





Czesław T. KOWALSKI

DIAGNOSTYKA UKŁADÓW NAPĘDOWYCH Z SILNIKIEM INDUKCYJNYM Z ZASTOSOWANIEM METOD SZTUCZNEJ INTELIGENCJI



Oficyna Wydawnicza Politechniki Wrocławskiej

Czesław T. Kowalski

**Diagnostyka układów napędowych
z silnikiem indukcyjnym
z zastosowaniem metod
sztucznej inteligencji**



Oficina Wydawnicza Politechniki Wrocławskiej
Wrocław 2013

Recenzenci

Ludwik ANTAL
Marian P. KAŻMIERKOWSKI

Opracowanie redakcyjne

Alina KACZAK

Korekta

Alina KACZAK
Agnieszka ŚCIEPURO

Projekt okładki

Marcin ZAWADZKI

Wszelkie prawa zastrzeżone. Żadna część niniejszej książki, zarówno w całości, jak i we fragmentach, nie może być reprodukowana w sposób elektroniczny, fotograficzny i inny bez zgody wydawcy i właściciela praw autorskich.

© Copyright by Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2013

OFICyna WYDAWNICZA POLITECHNIKI WROCLAWSKIEJ

Wybrzeże Wyspiańskiego 27, 50-370 Wrocław

<http://www.oficyna.pwr.wroc.pl>

e-mail: oficwyd@pwr.wroc.pl

zamawianie.ksiazek@pwr.wroc.pl

ISBN 978-83-7493-816-7

Drukarnia Oficyny Wydawniczej Politechniki Wrocławskiej. Zam. nr 1010/2013.

Ukochanej Żonie

Spis treści

Przedmowa	9
Wykaz ważniejszych oznaczeń	13
1. Wprowadzenie	15
1.1. Podstawowe problemy diagnostyki obiektów przemysłowych	15
1.2. Podstawowe zagadnienia monitorowania i diagnostyki silników indukcyjnych	21
1.3. Zastosowanie modeli matematycznych do diagnostyki silników indukcyjnych	24
1.4. Diagnostyka silników indukcyjnych oparta na analizie sygnałów pomiarowych	26
1.5. Diagnostyka silników indukcyjnych z zastosowaniem metod sztucznej inteligencji	27
1.6. Podsumowanie	28
Literatura	29
2. Przegląd podstawowych uszkodzeń napędów z silnikiem indukcyjnym	31
2.1. Rodzaje, przyczyny i statystyka uszkodzeń silników indukcyjnych	31
2.2. Uszkodzenia uzwojeń wirników klatkowych	34
2.3. Uszkodzenia uzwojeń stojana	36
2.4. Uszkodzenia mechaniczne	39
2.5. Specyficzne uszkodzenia przekształtnikowych układów napędowych z silnikiem indukcyjnym	42
2.6. Podsumowanie	46
Literatura	47
3. Charakterystyka sygnałów diagnostycznych	49
3.1. Wielkości elektryczne i mechaniczne stosowane w diagnostyce układów napędowych	49
3.2. Prąd stojana jako sygnał diagnostyczny	52
3.3. Moc chwilowa, strumień stojana i wirnika oraz moment elektromagnetyczny jako sygnały diagnostyczne	54
3.4. Sygnały chwilowej mocy czynnej i biernej	57
3.5. Sygnał strumienia poosiowego	58
3.6. Sygnał drgań mechanicznych	60
3.7. Temperatura jako sygnał diagnostyczny	64
3.8. Podsumowanie	67
Literatura	67
4. Analiza sygnałów – podstawowa metoda diagnostyki napędu elektrycznego	71
4.1. Wprowadzenie	71
4.2. Wstępne przetwarzanie sygnałów	73
4.3. Dobór i konfiguracja cyfrowego systemu akwizycji danych	77
4.4. Nieparametryczne metody wyznaczania cech sygnałów diagnostycznych	80
4.4.1. Transformata Fouriera	80
4.4.2. Krótkoczasowa transformata Fouriera STFT	88
4.4.3. Przekształcenie falkowe	90
4.4.4. Transformaty wyższych rzędów	96

