) wyznaczamy macierz S_{cz}^1 z wartościami wrażliwości cząstkowej:

$$S_{cz}^1 = \begin{bmatrix} 0,000 & 0,311 & 0,316 & 0,272 & 0,180 & 0,079 & 0,003 & -0,015 \\ 0,311 & 0,000 & 0,013 & -0,099 & -0,333 & -0,591 & -0,787 & -0,832 \\ 0,316 & 0,013 & 0,000 & -0,112 & -0,346 & -0,604 & -0,800 & -0,845 \\ 0,272 & -0,099 & -0,112 & 0,000 & -0,234 & -0,492 & -0,688 & -0,733 \\ 0,180 & -0,333 & -0,346 & -0,234 & 0,000 & -0,258 & -0,453 & -0,499 \\ 0,079 & -0,591 & -0,604 & -0,492 & -0,258 & 0,000 & -0,196 & -0,241 \\ 0,003 & -0,787 & -0,800 & -0,688 & -0,453 & -0,196 & 0,000 & -0,045 \\ -0,015 & -0,832 & -0,845 & -0,733 & -0,499 & -0,241 & -0,045 & 0,000 \end{bmatrix}. \quad (6.9)$$

Wrażliwość grupową S_{gr}^1 wyznaczamy korzystając z zależności (5.35) i (5.36):

$$S_{gr}^1 = \begin{bmatrix} 0,168 & 0,424 & 0,434 & 0,376 & 0,329 & 0,352 & 0,424 & 0,458 \end{bmatrix}. \quad (6.10)$$

Wrażliwość główną S^1 szacujemy korzystając z zależności (5.38). Jest ona równa:

$$S^1 = 0,371. \quad (6.11)$$

W podobny sposób jak opisano powyżej wyznaczamy wartości wrażliwości grupowej S_{gr}^j oraz głównej S^j ; $j = 1, 2, \dots, m$ dla wszystkich rozpatrywanych cech. Na ich podstawie wybieramy po dwie cechy charakteryzujące się największą wrażliwością grupową dla każdej z 8-miu klas stanu. Zestawiono je w tabeli 6.3.

Tab. 6.3. Wybrane cechy sygnałów.

L.p.	Cecha sygnału (nr podpory)	Wrażliwość	L.p.	Cecha sygnału (nr podpory)	Wrażliwość
1	$r_{P-P}(2)$	0,454	9	$r_{P-P}(5)$	0,404
2	$\varphi_r^1(1)$	0,429	10	$a_x^{0,33}(7)$	0,398
3	$y_{PEAK+}(3)$	0,425	11	$a_y^3(7)$	0,391
4	$a_r^{0,5}(7)$	0,423	12	$K_x(4)$	0,387
5	$a_r^{0,42}(1)$	0,418	13	$ReRzz(2)$	0,380
6	$y_{PEAK-}(3)$	0,417	14	$Ku_x(4)$	0,373
7	$a_y^{0,33}(7)$	0,410	15	$a_r^{0,33}(3)$	0,359
8	$a_y^{0,25}(7)$	0,410	16	$\varphi_r^2(1)$	0,353

6.5. Testy jakości wybranych cech sygnałów

Analiza wrażliwości powinna pozwalać na wybór zbioru kilku lub kilkunastu cech sygnałów, zawierających większość istotnych informacji o aktualnej klasie stanu badanego obiektu. Aby odpowiedzieć na pytanie, czy tak jest w istocie, należy rozwiązać kilka problemów, związanych między innymi z:

- opracowaniem modelu diagnostycznego, na którego wejściach mogłyby być różna liczba cech sygnałów, wyznaczonych dla jednego ze stanów. Wyjściem takiego modelu byłby numer klasy stanu do którego zaklasyfikowano rozpatrywany stan;
- przeprowadzaniem klasyfikacji zarówno dla przypadku gdy uwzględniane są cechy wybrane za pomocą analizy wrażliwości, jak i dla przypadku, gdy taka analiza nie jest przeprowadzana;
- porównaniem wyników klasyfikacji stanów, przeprowadzonej za pomocą opracowanego modelu diagnostycznego, dla różnych zbiorów cech sygnałów.

6.5.1. Identyfikacja modelu diagnostycznego

Model diagnostyczny identyfikowany jest na podstawie zbioru danych uczących. W zbiorze tym wyróżniamy dane związane z wejściami (cechami sygnałów) oraz dane związane z jednym wyjściem (numerem klasy stanu).

Do budowy modelu diagnostycznego wybrano narzędzia bazujące na rozmytych sieciach neuronalnych. Przyczyną tego były:

- łatwość stosowania;
- odporność, w szerokim zakresie, na zmianę liczby wejść;
- odporność na różne zakresy wartości wejściowych i wyjściowych;
- możliwość sterowania stopniem szczegółowości reguł, który ma wpływ na umiejętności uogólniania wspomnianych sieci;
- możliwość interpretacji reguł rozmytych (przezroczystość modelu) [68].

Opracowanie modelu diagnostycznego przebiega kilkietapowo:

1. Najpierw określana jest optymalna liczba grup dla poszczególnych cech sygnałów. Narzędziem do tego służącym jest algorytm substraktywnej klasteryzacji opisany w [10, 11, 23, 25, 90, 104].
2. Następnie na podstawie informacji o liczbie grup budowane są reguły rozmyte [68, 104].
3. Na podstawie wyprowadzonych reguł określana jest struktura rozmytej sieci neuronalnej [52].
4. Po określeniu struktury, sieć poddawana jest uczeniu. Do celów uczenia sieci, a tym samym określenia parametrów dla reguł rozmytych, skorzystano z narzędzia ANFIS (od ang. Adaptive Neuro-Fuzzy Inference System) [46, 51, 68, 104].

Bezpośredni wpływ na szczegółowość zbioru reguł (liczbę reguł) mamy zmieniając wartość parametru r_a . Określa on promień wpływu potencjału poszczególnych punktów w algorytmie substraktywnej klasteryzacji.

Wartość parametru r_a , którą można zmieniać w zakresie od 0 do 1, powinna być jak najlepiej dopasowana do „jakości” danych. Dla danych zawierających informację silnie zaszumioną preferowana jest duża wartość, np.: $r_a = 0,7$. Dla danych zawierających duży ładunek niezniekształconych informacji preferowana jest mała wartość, np.: $r_a = 0,3$. Ze względu na to, iż z góry nie wiadomo z jakimi danymi mamy do czynienia, dobrym rozwiązaniem jest przeprowadzenie badań dla kilku różnych wartości tego parametru.

6.5.2. Sposób badania modelu diagnostycznego

Najlepszym sposobem sprawdzenia poprawności zaproponowanej metody badania wrażliwości jest porównanie wyników otrzymywanych w sytuacji, gdy:

A1: Do wyboru cech stosowana jest analiza wrażliwości diagnostycznej.

A2: Brane pod uwagę są wszystkie cechy.

W celu weryfikacji jakości wybieranych za pomocą, lub bez udziału, analizy wrażliwości cech sygnałów, przeprowadzono badania dla dwóch różnych strategii podziału zbioru danych na dane uczące i testujące:

B1: Zbiór danych uczących oraz zbiór danych testujących są równe dostępnemu zbiorowi danych. Otrzymywane dla tej strategii wyniki są najbardziej zbliżone do oczekiwanych.

B2: Metoda *leave one out*. Dla każdego przykładu ze zbioru danych powtarzane są następujące działania:

- rozpatrywany przykład ze zbioru danych umieszczany jest w zbiorze danych testujących;
- pozostałe przykłady ze zbioru danych umieszczane są w zbiorze uczącym;
- na podstawie danych uczących identyfikowany jest model diagnostyczny;
- model diagnostyczny weryfikowany jest za pomocą danych testujących.

Wyniki otrzymywane za pomocą tej metody są z zasady gorsze, niż te otrzymane za pomocą metody **B1**. W przypadku, gdy zbiór danych uczących nie zawiera przykładów obejmujących wystarczającego zakres przestrzeni wartości cech sygnałów (dane są „zbyt rzadkie”), to uzyskanie oczekiwanych wyników może okazać się niemożliwe. Jeżeli pomimo zastosowania metody *leave one out* wyniki testów modelu diagnostycznego są poprawne, to świadczy to o poprawności badanego modelu.

Zbiór danych, rozpatrywany w badaniach, obejmuje cechy wyznaczone dla 85 stanów (8 klas stanu). Daje to w sumie 85 (metoda **B1**) lub 84 (metoda **B2**) przykładów uczących. Ze względu na to ograniczenie, należy ustalić maksymalną liczbę wejść modelu diagnostycznego (uwzględnianych cech sygnałów). Jeżeli będzie ona zbyt duża, to liczba

parametrów rozmytej sieci neuronalnej może przekroczyć liczbę przykładów uczących. Spowoduje to błąd w trakcie uczenia tej sieci.

Zakładamy, że za pomocą analizy wrażliwości wybieranych będzie każdorazowo 16 (dwie cechy na każdą klasę stanu) najbardziej wrażliwych cech sygnałów. Tych cech może być oczywiście mniej, jeżeli liczba cech charakteryzujących się zmiennością na poziomie istotności mniejszym od $\alpha = 0,3\%$ będzie mniejsza.

Ostatecznie wielkość zbioru cech sygnałów poddawanego analizie wrażliwości, w celu późniejszej identyfikacji modelu diagnostycznego, nie będzie miała znaczenia. Mając to na uwadze zaproponowano następujące zbiory cech sygnałów:

- C1:** Wszystkie cechy związane z sygnałami przemieszczeń względnych wyznaczone dla wszystkich podpór – 525 cech.
- C2:** Podzbiór zbioru **C1** bez cech związanych z: kurtozą, współczynnikiem asymetrii, składowymi widma amplitudowego o częstotliwości 0,25X, 0,33X, 0,5X, wszystkimi fazami składowych widma amplitudowego oraz niektórymi cechami trajektorii (punkty 2-4 rozdz. 6.3) – 294 cechy.
- C3:** Podzbiór zbioru **C2** ograniczony do cech związanych z łożyskiem nr 6 – 42 cechy.
- C4:** Podzbiór zbioru **C3** ograniczony do cech związanych przemieszczeniami w kierunku osi x oraz osi y – 28 cech.
- C5:** Podzbiór zbioru **C4** ograniczony do cech związanych przemieszczeniami w kierunku osi x – 14 cech.

W przypadku, gdy nie jest przeprowadzana analiza wrażliwości (**A2**) brane pod uwagę mogą być tylko zbiory **C3**, **C4** oraz **C5** cech sygnałów. Postępowanie to jest uzasadnione wcześniej opisanym ograniczeniem maksymalnej liczby wejść modelu diagnostycznego, ze względu na liczbę przykładów uczących.

Ostatnim elementem mogącym mieć duży wpływ na wyniki badań, który należy uwzględnić, jest opisany wcześniej parametr r_a . Wprowadzono dla jego poszczególnych wartości następujące oznaczenia:

R0.3: $r_a = 0,3$;

R0.4: $r_a = 0,4$;

R0.5: $r_a = 0,5$;

R0.6: $r_a = 0,6$;

R0.7: $r_a = 0,7$.

W celu skrócenia opisów przeprowadzanych testów wprowadzono wieloznaczny znak zapytania „?” zastępujący liczby związane z poprzedzającymi je literami **A**, **B**, **C** oraz **R**. Pozwala to zakodować pełny opis jednego lub grupy testów w formie krótkiego ciągu znaków. Przykładowo wszystkie testy, w których przeprowadzona została analiza wrażliwości, kodujemy jako:

$$\mathbf{A1B?C?R?}. \quad (6.12)$$

6.5.3. Sposób opisu wyników badań

Wyniki przeprowadzonych testów umieszczono w tabelach (przykład tab. 6.4). Kolejne ich wiersze B_0, B_1, \dots, B_7 odpowiadają oczekiwanyim klasom stanu, natomiast kolumny B_0, B_1, \dots, B_7 odpowiadają klasom stanu określonym przy użyciu modelu diagnostycznego. Dla takiej reprezentacji wyników ideałem byłoby uzyskanie wartości maksymalnych dla pól (B_i, B_i) ; $i = 0, 1, \dots, 7$. Pozostałe pola powinny być puste. Taki, idealny wynik, świadczyłby o prawidłowej klasyfikacji wszystkich rozpatrywanych stanów.

Tab. 6.4. Przykładowe wyniki klasyfikacji.

		Oszacowane klasy stanu							Liczba stanów	Ocena nr 1	Ocena nr 2	
		B_0	B_1	B_2	B_3	B_4	B_5	B_6				B_7
Oczekiwane klasy stanu	B_0	0					1		1	0%	0%	
	B_1		2	3	6	1			12	16,7%	42,7%	
	B_2		2	3	6	1			12	25%	60,4%	
	B_3			1	8	2	1		12	66,7%	81,3%	
	B_4				4	5	3		12	41,7%	70,8%	
	B_5				1	2	5	3	1	12	41,7%	66,7%
	B_6				1	3	3	4	1	12	33,3%	57,3%
	B_7				2		2	4	4	12	33,3%	55,2%
		Ogółem							85	36,5%	61,3%	

W kolumnie „liczba stanów” umieszczono informacje o ilości stanów, dla których udało się zbudować poprawny model diagnostyczny oraz przeprowadzić testy. W przypadku strategii *leave one out* (**B2**), dla klas stanu B_1, B_2, \dots, B_7 liczba ta może być mniejsza od 12.

Mając na celu ułatwienie interpretacji wyników, do tabeli wprowadzono dwie kolumny z ocenami poprawności klasyfikacji. Pierwsza z tych ocen O_1 (ocena nr 1) obliczana jest według następującej zależności:

$$O_1(B_i) = \hat{n}_{i,i}/n_i; \quad i = 0, 1, \dots, 7, \quad (6.13)$$

gdzie: $O_1(B_i)$ – ocena poprawności klasyfikacji dla stanu B_i ;

n_i – liczba stanów w poszczególnych klasach;

$\hat{n}_{i,j}$ – liczba stanów należących do klasy B_i , które zaklasyfikowano stosując model diagnostyczny do klasy B_j ; $i, j = 0, 1, \dots, 7$.

Ogólna dla wszystkich stanów ocena nr 1 jest średnią ważoną ocen wyznaczonych dla poszczególnych stanów:

$$O_1(B) = \frac{\sum_i n_i \cdot O_1(B_i)}{n}; \quad n = \sum_i n_i; \quad i = 0, 1, \dots, 7. \quad (6.14)$$

Wprowadzając drugą ocenę O_2 (ocena nr 2) brano pod uwagę specyfikę diagnozowanego obiektu. Przyjęto mianowicie, iż błąd klasyfikacji będzie mniejszy, jeżeli np. stan

należący do klasy B_1 zaklasyfikowano do klasy B_2 , zamiast do klasy B_7 . Zgodnie z tym:

$$O_2(B_i) = \frac{\sum_j w_{i,j} \cdot \hat{n}_{i,j}}{n_i}; \quad i, j = 0, 1, \dots, 7, \quad (6.15)$$

gdzie: $w_{i,j}$ jest wagą zależną od odległości podpór, obliczaną według następującej zależności:

$$w_{i,j} = \begin{cases} 2^{-|i-j|}, & \text{jeżeli: } i, j > 0; \\ 1, & \text{jeżeli: } i, j = 0; \\ 0, & \text{jeżeli: } i \neq j \wedge i = 0; \\ 0, & \text{jeżeli: } i \neq j \wedge j = 0; \end{cases} \quad (6.16)$$

$$i, j = 0, 1, 2, \dots, 7.$$

Podobnie jak dla oceny nr 1, ogólną dla wszystkich stanów ocenę nr 2, wyznaczamy jako średnią ważoną posługując się równaniem:

$$O_2(B) = \frac{\sum_i n_i \cdot O_2(B_i)}{n}; \quad n = \sum_i n_i; \quad i = 0, 1, \dots, 7. \quad (6.17)$$

6.6. Omówienie wyników testów

Przyglądając się wynikom przeprowadzonych testów można na pierwszy rzut oka zauważyć pewne prawidłowości zgodne z oczekiwaniami:

1. Większy wejściowy zbiór cech pozwala uzyskać lepsze wyniki.
2. Niezależnie od tego, czy analiza wrażliwości jest stosowana, czy też brane pod uwagę są wszystkie cechy z wejściowego zbioru cech, to uzyskujemy podobne wyniki.

Najlepszym sposobem na potwierdzenie tych prawidłowości jest sprawdzenie hipotezy H_0 o równości średnich dla skorelowanych ze sobą danych. Średnie te byłyby wyznaczane z ocen uzyskanych w testach dla:

- analizy wrażliwości (**A1**) lub jej braku (**A2**);
- strategii zbiór uczący równy zbiorowi testującemu (**B1**) lub metody *leave one out* (**B2**);
- wybranego zbioru cech sygnałów (**C1, C2, C3, C4** lub **C5**);
- wszystkich wartości parametru r_a (**R0.3, R0.4, R0.5, R0.6** i **R0.7**).

Porównania średnich powinny być przeprowadzone dla skorelowanych danych, z tego względu, iż zmienne w parach obserwacji:

$$(\mathbf{A?B?C?R}_i, \mathbf{A?B?C?R}_i); \quad i = \{0.3, 0.4, \dots, 0.7\}, \quad (6.18)$$

są związane z poszczególnymi wartościami r_a .

W celu lepszego przedstawienia zależności pomiędzy uzyskanymi w testach wynikami pod tabelami podano p -wartości oszacowane na podstawie wyznaczonych statystyk T oraz rozkładu t Studenta.

6.6.1. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości

Omawiane w tym punkcie wyniki badań dotyczą testów, w którym zbiory danych uczących i testujących były identyczne (**B1**). Miały one zweryfikować istnienie różnic pomiędzy wynikami uzyskanymi dla przypadku, gdy do wyboru cech stosowana jest analiza wrażliwości (**A1**) oraz dla przypadku, gdy nie jest ona stosowana (**A2**). Możliwe były tutaj do przeprowadzenia trzy porównania dla zbiorów cech ograniczonych do jednej podpory (**C5**, **C4**, **C3**).