4.5. Podsumowanie	101
Literatura	101
5. Modele matematyczne silnika indukcyjnego z uszkodzeniem	103
5.1. Podstawowy model obwodowy silnika indukcyjnego	103
5.2. Model silnika indukcyjnego ze zwartymi zwojami w uzwojeniu stojana	108
5.2.1. Model uwzględniający dodatkową macierz asymetrii w równaniach stanu	108
5.2.2. Model uwzględniający wektorowy współczynnik uszkodzenia	111
5.2.3. Model wykorzystujący modyfikację parametrów schematu zastępczego silnika	112
5.2.4. Weryfikacja modeli matematycznych silnika indukcyjnego z uszkodzonym stojanem	114
5.3. Modele matematyczne silnika indukcyjnego z uszkodzonym uzwojeniem wirnika klatkowego	115
5.3.1. Model I	115
5.3.2. Model II	118
5.4. Modele polowo-obwodowe silnika indukcyjnego z uszkodzonym stojanem	121
5.5. Posumowanie	127
Literatura	127
6. Estymatory zmiennych stanu i parametrów w diagnostyce napędów przekształtnikowych	131
6.1. Wprowadzenie	131
6.2. Algorytm rozszerzonego filtru Kalmana	134
6.2.1. Podstawowy model matematyczny filtru Kalmana	134
6.2.2. Estymacja rezystancji wirnika	135
6.2.3. Estymacja rezystancji stojana	137
6.3. Algorytm obserwatora Luenbergera	138
6.3.1. Podstawowy model matematyczny obserwatora Luenbergera	138
6.3.2. Estymacja rezystancji wirnika	140
6.3.3. Estymacja rezystancji stojana	141
6.4. Zastosowanie filtru Kalmana do wykrywania uszkodzeń w układzie wektorowego sterowania prędkością DFOC	142
6.4.1. Wykrywanie uszkodzeń wirnika klatkowego	142
6.4.2. Wykrywanie uszkodzeń stojana	146
6.5. Zastosowanie obserwatora Luenbergera do wykrywania uszkodzeń w układzie wektorowego sterowania prędkością DFOC	147
6.5.1. Wykrywanie uszkodzeń wirnika klatkowego	147
6.5.2. Wykrywanie uszkodzeń stojana	149
6.6. Podsumowanie	151
Literatura	151
7. Metody sztucznej inteligencji w diagnostyce	155
7.1. Wprowadzenie	155
7.2. Podstawowe informacje o sieciach neuronowych	157
7.3. Sieci neuronowe w diagnostyce	163
7.4. Metodyka uczenia i testowania neuronowych detektorów uszkodzeń	166
7.5. Metody logiki rozmytej w diagnostyce	173
7.6. Wstępne przetwarzanie sygnałów pomiarowych dla neuronowych detektorów uszkodzeń	176
7.7. Sieci neuronowe radialne RBF	180
7.8. Sieci neuronowe typu GRNN	183
7.9. Sieci neuronowo-rozmyte	186
7.10. Podsumowanie	189

Literatura	190
8. Wykrywanie uszkodzeń wirników klatkowych silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości	193
8.1. Charakterystyka zjawisk w silniku indukcyjnym z uszkodzonym wirnikiem klatkowym ...	193
8.2. Wykrywanie uszkodzeń wirnika na podstawie analizy widmowej prądu stojana	196
8.3. Wykrywanie uszkodzeń wirnika na podstawie analizy widmowej modułu wektora prądu stojana	203
8.4. Neuronowe detektory uszkodzeń wirnika	207
8.4.1. Charakterystyka badań	207
8.4.2. Perceptronowy detektor uszkodzeń wirników klatkowych	209
8.4.3. Detektor uszkodzeń wirników klatkowych oparty na sieci radialnej	217
8.4.4. Detektor uszkodzeń wirników klatkowych oparty na sieci neuronowo-rozmytej	220
8.4.5. Detektor uszkodzeń wirników klatkowych oparty na sieci MLP trenowanej danymi z analizy falkowej	223
8.5. Podsumowanie	234
Literatura	235
9. Wykrywanie zwarc zwojowych w stojanie silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości	237
9.1. Metody wykrywania uszkodzeń w stojanie	237
9.2. Symptomy zwarc zwojowych w stojanie silnika indukcyjnego zasilanego z przemiennika częstotliwości	239
9.2.1. Symptomy zwarc zwojowych w prądzie stojana	239
9.2.2. Symptomy zwarc zwojowych w wektorze przestrzennym prądu stojana	242
9.2.3. Zastosowanie hodografu wektora przestrzennego prądu stojana do wykrywania zwarc zwojowych w stojanie	247
9.2.4. Wykrywanie zwarc zwojowych na podstawie analizy przesunięcia kąowego między prądami fazowymi oraz prądem i napięciem stojana	252
9.2.5. Symptomy zwarc zwojowych w strumieniu poosiowym	256
9.2.6. Symptomy zwarc zwojowych w sygnałach mocy chwilowej i momentu elektromagnetycznego	260
9.2.7. Symptomy zwarc zwojowych w drganiach mechanicznych	263
9.3. Zastosowanie składowych symetrycznych do wykrywania zwarc zwojowych w silniku zasilanym z przemiennika częstotliwości	264
9.4. Neuronowe detektory uszkodzeń uzwojenia stojana	269
9.4.1. Neuronowy detektor uszkodzeń stojana oparty na danych z analizy PCA wektora przestrzennego prądu stojana	269
9.4.2. Neuronowy detektor uszkodzeń stojana oparty na danych z analizy składowych symetrycznych	274
9.5. Zastosowanie analizy falkowej do wykrywania zwarc zwojowych	276
9.6. Podsumowanie	281
Literatura	282
10. Wykrywanie uszkodzeń mechanicznych napędu z silnikiem indukcyjnym	285
10.1. Wprowadzenie	285
10.2. Wykrywanie uszkodzenia łożyska tocznego	288
10.2.1. Metody klasyczne oparte na analizie widmowej drgań i prądu	288
10.2.2. Metody wykrywania uszkodzenia łożyska tocznego oparta na analizie falkowej	297
10.3. Wykrywanie nieosiowości napędu z silnikiem indukcyjnym	301
10.4. Monitorowanie ekscentryczności maszyny	305