Jak można zauważyć między wynikami uzyskanymi dla zbiorów cech **C5** (tab. 6.5) oraz **C4** (tab. 6.6) nie ma żadnych istotnych różnic. Otrzymane p -wartości są wyraźnie większe od 0,05. Różnice te są natomiast istotne w przypadku zbioru cech **C3** (tab. 6.7), gdzie p -wartości dla ocen O_1 oraz O_2 są mniejsze od 0,006. Należy jednak mieć na uwadze to, iż szczególnie dla testów, dla których nie przeprowadzono analizy wrażliwości (**A2**), zbudowany model mógł zbyt dopasować się do danych. Potwierdza to fakt wystąpienia błędów, w 4-ech na 5 przypadkach (testy **A2B1C3R0.4**, **A2B1C3R0.5**, **A2B1C3R0.6**, **A2B1C3R0.7**, tab. 6.7), przy próbie uczenia rozmytej sieci neuronalnej. Pojawiły się one przy większych wartościach r_a , dla których generowanych jest mniejsza liczba reguł, a zatem model jest mniej dopasowany do danych.

Podsumowując można stwierdzić, że dla małych zbiorów cech (**C5**, **C4**), w przypadku, gdy zbiór danych uczących jest jednocześnie zbiorem danych testujących (**B1**), zastosowanie analizy wrażliwości nie wpływa znacząco na jakość uzyskiwanych wyników. Nie do pominięcia jest fakt pojawienia się błędów klasyfikacji stanów należących do klas B_4 , B_6 oraz B_7 (tab. 6.8). Zaklasyfikowano je, stosując zidentyfikowany model diagnostyczny, do klasy B_5 (tab. 6.8). Błędy w klasyfikacji pojawiły się także w przypadku stanów należących do klasy B_1 .

Tab. 6.5. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**.

R? (r_a)	Analiza wrażliwości A1B1C5R?				Brak analizy wrażliwości A2B1C5R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C5R0.3	85	25,9 %	52,9 %	A2B1C5R0.3	85	32,9 %	57,9 %
0,4	A1B1C5R0.4	85	27,1 %	55,4 %	A2B1C5R0.4	85	24,7 %	52,8 %
0,5	A1B1C5R0.5	85	27,1 %	53,8 %	A2B1C5R0.5	85	25,9 %	52,9 %
0,6	A1B1C5R0.6	85	23,5 %	51 %	A2B1C5R0.6	85	25,9 %	53,1 %
0,7	A1B1C5R0.7	85	24,7 %	51,2 %	A2B1C5R0.7	85	24,7 %	52,2 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,513

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,508

Tab. 6.6. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**.

R? (r_a)	Analiza wrażliwości A1B1C4R?				Brak analizy wrażliwości A2B1C4R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C4R0.3	85	29,4 %	55,5 %	A2B1C4R0.3	–	–	–
0,4	A1B1C4R0.4	85	25,9 %	52,5 %	A2B1C4R0.4	85	28,2 %	55,5 %
0,5	A1B1C4R0.5	85	25,9 %	53,1 %	A2B1C4R0.5	–	–	–
0,6	A1B1C4R0.6	–	–	–	A2B1C4R0.6	–	–	–
0,7	A1B1C4R0.7	85	22,4 %	49,4 %	A2B1C4R0.7	–	–	–

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,524

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,381

Tab. 6.7. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C3**.

R? (r_a)	Analiza wrażliwości A1B1C3R?				Brak analizy wrażliwości A2B1C3R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C3R0.3	85	28,2 %	55,4 %	A2B1C3R0.3	85	61,2 %	78,5 %
0,4	A1B1C3R0.4	85	24,7 %	52,8 %	A2B1C3R0.4	–	–	–
0,5	A1B1C3R0.5	85	24,7 %	52,6 %	A2B1C3R0.5	–	–	–
0,6	A1B1C3R0.6	–	–	–	A2B1C3R0.6	–	–	–
0,7	A1B1C3R0.7	–	–	–	A2B1C3R0.7	–	–	–

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00433

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00521

Tab. 6.8. Wyniki klasyfikacji uzyskane dla jednakowych zbiorów uczących i testujących, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C4** oraz $r_a = 0,3$ (**A1B1C4R0.3**).

		Oszacowane klasy stanu							Liczba stanów	Ocena nr 1	Ocena nr 2
		B_0	B_1	B_2	B_3	B_4	B_5	B_6			
Oczekiwane klasy stanu	B_0	0					1		1	0%	0%
	B_1		1	8	1		2		12	8,33%	44,8%
	B_2	1		8	1	2			12	66,7%	75%
	B_3			3	4	2	3		12	33,3%	60,4%
	B_4			1	2	2	7		12	16,7%	56,3%
	B_5				1	1	10		12	83,3%	89,6%
	B_6				1	1	10	0	12	0%	44,8%
	B_7				1	1	10		0	12	0%
		Ogółem							85	29,4%	55,5%

Otrzymane wyniki mogą świadczyć o tym, iż cechy sygnałów, zarejestrowane jedynie na jednej podporze, mogą zawierać informacje niewystarczające do prawidłowego rozpoznania wszystkich klas stanu. Pomimo błędów w klasyfikacji warto zauważyć, że stany w większości przypadków przypisywano klasom związanym z podporami znajdującymi się w pobliżu podpory, odpowiadającej klasie, do której stan ten powinien należeć.

Stan bazowy, należący do klasy B_0 dla żadnego testu nie został poprawnie zaklasyfikowany. Przyczyną tego może być to, że wspomniana klasa bazowa zawiera tylko jeden stan.

6.6.2. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech

Chcąc wykazać przydatność analizy wrażliwości w wyborze cech sygnałów przeprowadzono porównanie wyników testów, uzyskanych przy jej stosowaniu (**A1**), dla różnych zbiorów cech sygnałów (**C5**, **C4**, ..., **C1**). Testy przeprowadzono stosując identyczne dane uczące i testujące (**B1**).

Analizując uzyskane wyniki można stwierdzić, że poprawę jakości wyników otrzymano dopiero po uwzględnieniu cech pochodzących z więcej niż jednej podpory (**C2**, **C1**). Potwierdzają to otrzymane p -wartości, które w przypadku porównań wyników otrzymanych dla zbiorów cech **C5** i **C2** (tab. 6.11), są mniejsze od 0,05, a w przypadku zbioru cech **C5** i **C1** (tab. 6.12), są mniejsze od 0,01.

Uwzględniając wszystkie wyznaczone cechy dla przemieszczeń względnych (**C1**) najwyższe oceny uzyskano przy parametrze $r_a = 0,3$ (tab. 6.12, 6.13). Są one ($O_1 = 70,6\%$ oraz $O_2 = 83,1\%$) najlepszymi z uzyskanych ocen. Ze względu na stosowany sposób określania zbiorów danych uczących i testujących można niestety podejrzewać zbytne dopasowanie się modelu diagnostycznego do danych. Zweryfikowanie tego jest możliwe poprzez zastosowanie w testach metody *leave one out*.

Tab. 6.9. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4**, prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R?				Analiza wrażliwości A1B1C4R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C5R0.3	85	25,9 %	52,9 %	A1B1C4R0.3	85	29,4 %	55,5 %
0,4	A1B1C5R0.4	85	27,1 %	55,4 %	A1B1C4R0.4	85	25,9 %	52,5 %
0,5	A1B1C5R0.5	85	27,1 %	53,8 %	A1B1C4R0.5	85	25,9 %	53,1 %
0,6	A1B1C5R0.6	85	23,5 %	51 %	A1B1C4R0.6	–	–	–
0,7	A1B1C5R0.7	85	24,7 %	51,2 %	A1B1C4R0.7	85	22,4 %	49,4 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,876

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,875

Tab. 6.10. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3**, prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R?				Analiza wrażliwości A1B1C3R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C5R0.3	85	25,9 %	52,9 %	A1B1C3R0.3	85	28,2 %	55,4 %
0,4	A1B1C5R0.4	85	27,1 %	55,4 %	A1B1C3R0.4	85	24,7 %	52,8 %
0,5	A1B1C5R0.5	85	27,1 %	53,8 %	A1B1C3R0.5	85	24,7 %	52,6 %
0,6	A1B1C5R0.6	85	23,5 %	51 %	A1B1C3R0.6	–	–	–
0,7	A1B1C5R0.7	85	24,7 %	51,2 %	A1B1C3R0.7	–	–	–

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,875

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,584

Tab. 6.11. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2**, prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R?				Analiza wrażliwości A1B1C2R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C5R0.3	85	25,9 %	52,9 %	A1B1C2R0.3	85	43,5 %	67,8 %
0,4	A1B1C5R0.4	85	27,1 %	55,4 %	A1B1C2R0.4	85	31,8 %	59,2 %
0,5	A1B1C5R0.5	85	27,1 %	53,8 %	A1B1C2R0.5	85	36,5 %	61,1 %
0,6	A1B1C5R0.6	85	23,5 %	51 %	A1B1C2R0.6	85	29,4 %	55 %
0,7	A1B1C5R0.7	85	24,7 %	51,2 %	A1B1C2R0.7	85	25,9 %	52,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0383

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0497

Tab. 6.12. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1**, prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R?				Analiza wrażliwości A1B1C1R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B1C5R0.3	85	25,9 %	52,9 %	A1B1C1R0.3	85	70,6 %	83,1 %
0,4	A1B1C5R0.4	85	27,1 %	55,4 %	A1B1C1R0.4	85	52,9 %	71,2 %
0,5	A1B1C5R0.5	85	27,1 %	53,8 %	A1B1C1R0.5	85	36,5 %	61,3 %
0,6	A1B1C5R0.6	85	23,5 %	51 %	A1B1C1R0.6	85	38,8 %	62,9 %
0,7	A1B1C5R0.7	85	24,7 %	51,2 %	A1B1C1R0.7	85	42,4 %	64,1 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00712

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00511

Tab. 6.13. Wyniki klasyfikacji uzyskane dla jednakowych zbiorów uczących i testujących, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C1** oraz $r_a = 0,3$ (**A1B1C1R0.3**).

		Oszacowane klasy stanu							Liczba stanów	Ocena nr 1	Ocena nr 2
		B_0	B_1	B_2	B_3	B_4	B_5	B_6			
Oczekiwane klasy stanu	B_0	0					1		1	0%	0%
	B_1		8	3		1			12	66,7%	80,2%
	B_2			11	1				12	91,7%	95,8%
	B_3			2	9		1		12	75%	85,4%
	B_4				2	8	2		12	66,7%	83,3%
	B_5					1	9	2	12	75%	87,5%
	B_6					1	4	7	12	58,3%	77,1%
	B_7						2	2	8	12	66,7%
		Ogółem							85	70,6%	83,1%

Tab. 6.14. Wyniki klasyfikacji uzyskane dla jednakowych zbiorów uczących i testujących, bez zastosowania analizy wrażliwości, dla zbioru cech sygnałów **C3** oraz $r_a = 0,3$ (**A2B1C3R0.3**).

		Oszacowane klasy stanu							Liczba stanów	Ocena nr 1	Ocena nr 2
		B_0	B_1	B_2	B_3	B_4	B_5	B_6			
Oczekiwane klasy stanu	B_0	0					1		1	0%	0%
	B_1		12						12	100%	100%
	B_2		1	10	1				12	83,3%	91,7%
	B_3			2	4	5	1		12	33,3%	64,6%
	B_4				1	9	2		12	75%	87,5%
	B_5					1	7	4	12	58,3%	79,2%
	B_6						6	6	12	50%	75%
	B_7						4	4	4	12	33,3%
		Ogółem							85	61,2%	78,5%

Postawiony zarzut nie umniejsza znaczenia przydatności analizy wrażliwości w wyborze cech sygnałów. Można tak twierdzić, ponieważ stosując analizę wrażliwości i uwzględniając 16 cech, uzyskano lepsze wyniki (tab. 6.13), niż budując model diagnostyczny posiadający na wejściu maksymalną, przyjętą ze względu na liczbę przykładów uczących, liczbę 42-óch cech sygnałów (tab. 6.14).

6.6.3. Testy prowadzone metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości

Zamieszczone w tym punkcie porównania uzyskanych wyników testów przeprowadzono dla metody *leave one out* (**B2**). Pozwalają one zweryfikować wcześniej wyciągnięte wnioski (rozdział 6.6.1) o istotności różnic pomiędzy wynikami uzyskanymi dla

przypadku, gdy do wyboru cech była stosowana analiza wrażliwości (**A1**) oraz dla przypadku, gdy nie była ona stosowana (**A2**). Tak jak poprzednio możliwe są tutaj porównania wyników uzyskanych dla zbiorów cech ograniczonych do jednej podpory (**C5**, **C4**, **C3**).

Przyglądając się otrzymanym p -wartościom (tab. 6.15, 6.16, 6.17), które są wyraźnie większe od granicznej wartości 0,05, można śmiało odrzucić hipotezę o różnicach w uzyskanych wynikach. Korzystając z tego faktu zamiast bardziej skomplikowanych modeli diagnostycznych posiadających dużą do wyznaczenia liczbę parametrów można identyfikować prostsze modele, wykorzystując do tego celu analizę wrażliwości, bez obawy o jakość uzyskiwanych wyników. Dodatkowym atutem na korzyść takiego rozwiązania jest liczba stanów n , dla których identyfikacja poprawnego modelu diagnostycznego zakończyła się powodzeniem. Dla wszystkich oprócz jednego przypadku (test **A1B2C3R0.6**, tab. 6.17) jest ona większa dla testów, w których do wyboru cech sygnałów zastosowano analizę wrażliwości.

Można zakładać, że przeprowadzając testy dla strategii *leave one out*, nie mogło w żadnym przypadku nastąpić zbytnie dopasowanie się modelu do danych. Jest to założenie poprawne z tego względu, że dane testujące nie znajdowały się w zbiorze danych uczących.

Tab. 6.15. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**.

R? (r_a)	Analiza wrażliwości A1B2C5R?				Brak analizy wrażliwości A2B2C5R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C5R0.3	85	25,9 %	51,5 %	A2B2C5R0.3	68	23,5 %	50 %
0,4	A1B2C5R0.4	83	24,1 %	49,4 %	A2B2C5R0.4	74	20,3 %	47,1 %
0,5	A1B2C5R0.5	83	22,9 %	50,1 %	A2B2C5R0.5	65	26,2 %	51,6 %
0,6	A1B2C5R0.6	83	22,9 %	46,6 %	A2B2C5R0.6	72	19,4 %	47,2 %
0,7	A1B2C5R0.7	81	23,5 %	51,2 %	A2B2C5R0.7	75	24 %	51,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,413

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,838

Tab. 6.16. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**.

R? (r_a)	Analiza wrażliwości A1B2C4R?				Brak analizy wrażliwości A2B2C4R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C4R0.3	82	20,7 %	48,8 %	A2B2C4R0.3	75	22,7 %	50,2 %
0,4	A1B2C4R0.4	75	26,7 %	54,5 %	A2B2C4R0.4	52	28,8 %	52,8 %
0,5	A1B2C4R0.5	72	22,2 %	49,8 %	A2B2C4R0.5	46	17,4 %	46,5 %
0,6	A1B2C4R0.6	56	25 %	54,5 %	A2B2C4R0.6	–	–	–
0,7	A1B2C4R0.7	56	14,3 %	45,4 %	A2B2C4R0.7	–	–	–

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,761

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,785

Mając to na uwadze należy przyrzeć się wynikom testu **A2B2C3R0.3** (tab. 6.17), dla którego metodę tę stosowano oraz wynikom testu **A2B1C3R0.3** (tab. 6.7), w przypadku którego zbiór danych testujących był identyczny jak zbiór danych uczących. Potwierdzają one wcześniej wysnute przypuszczenia (punkt 6.6.1) odnośnie zbytniego dopasowania się modelu do danych dla testu **A2B1C3R0.3** (tab. 6.7, 6.14), gdzie uzyskane oceny pomimo uwzględnienia cech sygnałów pochodzących tylko z jednego łożyska były wysokie.

Tab. 6.17. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C3**.

R? (r_a)	Analiza wrażliwości A1B2C3R?				Brak analizy wrażliwości A2B2C3R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C3R0.3	81	17,3 %	45,6 %	A2B2C3R0.3	76	26,3 %	49 %
0,4	A1B2C3R0.4	70	22,9 %	47,3 %	A2B2C3R0.4	38	23,7 %	49,7 %
0,5	A1B2C3R0.5	60	26,7 %	53,3 %	A2B2C3R0.5	36	27,8 %	48,8 %
0,6	A1B2C3R0.6	1	100 %	100 %	A2B2C3R0.6	12	41,7 %	58,5 %
0,7	A1B2C3R0.7	27	33,3 %	66,7 %	A2B2C3R0.7	–	–	–

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,582

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,371

6.6.4. Testy prowadzone metodą *leave one out* z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech

Porównując wyniki uzyskane z testów **A1B1C?R?** (punkt 6.6.2), w których zbiory danych uczących i testujących były identyczne (**B1**), okazało się, że poprawa otrzymywanych wyników następuje dopiero po uwzględnieniu cech pochodzących z więcej niż jednej podpory. O tym, czy podobna poprawa następuje dla testów przeprowadzonych z użyciem metody *leave one out* (**B2**), można się dowiedzieć analizując wyniki porównań ocen uzyskanych dla testów **A1B2C?R?** (tab. 6.18, 6.19, 6.20, 6.21).

Przypatrując się otrzymanym wynikom okazuje się, że w przypadku uwzględnienia cech sygnałów pochodzących tylko z jednej podpory (**C5**, **C4**, **C3**), nie następuje żadna wyraźna poprawa jakości identyfikowanych modeli diagnostycznych. Świadczą o tym otrzymane p -wartości, które dla wszystkich porównań, są większe od progowej wartości 0,05. Podobną sytuację, gdy nie stwierdzono istotnych różnic, mamy w przypadku niepełnego zbioru cech sygnałów (**C2**) zawierającego cechy pochodzące z wszystkich podpór (testy **A1B2C2R?**, tab. 6.18). Tutaj także p -wartości dla ocen O_1 oraz O_2 są większe od 0,05.

Wyraźne zwiększenie wartości wyznaczanych ocen O_1 oraz O_2 obserwujemy dopiero w momencie, gdy analizę wrażliwości przeprowadzamy uwzględniając wszystkie cechy związane z przemieszczeniami względnymi (**C1**). Oszacowane p -wartości wynoszą wtedy odpowiednio 0,0036 oraz 0,00083.

Najwyższe oceny ($O_1 = 44,7\%$ oraz $O_2 = 64,2\%$), w przypadku metody *leave one*

out, otrzymano dla testu **A1B2C1R0.3** (tab. 6.22). Przeprowadzając go, do wyboru cech sygnałów zastosowano analizę wrażliwości.

Tab. 6.18. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4**, prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R?				Analiza wrażliwości A1B2C4R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C5R0.3	85	25,9 %	51,5 %	A1B2C4R0.3	82	20,7 %	48,8 %
0,4	A1B2C5R0.4	83	24,1 %	49,4 %	A1B2C4R0.4	75	26,7 %	54,5 %
0,5	A1B2C5R0.5	83	22,9 %	50,1 %	A1B2C4R0.5	72	22,2 %	49,8 %
0,6	A1B2C5R0.6	83	22,9 %	46,6 %	A1B2C4R0.6	56	25 %	54,5 %
0,7	A1B2C5R0.7	81	23,5 %	51,2 %	A1B2C4R0.7	56	14,3 %	45,4 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,375

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,679

Tab. 6.19. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3**, prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R?				Analiza wrażliwości A1B2C3R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C5R0.3	85	25,9 %	51,5 %	A1B2C3R0.3	81	17,3 %	45,6 %
0,4	A1B2C5R0.4	83	24,1 %	49,4 %	A1B2C3R0.4	70	22,9 %	47,3 %
0,5	A1B2C5R0.5	83	22,9 %	50,1 %	A1B2C3R0.5	60	26,7 %	53,3 %
0,6	A1B2C5R0.6	83	22,9 %	46,6 %	A1B2C3R0.6	1	100 %	100 %
0,7	A1B2C5R0.7	81	23,5 %	51,2 %	A1B2C3R0.7	27	33,3 %	66,7 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,319

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,24

Tab. 6.20. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2**, prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R?				Analiza wrażliwości A1B2C2R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C5R0.3	85	25,9 %	51,5 %	A1B2C2R0.3	85	32,9 %	59,4 %
0,4	A1B2C5R0.4	83	24,1 %	49,4 %	A1B2C2R0.4	83	31,3 %	55,7 %
0,5	A1B2C5R0.5	83	22,9 %	50,1 %	A1B2C2R0.5	84	23,8 %	51,8 %
0,6	A1B2C5R0.6	83	22,9 %	46,6 %	A1B2C2R0.6	72	18,1 %	45,8 %
0,7	A1B2C5R0.7	81	23,5 %	51,2 %	A1B2C2R0.7	67	22,4 %	47,3 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,536

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,429

Tab. 6.21. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1**, prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R?				Analiza wrażliwości A1B2C1R?			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,3	A1B2C5R0.3	85	25,9 %	51,5 %	A1B2C1R0.3	85	44,7 %	64,2 %
0,4	A1B2C5R0.4	83	24,1 %	49,4 %	A1B2C1R0.4	84	34,5 %	57,1 %
0,5	A1B2C5R0.5	83	22,9 %	50,1 %	A1B2C1R0.5	76	32,9 %	56,7 %
0,6	A1B2C5R0.6	83	22,9 %	46,6 %	A1B2C1R0.6	75	28 %	56,1 %
0,7	A1B2C5R0.7	81	23,5 %	51,2 %	A1B2C1R0.7	81	35,8 %	59,6 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00356

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,000825

Tab. 6.22. Wyniki klasyfikacji uzyskane dla testów prowadzonych metodą *leave one out*, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C1** oraz $r_a = 0,3$ (**A1B2C1R0.3**).

		Oszacowane klasy stanu							Liczba stanów	Ocena nr 1	Ocena nr 2	
		B_0	B_1	B_2	B_3	B_4	B_5	B_6				B_7
Oczekiwane klasy stanu	B_0	0					1		1	0%	0%	
	B_1	1	3	4	3	1			12	25%	49%	
	B_2	1	2	8	1				12	66,7%	79,2%	
	B_3	1		3	5	1	1	1	12	41,7%	60,9%	
	B_4			2		7	2	1	12	58,3%	71,9%	
	B_5					3	6	1	2	12	50%	70,8%
	B_6	1					6	4	1	12	33,3%	62,5%
	B_7	1					3	3	5	12	41,7%	60,4%
		Ogółem							85	44,7%	64,2%	

6.7. Wnioski

Na podstawie badań porównawczych, przeprowadzonych na danych pochodzących z symulacji, można wyciągnąć pewne wnioski i ująć je w formie następujących punktów:

1. Klasyfikacja stanów jest w wielu przypadkach poprawna pomimo, iż w jednej klasie stanu umieszczono zarówno stany związane z przemieszczeniem podpór jak i z przekoszeniem łożysk.
2. Klasyfikacja stanu bazowego B_0 jest niepoprawna, prawdopodobnie ze względu na małą liczbę stanów należących do tej klasy (jeden stan).
3. Pomimo, iż stany należące do klas stanu B_i ; $i = 1, 2, \dots, 7$ były niepoprawnie klasyfikowane, to przypisywano je klasom związanym z podporami znajdującymi się niedaleko przemieszczonej podpory lub przekoszonego łożyska.

4. Zgodnie z oczekiwaniami, dla przypadku, w którym zbiór danych uczących był równy zbiorowi danych testujących, otrzymano lepsze wyniki niż dla metody *leave one out*.
5. Jeżeli zbiór cech jest na tyle mały, że można go w całości wykorzystać do identyfikacji modelu diagnostycznego, to ograniczenie tego zbioru za pomocą analizy wrażliwości nie spowoduje pogorszenia jakości tego modelu.
6. Uwzględniając punkt nr 5 prawdziwym staje się stwierdzenie, że zastosowanie analizy wrażliwości pozwala uprościć, identyfikowany na podstawie danych uczących model diagnostyczny, a przez to zmniejszyć liczbę wymaganych przykładów uczących.
7. Jeżeli zbiór cech sygnałów jest zbyt duży, żeby można go było w całości wykorzystać do identyfikacji modelu diagnostycznego, to zastosowanie analizy wrażliwości może być optymalnym rozwiązaniem, jeżeli chodzi o selekcję tych cech.
8. Maksymalna liczba 16-tu wrażliwych cech sygnałów, wybranych ze zbioru 525 cech pozwala uzyskać znacząco lepsze wyniki klasyfikacji niż 42 cechy wybrane w sposób przypadkowy lub wybrane w sposób, który dla osoby dokonującej tego wyboru mógł wydawać się najlepszy.
9. Polepszenia wyników klasyfikacji możemy się spodziewać jeżeli wartości wrażliwości będą większe. Można tego dokonać:
 - zwiększając zbiór rozpatrywanych cech sygnałów, co zostało udowodnione;
 - w inny, bardziej optymalny sposób definiując klasy stanu;
 - zwiększając zbiór stanów należących do poszczególnych klas stanu;
 - zmniejszając liczbę klas stanu.

Rozdział 7

Przykład zastosowania statystycznej metody badania wrażliwości – dane pomiarowe

W poprzednim rozdziale potwierdzono przydatność analizy wrażliwości w wyborze cech sygnałów, w przypadku, gdy dane do badań zostały otrzymywane na drodze symulacji numerycznej. W tym rozdziale przeprowadzona zostanie weryfikacja metody badania wrażliwości na danych, uzyskanych z badań rzeczywistego obiektu technicznego.


Spodziewanym rezultatem weryfikacji, podobnie jak poprzednio, jest potwierdzenie przydatności analizy wrażliwości. Przemawiają za tym:

1. Bardzo dobre dopasowanie poprzednio omawianego modelu do modelowanego za jego pomocą obiektu technicznego.
2. Otrzymane w poprzednich badaniach ogólnie niskie wartości wrażliwości grupowej (6.10) oraz głównej (6.11), które w przypadku prostych nieliniowych modeli są bliskie lub równe jedności.

7.1. Badany obiekt techniczny

Do badań wybrany został obiekt należący do klasy maszyn wirnikowych łożyskowanych ślizgowo. Jest nim stanowisko *Rotor Kit* firmy *Bently Nevada* [107,108]. Stanowisko to służy do badań drgań wałów i znajduje się w laboratorium Katedry Podstaw Konstrukcji Maszyn Politechniki Śląskiej w Gliwicach. Podstawowymi jego elementami są (rys. 7.1):

- wał;
- dwie tarcze umożliwiające wprowadzenie niewyważenia;
- dwa usadowione w podporach łożyska ślizgowe;
- silnik elektryczny przekazujący moc na wał poprzez sprzęgło podatne;
- układ pomiarowy służący do akwizycji sygnałów przemieszczeń względnych wału.



Rys. 7.1. Stanowisko badawcze *Rotor Kit* [96].

Omawiane stanowisko badawcze poprzez zmianę stanu technicznego daje możliwość wprowadzenia i badania szeregu najczęściej spotykanych niesprawności związanych z maszynami wirnikowymi, do których zaliczamy [107]:

- niewyważenie;
- przycieranie wirnika;
- nadmierne przeciążenie;
- niestabilność działania łożysk hydrodynamicznych (bicz oraz wir olejowy) [108];
- wpływ warunków zasilania olejem na pracę łożyska hydrodynamicznego [108].

Korzystając z możliwości płynnej regulacji prędkości obrotowej w zakresie od 0 do 10000 [obr/min] badania można przeprowadzać w różnych ustalonych i/lub niustalonych warunkach działania.

7.2. Klasy stanu

W wyniku przeprowadzonych przez A. Klimka oraz B. Wysogłada pomiarów [45, 97] otrzymano dane zawierające informacje o wejściach, wyjściach oraz o stanie badanego obiektu.

Dane dotyczące wejść obiektu obejmują informację o prędkości obrotowej wału związanej z:

n1: obszarem przedrezonansowym, $n = 5500$ [obr/min];

n2: obszarem bliskim drugiej częstotliwości rezonansowej układu, $n = 6300[\text{obr}/\text{min}]$;

n3: obszarem pozarezonansowym, $n = 7200[\text{obr}/\text{min}]$.

Prędkość obrotową można łatwo zmierzyć i/lub wyznaczyć na podstawie sygnałów diagnostycznych. Ma ona jednak zasadniczy wpływ na generowane przez badany obiekt sygnały i wyznaczane z tych sygnałów cechy. Mając to na uwadze, wszystkie dane z badań podzielono na trzy części, z których każda obejmuje tylko jedną prędkość obrotową wału. Będą one rozpatrywane niezależnie. Oprócz eliminacji wpływu prędkości obrotowej, podejście takie umożliwi np.: budowę trzech niezależnych modeli diagnostycznych i połączenie ich w jeden wielomodel lub model wieloaspektowy. Agregacja trzech modeli mogłaby wtedy pozwolić na uzyskanie lepszych wyników od tych, jakie można otrzymać dla jednego modelu opracowanego na podstawie wszystkich danych.

Otrzymane z badań stanowiska *Rotor Kit* dane, w przypadku każdej prędkości obrotowej, obejmują 166 stany techniczne. Odróżnić je pozwalają takie cechy stanu jak:

1. Umieszczenie wprowadzanych do badanego obiektu niewyważień:

t1: tarcza nr 1;

t2: tarcza nr 2;

t3: jednocześnie tarcza nr 1 oraz tarcza nr 2.

2. Masa wprowadzanego niewyważenia:

m1: $m = 0[\text{g}]$;

m2: $m = 0,6[\text{g}]$;

m3: $m = 0,8[\text{g}]$;

m4: $m = 1[\text{g}]$;

m5: $m = 1,2[\text{g}]$;

m6: $m = 1,4[\text{g}]$;

m7: $m = 1,6[\text{g}]$.

Odległość środka masy niewyważenia od osi obrotu jest jednakowa dla wszystkich stanów i wynosi 30[mm].

3. Położenie kątowne niewyważenia na tarczy:

a1: $\alpha = 0^\circ$;

a2: $\alpha = 22,5^\circ$;

a3: $\alpha = 45^\circ$;

a4: $\alpha = 67,5^\circ$;

... ;

a16: $\alpha = 337,5^\circ$.

Biorąc pod uwagę fakt, że opracowana metoda badania wrażliwości wymaga jednoznacznego zaklasyfikowania poszczególnych stanów, postanowiono wprowadzić następujące klasy stanu:

B_1 : masa niewyważenia na tarczy nr 1 równa 0[g] lub 0,6[g] (**m1, m2**);

B_2 : masa niewyważenia na tarczy nr 1 równa 0,8[g], 1[g] lub 1,2[g] (**m3, m4, m5**);

B_3 : masa niewyważenia na tarczy nr 1 równa 1,4[g] lub 1,6[g] (**m6, m7**).

Każda z powyższych klas stanu B_i ; $i = 1, 2, 3$ reprezentowana jest przez stany związane z:

- charakterystyczną dla każdej klasy, masą niewyważenia na tarczy nr 1;
- 16-toma różnymi kątami zamocowania niewyważenia na tarczy nr 1;
- 7-mioma różnymi masami niewyważenia na tarczy nr 2;
- 16-toma różnymi kątami zamocowania niewyważenia na tarczy nr 2.

Ze względu na to, iż w badaniach nie uwzględniono wszystkich kombinacji wartości cech stanu, to każdą klasę stanu reprezentuje od 38-miu do 65-ciu stanów:

- $B_1 = \{b_{1.1}, b_{1.2}, \dots, b_{1.n_1}\}$;
- $B_2 = \{b_{2.1}, b_{2.2}, \dots, b_{2.n_2}\}$;
- $B_3 = \{b_{3.1}, b_{3.2}, \dots, b_{3.n_3}\}$.

Klasy te tworzą zbiór klas stanu $B = \{B_1, B_2, B_3\}$.

7.3. Cechy sygnałów

Dane wyjściowe otrzymane z badań stanowiska *Rotor Kit* obejmują sygnały przemieszczeń względnych wału mierzone w dwóch płaszczyznach pomiarowych zlokalizowanych w pobliżu podpór łożyskowych nr 1 oraz nr 2 (rys. 7.1). Są to:

1. Sygnały przemieszczeń względnych wału w pierwszej płaszczyźnie pomiarowej położonej w pobliżu podpory łożyskowej nr 1:
 - mierzone w kierunku poziomym;
 - mierzone w kierunku pionowym.
2. Sygnały przemieszczeń względnych wału w drugiej płaszczyźnie pomiarowej położonej w pobliżu podpory łożyskowej nr 2:
 - mierzone w kierunku poziomym;
 - mierzone w kierunku pionowym.

Każdy z sygnałów obejmuje 1024 wartości dyskretne zarejestrowane z częstotliwością 1280[Hz]. Czas realizacji tych sygnałów wynosi 0,8[s].

W ramach badań przydatności analizy wrażliwości w budowie modeli diagnostycznych wyznaczone zostały 75 cechy sygnałów dla każdej płaszczyzny pomiarowej. Opisane zostały one wcześniej, w rozdziale 6.3. Cechy te tworzą zbiór 150-ciu cech sygnałów:

$$c = \{c_1, c_2, \dots, c_m\}; \quad m = 150. \quad (7.1)$$

Przykładową nazwą $\text{nam}(c_j)$ cechy sygnału c_j jest 'wartość skuteczna sygnału przemieszczeń względnych wału zmierzonego w pierwszej płaszczyźnie pomiarowej w kierunku pionowym'. W nazwie tej cechy zawarta jest informacja pozwalająca określić zarówno sposób jej wyznaczenia jak i miejsce oraz sposób rejestracji sygnału na podstawie którego została ona wyznaczona.

Mając określone klasy stanu B_i ; $i = 1, 2, 3$ oraz zbiór cech sygnałów c przeprowadzamy szereg działań opisanych w rozdziale 6.3. W wyniku tych działań otrzymujemy informację o grupach wartości cech sygnałów W^j ; $j = 1, 2, \dots, m$ tworzących zbiór wszystkich wyznaczanych wartości cech:

$$W = \{W^1, W^2, \dots, W^m\}; \quad W^j = \{w_1^j, w_2^j, w_3^j\}, \quad (7.2)$$

oraz informacje o klasach stanu:

$$B = \{B_1, B_2, B_3\}. \quad (7.3)$$

Dane te pozwalają zidentyfikować model diagnostyczny. Można to zrobić przeprowadzając najpierw analizę wrażliwości (rys. 5.3) lub wykorzystując do tego celu wszystkie wyznaczone cechy (rys. 5.2).

7.4. Testy jakości wybranych cech sygnałów

W poprzednim rozdziale potwierdzono przydatność analizy wrażliwości w wyborze cech sygnałów zawierających informacje istotne z punktu widzenia klasyfikacji. Zrobiono to dla przypadku, gdy analizowane dane otrzymano w wyniku symulacji komputerowej.

W tym rozdziale badania prowadzone są na danych pochodzących z pomiarów dokonanych na rzeczywistym obiekcie technicznym. Pozwalają one zweryfikować wyciągnięte wcześniej wnioski i potwierdzić skuteczność zaproponowanej metody badania wrażliwości dla innej liczby klas stanu i innej „jakości” danych.

Bardzo ważną zmianą dokonaną ze względu na wspomnianą „jakość” danych jest modyfikacja poziomu istotności z $\alpha = 0,3\%$ na $\alpha = 0,1\%$. Przemawiała za tym wysoka wartość otrzymywanych wartości wrażliwości grupowych. Zmianę tą wprowadzono bazując na algorytmie sel3 (rys. 5.6) selekcji wrażliwych cech sygnałów.

Tak jak poprzednio w celu przeprowadzenia testów należy podjąć się zadań związanych z:

- identyfikacją modelu diagnostycznego;
- przeprowadzaniem klasyfikacji;

- porównaniem uzyskanych wyników klasyfikacji.

Pierwsze dwa z tych punktów omówiono wcześniej w rozdziale 6.5.1. Należy je jednak uzupełnić o pewne opisy dotyczące sposobu testowania modelu diagnostycznego oraz prezentacji uzyskanych wyników.

7.4.1. Sposób badania modelu diagnostycznego

Tak jak we wcześniejszym rozdziale, gdy dane do badań uzyskano w wyniku symulacji, tak i teraz dokonywane są porównywania dla przypadków, w których:

A1: Do wyboru cech stosowana jest analiza wrażliwości diagnostycznej.

A2: Brane pod uwagę są wszystkie cechy.

Badania prowadzone są dla dwóch różnych strategii podziału zbioru danych na dane uczące i testujące:

B1: Zbiór danych uczących oraz zbiór danych testujących są równe zbiorowi danych.

B2: Stosowana jest metoda *leave one out*.

Zbiór danych, rozpatrywanych w badaniach, obejmuje cechy wyznaczone dla 166-ciu stanów (3 klasy stanu). Daje to 166 (metoda **B1**) lub 165 (metoda **B2**) przykładów uczących.

Duża liczba przykładów uczących w stosunku do liczby rozpatrywanych klas stanu eliminuje wcześniej pojawiający się problem związany z określeniem wszystkich parametrów rozmytej sieci neuronalnej. Parametry te, bez żadnych trudności, można tym razem wyznaczyć w przypadku wszystkich testów.