10.5. Neuronowe detektory uszkodzeń łożysk tocznych	314
10.5.1. Perceptronowy detektor uszkodzeń łożysk tocznych silnika zasilanego z prze- miennika częstotliwości	314
10.5.2. Detektor neuronowy wykorzystujący radialną sieć neuronową	317
10.5.3. Detektor neuronowy wykorzystujący analizę falkową	323
10.6. Neuronowe detektory nieosiowości napędu	325
10.7. Neuronowe detektory ekscentryczności silnika	329
10.8. Podsumowanie	331
Literatura	332
11. Zagadnienia realizacji praktycznej systemów diagnostycznych	335
11.1. Wprowadzenie	335
11.2. Przenośny system diagnostyczny silnika indukcyjnego	336
11.3. Komputerowy system do monitorowania i diagnostyki uzwojenia stojana	345
11.4. Komputerowy system do monitorowania i diagnostyki uszkodzeń mechanicznych	350
11.5. Komputerowy system do monitorowania i diagnostyki uzwojeń stojana i wirnika oparty na estymacji parametrów	354
Literatura	356
Załącznik 1. Parametry badanych silników	359
Załącznik 2. Schematy ideowe stanowisk badawczych	363

Przedmowa

Metody diagnostyki elektrycznych układów napędowych rozwija się od wielu lat. W ostatnim dziesięcioleciu nastąpiło gwałtowne przyspieszenie wynikające z pojawienia się nowych możliwości technicznych oraz rozwoju nowych metod przetwarzania sygnałów. Dzięki coraz doskonalszym układom pomiarowym oraz komputerowym systemom akwizycji i przetwarzania danych pomiarowych możliwe jest rejestrowanie w czasie rzeczywistym bardzo licznych zbiorów danych pomiarowych, na podstawie których diagnosta musi ocenić stan techniczny napędu elektrycznego.

W diagnostyce opartej na analizie sygnałów wykorzystuje się przede wszystkim wiedzę i doświadczenie człowieka-eksperta. To on dokonuje na bieżąco interpretacji aktualnych danych dostarczanych przez system pomiarowy. W takim podejściu najsłabszym punktem jest człowiek, który może się mylić i którego doświadczenie jest bardzo trudne do zautomatyzowania. Dlatego oprócz ciągłego doskonalenia metod pozyskiwania informacji diagnostycznej, poszukuje się sposobów na zobiektywizowanie procesu wykrywania i oceny stopnia uszkodzenia. Do realizacji tego celu w dużym stopniu mogą przyczynić się metody i techniki sztucznej inteligencji. Metody te, a przede wszystkim sztuczne sieci neuronowe i logika rozmyta, umożliwiają zobiektywizowanie i zautomatyzowanie procesu klasyfikacji i oceny uszkodzeń.

Niniejsza monografia zawiera analizę i ocenę metod wczesnego wykrywania uszkodzeń, najczęściej występujących we współczesnych napędach elektrycznych, oraz przedstawia możliwości zastosowania metod sztucznej inteligencji do realizacji detektorów i klasyfikatorów uszkodzeń.

Na podstawie cech diagnostycznych, wyekstrahowanych z sygnałów mierzonych w realnych silnikach zasilanych z przemiennika częstotliwości, opracowano przykłady neuronowych detektorów uszkodzeń. Umożliwiło to sprawdzenie w warunkach laboratoryjnych metodyki projektowania neurodetektorów i ocenę ich przydatności.

Ze względu na zależność efektywności działania neurodetektorów uszkodzeń od jakości danych wejściowych otrzymywanych w wyniku wstępnego przetwarzania i selekcji symptomów, zwrócono uwagę na nowe możliwości wynikające z zastosowania transformaty falkowej lub transformat wyższych rzędów.

Intensywnie rozwijane środowiska programistyczne, jak LabVIEW i Matlab, dostarczają nowych narzędzi informatycznych do coraz bardziej złożonych analiz sy-

gnałów oraz projektowania struktur opartych na sztucznej inteligencji. Umożliwia to w dużym stopniu samodzielne tworzenie nowoczesnych systemów pomiarowo-diagnostycznych o stosunkowo małych nakładach finansowych. Przykłady takich autorskich rozwiązań przedstawiono w niniejszej monografii.

Monografia składa się z 11 rozdziałów. Pierwszy rozdział jest wprowadzeniem do ogólnie rozumianej problematyki diagnostyki i zawiera podstawowe definicje i pojęcia. Ponadto scharakteryzowano w nim aktualne problemy monitorowania i diagnostyki występujące w maszynach i napędach elektrycznych. Przegląd podstawowych uszkodzeń występujących w napędach z silnikami indukcyjnymi jest tematem rozważań w rozdziale 2. W silnikach indukcyjnych wykrywanie uszkodzeń jest realizowane przede wszystkim na podstawie informacji diagnostycznej zawartej w mierzonych sygnałach diagnostycznych. Charakterystykę tych sygnałów zawiera rozdział 3. Do wyodrębniania cech charakteryzujących poszczególne uszkodzenia niezbędne są odpowiednie metody pomiaru i przetwarzania informacji diagnostycznej. W rozdziale 4 przedstawiono zagadnienia wstępnego przetwarzania sygnałów pomiarowych, doboru parametrów systemu akwizycji danych pomiarowych oraz dokonano szczegółowego omówienia nieparametrycznych metod wyznaczania cech sygnałów wykorzystywanych w diagnozowaniu. Uwaga została skupiona na transformacie Fouriera, krótkoczasowej transformacie Fouriera i przekształceniu falkowym. Ponadto scharakteryzowano transformaty wyższych rzędów, rzadko dotychczas stosowane w napędach elektrycznych.