Eliminacja jednego problemu niestety powoduje pojawienie się kolejnego. Jest nim wzrost liczby reguł i związane z tym:

- zwiększenie liczby węzłów rozmytej sieci neuronalnej;
- możliwość jeszcze lepszego dopasowania się modelu do danych, niż w opisanych wcześniej testach, dla przypadku, gdy zbiory danych uczących i testujących są jednakowe (**B1**);
- zwiększone wymagania odnośnie nakładów obliczeniowych i zasobów pamięciowych rosnące dużo szybciej niż liczba reguł wchodzących w skład modelu diagnostycznego.

Przyjmujemy, że za pomocą analizy wrażliwości wybieranych będzie każdorazowo 6 (dwie cechy na każdą klasę stanu) najbardziej wrażliwych cech sygnałów. Może ich być mniej, jeżeli liczba cech charakteryzujących się zmiennością na poziomie istotności mniejszym niż $\alpha = 0,1\%$ będzie mniejsza.

W przypadku cech sygnałów poddawanych najpierw analizie wrażliwości, w celu późniejszego opracowania modelu diagnostycznego, wielkość zbioru cech sygnałów nie ma znaczenia. Uwzględniając to zaproponowano przeprowadzenie badań dla:

C1: Zbioru wszystkich cech związanych z sygnałami przemieszczeń względnych zarejestrowanych w obu rozpatrywanych płaszczyznach pomiarowych – 150 cech.

- C2:** Podzbiór zbioru **C1** bez cech związanych z: kurtozą, współczynnikiem asymetrii, składowymi widma amplitudowego o częstotliwości 0,25X, 0,33X, 0,5X, wszystkimi fazami składowych widma amplitudowego oraz niektórymi cechami trajektorii (punkty 2-4 rozdz. 6.3) – 84 cechy.
- C3:** Podzbiór zbioru **C2** ograniczony do cech związanych z pierwszą płaszczyzną pomiarową – 42 cechy.
- C4:** Podzbiór zbioru **C3** ograniczony do cech związanych przemieszczeniami w kierunku poziomym oraz pionowym – 28 cech.
- C5:** Podzbiór zbioru **C4** ograniczony do cech związanych przemieszczeniami w kierunku poziomym – 14 cech.

W przypadku, gdy nie jest przeprowadzana analiza wrażliwości (**A2**) brane pod uwagę mogą być tylko zbiory **C4** oraz **C5** cech sygnałów. Postępowanie to podyktowane jest wcześniej opisanym ograniczeniem związanym z możliwościami obliczeniowymi dostępnego sprzętu komputerowego.

Ostatnim elementem mającym duży wpływ na wyniki badań, jest opisany w rozdziale 6.5.1 parametr r_a . Wprowadzono dla jego poszczególnych wartości następujące oznaczenia:

R0.4: $r_a = 0,4$;

R0.5: $r_a = 0,5$;

R0.6: $r_a = 0,6$;

R0.7: $r_a = 0,7$;

R0.8: $r_a = 0,8$.

Porównując te wartości r_a , z tymi ustalonymi dla wcześniejszych testów (rozdział 6.5.2), to zwiększono je o 0,1. Zrobiono to w celu zmniejszenia liczby reguł rozmytych, a tym samym przyspieszenia obliczeń i umożliwienia wykonania testów.

Mając na celu uproszczenie sposobu opisu przeprowadzanych testów tak jak poprzednio wprowadzono wieloznaczny znak zapytania „?” zastępujący liczby związane z poprzedzającymi je literami **A**, **B**, **C** oraz **R**. Stosując go można zakodować pełny opis jednego lub grupy testów w formie krótkiego ciągu znaków. Przykładowo wszystkie testy, w których przeprowadzona została analiza wrażliwości to:

$$\mathbf{A1B?C?R?}. \quad (7.4)$$

7.4.2. Sposób opisu wyników badań

Wyniki przeprowadzonych testów podobnie jak w rozdziale 6.5.3 umieszczono w tabelach. Tym razem jednak, w przypadku oczekiwanych klas stanu, dołączono dodatkową informację o wartościach niewyważenia na tarczy nr 1 (tab. 7.1).

Wprowadzone do tabeli dwie kolumny z ocenami poprawności klasyfikacji ułatwiają interpretację wyników i umożliwiają przeprowadzenie późniejszej ich analizy.

Tab. 7.1. Przykładowe wyniki klasyfikacji.

		Masa niewyw. [g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	14			14	100%	100%
		0,6	38	13		51	74,5%	87,3%
	B_2	0,8		6		6	100%	100%
		1	8	43	2	53	81,1%	90,6%
		1,2		3	1	4	75%	87,5%
	B_3	1,4			2	2	100%	100%
		1,6		8	28	36	77,8%	88,9%
		Ogółem			166	80,7%	90,4%	

Ocena nr 1 (O_1) obliczana jest według następującej zależności dla poszczególnych wartości masy niewyważenia na tarczy nr 1:

$$O_1(\mathbf{m}_i) = \begin{cases} \hat{n}_{i,1}/n_i, & \text{dla } i = 1, 2; \\ \hat{n}_{i,2}/n_i, & \text{dla } i = 3, 4, 5; \\ \hat{n}_{i,3}/n_i, & \text{dla } i = 6, 7. \end{cases} \quad (7.5)$$

gdzie: $O_1(\mathbf{m}_i)$ – ocena poprawności klasyfikacji stanów związanych z wartościami masy niewyważenia \mathbf{m}_i ;

n_i – liczba stanów, w których masa niewyważenia na tarczy nr 1 jest równa \mathbf{m}_i ;

$\hat{n}_{i,j}$ – liczba stanów związanych z \mathbf{m}_i -tą masą niewyważenia, które zaklasyfikowano stosując model diagnostyczny do klasy B_j ; $j = 1, 2, 3$.

Ogólna dla wszystkich stanów ocena nr 1 jest średnią ważoną z wyznaczonych powyżej ocen:

$$O_1 = \frac{\sum_i n_i \cdot O_1(\mathbf{m}_i)}{n}; \quad n = \sum_i n_i; \quad i = 1, \dots, 7. \quad (7.6)$$

Wprowadzając ocenę nr 2 (O_2) założono, iż błąd klasyfikacji powinien być mniejszy, jeżeli np.: stan należący do klasy B_1 zaklasyfikowano do klasy B_2 , zamiast do klasy B_3 . Zgodnie z tym:

$$O_2(\mathbf{m}_i) = \begin{cases} \frac{\hat{n}_{i,1} + 0,5 \cdot \hat{n}_{i,2}}{n_i}, & \text{dla } i = 1, 2; \\ \frac{0,5 \cdot \hat{n}_{i,1} + \hat{n}_{i,2} + 0,5 \cdot \hat{n}_{i,3}}{n_i}, & \text{dla } i = 3, 4, 5; \\ \frac{0,5 \cdot \hat{n}_{i,2} + \hat{n}_{i,3}}{n_i}, & \text{dla } i = 6, 7. \end{cases} \quad (7.7)$$

Podobnie jak dla oceny nr 1, ogólną dla wszystkich stanów ocenę nr 2, wyznaczamy jako średnią ważoną postępując się równaniem:

$$O_2 = \frac{\sum_i n_i \cdot O_2(\mathbf{m}i)}{n}; \quad n = \sum_i n_i; \quad i = 0, 1, \dots, 7. \quad (7.8)$$

7.5. Omówienie wyników testów

Podobnie jak w poprzednich (rozdział 6), tak i w tych testach można zauważyć pewne prawidłowości, które są zgodne z oczekiwaniami. Tym jednak razem dotyczą one:

1. Lepszych lub takich samych wyników uzyskiwanych w przypadku większego wejściowego zbioru cech.
2. Gorszych wyników w przypadku, gdy do wyboru cech stosowana jest metoda badania wrażliwości, a zbiór danych uczących jest taki sam jak zbiór danych testujących.
3. Lepszych lub takich samych wyników w przypadku, gdy do wyboru cech stosowana jest metoda badania wrażliwości, a do testowania metoda *leave one out*.

Potwierdzenie tych prawidłowości można uzyskać sprawdzając hipotezę H_0 o równości średnich dla skorelowanych ze sobą danych. Średnie te są wyznaczane z ocen uzyskanych w testach dla:

- analizy wrażliwości (**A1**) lub jej braku (**A2**);
- strategii zbiór uczący równy zbiorowi testującemu (**B1**) lub metody *leave one out* (**B2**);
- rozpatrywanego zbioru cech sygnałów (**C1**, **C2**, **C3**, **C4** lub **C5**);
- wszystkich wartości parametru r_a (**R0.4**, **R0.5**, **R0.6**, **R0.7** i **R0.8**).

Porównania średnich przeprowadzono podobnie jak w poprzednich testach dla skorelowanych danych, a ich wyniki podano w postaci p -wartości oszacowanych na podstawie wyznaczonych statystyk T oraz rozkładu t Studenta.

7.5.1. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości

Wyniki badań zamieszczone w tym punkcie dotyczą przypadku, w którym dane uczące były jednocześnie danymi testującymi (**B1**). Celem analizy tych wyników jest stwierdzenie różnic w uzyskiwanych ocenach dla przypadku, gdy do wyboru cech stosowana była analiza wrażliwości (**A1**) oraz dla przypadku, gdy nie była ona stosowana (**A2**). Ze względu na ograniczenia sprzętowe, możliwe były tutaj do przeprowadzenia porównania jedynie dla cech związanych z przemieszczeniami w jednej płaszczyźnie, w kierunku poziomym oraz pionowym (**C5**, **C4**).

Jak można zauważyć, otrzymywane p -wartości są małe dla obu rozpatrywanych zbiorów cech (**C5**, **C4**), w przypadku wszystkich prędkości obrotowych $n = \{5500, 6300, 7200\}$ [obr/min].

Tab. 7.2. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**, $n = 5500$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 5500$ [obr/min])				Brak analizy wrażliwości A2B1C5R? ($n = 5500$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	66,9 %	82,8 %	A2B1C5R0.4	166	96,4 %	98,2 %
0,5	A1B1C5R0.5	166	66,9 %	82,8 %	A2B1C5R0.5	166	86,7 %	93,4 %
0,6	A1B1C5R0.6	166	66,3 %	82,5 %	A2B1C5R0.6	166	86,1 %	93,1 %
0,7	A1B1C5R0.7	166	60,2 %	79,5 %	A2B1C5R0.7	166	74,7 %	87,3 %
0,8	A1B1C5R0.8	166	58,4 %	78,6 %	A2B1C5R0.8	166	71,7 %	85,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00389

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00278

Tab. 7.3. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**, $n = 5500$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B1C4R? ($n = 5500$ [obr/min])				Brak analizy wrażliwości A2B1C4R? ($n = 5500$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C4R0.4	166	67,5 %	83,7 %	A2B1C4R0.4	166	100 %	100 %
0,5	A1B1C4R0.5	166	63,3 %	81,3 %	A2B1C4R0.5	166	100 %	100 %
0,6	A1B1C4R0.6	166	63,9 %	81,3 %	A2B1C4R0.6	166	97,6 %	98,8 %
0,7	A1B1C4R0.7	166	61,4 %	80,7 %	A2B1C4R0.7	166	94,6 %	97,3 %
0,8	A1B1C4R0.8	166	66,3 %	82,5 %	A2B1C4R0.8	166	93,4 %	96,7 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 6,78e-008

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 5,55e-008

Tab. 7.4. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**, $n = 6300$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 6300$ [obr/min])				Brak analizy wrażliwości A2B1C5R? ($n = 6300$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	80,7 %	90,1 %	A2B1C5R0.4	166	91 %	95,5 %
0,5	A1B1C5R0.5	166	77,1 %	88,3 %	A2B1C5R0.5	166	85,5 %	92,8 %
0,6	A1B1C5R0.6	166	75,9 %	87,7 %	A2B1C5R0.6	166	85,5 %	92,8 %
0,7	A1B1C5R0.7	166	72,9 %	85,8 %	A2B1C5R0.7	166	80,1 %	90,1 %
0,8	A1B1C5R0.8	166	75,3 %	87 %	A2B1C5R0.8	166	78,9 %	89,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0146

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00979

Tab. 7.5. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**, $n = 6300$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B1C4R? ($n = 6300$ [obr/min])				Brak analizy wrażliwości A2B1C4R? ($n = 6300$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C4R0.4	166	80,7 %	90,4 %	A2B1C4R0.4	166	100 %	100 %
0,5	A1B1C4R0.5	166	78,9 %	89,2 %	A2B1C4R0.5	166	97 %	98,5 %
0,6	A1B1C4R0.6	166	78,3 %	88,9 %	A2B1C4R0.6	166	94,6 %	97,3 %
0,7	A1B1C4R0.7	166	76,5 %	88 %	A2B1C4R0.7	166	90,4 %	95,2 %
0,8	A1B1C4R0.8	166	77,7 %	88,6 %	A2B1C4R0.8	166	84,9 %	92,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,000585

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,000507

Tab. 7.6. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**, $n = 7200$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 7200$ [obr/min])				Brak analizy wrażliwości A2B1C5R? ($n = 7200$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	67,5 %	83,7 %	A2B1C5R0.4	166	100 %	100 %
0,5	A1B1C5R0.5	166	66,9 %	83,1 %	A2B1C5R0.5	166	94 %	97 %
0,6	A1B1C5R0.6	166	64,5 %	81,9 %	A2B1C5R0.6	166	87,3 %	93,7 %
0,7	A1B1C5R0.7	166	63,3 %	81,3 %	A2B1C5R0.7	166	79,5 %	89,8 %
0,8	A1B1C5R0.8	166	62 %	80,7 %	A2B1C5R0.8	166	75,9 %	88 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00117

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00098

Tab. 7.7. Porównanie wyników testów prowadzonych na jednakowych zbiorach uczących i testujących z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**, $n = 7200$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B1C4R? ($n = 7200$ [obr/min])				Brak analizy wrażliwości A2B1C4R? ($n = 7200$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C4R0.4	166	75,9 %	88 %	A2B1C4R0.4	166	100 %	100 %
0,5	A1B1C4R0.5	166	72,3 %	86,1 %	A2B1C4R0.5	166	100 %	100 %
0,6	A1B1C4R0.6	166	72,3 %	86,1 %	A2B1C4R0.6	166	100 %	100 %
0,7	A1B1C4R0.7	166	68,7 %	84,3 %	A2B1C4R0.7	166	100 %	100 %
0,8	A1B1C4R0.8	166	65,7 %	82,8 %	A2B1C4R0.8	166	100 %	100 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 1,71e-007

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 1,91e-007

Tab. 7.8. Wyniki klasyfikacji uzyskane dla jednakowych zbiorów uczących i testujących, bez zastosowania analizy wrażliwości, dla zbioru cech sygnałów **C5**, $n = 7200$ [obr/min] oraz dla $r_a = 0,4$ (**A2B1C5R0.4**).

		Masa niewyw.[g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	14			14	100%	100%
		0,6	52			52	100%	100%
	B_2	0,8		6		6	100%	100%
		1		52		52	100%	100%
		1,2		4		4	100%	100%
	B_3	1,4			2	2	100%	100%
		1,6			36	36	100%	100%
	Ogółem					166	100%	100%

Tab. 7.9. Wyniki klasyfikacji uzyskane dla jednakowych zbiorów uczących i testujących, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C4**, $n = 6300$ [obr/min] oraz dla $r_a = 0,4$ (**A1B1C4R0.4**).

		Masa niewyw.[g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	11	3		14	78,6%	89,3%
		0,6	43	9		52	82,7%	91,3%
	B_2	0,8	1	4	1	6	66,7%	83,3%
		1	1	49	3	53	92,5%	96,2%
		1,2		1	3	4	25%	62,5%
	B_3	1,4		2	0	2	0%	50%
		1,6		9	26	35	74,3%	87,1%
	Ogółem					166	80,7%	90,4%

Potwierdzają one występowanie istotnych różnic w porównywanych wynikach testów i pozwalają stwierdzić, że dla przypadku gdy analiza wrażliwości nie była stosowana uzyskiwano wyniki zdecydowanie lepsze, niż dla przypadku, gdy z niej korzystano.

Obserwowanych jest kilkanaście przypadków 100%-towej trafności diagnozy (tab. 7.3, 7.5, 7.6, 7.7). Dotyczą one szczególnie modeli diagnostycznych zbudowanych dla prędkości obrotowej $n = 7200$ [obr/min]. Przykład takiego wyniku, uzyskiwanego tylko w przypadkach, gdy nie jest stosowana analiza wrażliwości, zamieszczono w tabeli 7.8.

Należy mieć na uwadze to, iż dla testów, w których zbiory danych uczących i testujących są takie same, może następować i następuje dopasowanie się modelu diagnostycznego do danych uczących, na podstawie których model ten został zidentyfikowany. Nasila się to szczególnie w przypadku, gdy do określenia zaledwie trzech klas stanu użytych jest aż 28 cech sygnałów (testy **A2B1C4R?**, tab. 7.3, 7.5, 7.7).

Stosując analizę wrażliwości do wyboru 6-ciu z 28-miu cech sygnałów maksymalne

wartości ocen wynosiły odpowiednio: $O_1 = 80,7\%$ oraz $O_2 = 90,4\%$ (test **A1B1C4R0.4**, tab. 7.9, $n = 6300$ [obr/min]). Oznacza to, że wszystkie 167-stanów można jednoznacznie zaklasyfikować do jednej z trzech klas stanu B_i ; $i = 1, 2, 3$ korzystając z informacji dostarczonej przez więcej niż 6 cech sygnałów. Uwzględniając wyniki znajdujące się w tabeli 7.6 można stwierdzić, że wystarczy do tego 14 cech.

Przyglądając się dalej tabeli 7.9 można zauważyć, że stany należące do klasy B_1 nigdy nie zostały zaklasyfikowane do klasy B_3 i odwrotnie, zatem 6 spośród 28-miu cech sygnałów może być wystarczające w przypadku, gdy chcemy zbudować system diagnostyczny rozróżniający te dwie klasy stanu.

Zgodnie z oczekiwaniami dla wszystkich testów, zarówno w przypadku, gdy analiza wrażliwości jest stosowana, jak i w przypadku, gdy nie jest ona stosowana obserwujemy poprawę jakości budowanych modeli diagnostycznych, jeżeli zmienimy zbiór rozpatrywanych cech sygnałów z mniejszego **C5** na większy **C4**.

7.5.2. Testy prowadzone na jednakowych zbiorach uczących i testujących z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech

Przeprowadzone w tym punkcie porównywania wyników testów miały na celu sprawdzenie wpływu bazowego zbioru cech sygnałów (**C5**, **C4**, ..., **C1**) na jakość uzyskiwanych modeli diagnostycznych. Testy wykonano dla jednakowych zbiorów danych uczących i testujących (**B1**) stosując do wyboru cech analizę wrażliwości (**A1**).

Analizując uzyskane wyniki można stwierdzić, że istotną poprawę jakości modeli diagnostycznych otrzymano:

1. Uwzględniając cechy wyznaczone z sygnałów mierzonych w więcej niż jednej płaszczyźnie pomiarowej (**C2**, **C1**) dla prędkości obrotowej $n = 5500$ [obr/min] (tab. 7.12, 7.13).
2. Zmieniając zbiór cech sygnałów z **C5** na inny (**C4**, **C3**, **C2**, **C1**) dla prędkości obrotowej $n = 7200$ [obr/min] (tab. 7.18–7.21).

Tab. 7.10. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4** ($n = 5500$ [obr/min]), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 5500$ [obr/min])				Analiza wrażliwości A1B1C4R? ($n = 5500$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	66,9 %	82,8 %	A1B1C4R0.4	166	67,5 %	83,7 %
0,5	A1B1C5R0.5	166	66,9 %	82,8 %	A1B1C4R0.5	166	63,3 %	81,3 %
0,6	A1B1C5R0.6	166	66,3 %	82,5 %	A1B1C4R0.6	166	63,9 %	81,3 %
0,7	A1B1C5R0.7	166	60,2 %	79,5 %	A1B1C4R0.7	166	61,4 %	80,7 %
0,8	A1B1C5R0.8	166	58,4 %	78,6 %	A1B1C4R0.8	166	66,3 %	82,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,738

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,549

Tab. 7.11. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3** ($n = 5500[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 5500[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C3R? ($n = 5500[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	66,9 %	82,8 %	A1B1C3R0.4	166	67,5 %	83,7 %
0,5	A1B1C5R0.5	166	66,9 %	82,8 %	A1B1C3R0.5	166	63,3 %	81,3 %
0,6	A1B1C5R0.6	166	66,3 %	82,5 %	A1B1C3R0.6	166	63,9 %	81,3 %
0,7	A1B1C5R0.7	166	60,2 %	79,5 %	A1B1C3R0.7	166	61,4 %	80,7 %
0,8	A1B1C5R0.8	166	58,4 %	78,6 %	A1B1C3R0.8	166	66,3 %	82,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,738

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,549

Tab. 7.12. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2** ($n = 5500[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 5500[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C2R? ($n = 5500[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	66,9 %	82,8 %	A1B1C2R0.4	166	80,7 %	90,4 %
0,5	A1B1C5R0.5	166	66,9 %	82,8 %	A1B1C2R0.5	166	78,9 %	89,5 %
0,6	A1B1C5R0.6	166	66,3 %	82,5 %	A1B1C2R0.6	166	69,9 %	84,9 %
0,7	A1B1C5R0.7	166	60,2 %	79,5 %	A1B1C2R0.7	166	66,3 %	83,1 %
0,8	A1B1C5R0.8	166	58,4 %	78,6 %	A1B1C2R0.8	166	66,3 %	83,1 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0425

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0257

Tab. 7.13. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1** ($n = 5500[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 5500[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C1R? ($n = 5500[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	66,9 %	82,8 %	A1B1C1R0.4	166	80,7 %	90,4 %
0,5	A1B1C5R0.5	166	66,9 %	82,8 %	A1B1C1R0.5	166	78,9 %	89,5 %
0,6	A1B1C5R0.6	166	66,3 %	82,5 %	A1B1C1R0.6	166	69,9 %	84,9 %
0,7	A1B1C5R0.7	166	60,2 %	79,5 %	A1B1C1R0.7	166	66,3 %	83,1 %
0,8	A1B1C5R0.8	166	58,4 %	78,6 %	A1B1C1R0.8	166	66,3 %	83,1 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0425

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0257

Tab. 7.14. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C4R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	80,7 %	90,1 %	A1B1C4R0.4	166	80,7 %	90,4 %
0,5	A1B1C5R0.5	166	77,1 %	88,3 %	A1B1C4R0.5	166	78,9 %	89,2 %
0,6	A1B1C5R0.6	166	75,9 %	87,7 %	A1B1C4R0.6	166	78,3 %	88,9 %
0,7	A1B1C5R0.7	166	72,9 %	85,8 %	A1B1C4R0.7	166	76,5 %	88 %
0,8	A1B1C5R0.8	166	75,3 %	87 %	A1B1C4R0.8	166	77,7 %	88,6 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,198

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,168

Tab. 7.15. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C3R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	80,7 %	90,1 %	A1B1C3R0.4	166	77,1 %	88,6 %
0,5	A1B1C5R0.5	166	77,1 %	88,3 %	A1B1C3R0.5	166	75,9 %	87,7 %
0,6	A1B1C5R0.6	166	75,9 %	87,7 %	A1B1C3R0.6	166	75,9 %	87,7 %
0,7	A1B1C5R0.7	166	72,9 %	85,8 %	A1B1C3R0.7	166	77,1 %	88,3 %
0,8	A1B1C5R0.8	166	75,3 %	87 %	A1B1C3R0.8	166	77,7 %	88,6 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,793

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,605

Tab. 7.16. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C2R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	80,7 %	90,1 %	A1B1C2R0.4	166	77,1 %	88,6 %
0,5	A1B1C5R0.5	166	77,1 %	88,3 %	A1B1C2R0.5	166	75,9 %	87,7 %
0,6	A1B1C5R0.6	166	75,9 %	87,7 %	A1B1C2R0.6	166	75,9 %	87,7 %
0,7	A1B1C5R0.7	166	72,9 %	85,8 %	A1B1C2R0.7	166	77,1 %	88,3 %
0,8	A1B1C5R0.8	166	75,3 %	87 %	A1B1C2R0.8	166	77,7 %	88,6 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,793

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,605

Tab. 7.17. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C1R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	80,7 %	90,1 %	A1B1C1R0.4	166	78,9 %	89,2 %
0,5	A1B1C5R0.5	166	77,1 %	88,3 %	A1B1C1R0.5	166	78,9 %	89,2 %
0,6	A1B1C5R0.6	166	75,9 %	87,7 %	A1B1C1R0.6	166	75,3 %	87,3 %
0,7	A1B1C5R0.7	166	72,9 %	85,8 %	A1B1C1R0.7	166	74,1 %	86,7 %
0,8	A1B1C5R0.8	166	75,3 %	87 %	A1B1C1R0.8	166	75,3 %	87,3 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,943

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,861

Tab. 7.18. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C4R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	67,5 %	83,7 %	A1B1C4R0.4	166	75,9 %	88 %
0,5	A1B1C5R0.5	166	66,9 %	83,1 %	A1B1C4R0.5	166	72,3 %	86,1 %
0,6	A1B1C5R0.6	166	64,5 %	81,9 %	A1B1C4R0.6	166	72,3 %	86,1 %
0,7	A1B1C5R0.7	166	63,3 %	81,3 %	A1B1C4R0.7	166	68,7 %	84,3 %
0,8	A1B1C5R0.8	166	62 %	80,7 %	A1B1C4R0.8	166	65,7 %	82,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0165

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0131

Tab. 7.19. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C3R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	67,5 %	83,7 %	A1B1C3R0.4	166	84,9 %	92,5 %
0,5	A1B1C5R0.5	166	66,9 %	83,1 %	A1B1C3R0.5	166	77,1 %	88,6 %
0,6	A1B1C5R0.6	166	64,5 %	81,9 %	A1B1C3R0.6	166	77,1 %	88,6 %
0,7	A1B1C5R0.7	166	63,3 %	81,3 %	A1B1C3R0.7	166	72,9 %	86,1 %
0,8	A1B1C5R0.8	166	62 %	80,7 %	A1B1C3R0.8	166	73,5 %	86,7 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,000874

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00094

Tab. 7.20. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C2R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	67,5 %	83,7 %	A1B1C2R0.4	166	78,9 %	89,5 %
0,5	A1B1C5R0.5	166	66,9 %	83,1 %	A1B1C2R0.5	166	79,5 %	89,8 %
0,6	A1B1C5R0.6	166	64,5 %	81,9 %	A1B1C2R0.6	166	71,7 %	85,5 %
0,7	A1B1C5R0.7	166	63,3 %	81,3 %	A1B1C2R0.7	166	71,7 %	85,5 %
0,8	A1B1C5R0.8	166	62 %	80,7 %	A1B1C2R0.8	166	70,5 %	84,9 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00245

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00365

Tab. 7.21. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości, dla jednakowych zbiorów uczących i testujących.

R? (r_a)	Analiza wrażliwości A1B1C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B1C1R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B1C5R0.4	166	67,5 %	83,7 %	A1B1C1R0.4	166	78,9 %	89,5 %
0,5	A1B1C5R0.5	166	66,9 %	83,1 %	A1B1C1R0.5	166	79,5 %	89,8 %
0,6	A1B1C5R0.6	166	64,5 %	81,9 %	A1B1C1R0.6	166	71,7 %	85,5 %
0,7	A1B1C5R0.7	166	63,3 %	81,3 %	A1B1C1R0.7	166	71,7 %	85,5 %
0,8	A1B1C5R0.8	166	62 %	80,7 %	A1B1C1R0.8	166	70,5 %	84,9 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,00245

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,00365

W pierwszym przypadku powodem poprawy jakości uzyskiwanych wyników było to, iż cechy wyznaczone dla sygnałów związanych z drugą płaszczyzną pomiarową (zbiory cech **C1** oraz **C2**) charakteryzowały się zdecydowanie większą wrażliwością. W drugim przypadku najbardziej wrażliwymi na zmianę klas stanu okazały się cechy związane z trajekcją centralną (rozdział 6.3), uwzględnione w zbiorach cech **C1**, **C2** oraz **C3**. Przyglądając się wynikom uzyskanym dla prędkości obrotowej $n = 6300[\text{obr}/\text{min}]$ (tab. 7.14–7.17) nie zaobserwowano żadnych istotnych różnic. Spowodowane to jest tym, iż największą wrażliwością charakteryzowały się cechy związane z przemieszczeniami w pierwszej płaszczyźnie pomiarowej, w kierunku poziomym, uwzględnione we wszystkich rozpatrywanych zbiorach cech (**C1**, **C2**, ..., **C5**).

Dla kilku przypadków, gdy przed identyfikacją systemu diagnostycznego przeprowadzona została analiza wrażliwości, otrzymano identyczne wyniki:

- testy **A1B1C1R?** (tab. 7.13) oraz **A1B1C2R?** (tab. 7.12) dla prędkości obrotowej $n = 5500[\text{obr}/\text{min}]$;

- testy **A1B1C3R?** (tab. 7.11) oraz **A1B1C4R?** (tab. 7.10) także dla prędkości obrotowej $n = 5500$ [obr/min];
- testy **A1B1C2R?** (tab. 7.16) oraz **A1B1C3R?** (tab. 7.15) dla prędkości obrotowej $n = 6300$ [obr/min];
- testy **A1B1C1R?** (tab. 7.21) oraz **A1B1C2R?** (tab. 7.20) dla prędkości obrotowej $n = 7200$ [obr/min].

Związane jest to z wyborem za pomocą analizy wrażliwości dla powyższych par testów tych samych cech sygnałów.

Uwzględniając wszystkie wyznaczone cechy dla przemieszczeń względnych (**C1**) najwyższe oceny uzyskano dla prędkości obrotowej $n = 7200$ [obr/min] przy parametrze $r_a = 0,4$ (tab. 7.19, 7.22). Oceny te ($O_1 = 84,9\%$ oraz $O_2 = 92,5\%$) są najlepsze z uzyskanych w przypadku stosowania analizy wrażliwości.

Tab. 7.22. Wyniki klasyfikacji uzyskane dla jednakowych zbiorów uczących i testujących, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C3**, $n = 6300$ [obr/min] oraz dla $r_a = 0,4$ (**A1B1C3R0.4**).

		Masa niewyw. [g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	13	1		14	92,9%	96,4%
		0,6	44	8		52	84,6%	92,3%
	B_2	0,8	1	5		6	83,3%	91,7%
		1	8	42	2	52	80,8%	90,4%
		1,2		4		4	100%	100%
	B_3	1,4			2	2	100%	100%
1,6			5	31	36	86,1%	93,1%	
Ogółem					166	84,9%	92,5%	

7.5.3. Testy prowadzone metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości

Porównując wyniki uzyskane z testów, w których zbiory danych uczących i testujących były identyczne (rozdział 7.5.1), okazało się, że zastosowanie analizy wrażliwości do selekcji cech sygnałów pogarsza jakość uzyskiwanych modeli diagnostycznych. O tym, czy to jest efekt zbyt dobrego dopasowania się modelu diagnostycznego do danych, czy też efekt zastosowania analizy wrażliwości można przekonać się przeprowadzając testy metodą *leave one out* (**B2**).

Tak jak poprzednio, możliwe są tutaj do przeprowadzenia dwa porównania dla zbiorów cech ograniczonych do jednej płaszczyzny pomiarowej (**C5**, **C4**).

Przyglądając się otrzymanym wynikom klasyfikacji (oceny O_1 oraz O_2) można stwierdzić, że we wszystkich przypadkach są one lepsze dla testów, w których do wyboru cech

sygnałów była stosowana analiza wrażliwości (**A1**). W prawie połowie przypadków różnice w wartościach ocen były istotne:

- dla zbioru cech **C5** związanych z prędkością obrotową $n = 5500$ [obr/min] (tab. 7.23) p -wartość dla oceny O_1 jest mniejsza od 5%;
- dla zbioru cech **C4** związanych z prędkością obrotową $n = 6300$ [obr/min] (tab. 7.26) p -wartość dla obu wyznaczanych ocen jest mniejsza od 0,1%;
- dla zbioru cech **C4** związanych z prędkością obrotową $n = 7200$ [obr/min] (tab. 7.28) p -wartość dla oceny O_1 jest mniejsza od 5%, a dla oceny O_2 mniejsza od 2%.

W przypadku zastosowania analizy wrażliwości najwyższe wartości ocen ($O_1 = 69,3\%$ oraz $O_2 = 83,7\%$) otrzymano dla testu **A1B2C5R0.7**, $n = 6300$ [obr/min] (tab. 7.29). Są one lepsze od najlepszych ocen ($O_1 = 63,9\%$ oraz $O_2 = 81,3\%$) uzyskanych w przypadku gdy analiza wrażliwości nie była przeprowadzana (test **A2B2C5R0.8**, $n = 6300$ [obr/min], tab. 7.30).

Bardzo ważnym, jeszcze nie omawianym szerzej problemem, jest czas realizacji obliczeń. Wzrósł on znacznie w przypadku testów, w których nie przeprowadzano analizy wrażliwości (**A2**). Dało się szczególnie odczuć przy zastosowaniu do wyboru danych uczących i testujących metody *leave one out* (**B2**), gdzie dla każdego testu 166 razy przeprowadzana była procedura identyfikacji modelu diagnostycznego.

Przykładowy czas obliczeń dla zbioru cech **C4** i prędkości obrotowej $n = 7200$ [obr/min] wynosił:

- 5–20[s/model diag.], jeżeli przeprowadzana była wstępnie analiza wrażliwości;
- 2–3[godz./model diag.], jeżeli uwzględniano wszystkie cechy ze zbioru **C4**.

Był on zatem w przypadku zastosowania analizy wrażliwości około 1000 krotnie krótszy.

Uwzględniając powyższe spostrzeżenia można śmiało stwierdzić, że zamiast bardziej skomplikowanych modeli diagnostycznych, posiadających dużą liczbę parametrów do wyznaczenia można budować modele prostsze, uzyskujące lepsze pod względem jakości klasyfikacji wyniki, wykorzystując do tego celu analizę wrażliwości.

Tab. 7.23. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**, $n = 5500$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 5500$ [obr/min])				Brak analizy wrażliwości A2B2C5R? ($n = 5500$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	52,4 %	74,1 %	A2B2C5R0.4	166	43,4 %	66 %
0,5	A1B2C5R0.5	166	50,6 %	73,8 %	A2B2C5R0.5	166	49,4 %	71,4 %
0,6	A1B2C5R0.6	166	53,6 %	75 %	A2B2C5R0.6	166	45,8 %	70,2 %
0,7	A1B2C5R0.7	166	54,2 %	75,3 %	A2B2C5R0.7	166	50 %	73,5 %
0,8	A1B2C5R0.8	166	50 %	73,2 %	A2B2C5R0.8	166	51,8 %	74,1 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0459

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0619

Tab. 7.24. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**, $n = 5500$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B2C4R? ($n = 5500$ [obr/min])				Brak analizy wrażliwości A2B2C4R? ($n = 5500$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C4R0.4	166	47 %	71,1 %	A2B2C4R0.4	166	45,8 %	68,1 %
0,5	A1B2C4R0.5	166	50 %	72 %	A2B2C4R0.5	166	42,8 %	64,8 %
0,6	A1B2C4R0.6	166	50,6 %	73,5 %	A2B2C4R0.6	166	50,6 %	71,1 %
0,7	A1B2C4R0.7	166	55,4 %	76,8 %	A2B2C4R0.7	166	53 %	73,2 %
0,8	A1B2C4R0.8	166	50,6 %	74,4 %	A2B2C4R0.8	166	48,8 %	71,4 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,293

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,063

Tab. 7.25. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**, $n = 6300$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 6300$ [obr/min])				Brak analizy wrażliwości A2B2C5R? ($n = 6300$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	62 %	79,8 %	A2B2C5R0.4	166	47 %	72 %
0,5	A1B2C5R0.5	166	63,9 %	81,3 %	A2B2C5R0.5	166	62,7 %	80,1 %
0,6	A1B2C5R0.6	166	63,9 %	81 %	A2B2C5R0.6	166	58,4 %	78,9 %
0,7	A1B2C5R0.7	166	69,3 %	83,7 %	A2B2C5R0.7	166	63,3 %	80,7 %
0,8	A1B2C5R0.8	166	68,1 %	83,1 %	A2B2C5R0.8	166	63,9 %	81,3 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,102

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,122

Tab. 7.26. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**, $n = 6300$ [obr/min].

R? (r_a)	Analiza wrażliwości A1B2C4R? ($n = 6300$ [obr/min])				Brak analizy wrażliwości A2B2C4R? ($n = 6300$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C4R0.4	166	66,3 %	81,9 %	A2B2C4R0.4	166	51,8 %	72,6 %
0,5	A1B2C4R0.5	166	63,3 %	81 %	A2B2C4R0.5	166	52,4 %	74,7 %
0,6	A1B2C4R0.6	166	68,7 %	83,7 %	A2B2C4R0.6	166	51,2 %	72,9 %
0,7	A1B2C4R0.7	166	66,9 %	82,8 %	A2B2C4R0.7	166	60,2 %	78,3 %
0,8	A1B2C4R0.8	166	65,7 %	82,2 %	A2B2C4R0.8	166	58,4 %	78 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,000566

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,000644

Tab. 7.27. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C5**, $n = 7200$ [obr/min].