Problematykę modelowania matematycznego silnika indukcyjnego z uszkodzeniami w obwodach elektrycznych omówiono w rozdziale 5. Przedstawiono podstawowe rozwiązania obwodowych modeli z uszkodzeniem uzwojeń wirnika i stojana oraz oceniono przydatność modeli polowo-obwodowych w diagnostyce napędów elektrycznych. Zastosowanie estymatorów zmiennych stanu i parametrów do diagnostyki napędów przekształtnikowych, pracujących w strukturach sterowania skalarnego i wektorowego, przedstawiono w rozdziale 6.

W rozdziale 7 omówiono metody sztucznej inteligencji, a zwłaszcza sieci neuronowe stosowane w diagnostyce napędów z silnikiem indukcyjnym. Przedstawiono najważniejsze informacje praktyczne na temat projektowania struktur z sieciami neuronowymi i neuronowo-rozmytymi.

Kolejne trzy rozdziały dotyczą wykrywania uszkodzeń w układach napędowych z silnikiem indukcyjnym zasilanym z falownika PWM. W rozdziale 8 omówiono uszkodzenia wirników klatkowych, w rozdziale 9 – uszkodzenia uzwojeń stojana oraz w rozdziale 10 – wybrane uszkodzenia typu mechanicznego (uszkodzenia łożyska tocznego, niewyosiowanie i ekscentryczność). W rozdziałach tych omawiane są podstawowe metody wykrywania danego typu uszkodzeń, z uwzględnieniem specyfiki pracy maszyny w strukturze sterowania częstotliwościowego oraz przedstawione przykłady rozwiązań neuronowych detektorów uszkodzeń. Wszystkie przedstawione rozwiązania neuronowych detektorów uszkodzeń opracowano na podstawie danych

pomiarowych zebranych na rzeczywistych obiektach laboratoryjnych, z wykorzystaniem własnych rozwiązań systemów pomiarowo-diagnostycznych. Systemy te ogólnie scharakteryzowano w rozdziale 11 oraz sformułowano wytyczne do ich wdrażania w warunkach przemysłowych. W załącznikach zamieszczono dane techniczne silników, na których były testowane metody i techniki diagnostyczne przedstawione w monografii oraz schematy stanowisk badawczych.

Zaprezentowane w monografii wyniki badań zweryfikowano w warunkach laboratoryjnych oraz częściowo w warunkach przemysłowych. Stanowią one podsumowanie prac badawczych prowadzonych pod kierunkiem Autora z ostatnich 10 lat, w zespole badawczym w Instytucie Maszyn, Napędów i Pomiarów Elektrycznych na Wydziale Elektrycznym Politechniki Wrocławskiej. Były to prace realizowane w ramach projektów badawczych własnych, rozwojowych i promotorskich kierowanych przez Autora monografii i finansowanych przez KBN, MNiSzW i NCN.

W znacznej części wyniki naukowe i aplikacyjne prezentowane w monografii były również publikowane w postaci artykułów w czasopismach naukowych, referatów na konferencjach naukowych krajowych i zagranicznych oraz w raportach z badań realizowanych w grantach.

Dziękuję wszystkim Kolegom, z którymi wykonywałem podane prace, a zwłaszcza: dr. inż. Marcinowi Pawlakowi, dr. inż. Pawłowi Ewertowi, dr. inż. Marcinowi Wolkiewiczowi, dr. inż. Robertowi Wierzbickiemu, dr. inż. Marcinowi Kamińskiemu i mgr. inż. Zdzisławowi Żarczyńskiemu. Dziękuję także osobom, które pomogły w przygotowaniu niniejszej monografii, przede wszystkim prof. dr. hab. inż. Marianowi P. Kaźmierkowskiemu oraz dr. hab. inż. Ludwikowi Antalowi, prof. PWr., za zrecenzowanie pracy i cenne uwagi.

Czesław Tadeusz Kowalski

Wykaz ważniejszych oznaczeń

B	– indukcja magnetyczna [T]
f	– częstotliwość [Hz]
f_e	– częstotliwość charakterystyczna dla ekscentryczności i żłobkowania wirnika
f_{p1}, f_{p2}	– częstotliwości poślizgowe występujące przy uszkodzeniu wirnika
f_r	– częstotliwość obrotowa wirnika
f_s	– częstotliwość znamionowa stojana
I	– prąd [A]
I^s	– amplituda składowej podstawowej prądu stojana
I_A	– wartość skuteczna prądu fazowego
I_{p1}^s	– amplituda składowej poślizgowej prądu stojana
i	– wartość chwilowa prądu [A]
\mathbf{i}_s	– wektor przestrzenny prądu stojana
$i_{s\alpha}, i_{s\beta}$	– składowe wektora prądu stojana w nieruchomym układzie współrzędnych α, β
$ \mathbf{i}_s $	– moduł wektora prądu stojana
J	– moment bezwładności [$\text{N}\cdot\text{m}\cdot\text{s}^2$]
L	– indukcyjność [H]
L_M	– indukcyjność główna maszyny
L_r'	– indukcyjność własna uzwojenia wirnika sprowadzona do obwodu stojana
$L_{\sigma r}'$	– indukcyjność rozproszenia uzwojenia wirnika sprowadzona do obwodu stojana
L_s	– indukcyjność własna uzwojenia stojana silnika indukcyjnego
$L_{\sigma s}$	– indukcyjność rozproszenia uzwojenia stojana
M	– moment obrotowy [$\text{N}\cdot\text{m}$]
M_e	– moment elektromagnetyczny
M_o	– moment obciążenia
n	– liczba uszkodzonych prętów wirnika
N_r	– liczba prętów wirnika
P	– moc czynna [W]
p_{AB}	– moc czynna chwilowa [W]
p_b	– liczba par biegunów silnika indukcyjnego
R	– rezystancja [Ω]
R_r	– rezystancja uzwojenia wirnika
R_s	– rezystancja uzwojenia stojana
s	– poślizg
U	– napięcie [V]
U_N	– napięcie znamionowe
U_{AB}	– wartość skuteczna napięcia międzyfazowego
$u_{s\alpha}, u_{s\beta}$	– składowe wektora napięcia stojana silnika indukcyjnego w nieruchomym układzie współrzędnych α, β