R? (r_a)	Analiza wrażliwości				Brak analizy wrażliwości			
	A1B2C5R? ($n = 7200$ [obr/min])				A2B2C5R? ($n = 7200$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	44,6 %	70,8 %	A2B2C5R0.4	166	41 %	64,2 %
0,5	A1B2C5R0.5	166	46,4 %	71,7 %	A2B2C5R0.5	166	48,8 %	70,8 %
0,6	A1B2C5R0.6	166	54,2 %	76,5 %	A2B2C5R0.6	166	45,2 %	70,2 %
0,7	A1B2C5R0.7	166	56,6 %	77,4 %	A2B2C5R0.7	166	53 %	74,4 %
0,8	A1B2C5R0.8	166	58,4 %	78,3 %	A2B2C5R0.8	166	53 %	74,7 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,318

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,134

Tab. 7.28. Porównanie wyników testów prowadzonych metodą *leave one out* z zastosowaniem oraz bez zastosowania analizy wrażliwości. Rozpatrywany zbiór cech sygnałów: **C4**, $n = 7200$ [obr/min].

R? (r_a)	Analiza wrażliwości				Brak analizy wrażliwości			
	A1B2C4R? ($n = 7200$ [obr/min])				A2B2C4R? ($n = 7200$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C4R0.4	166	50,6 %	74,7 %	A2B2C4R0.4	166	54,8 %	76,8 %
0,5	A1B2C4R0.5	166	55,4 %	77,1 %	A2B2C4R0.5	166	50 %	71,7 %
0,6	A1B2C4R0.6	166	54,2 %	76,5 %	A2B2C4R0.6	166	48,8 %	69,6 %
0,7	A1B2C4R0.7	166	57,8 %	78 %	A2B2C4R0.7	166	48,8 %	69,6 %
0,8	A1B2C4R0.8	166	55,4 %	76,8 %	A2B2C4R0.8	166	40,4 %	65,4 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0465

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0145

Uzasadnia to dodatkowo fakt, iż przeprowadzając testy metodą *leave one out*, nie mogło nastąpić zbytne dopasowanie się modelu diagnostycznego do danych, ponieważ dane testujące nie znajdują się w zbiorze danych uczących.

Wyniki przedstawionych w rozdziale 7.5.1 testów mogły nasunąć błędny wniosek sugerujący, iż analiza wrażliwości pogarsza jakość budowanych z jej uwzględnieniem modeli diagnostycznych. Przyglądając się jednak przedstawionym w tym rozdziale wynikom testów zauważamy:

- niewielkie, o około 10%, pogorszenie się wyników klasyfikacji po zastosowaniu metody *leave one out* (**B2**) dla testów, w których stosowana była analiza wrażliwości (**A1**). Oceny O_1 i O_2 wyznaczone dla testów **A1B1C?R?** oraz **A1B2C?R?**;
- duże, o około 30%, pogorszenie się wyników klasyfikacji w przypadku, gdy analiza wrażliwości nie była stosowana (**A2**). Oceny O_1 i O_2 wyznaczone dla testów **A2B1C?R?** oraz **A2B2C?R?**.

Widzimy zatem, że przeprowadzając analizę wrażliwości otrzymujemy niejako cechy niosące uogólnialną na wszystkie stany informację o interesujących nas klasach stanu. Pozwala to zastosować do budowy modeli diagnostycznych narzędzia, które na takie uogólnienia nie pozwalają, lub w przypadku których, trudno jest określić stopień dopasowania identyfikowanych przez te narzędzia modeli do danych uczących.

Tab. 7.29. Wyniki klasyfikacji uzyskane dla testów prowadzonych metodą *leave one out*, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C5**, $n = 6300$ [obr/min] oraz dla $r_a = 0,7$ (**A1B2C5R0.7**).

		Masa niewyw.[g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	6	7	1	14	42,9%	67,9%
		0,6	38	14		52	73,1%	86,5%
	B_2	0,8	2	3	1	6	50%	75%
		1	5	43	5	53	81,1%	90,6%
		1,2	1	1	2	4	25%	62,5%
	B_3	1,4		2	0	2	0%	50%
1,6		2	9	24	35	68,6%	81,4%	
Ogółem						166	69,3%	83,7%

Tab. 7.30. Wyniki klasyfikacji uzyskane dla testów prowadzonych metodą *leave one out*, bez zastosowania analizy wrażliwości, dla zbioru cech sygnałów **C5**, $n = 6300$ [obr/min] oraz dla $r_a = 0,8$ (**A2B2C5R0.8**).

		Masa niewyw.[g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	7	6	1	14	50%	71,4%
		0,6	35	17		52	67,3%	83,7%
	B_2	0,8	1	5		6	83,3%	91,7%
		1	13	36	4	53	67,9%	84%
		1,2	1	2	1	4	50%	75%
	B_3	1,4		2	0	2	0%	50%
1,6		1	13	21	35	60%	78,6%	
Ogółem						166	63,9%	81,3%

7.5.4. Testy prowadzone metodą *leave one out* z zastosowaniem analizy wrażliwości dla różnych bazowych zbiorów cech

Porównując wyniki uzyskane z testów **A1B1C?R?** (rozdział 7.5.2), w których zbiory danych uczących i testujących były identyczne (**B1**), okazało się, że istotna poprawa otrzymywanych wyników następuje przy zwiększeniu zbioru cech sygnałów jedynie dla prędkości obrotowej $n = 5500$ [obr/min] oraz $n = 7200$ [obr/min].

O tym, jak wielkość zbioru cech sygnałów wpływa na jakość budowanych modeli diagnostycznych w przypadku testów przeprowadzonych z użyciem metody *leave one out* (**B2**), można się dowiedzieć analizując wyniki porównań ocen uzyskanych dla testów **A1B2C?R?**.

Analizując uzyskane wyniki można stwierdzić, że istotną poprawę jakości modeli diagnostycznych otrzymano:

1. Uwzględniając cechy wyznaczone z sygnałów mierzonych w więcej niż jednej płaszczyźnie pomiarowej (**C2**, **C1**) dla prędkości obrotowej $n = 5500$ [obr/min] (tab. 7.33, 7.34).
2. Uwzględniając wszystkie cechy sygnałów (**C1**) w przypadku prędkości obrotowej $n = 6300$ [obr/min] (tab. 7.38).

W pierwszym przypadku, podobnie jak w rozdziale 7.5.2, powodem poprawy jakości uzyskiwanych wyników było to, iż cechy wyznaczone dla sygnałów związanych z drugą płaszczyzną pomiarową (zbiory cech **C1** oraz **C2**) charakteryzowały się zdecydowanie większą wrażliwością od pozostałych cech. W drugim przypadku najbardziej wrażliwymi na zmianę klas stanu okazały się cechy związane z trajektorią centralną (rozdział 6.3) wyznaczone dla drugiej płaszczyzny pomiarowej. Zawiera je tylko zbiór cech **C1**. Przeglądając się wynikom uzyskanym dla prędkości obrotowej $n = 7200$ [obr/min] (tab. 7.39–7.42) nie zaobserwowano żadnych istotnych różnic, pomimo tego, iż były one obserwowane dla testów, w których zbiory danych uczących i testujących były identyczne (rozdział 7.5.2).

Podobnie jak dla testów **A1B1C?R?** (rozdział 7.5.2) w dwóch przypadkach, gdy do wyboru cech stosowano analizę wrażliwości, otrzymano identyczne wyniki:

- testy **A1B2C1R?** (tab. 7.34) oraz **A1B2C2R?** (tab. 7.33) dla prędkości obrotowej $n = 5500$ [obr/min];
- testy **A1B2C3R?** (tab. 7.32) oraz **A1B2C4R?** (tab. 7.31) także dla prędkości obrotowej $n = 5500$ [obr/min].

Tab. 7.31. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4** ($n = 5500$ [obr/min]), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 5500$ [obr/min])				Analiza wrażliwości A1B2C4R? ($n = 5500$ [obr/min])			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	52,4 %	74,1 %	A1B2C4R0.4	166	47 %	71,1 %
0,5	A1B2C5R0.5	166	50,6 %	73,8 %	A1B2C4R0.5	166	50 %	72 %
0,6	A1B2C5R0.6	166	53,6 %	75 %	A1B2C4R0.6	166	50,6 %	73,5 %
0,7	A1B2C5R0.7	166	54,2 %	75,3 %	A1B2C4R0.7	166	55,4 %	76,8 %
0,8	A1B2C5R0.8	166	50 %	73,2 %	A1B2C4R0.8	166	50,6 %	74,4 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,388

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,518

Tab. 7.32. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3** ($n = 5500[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 5500[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C3R? ($n = 5500[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	52,4 %	74,1 %	A1B2C3R0.4	166	47 %	71,1 %
0,5	A1B2C5R0.5	166	50,6 %	73,8 %	A1B2C3R0.5	166	50 %	72 %
0,6	A1B2C5R0.6	166	53,6 %	75 %	A1B2C3R0.6	166	50,6 %	73,5 %
0,7	A1B2C5R0.7	166	54,2 %	75,3 %	A1B2C3R0.7	166	55,4 %	76,8 %
0,8	A1B2C5R0.8	166	50 %	73,2 %	A1B2C3R0.8	166	50,6 %	74,4 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,388

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,518

Tab. 7.33. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2** ($n = 5500[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 5500[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C2R? ($n = 5500[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	52,4 %	74,1 %	A1B2C2R0.4	166	62,7 %	80,1 %
0,5	A1B2C5R0.5	166	50,6 %	73,8 %	A1B2C2R0.5	166	63,9 %	80,7 %
0,6	A1B2C5R0.6	166	53,6 %	75 %	A1B2C2R0.6	166	59 %	78,6 %
0,7	A1B2C5R0.7	166	54,2 %	75,3 %	A1B2C2R0.7	166	60,8 %	79,8 %
0,8	A1B2C5R0.8	166	50 %	73,2 %	A1B2C2R0.8	166	60,8 %	79,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 4,91e-005

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 5,13e-006

Tab. 7.34. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1** ($n = 5500[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 5500[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C1R? ($n = 5500[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	52,4 %	74,1 %	A1B2C1R0.4	166	62,7 %	80,1 %
0,5	A1B2C5R0.5	166	50,6 %	73,8 %	A1B2C1R0.5	166	63,9 %	80,7 %
0,6	A1B2C5R0.6	166	53,6 %	75 %	A1B2C1R0.6	166	59 %	78,6 %
0,7	A1B2C5R0.7	166	54,2 %	75,3 %	A1B2C1R0.7	166	60,8 %	79,8 %
0,8	A1B2C5R0.8	166	50 %	73,2 %	A1B2C1R0.8	166	60,8 %	79,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 4,91e-005

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 5,13e-006

Tab. 7.35. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C4R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	62 %	79,8 %	A1B2C4R0.4	166	66,3 %	81,9 %
0,5	A1B2C5R0.5	166	63,9 %	81,3 %	A1B2C4R0.5	166	63,3 %	81 %
0,6	A1B2C5R0.6	166	63,9 %	81 %	A1B2C4R0.6	166	68,7 %	83,7 %
0,7	A1B2C5R0.7	166	69,3 %	83,7 %	A1B2C4R0.7	166	66,9 %	82,8 %
0,8	A1B2C5R0.8	166	68,1 %	83,1 %	A1B2C4R0.8	166	65,7 %	82,2 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,664

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,54

Tab. 7.36. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C3R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	62 %	79,8 %	A1B2C3R0.4	166	65,1 %	81,9 %
0,5	A1B2C5R0.5	166	63,9 %	81,3 %	A1B2C3R0.5	166	65,7 %	82,5 %
0,6	A1B2C5R0.6	166	63,9 %	81 %	A1B2C3R0.6	166	70,5 %	84,6 %
0,7	A1B2C5R0.7	166	69,3 %	83,7 %	A1B2C3R0.7	166	69,9 %	84,3 %
0,8	A1B2C5R0.8	166	68,1 %	83,1 %	A1B2C3R0.8	166	66,3 %	82,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,282

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,143

Tab. 7.37. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C2R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	62 %	79,8 %	A1B2C2R0.4	166	65,1 %	81,9 %
0,5	A1B2C5R0.5	166	63,9 %	81,3 %	A1B2C2R0.5	166	66,9 %	83,1 %
0,6	A1B2C5R0.6	166	63,9 %	81 %	A1B2C2R0.6	166	71,1 %	84,9 %
0,7	A1B2C5R0.7	166	69,3 %	83,7 %	A1B2C2R0.7	166	70,5 %	84,6 %
0,8	A1B2C5R0.8	166	68,1 %	83,1 %	A1B2C2R0.8	166	66,9 %	83,1 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,179

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0896

Tab. 7.38. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1** ($n = 6300[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 6300[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C1R? ($n = 6300[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	62 %	79,8 %	A1B2C1R0.4	166	72,9 %	85,8 %
0,5	A1B2C5R0.5	166	63,9 %	81,3 %	A1B2C1R0.5	165	67,9 %	83,3 %
0,6	A1B2C5R0.6	166	63,9 %	81 %	A1B2C1R0.6	166	68,1 %	83,7 %
0,7	A1B2C5R0.7	166	69,3 %	83,7 %	A1B2C1R0.7	166	71,1 %	85,2 %
0,8	A1B2C5R0.8	166	68,1 %	83,1 %	A1B2C1R0.8	166	65,7 %	82,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0851

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,0387

Tab. 7.39. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C4** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C4R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	44,6 %	70,8 %	A1B2C4R0.4	166	50,6 %	74,7 %
0,5	A1B2C5R0.5	166	46,4 %	71,7 %	A1B2C4R0.5	166	55,4 %	77,1 %
0,6	A1B2C5R0.6	166	54,2 %	76,5 %	A1B2C4R0.6	166	54,2 %	76,5 %
0,7	A1B2C5R0.7	166	56,6 %	77,4 %	A1B2C4R0.7	166	57,8 %	78 %
0,8	A1B2C5R0.8	166	58,4 %	78,3 %	A1B2C4R0.8	166	55,4 %	76,8 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,405

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,333

Tab. 7.40. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C3** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C3R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	44,6 %	70,8 %	A1B2C3R0.4	166	47 %	72 %
0,5	A1B2C5R0.5	166	46,4 %	71,7 %	A1B2C3R0.5	166	53 %	75,3 %
0,6	A1B2C5R0.6	166	54,2 %	76,5 %	A1B2C3R0.6	166	57,2 %	77,4 %
0,7	A1B2C5R0.7	166	56,6 %	77,4 %	A1B2C3R0.7	166	56,6 %	77,1 %
0,8	A1B2C5R0.8	166	58,4 %	78,3 %	A1B2C3R0.8	166	59,6 %	78,9 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,476

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,554

Tab. 7.41. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C2** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C2R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	44,6 %	70,8 %	A1B2C2R0.4	166	55,4 %	76,5 %
0,5	A1B2C5R0.5	166	46,4 %	71,7 %	A1B2C2R0.5	166	57,2 %	77,1 %
0,6	A1B2C5R0.6	166	54,2 %	76,5 %	A1B2C2R0.6	166	57,8 %	78,3 %
0,7	A1B2C5R0.7	166	56,6 %	77,4 %	A1B2C2R0.7	166	57,2 %	78 %
0,8	A1B2C5R0.8	166	58,4 %	78,3 %	A1B2C2R0.8	166	59,6 %	79,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,0945

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,108

Tab. 7.42. Porównywanie wyników testów dla zbiorów cech sygnałów: **C5** i **C1** ($n = 7200[\text{obr}/\text{min}]$), prowadzonych z zastosowaniem analizy wrażliwości metodą *leave one out*.

R? (r_a)	Analiza wrażliwości A1B2C5R? ($n = 7200[\text{obr}/\text{min}]$)				Analiza wrażliwości A1B2C1R? ($n = 7200[\text{obr}/\text{min}]$)			
	Test	n	O_1	O_2	Test	n	O_1	O_2
0,4	A1B2C5R0.4	166	44,6 %	70,8 %	A1B2C1R0.4	166	54,8 %	76,2 %
0,5	A1B2C5R0.5	166	46,4 %	71,7 %	A1B2C1R0.5	166	57,2 %	77,1 %
0,6	A1B2C5R0.6	166	54,2 %	76,5 %	A1B2C1R0.6	166	57,8 %	78,3 %
0,7	A1B2C5R0.7	166	56,6 %	77,4 %	A1B2C1R0.7	166	57,2 %	78 %
0,8	A1B2C5R0.8	166	58,4 %	78,3 %	A1B2C1R0.8	166	59,6 %	79,5 %

p -wartość dla hipotezy H_0 o równości średnich ocen O_1 wynosi 0,103

p -wartość dla hipotezy H_0 o równości średnich ocen O_2 wynosi 0,117

Związane jest to z wyborem tych samych cech sygnałów jako najbardziej wrażliwych. W pierwszym przypadku były to cechy wyznaczone na podstawie sygnałów przemieszczeń względnych zarejestrowanych w drugiej płaszczyźnie pomiarowej. W drugim przypadku były to cechy sygnałów, które zawierał zarówno zbiór cech **C4**, jak i zbiór **C3**.

Uwzględniając wszystkie wyznaczone cechy najwyższe oceny uzyskano dla prędkości obrotowej $n = 6300[\text{obr}/\text{min}]$ przy parametrze $r_a = 0,4$ (tab. 7.38, 7.43). Wynoszą one odpowiednio $O_1 = 72,9\%$ oraz $O_2 = 85,8\%$ i są najlepsze z uzyskanych w przypadku testów prowadzonych metodą *leave one out*.

Tab. 7.43. Wyniki klasyfikacji uzyskane dla testów prowadzonych metodą *leave one out*, przy zastosowaniu analizy wrażliwości, dla zbioru cech sygnałów **C1**, $n = 6300$ [obr/min] oraz dla $r_a = 0,4$ (**A1B2C1R0.4**).

		Masa niewyw.[g]	Oszacowane klasy stanu			Liczba stanów	Ocena nr 1	Ocena nr 2
			B_1	B_2	B_3			
Oczekiwane klasy stanu	B_1	0	8	6		14	57,1%	78,6%
		0,6	39	12	1	52	75%	86,5%
	B_2	0,8	1	5		6	83,3%	91,7%
		1	10	43		53	81,1%	90,6%
		1,2		3	1	4	75%	87,5%
	B_3	1,4		1	1	2	50%	75%
1,6		1	12	22	35	62,9%	80%	
Ogółem						166	72,9%	85,8%

7.6. Wnioski

Na podstawie porównań otrzymanych wyników testów, przeprowadzonych na danych pochodzących z badań rzeczywistego obiektu technicznego, można stwierdzić, że:

1. Klasyfikacja stanów jest w wielu przypadkach poprawna pomimo, iż w jednej klasie stanu umieszczono stany związane z:
 - różnymi wartościami oraz lokalizacjami niewyważenia na tarczy nr 2;
 - różnymi lokalizacjami niewyważenia na tarczy nr 1.
2. Pomimo, iż stany należące do klasy stanu B_1 były niepoprawnie klasyfikowane, to przypisywano je zazwyczaj klasie B_2 co można traktować jako mniejszy błąd niż przypisanie ich do klasy B_3 .
3. Podobnie jak powyżej stany należące do klasy stanu B_3 częściej klasyfikowano do klasy B_2 , niż do klasy B_1 .
4. Zgodnie z oczekiwaniami, dla przypadku, w którym zbiór danych uczących był równy zbiorowi danych testujących, otrzymano lepsze wyniki niż dla metody *leave one out*.
5. Jeżeli zbiór cech jest na tyle mały, że można go w całości zastosować do identyfikacji modelu diagnostycznego, to ograniczenie tego zbioru za pomocą analizy wrażliwości:
 - polepszy lub nie wpłynie w znaczący sposób na jakość modeli diagnostycznych, w przypadku zastosowania metody *leave one out*;

- pogorszy jakość modeli diagnostycznych, w przypadku, gdy zbiory danych uczących i testujących są jednakowe.
6. Uwzględniając punkt nr 5 oraz mając na uwadze, że w przypadku jednakowych zbiorów danych uczący i testujący, model diagnostyczny mógł zbyt dobrze dopasować się do danych, prawdziwym staje się to, iż:
 - zastosowanie analizy wrażliwości pozwala uprościć, identyfikowany na podstawie danych uczących model diagnostyczny;
 - zastosowanie analizy wrażliwości do identyfikacji prostszego modelu diagnostycznego wymaga mniejszych nakładów obliczeniowych;
 - korzystając z analizy wrażliwości i budując prostszy model diagnostyczny wymaganych jest mniejsza liczba przykładów uczących.
 7. Jeżeli zbiór cech sygnałów jest zbyt duży, żeby można go było w całości uwzględnić przy identyfikacji modelu diagnostycznego, to zastosowanie analizy wrażliwości może być optymalnym rozwiązaniem, jeżeli chodzi o selekcję tych cech.
 8. Stosując metodę *leave one out* maksymalna liczba 6-ciu wrażliwych cech sygnałów wybranych ze zbioru 150-ciu cech pozwala uzyskać znacząco lepsze wyniki klasyfikacji, niż 28 cech wybranych w sposób przypadkowy lub w sposób, który dla osoby dokonującej wyboru mógł wydawać się najlepszy.
 9. Polepszenia wyników klasyfikacji możemy się spodziewać jeżeli wartości wrażliwości będą większe. Można tego dokonać:
 - zwiększając zbiór rozpatrywanych cech sygnałów, co zostało udowodnione;
 - w inny, bardziej optymalny sposób definiując klasy stanu;
 - zwiększając zbiór stanów należących do poszczególnych klas stanu;
 - zmniejszając liczbę klas stanu.

Rozdział 8

Podsumowanie i wnioski

Praca ta jest wynikiem badań mających na celu znalezienie miar wrażliwości cech sygnałów diagnostycznych. Po określeniu wymogów i ograniczeń związanych z wykonaniem tego zadania zaproponowano szereg definicji wrażliwości, których stosowanie uzależnione jest od danych, jakimi dysponuje badacz. Na podstawie przedstawionych definicji opracowano i opisano dwie metody wyznaczania wartości wrażliwości diagnostycznej:

- metodę opartą na różnicach wartości cech sygnałów, w której wyznaczone są wartości wrażliwości dla wszystkich kombinacji cech sygnałów i klas stanu;
- metodę statystyczną, w której określane są wrażliwości cząstkowe, grupowe oraz główne.

Określenie wyłącznie wartości wrażliwości i wybór jednej, najbardziej wrażliwej cechy sygnału może być niewystarczające w przypadku, gdy naszym zadaniem jest określenie klasy stanu technicznego badanego obiektu. Powodem tego może być zbyt mała ilość informacji zawarta w takiej cesze. Uwzględniając jednak kilka cech jednocześnie można tą ilość informacji na tyle zwiększyć, że określenie klasy stanu stanie się możliwe. Mając to na uwadze, zaproponowano algorytmy selekcji cech wrażliwych:

- algorytmy sel1 (rys. 5.4) oraz sel2 (rys. 5.5) dla metody opartej na różnicach wartości cech sygnałów;
- algorytmy sel3 (rys. 5.6) oraz sel4 (rys. 5.7) dla metody statystycznej.

Łącząc metody wyznaczania wrażliwości oraz metody selekcji cech wrażliwych zaproponowane zostały dwie metody analizy wrażliwości pozwalające na wybór większej liczby nieskorelowanych ze sobą cech. Są to:

- metoda selekcji wrażliwych cech sygnałów;
- statystyczna metoda analizy wrażliwości.

Druga z tych metod poddana została ocenie mającej na celu potwierdzenie jej przydatności. Badania z tym związane przeprowadzono dla:

- danych pochodzących z eksperymentu numerycznego na modelu turbosespołu 13K215;
- danych zarejestrowanych w trakcie eksperymentu diagnostycznego prowadzonego na stanowisku *Rotor Kit*.

Potwierdzenie przydatności statystycznej metody analizy wrażliwości w wyborze cech sygnałów niosących najwięcej informacji o klasie stanu badanego obiektu, dla każdego rozpatrywanego zbioru danych, wymagało podjęcia się szeregu zadań związanych z:

- określeniem zbioru rozpatrywanych stanów technicznych;
- zdefiniowaniem klas stanu i należących do nich stanów;
- określeniem zbioru rozpatrywanych sygnałów;
- określeniem zbioru wyznaczanych cech sygnałów;
- przeprowadzeniem analizy wrażliwości;
- identyfikacją modelu diagnostycznego;
- zastosowaniem zidentyfikowanego modelu w zadaniu klasyfikacji stanów;
- analizą otrzymanych wyników klasyfikacji.

Analiza otrzymanych wyników pozwoliła na sformułowanie szeregu wniosków i udowodnienie słuszności postawionych tez.

8.1. Wnioski ogólne

Wyniki przedstawionych w pracy badań, przeprowadzonych zarówno na danych pochodzących z eksperymentu numerycznego jak i danych otrzymanych z pomiarów przemieszczeń występujących w rzeczywistym obiekcie technicznym, pozwalają na sformułowanie wniosków ogólnych:

1. Wrażliwość diagnostyczna może być stosowana, w procesie optymalizacji modeli diagnostycznych, jako kryterium wyboru uwzględnianych cech sygnałów. Potwierdzono to przedstawiając przykłady zastosowania, zaproponowanej w pracy, metody badania wrażliwości. Optymalizując zbiór cech sygnałów, a następnie przeprowadzając testy metodą *leave one out* uzyskiwano lepsze, lub w najgorszym razie takie same wyniki, jak w przypadku, gdy optymalizacja ta nie była przeprowadzana.
2. Dla obiektów charakteryzujących się dyskretną przestrzenią stanów, możliwe jest definiowanie miar wrażliwości diagnostycznej, pozwalających na porządkowanie cech sygnałów diagnostycznych. Wykazano to proponując miary wrażliwości, które wyznaczamy, mając daną do dyspozycji dyskretną przestrzeń stanów oraz ciągłą lub dyskretną przestrzeń cech sygnałów. Dysponując tymi miarami, oraz korzystając z zaproponowanych algorytmów selekcji cech wrażliwych, można cechy sygnałów uporządkować wg ilości zawartej w nich, interesującej nas informacji.

Uzupełniając drugi z przedstawionych wniosków można powiedzieć, że uporządkowanie cech sygnałów na podstawie miar wrażliwości diagnostycznej, dla obiektów charakteryzujących się dyskretną przestrzenią stanów, jest nie tylko możliwe, ale pozwala uzyskać poprawę jakości budowanego modelu diagnostycznego pomimo stałej liczby, uwzględnianych przez ten model cech sygnałów. Potwierdzeniem tego są wyniki testów uzyskanych przy zastosowaniu statystycznej metody badania wrażliwości, gdy przy zwiększających

się zbiorach rozpatrywanych cech sygnałów uzyskiwano lepsze lub takie same wyniki. Ponadto, takie same wyniki otrzymywane były zazwyczaj wtedy, gdy cechy najbardziej wrażliwe należały do najmniejszego rozpatrywanego zbioru cech sygnałów.

8.2. Wnioski szczegółowe

Oprócz przedstawionych wniosków ogólnych na podstawie przedstawionych wyników badań sformułowano szereg wniosków szczegółowych. Ujęto je w formie tabeli 8.1. Wyszczególniono w niej kolumny związane z małymi oraz dużymi, w odniesieniu do liczby rozpatrywanych klas stanu, zbiorami przykładów uczących. Odpowiadają one odpowiednio badaniom przeprowadzonym na danych symulacyjnych oraz na danych pomiarowych.

Przedstawione w pracy wyniki pozwalają przypuszczać, że analiza wrażliwości może znaleźć zastosowanie w:

- początkowym etapie projektowania prostych, szybkich i niezawodnych pod względem podejmowanych decyzji układów diagnostycznych, w przypadku, gdy liczba klas stanu jest znana, możliwa do zbadania;
- projektowaniu „inteligentnych” układów diagnostyki, przebudowujących np. zestawy reguł na podstawie wyznaczanych „on-line” wartości wrażliwości po pojawieniu się nowej, nierozpatrywanej dotąd klasy stanu;
- doborze wejść dla dowolnych algorytmów oraz metod, gdzie analiza wrażliwości pozwoli polepszyć jakość otrzymywanych wyników redukując jednocześnie złożoność postawionych zadań.

8.3. Kierunki dalszych badań

Przedstawione metody analizy wrażliwości, a w szczególności metoda statystyczna, mogą znaleźć zastosowanie w optymalizacji istniejących układów diagnostycznych oraz w budowie nowych, bardziej wydajnych oraz niezawodnych. Nowym obszarem w kierunku którego mogą pójść przyszłe badania jest optymalizacja klas stanu. Klasy te przy wykorzystaniu istniejących i stosowanych metod grupowania oraz przedstawionej w pracy metody badania wrażliwości będzie można definiować w sposób optymalny i automatyczny. Podejście takie umożliwi nie tylko wybór najbardziej wrażliwych cech sygnałów dla narzuconego zbioru klas stanu, lecz także pozwoli na określenie takich klas stanu których rozróżnienie będzie najłatwiejsze.

Tab. 8.1. Wnioski szczegółowe dotyczące zastosowania analizy wrażliwości.

	Mały w porównaniu z liczbą rozpatrywanych klas stanu zbior przykładów uczących.	Duży w porównaniu z liczbą rozpatrywanych klas stanu zbior przykładów uczących.
Rozpatrywane są jednakowe zbiory danych uczących oraz testujących.	Uzyskuje się podobne wyniki zarówno przeprowadzając jak i pomijając analizę wrażliwości.	Wyraźnie lepsze wyniki otrzymuje się jeżeli na wstępie nie jest przeprowadzana analiza wrażliwości. Przyczyną tego jest zbytne dopasowanie się modelu diagnostycznego do danych uczących.
Do wyboru zbiorów danych uczących oraz testujących stosowana jest metoda leave one out.	Zarówno w przypadku gdy analiza wrażliwości jest stosowana, jak i przypadku, w którym z niej zrezygnowano otrzymywane są podobne wyniki klasyfikacji.	Obserwowana jest poprawa lub brak zmian jakości modeli diagnostycznych w przypadku skorzystania z analizy wrażliwości.
Problemy związane z budową modelu diagnostycznego.	Jeżeli analiza wrażliwości jest stosowana to rzadziej pojawiają się trudności w wyznaczaniu parametrów budowanego modelu diagnostycznego niż w przypadku, gdy analizę wrażliwości pominięto.	Pominięcie działań związanych z przeprowadzeniem analizy wrażliwości i eliminacją nieistotnych cech przy wystarczającej liczbie danych uczących może prowadzić do konieczności budowy bardziej skomplikowanych modeli diagnostycznych. Wiąże się to z wzrostem czasu obliczeń, większymi wymogami sprzętowymi, itp.
Dopasowanie modelu diagnostycznego do danych.	Pomijając analizę wrażliwości otrzymujemy zbyt dopasowany do danych uczących model diagnostyczny. Nie obserwujemy tego w przypadku, gdy analiza wrażliwości jest stosowana.	
Wpływ wielkości rozpatrywanego zbioru cech.	Zgodnie z oczekiwaniami następuje znacząca poprawa jakości otrzymywanych wyników klasyfikacji jeżeli zwiększymy zbiór rozpatrywanych cech, co do wielkości którego, w przypadku zastosowania analizy wrażliwości nie ma ograniczeń. W przypadku pominięcia analizy wrażliwości występuje ograniczenie liczby cech (wejść modelu diagnostycznego).	

Bibliografia

- [1] Anderson F., Aberg M., Jacobsson S.: *Algorithmic approaches for studies of variable influence, contribution and selection in neural networks*. Chemo-metrics and Intelligent Laboratory Systems, 51(1):61–72, 2000.
- [2] Banaszek S.: *Obliczenia pęknięć wirnika turbozespołu 13K215*. IMP PAN, 2004.
- [3] Blanchard G.: *The 'progressive mixture' estimator for regression trees*. <http://www.dma.ens.fr/edition/preprints/Index.98.html>, 1998.
- [4] Brandt S.: *Analiza danych: metody statystyczne i obliczeniowe*. Wydawnictwo Naukowe PWN, Warszawa, 1999.
- [5] Brun R., Reichert P., Kunsch H.: *Practical identifiability analysis of large environmental simulation models*. Water Resources Research, 37(4):1015–1030, 2001.
- [6] Cempel C.: *Diagnostyka wibroakustyczna maszyn*. PWN, Warszawa, 1989.
- [7] Cempel C.: *Wibroakustyka stosowana*. PWN, Warszawa, 1989.
- [8] Cempel C., Golec M.: *Ocena przydatności miar widmowych procesów wibroakustycznych w diagnostyce maszyn*. Diagnostyka, 61(1):165–182, 1985.
- [9] Chan K., Saltelli A., Tarantola S.: *Sensitivity analysis of model output: Variance-based methods make the difference*. Proceedings of the 1997 Winter Simulation Conference, str. 261–268, 1997.
- [10] Chen M. S., Wang S. W.: *Fuzzy clustering analysis for optimizing fuzzy membership functions*. Fuzzy Sets and Systems, 103:239–254, 1999.
- [11] Chiu S.: *Fuzzy model identification based on cluster estimation*. Journal of Intelligent and Fuzzy Systems, 2:267–278, 1994.
- [12] Cholewa W. (red.): *Metody modelowania obiektów dla potrzeb diagnostyki technicznej*. Projekt badawczy KBN: 8 T07B 023 21, 2004.
- [13] Cholewa W., Cholewa A., Chrzanowski P., Psiuk K.: *Karty diagnostyczne obejmujące wybrane dane z systemu DT200 dla różnych stanów obciążenia*. Politechnika Śląska, Katedra Podstaw Konstrukcji Maszyn, 2003.
- [14] Cholewa W., Kaźmierczak J.: *Diagnostyka techniczna maszyn. Przetwarzanie cech sygnałów*. Wydawnictwo Politechniki Śląskiej, Gliwice, 1992.
- [15] Cholewa W., Kaźmierczak J.: *Data processing and reasoning in technical diagnostics*. WNT, Warszawa, 1995.

- [16] Cholewa W., Kiciński J. (red.): *Diagnostyka techniczna. Odwrotne modele diagnostyczne*. Wydawnictwo Politechniki Śląskiej, Gliwice, 1997.
- [17] Cholewa W., Kiciński J. (red.): *Diagnostyka techniczna. Metody odwracania nieliniowych modeli obiektów*. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Gliwice, 2001.
- [18] Chorowski B., Werszko M.: *Mechaniczne urządzenia sterujące*. PWN, Warszawa, 1974.
- [19] Chrzanowski P.: *Metoda jakościowej oceny cech sygnałów diagnostycznych*. Rozprawa Doktorska. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Gliwice, 2001.
- [20] Chrzanowski P.: *Redukcja danych w diagnostycznych bazach danych*. Diagnostyka, 29, 2003.
- [21] Ciupke K.: *Metoda selekcji i redukcji informacji w diagnostyce maszyn*. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Gliwice, 2001.
- [22] Cullen A., Frey H.: *Probabilistic techniques in exposure assessment*. Plenum Press, New York, 1999.
- [23] Davé R. N., Krishnapuram R.: *Robust clustering methods: a unified view*. IEEE Trans. Fuzzy Systems, 5:270–293, 1997.
- [24] Davidson J., Savic D., Walters G.: *Symbolic and numerical regression: experiments and applications*. Information Sciences, 150:95–117, 2003.
- [25] Demirli K., Cheng S. X., Muthukumaran P.: *Subtractive clustering based modelling of job sequencing with parametric search*. Fuzzy Sets and Systems, 137:235–270, 2003.
- [26] Derksen S., Keselman H.: *Backward, forward and stepwise automated subset selection algorithms: frequency of obtaining authentic and noise variables*. British Journal of Mathematical and Statistical, 45:265–282, 1992.
- [27] Devore J.: *Probability and statistics for engineering and the sciences*. Thomson, Belmont, 2004.
- [28] Devore J., Peck R.: *Statistics: the exploration and analysis of data*. Brooks/Cole Publishing Company, London, 1996.
- [29] Doane D., Mathieson K., Tracy R.: *Visual Statistics 2.0*. McGraw-Hill/Irwin, Boston, 2001.
- [30] Dunaj B.: *Popularny słownik języka polskiego*. ISBN, Warszawa, 2000.
- [31] Eskandari F., Meshkani M.: *Empirical Bayes analysis of log-linear models for a generalized finite stationary Markov chain*. Metrika, 59:173–191, 2004.
- [32] Findeisen W. (red.): *Poradnik inżyniera automatyka*. WNT, 1973.
- [33] Frey C., Patil S.: *Identification and review of sensitivity analysis methods*. NCSU/USDA Workshop on Sensitivity Analysis Methods, North Carolina State University, 2001.