- ϕ – kąt przesunięcia fazowego
- Ψ – strumień magnetyczny skojarzony [Wb]
- Ψ_r – wektor przestrzenny strumienia skojarzonego wirnika
- $\Psi_{r\alpha}, \Psi_{r\beta}$ – składowe wektora przestrzennego strumienia skojarzonego wirnika w nieruchomym układzie współrzędnych α, β
- Ψ_s – wektor przestrzenny strumienia skojarzonego stojana
- $\Psi_{s\alpha}, \Psi_{s\beta}$ – składowe wektora przestrzennego strumienia skojarzonego stojana silnika indukcyjnego w nieruchomym układzie współrzędnych α, β
- ω – prędkość kątowa, pulsacja [rad/s]
- ω_m – prędkość kątowa mechaniczna wirowania wirnika
- ω_s – pulsacja w stojanie

1. Wprowadzenie

1.1. Podstawowe problemy diagnostyki obiektów przemysłowych

W ostatnim dziesięcioleciu nastąpił znaczny wzrost rozmiarów instalacji technologicznych we wszystkich gałęziach przemysłu. Dążenie do obniżenia jednostkowych kosztów produkcji oraz zwiększenia wydajności wpływa na wzrost koncentracji wszelkiego rodzaju urządzeń (pomiarowych, sterujących, wykonawczych, napędowych) oraz złożoność systemów technicznych i technologicznych. Niezawodność procesów przemysłowych stanowi bardzo ważne zagadnienie eksploatacji tych systemów. Uszkodzenia elementów systemu, które mogą pojawić się w trakcie eksploatacji, wynikające z procesów zużycia podzespołów lub błędów obsługi, mają istotny wpływ na bezpieczeństwo procesu i obsługi oraz jego ekonomiczną opłacalność.

Przeciwdziałanie awariom może być realizowane na różne sposoby: przez zabezpieczenia, redundancję sprzętową i redundancję analityczną oraz szeroko rozumianą diagnostykę techniczną.

Zabezpieczenia (ang. *protection*) wykorzystuje się w ostatecznej, katastroficznej fazie awarii, natomiast stosowanie redundancji sprzętowej wiąże się z dużymi kosztami i koniecznością rozbudowy systemów sterowania i nadzoru. Redundancja sprzętowa zwykle jest stosowana na bardzo ważnych obiektach przemysłowych. Zwiększenie niezawodności obiektów przemysłowych może być osiągnięte również na podstawie tzw. redundancji analitycznej. Redundancja analityczna jest dodatkową informacją diagnostyczną uzyskiwaną (obliczaną) na podstawie modelu matematycznego obiektu, z wykorzystaniem metod i techniki teorii sterowania, przetwarzania sygnałów i modelowania.

Diagnostyka techniczna stanowi obecnie dyscyplinę naukową rozwijającą się bardzo intensywnie w kraju i na świecie, dotyczy rozpoznawania stanu technicznego obiektu (urządzeń, maszyn, procesów) na podstawie aktualnie dostępnych informacji o obiekcie [1.2, 1.9, 1.10, 1.13, 1.14]. Celem nadrzędnym diagnostyki technicznej jest zapewnienie dyspozycyjności eksploatacyjnej maszyn i urządzeń, maksymalne zabezpieczenie ich przed awariami, ustalenie przyczyn powstałych uszkodzeń oraz sposobów ich uniknięcia. Obecnie diagnostyka techniczna korzysta z najnowszych osią-

gnięć teorii sterowania, teorii systemów, metod sztucznej inteligencji, informatyki, budowy maszyn i urządzeń, technologii procesów.

W skład działań związanych z diagnostyką wchodzi [1.13]:

- diagnozowanie, czyli działania mające na celu określenie aktualnego stanu technicznego obiektu diagnozowanego (stawianie diagnozy);
- genezowanie, czyli rozpoznawanie wcześniejszych (przeszłych) stanów obiektu (poszukiwanie genezy uszkodzenia);
- prognozowanie (przewidywanie) przyszłych stanów obiektu (opracowanie przewidywanego rozwoju uszkodzenia).

Według terminologii zaproponowanej przez Isermana i Balle'a [1.9] można wyróżnić trzy różne fazy badania stanu technicznego obiektu:

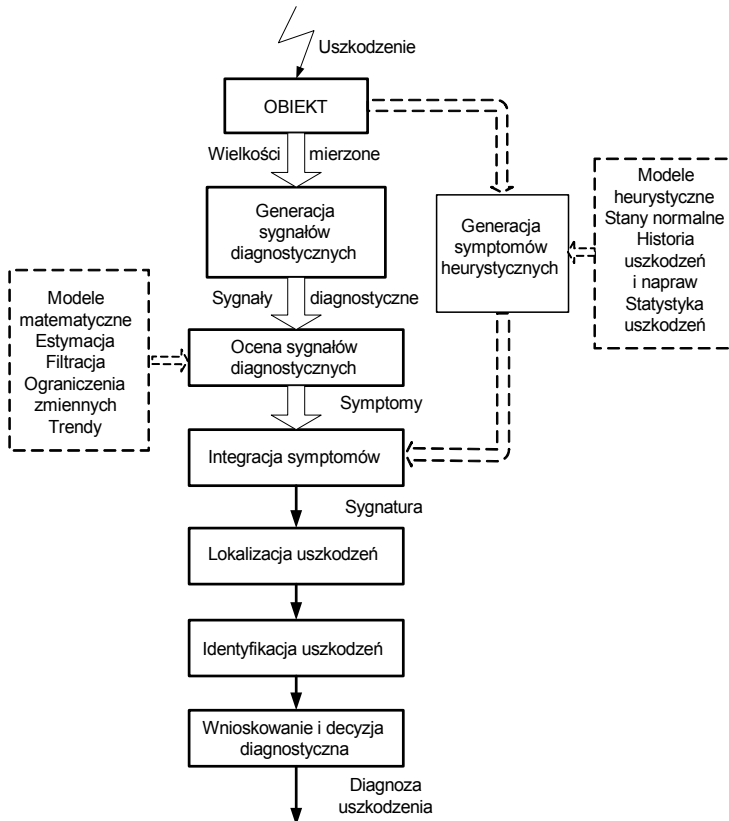
- detekcja uszkodzenia (ang. *fault detection*), czyli wykrycie uszkodzenia w obiekcie i określenie chwili detekcji;
- lokalizacja uszkodzenia (ang. *fault isolation*), czyli określenie rodzaju, miejsca i czasu wystąpienia uszkodzenia;
- identyfikacja uszkodzenia (ang. *fault identification*), czyli określenie rozmiaru i charakteru zmienności uszkodzenia w czasie.

W literaturze związanej z diagnostyką występuje jeszcze pojęcie *diagnostyka uszkodzeń* (ang. *fault diagnosis*) rozumiane jako proces wykrywania, lokalizacji i identyfikacji uszkodzeń w wyniku zbierania, przetwarzania, analizy i oceny sygnałów diagnostycznych.

Często wraz z pojęciem *diagnostyki* stosuje się termin *monitorowanie* (ang. *monitoring*). Można wyróżnić *monitorowanie działania obiektu* (przebiegu procesu) oraz *monitorowanie stanu obiektu* (procesu). Monitorowanie działania obiektu rozumiane jest jako zadanie realizowane w czasie rzeczywistym, polegające na zbieraniu i przetwarzaniu sygnałów diagnostycznych (zmiennych procesowych) oraz rozpoznawaniu nieprawidłowych zachowań obiektu (sygnalizacja alarmów) [1.11, 1.13]. Monitorowanie stanu obiektu (procesu) jest cyklicznie powtarzaniem formułowania diagnozy o stanie obiektu wraz z sygnalizacją i graficzną wizualizacją stanu lub zmian stanu (rozpoznanych uszkodzeń). Zwykle jest realizowane na bieżąco (w czasie rzeczywistym) przez komputerowy system diagnozujący. Jeżeli monitorowanie zostanie rozszerzone na działanie obiektu (procesu) i podejmowanie czynności mających na celu utrzymanie obiektu w prawidłowym stanie po wystąpieniu uszkodzenia (zabezpieczenia), mówi się o **nadzorowaniu** (ang. *supervision*). Na rysunku 1.1 przedstawiono ogólny schemat ideowy systemu realizującego nadzorowanie, wykrywanie i diagnostykę uszkodzeń, spełniającego następujące wymagania [1.11]:

- wczesne wykrywanie małych uszkodzeń we wstępnej fazie (ang. *incipient fault*) lub pojawiających się nagle (ang. *abrupt fault*),
- realizacja diagnostyki działania obiektu oraz stanu wszystkich jego części składowych, np. instalacji technologicznych, maszyn, czujników, układów wykonawczych itp.,

automatycznym przetwarzaniu zmierzonych sygnałów niezbędna jest odpowiednia wiedza analityczna (ang. *analytical knowledge*), natomiast do oceny zmiennych obserwowanych niezbędna jest wiedza człowieka–eksperta, tzw. wiedza heurystyczna (ang. *heuristic knowledge*). Wiedza analityczna obejmuje różne metody, począwszy od prostych reguł określających graniczne wartości mierzonych sygnałów, po złożone metody analizy sygnałów (np. analiza widmowa, filtracja, estymacja stanów i parametrów, modele matematyczne itp.). Na wiedzę heurystyczną składają się między innymi bezpośrednio obserwacje operatora (szumy, wibracje, kolory, temperatura, zapach itp.), jego wiedza historyczna o obiekcie (np. o wcześniejszych awariach), doświadczenia wynikające z remontów i konserwacji, bazy danych zawierające między innymi informacje statystyczne o eksploatacji podobnych obiektów. Na podstawie mierzonych sygnałów i zmiennych obserwowanych oraz wiedzy analitycznej i heurystycznej możliwe jest wyodrębnienie analitycznych i heurystycznych symptomów uszkodzeń obiektu będących podstawą do postawienia diagnozy (rys. 1.2).