- [34] Fu C. Y.: *Combining loglinear model with classification and regression tree (CART): An application to birth data*. Computational Statistics and Data Analysis, 45:865–874, 2004.
- [35] Geldermann J., Rentz O.: *Integrated technique assessment with imprecise information as a support for the identification of best available techniques*. OR Spectrum, 23(1):137–157, 2001.
- [36] Golec M.: *Ocena przydatności dyskryminant procesów wibroakustycznych w diagnostyce maszyn*. PhD thesis, Politechnika Poznańska, 1981.
- [37] He G., Müller H., Wang J.: *Methods of canonical analysis for functional data*. Journal of Statistical Planning and Inference, 122:141–159, 2004.
- [38] Helton J. i inni: *Uncertainty and sensitivity analysis of food pathway result with MACCS reactor accident consequence model*. Reliability Engineering and System Safety, 49(2):109–144, 1995.
- [39] Hwang D., Byun D., Odman M.: *An automatic differentiation technique for sensitivity analysis of numerical advection schemes in air quality models*. Atmospheric Environment, 31(6):879–888, 1997.
- [40] Kiciński J.: *Teoria i badania hydrodynamicznych poprzecznych łożysk ślizgowych*. Wydawnictwo Polskiej Akademii Nauk, Wrocław, 1994.
- [41] Kiciński J. (red.): *Modelowanie i diagnostyka oddziaływań mechanicznych, aerodynamicznych i magnetycznych w turbospołach energetycznych*. Wydawnictwo IMP PAN, Gdańsk, 2005.
- [42] Kiciński J., Markiewicz-Kicińska A.: *NLDW–LEW–75*. IMP PAN, 2003.
- [43] Kiciński J., Markiewicz-Kicińska A.: *Programy NLDW–75 do obliczeń sprzężonych form drgań giętno–wzdłużno–skrętnych z imperfekcjami typu pęknięcia wału i rozosiowania elementów oraz z zewnętrznymi obciążeniami w formie dodatkowych (poza niewyważeniami) sił poprzecznych, wzdłużnych i momentów skrętnych*. IMP PAN, 2003.
- [44] Kiciński J., Prońska A.: *Identyfikacja modelu obliczeniowego turbospołu 13K215*. IMP PAN, 2004.
- [45] Klimek A.: *Metody doskonalenia odwrotnych modeli diagnostycznych*. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Gliwice, 1999.
- [46] Koivo H.: *Soft computing in dynamical systems*. <http://www.control.hut.fi/Kurssit/as-74.115/Material/>, 2000.
- [47] Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W. (red.): *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*. Wydawnictwa Naukowo–Techniczne, Warszawa, 2002.
- [48] Koronacki J., Mielniczuk J.: *Statystyka dla studentów kierunków technicznych i przyrodniczych*. Wydawnictwo Naukowo–Techniczne, Warszawa, 2001.

- [49] Królicki Z., Żółtowski B.: *Modele diagnostyczne przekładni zębatej*. Diagnostyka, 32, 2004.
- [50] Krzyśko M.: *Analiza dyskryminacyjna*. WNT, Warszawa, 1990.
- [51] Kwok H., Linkens D., Mahfouf M., Mills G.: *Rule-base derivation for intensive care ventilator control using ANFIS*. Artificial Intelligence in Medicine, 29:185–201, 2003.
- [52] Lin C. T.: *A neural fuzzy control scheme with structure and parameter learning*. Fuzzy Sets and Systems, 70:183–212, 1995.
- [53] Lowry R.: *VassarStats: Web site for statistical computation*. <http://faculty.vassar.edu/lowry/VassarStats.html>, 1998-2005.
- [54] Luszniwicz A., Słaby T.: *Statystyka z pakietem komputerowym STATISTICA TM PL: Teoria i zastosowania*. Wydawnictwo C.H. Beck, Warszawa, 2003.
- [55] Łuczak M.: *Badania symulacyjne wpływu defektu w postaci przekoszenia panwi na własności dynamiczne turbozespołu 200 MW*. IMP PAN, 2004.
- [56] Maliński M.: *Weryfikacja hipotez statystycznych wspomagana komputerowo*. Wydawnictwo Politechniki Śląskiej, Gliwice, 2004.
- [57] Malone S., Tarazaga P., Trosset P.: *Better initial configurations for metric multidimensional scaling*. Computational Statistics and Data Analysis, 41:143 – 156, 2002.
- [58] Mańczak K.: *Estymacja parametrów i weryfikacja modeli. Analiza systemowa – podstawy i metodologia*. PWN, Warszawa, 1985.
- [59] Martinez W., Martinez A.: *Computational statistics handbook with Matlab*. Chapman & Hall/CRC, Boca Raton, 2002.
- [60] McCamley F., Rudel R.: *Graphical sensitivity analysis for generalized stochastic dominance*. Journal of Agricultural and Resource Economics, 20(2):403–403, 1995.
- [61] Michie D., Spiegelhalter D., Taylor C.: *Machine learning, neural and statistical classification*. Ellis Horwood Limited, England, 1994.
- [62] Moczulski W.: *Metody pozyskiwania wiedzy dla potrzeb diagnostyki technicznej*. Mechanika, 130, 1997.
- [63] Moczulski W.: *Diagnostyka Techniczna. Metody pozyskiwania wiedzy*. Wydawnictwo Politechniki Śląskiej, Gliwice, 2002.
- [64] Morgan M., Henrion M.: *Uncertainty: A guide to dealing with uncertainty in quantitative risk and policy analysis*. Cambridge University Press, Cambridge, NY, 1990.
- [65] Neter J., Kutner M., Nachtsheim C., Wasserman W.: *Applied linear statistical models*. McGraw–Hill, Chicago, IL, 4 edition, 1996.
- [66] Neter J., Wasserman W., Kutner M.: *Applied linear statistical models: regression, analysis of variance, and experimental designs*. IRWIN, Homewood, 1985.

- [67] Oktaba W.: *Metody statystyki matematycznej w doświadczeniu*. PWN, Warszawa, 1986.
- [68] Paiva R., Dourado A.: *Interpretability and learning in neuro-fuzzy systems*. Fuzzy Sets and Systems, 147:17–38, 2004.
- [69] Penc J.: *Leksykon biznesu*. Agencja Wydawniczo-Poligraficzna „Placet”, Warszawa, 1997.
- [70] Rybczyński J.: *Przemieszczenia termiczne i montażowe podpór łożyskowych*. IMP PAN, 2004.
- [71] Ryu T. W., Christoph C.: *A database clustering methodology and tool*. Information Sciences, 171:29–59, 2004.
- [72] Safizadeh M. H., McKenna D.: *Application of multidimensional scaling techniques to facilities layout*. European Journal of Operational Research, 92:54–62, 1996.
- [73] Saltelli A.: *Sensitivity analysis for importance assessment*. NCSU/USDA Workshop on Sensitivity Analysis Methods, North Carolina State University, 2001.
- [74] Saltelli A., Chan K., Scot E. M.: *Sensitivity analysis*. John Wiley & Sons Ltd., West Sussex, UK, 2000.
- [75] Saltelli A., Tarantola S., Campolongo F., Ratto M.: *Sensitivity analysis in practice*. John Wiley & Sons Ltd., West Sussex, UK, 2004.
- [76] Sławik D.: *Wrażliwość diagnostyczna cech sygnałów wibroakustycznych w dziedzinie częstotliwości*. Burczyński T., Cholewa W. (red.), AI-MECH 2000, Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, str. 319–324, Gliwice, 2000.
- [77] Sławik D.: *Application of statistical methods in the diagnostic sensitivity research*. Burczyński T., Cholewa W., Moczulski W. (red.), AI-METH 2003, Methods of Artificial Intelligence, str. 126–127, Gliwice, 2003.
- [78] Sławik D.: *Badanie wrażliwości diagnostycznej z zastosowaniem metod statystycznych*. VI Krajowa Konferencja Naukowo-Techniczna „Diagnostyka Procesów Przemysłowych” DPP’2003, Władysławowo, 2003.
- [79] Sławik D., Wachla D., Wojtusik J.: *Wrażliwość diagnostyczna cech sygnałów wibroakustycznych*. Korbicz J., Cholewa W. (red.), V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka Procesów Przemysłowych” DPP’2001, str. 439–442, Łągów Lubuski, 2001.
- [80] Sławik D., Wojtusik J.: *Application of heuristic algorithms in inverse modelling*. Burczyński T., Cholewa W. (red.), AI-MECH 2001, Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, str. 255–260, Gliwice, 2001.
- [81] Sławik D., Wojtusik J.: *Kryterium wyboru cech sygnałów wibroakustycznych dla potrzeb odwracania modeli diagnostycznych*. Korbicz J., Cholewa W. (red.), V Krajowa Konferencja Naukowo-Techniczna „Diagnostyka Procesów Przemysłowych” DPP’2001, Łągów Lubuski, 2001.

- [82] Sobczak W., Malina W.: *Metody selekcji i redukcji informacji*. WNT, Warszawa, 1985.
- [83] Sobczyk M.: *Statystyka*. Wydawnictwo Naukowe PWN, Warszawa, 2002.
- [84] Sobol I.: *Sensitivity estimates for nonlinear mathematical models*. Mathematical Modelling and Computation, 4(1):407–414, 1993.
- [85] Tenenhaus M., Young F.: *An analysis and synthesis of multiple correspondence analysis, optimal scaling, dual scaling, homogeneity analysis and other methods for quantifying categorical multivariate data*. Psychometrika, 50:91–119, 1985.
- [86] Tłuchowski W.: *Wielowymiarowa analiza dyskryminacji narzędziem prognozowania upadłości przedsiębiorstw*. Zeszyty Naukowe WSHiU, Poznań, 2004.
- [87] Uhl T.: *Komputerowo wspomagana identyfikacja modeli konstrukcji mechanicznych*. WNT, Warszawa, 1997.
- [88] Van de Velden M., Neudecker H.: *On an eigenvalue property relevant in correspondence analysis and related methods*. Linear Algebra and its Applications, 321:347–364, 2000.
- [89] Varian H. (red.): *Computational economics and finance: Modelling and analysis with Mathematica*. Springer-Verlag, New York, 1996.
- [90] Vernieuwe H., Georgieva O., De Baets B., Pauwels V., Verhoest N., De Troch F.: *Comparison of data-driven Takagi-Sugeno models of rainfall-discharge dynamics*. Journal of Hydrology, 302:173–186, 2005.
- [91] Wachla D.: *Badanie wrażliwości diagnostycznej cech sygnałów wibroakustycznych przekładni zębatych w dziedzinie czasu*. Burczyński T., Cholewa W. (red.), AI-MECH 2000, Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, str. 349–357, Gliwice, 2000.
- [92] Walczyk Z., Kiciński J.: *Dynamika turbozespołów energetycznych. Wybrane zagadnienia drgań prostych i sprzężonych*. Wydawnictwo Politechniki Gdańskiej, Gdańsk, 2001.
- [93] Wierzbicki A.: *Modele i wrażliwość sterowania*. WNT, Warszawa, 1977.
- [94] Wojtusik J.: *Wrażliwość diagnostyczna wzajemnych cech par sygnałów wibroakustycznych w ujęciu metod klasyfikacji i grupowania*. Burczyński T., Cholewa W. (red.), AI-MECH 2000, Methods of Artificial Intelligence in Mechanics and Mechanical Engineering, str. 363–366, Gliwice, 2000.
- [95] Wotawa G., Stohl A., Kolb H.: *Estimating the uncertainty of a Lagrangian photochemical air quality simulation model caused by inexact meteorological input data*. Reliability Engineering and System Safety, 57(1):31–40, 1997.
- [96] Wysogład B.: *Mikrostanowisko do badań drgań wałów. Parametryzacja dla potrzeb symulacji komputerowej*. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Gliwice, 1997.

- [97] Wysogład B.: *Mikrostanowisko do badań drgań wałów. Zbiór wyników pomiarów drgań w warunkach stacjonarnych*. Katedra Podstaw Konstrukcji Maszyn, Politechnika Śląska, Gliwice, 1997.
- [98] Yin X.: *Canonical correlation analysis based on information theory*. Journal of Multivariate Analysis, 91:161–176, 2001.
- [99] Żółtowski B.: *Podstawy diagnostyki maszyn*. Wydawnictwo Uczelniane Akademii Techniczno–Rolniczej, Bydgoszcz, 1996.
- [100] Żółtowski B.: *Badania dynamiki maszyn*. Wydawnictwo MARKAR, Bydgoszcz, 2002.
- [101] Żółtowski B., Ćwik Z.: *Leksykon diagnostyki technicznej*. Wydawnictwo Uczelniane Akademii Techniczno–Rolniczej, Bydgoszcz, 1996.
- [102] *Electronic Statistics Textbook*. <http://www.statsoft.com/textbook/stathome.html>, 2004.
- [103] *Leksykon naukowo techniczny*. Wydawnictwa Naukowo–Techniczne, Warszawa, 2001.
- [104] The MathWorks, Inc.: *Fuzzy logic toolbox user's guide*, 2004.
- [105] *Metody statystyki i data mining w badaniach naukowych*. StatSoft Polska, Kraków, 2003.
- [106] *Nowy leksykon PWN*. Wydawnictwo Naukowe PWN, Warszawa, 1998.
- [107] *Rotor Kit*. Bently Nevada Corporation, Mindem USA, 1994.
- [108] *Rotor Kit, oil whirl/whip option*. Bently Nevada Corporation, Mindem USA, 1994.
- [109] *Słownik współczesnego języka polskiego*. Wydawnictwo Wilga, Warszawa, 1996.

Metody badania wrażliwości cech sygnałów diagnostycznych

(Streszczenie)

Celem pracy było zaproponowanie metod badania wrażliwości cech sygnałów diagnostycznych. Metody te, stosujące miary wrażliwości jako kryterium wyboru cech, miały pozwolić na optymalizację modeli diagnostycznych. Przeszkodą w realizacji tego celu, wynikającą bezpośrednio ze specyfiki diagnostyki maszyn, była konieczność uwzględnienia dyskretnej przestrzeni stanów.

W ramach podjętych działań zaproponowano definicję wrażliwości diagnostycznej, na podstawie której opracowane zostały dwie metody badania wrażliwości. W pierwszej z nich, metodzie selekcji wrażliwych cech sygnałów, wyznaczane są wartości wrażliwości będące różnicami wartości cech sygnałów, natomiast w drugiej metodzie, statystycznej, określane są wartości wrażliwości cząstkowej, grupowej oraz głównej. Obie metody równie dobrze sobie radzą z dyskretnymi jak i ciągłymi wartościami cech sygnałów oraz z dyskretną przestrzenią stanów. Stosować je możemy zamiennie, w zależności od tego, ile rozróżniamy stanów, a ile klas stanu.

Statystyczną metodę badania wrażliwości zastosowano w praktyce. Skorzystano w tym celu z dwóch zbiorów danych: pochodzących z eksperymentu numerycznego prowadzonego na modelu turbosespołu 13K215 oraz zarejestrowanych w trakcie eksperymentu diagnostycznego prowadzonego na stanowisku *Rotor Kit*.

Przeprowadzenie badań, potwierdzających przydatność zaproponowanej metody, wymagało: zdefiniowania rozpatrywanego zbioru klas stanu, indywidualnego dla każdego z badanych obiektów; wyznaczenia zbioru cech sygnałów; przeprowadzenia selekcji wrażliwych cech sygnałów za pomocą metody badania wrażliwości oraz cech, które wg badacza mogły wydawać się najbardziej istotne; zbudowania modelu diagnostycznego. Działania takie powtarzano wielokrotnie, za każdym razem dodatkowo weryfikując zbudowany model, a otrzymane wyniki testów poddając analizie.

Badania prowadzono z zastosowaniem dwóch strategii podziału danych. W pierwszej zbiór danych testujących był równy zbiorowi danych uczących, natomiast w drugim przypadku skorzystano z metody *leave one out*.

Porównując jakość otrzymanych modeli diagnostycznych, zbudowanych z udziałem oraz bez udziału analizy wrażliwości, potwierdzona została przydatność statystycznej metody badania wrażliwości w wyborze cech sygnałów niosących istotne informacje o klasie stanu badanego obiektu.

Opracowana oraz zastosowana z powodzeniem statystyczna metoda badania wrażliwości może znaleźć zastosowanie w początkowym etapie projektowania prostych, szybkich i niezawodnych pod względem podejmowanych decyzji układów diagnostycznych, w przypadku, gdy liczba klas stanu jest znana, możliwa do zbadania.

Słowa kluczowe: analiza wrażliwości, selekcja cech, diagnostyka maszyn, cechy sygnałów, klasy stanu, model diagnostyczny, system diagnostyczny, selekcja informacji, redukcja informacji.

Dziedziny: diagnostyka, diagnostyka maszyn, analiza danych.

Methods of sensitivity analysis of diagnostic signal features

(Summary)

The goal of this thesis was to elaborate the methodology of the sensitivity analysis of diagnostic signal features. These methods, which uses the measure of sensitivity as a criterion of feature choice, should allow to optimize diagnostic models. Additionally, discrete state space, which is characteristic feature of technical diagnostics, should be taken into consideration. This requirement was the main barrier in the research realization.

Within a framework of research, definition of the diagnostic sensitivity was proposed. On the basis of such definition two methods of sensitivity analysis were elaborated. First of them, which is used to evaluation of sensitivity values as differences between values of signal features, is a method of selection of sensitive signal feature. The second one, which is statistical method, determines partial-, group- and main sensitivity measures. Both methods can be applied with discrete as well as continuous values of signal features and with discrete state space. These methods can be used substitutable according to number of states and number of state classes.

Statistic method of sensitivity analysis was applied in practice. Two data sets were used: data from numeric experiment on determined model of turbine set 13K215 and data from diagnostic measurements on the *Rotor Kit* test stand.

Realization of the researches, which prove the usefulness of proposed methods, required: definition of considered set of state classes individually for each of examined objects; determination of signal features set; selection of sensitive signal features based on sensitivity research method and on the most important features according to the researcher; identification of diagnostic model. The procedure was repeated several times. Additionally, each time the identified model was verified and received results were analyzed.

The research were performed with application of two strategies of learning data division. Set of testing data was equal to set of training data in the first case. In the second one the *leave one out* method was applied.

Quality comparison of the diagnostic models identified with and without sensitivity analysis proves usefulness of statistical method of sensitivity analysis in the selection of signal features possessing meaningful information about classes of state of examined object.

The elaborated and applied statistical method of sensitivity analysis may be used in the initial designing stage of simply, fast and reliable diagnostics systems, if the number of state classes is known and possible to determine.

Keywords: sensitivity analysis, feature selection, machinery diagnostics, signal features, state classes, diagnostic model, diagnostic system, selection of information, reduction of information.

Domains: diagnostics, machinery diagnostics, data analysis.