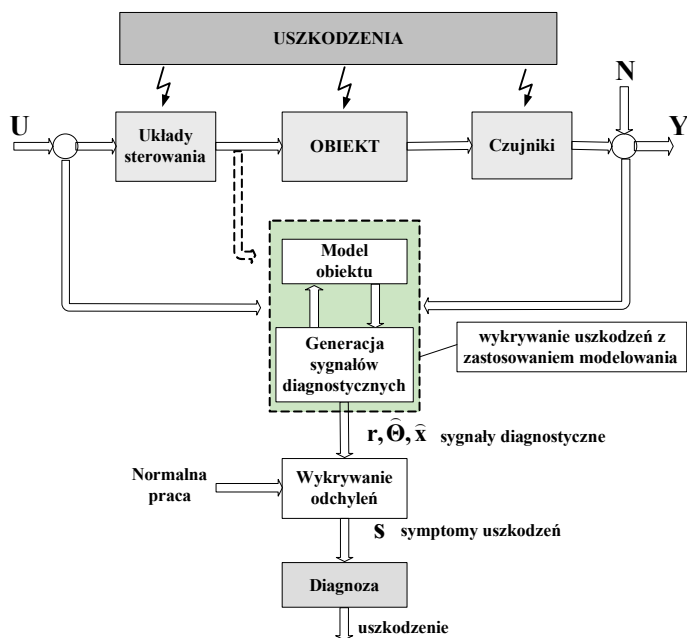


Rys. 1.2. Idea procesu diagnozowania

Ze względu na sposób uzyskiwania (generowania) symptomów można wyróżnić dwie podstawowe metody detekcji uszkodzeń:

- korzystające ze związków między zmiennymi charakteryzującymi obiekt (*metody porównawcze*),
- oparte na analizie i kontroli parametrów zmiennych charakteryzujących obiekt (*metody bezpośrednie*).

W metodach porównawczych system diagnostyczny jest wyposażony w model obiektu pracujący jednocześnie z obiektem diagnozowania. Na rysunku 1.3 przedstawiono podstawową strukturę układu detekcji z modelem obiektu. Na podstawie mierzonych sygnałów wejściowych i wyjściowych określone metody detekcji realizują zadania generacji residuów \mathbf{r} , estymacji stanu \mathbf{x} i parametrów Θ . W najprostszym przypadku sygnał diagnostyczny jest obliczany jako różnica między sygnałami wyjściowymi mierzonymi na obiekcie i uzyskiwanymi z modelu (residuum \mathbf{r}). Różnica ta oscyluje wokół zera, gdy obiekt działa poprawnie, natomiast wartości znacznie odbiegające od zera świadczą o uszkodzeniu. Najczęściej jednak na podstawie różnicy wyjścia modelu i obiektu estymuje się zmienne lub parametry stanowiące sygnały diagnostyczne, w których poszukuje się symptomów uszkodzeń.




Rys. 1.3. Ogólny schemat detekcji uszkodzeń z wykorzystaniem modeli analitycznych

Modele analityczne (modele ilościowe) mogą być w postaci: estymatorów lub obserwatorów stanu, filtrów Kalmana, równań parzystości typu wejście–wyjście [1.11,

1.13, 1.14]. Metody porównawcze wywodzą się bezpośrednio z metod redundancyjnych i w przypadku gdy model ma postać analityczną, mówi się o tzw. redundancji analitycznej. W przypadkach gdy residuum otrzymuje się z porównania sygnałów rzeczywistych z sygnałami z modeli neuronowych lub rozmytych, można mówić o redundancji informatycznej [1.11, 1.14], rozumianej jako szczególny przypadek redundancji analitycznej. Modele tworzone za pomocą metod sztucznej inteligencji są modelami jakościowymi lub jakościowo-ilościowymi.

Metody diagnostyki wykorzystujące modele matematyczne są bardzo wrażliwe na adekwatność zastosowanych modeli i zakłócenia pomiarowe. Przy realizacji on-line wymagają dużych mocy obliczeniowych. Złożoność obiektów, jakimi są maszyny (maszyny elektryczne, napędy obrabiarek i robotów przemysłowych itp.), konieczność znajomości wielu trudno identyfikowalnych parametrów powoduje, że występują istotne problemy związane z zagadnieniem odpowiedniej wiarygodności modeli analitycznych. Niedokładny model dostarczałby nieprawdziwych informacji i wzorców diagnostycznych, co powodowałoby powstawanie fałszywych alarmów. Metody te są powszechnie stosowane w diagnostyce procesów technologicznych. Problemy zastosowania metod opartych na modelach matematycznych w diagnostyce napędów elektrycznych szerzej przedstawiono w rozdziale 6.

W metodach należących do drugiej grupy, symptomy uszkodzeń są wykrywane bezpośrednio na podstawie analizy i oceny przebiegu wybranej wielkości fizycznej. W najprostszych przypadkach kontrolowane są granice wiarygodności, granice alarmowe poszczególnych zmiennych lub dokonywana jest analiza tych zmiennych (np. analiza spektralna, korelacyjna, falkowa, analiza parametrów statystycznych, kontrola trendów, kontrola ograniczeń itp.) w celu wykrycia i wyodrębnienia symptomów uszkodzeń (rys.1.4).



Rys. 1.4. Ilustracja działania z zastosowaniem klasycznych metod diagnostyki opartych na analizie sygnałów

Metody tej grupy są stosunkowo proste, gdyż nie wymagają wiedzy w postaci modelu matematycznego obiektu. Natomiast mają wady wynikające z ograniczonej informacji diagnostycznej przekazywanej przez pojedyncze sygnały oraz interakcje i niejednoznaczności zmian parametrów sygnałów (np. ich niestacjonarność), co istotnie utrudnia określanie związków między symptomami a uszkodzeniami.

Obecnie obserwuje się rosnące zainteresowanie zastosowaniem metod i techniki sztucznej inteligencji (sieci neuronowych, logiki rozmytej i sieci neuro-rozmytych)

w monitorowaniu i diagnostyce uszkodzeń obiektów [1.1, 1.4, 1.6, 1.11, 1.13, 1.15, 1.17, 1.23, 1.24]. Metody te w odniesieniu do diagnostyki procesów technologicznych umożliwiają zastąpienie modeli analitycznych modelami jakościowymi i jakościowo-ilościowymi, natomiast w odniesieniu do diagnostyki takich obiektów, jak maszyny i urządzenia, stanowią atrakcyjne narzędzie ułatwiające przetwarzanie informacji diagnostycznej i detekcję uszkodzeń.

1.2. Podstawowe zagadnienia monitorowania i diagnostyki silników indukcyjnych

Obecnie zautomatyzowane procesy produkcyjne wymagają stosowania coraz bardziej skomplikowanych urządzeń, w tym również napędów elektrycznych. Maszyna elektryczna wraz z maszyną roboczą oraz układami zasilania i sterowania, narażone są na liczne awarie, pomimo stosowania elementów i materiałów o dużej niezawodności. Długotrwałe zakłócenia procesu technologicznego powodują duże straty ekonomiczne. Dlatego też zagadnienie oceny stanu technicznego maszyny elektrycznej oraz związanej z tym szybkiej detekcji i lokalizacji uszkodzeń mają duże znaczenie praktyczne.

Zagadnienie wczesnego wykrywania uszkodzeń w silniku i informowania o fakcie ich zaistnienia użytkownika układu napędowego ma bardzo duże znaczenie praktyczne i ekonomiczne. Umożliwia uniknięcie przerwy w produkcji, obniżenie kosztów remontów i nakładów na bieżącą eksploatację [1.8, 1.16, 1.22].

Nawet w normalnych warunkach eksploatacji maszyn elektrycznych procesy zużycia i starzenia przebiegają nieprzerwanie. Dlatego w eksploatacji układów napędowych podstawowe znaczenie ma prawidłowa realizacja tzw. obsługi technicznej napędu. Na obsługę techniczną składają się czynności prewencyjne (konserwacja, kontrola) oraz czynności korekcyjne (remonty i naprawy). Wszystkie te czynności mają na celu zapobieganie awariom, wczesne wykrywanie anomalii, umożliwiające wymianę elementów w momencie najkorzystniejszym ze względu na minimalizację strat. Obsługa techniczna może być realizowana na różne sposoby, w zależności od rodzaju uszkodzenia, czasu eksploatacji, aktualnego stanu technicznego.

W przypadku obsługi technicznej powiązanej z rodzajem uszkodzenia użytkownik nie ma żadnego wpływu na stan maszyny elektrycznej. Każdy przestój zdarza się nagle i niezapowiedzianie, a obsługa techniczna działa dopiero po wystąpieniu uszkodzenia. Ma to w praktyce sens tylko w niektórych sektorach działalności gospodarczej (np. w drobnym przemyśle i gospodarstwach domowych). Obecnie dominuje obsługa zapobiegawcza, prowadzona w określonych odstępach czasu. Uwzględniając plan produkcji, po określonym na podstawie doświadczeń czasie eksploatacji, układ napędowy zatrzymuje się, poddaje kontroli, rozbiera na elementy, wymienia części lub całe podzespoły.

Taka strategia obsługi jest kosztowna i nieoptymalna. Często się zdarza, że wymieniane są części i podzespoły jeszcze dobre lub wymiana przeprowadzana jest zbyt późno. Tak więc korzyściom wynikającym z możliwości zaplanowania przestojów w eksploatacji można przeciwstawić duże koszty związane z taką obsługą techniczną.

Koszty eksploatacyjne można istotnie zredukować, jeżeli jest realizowane monitorowanie pracy maszyny (nadzór eksploatacyjny). W sytuacji gdy wprowadza się monitorowanie pracy maszyny, staje się możliwe przejście do obsługi technicznej realizowanej na podstawie rzeczywistego stanu technicznego maszyny elektrycznej. Przy takim postępowaniu należy układ wyłączyć z eksploatacji tylko wtedy, gdy jego stan techniczny jest nieodpowiedni.

Monitorowanie maszyn i układów napędowych może być realizowane według różnych strategii. Wybór strategii zależy od rangi, jaką w zakładzie przemysłowym i procesie produkcyjnym ma każdy napęd. W ogólnym przypadku można wyróżnić trzy podstawowe grupy maszyn i układów:

- maszyny i układy newralgiczne,
- maszyny i układy ważne ze względu na realizowane funkcje i moc,
- maszyny i układy małej mocy ważne ze względu na ich liczbę, mniej ważne ze względu na wykonywane funkcje.

Przynależność maszyny i układu do określonej grupy ma istotny wpływ na strategię monitorowania oraz dobór i zakres metod diagnozowania. Można wyróżnić trzy podstawowe rodzaje monitorowania:

- monitorowanie ciągłe (on-line), podczas funkcjonowania maszyny, wymagające zainstalowania aparatury diagnostycznej na stałe,
- monitorowanie okresowe, prowadzone według określonego harmonogramu,
- monitorowanie inspekcyjne, stosowane w określonych krytycznych sytuacjach.

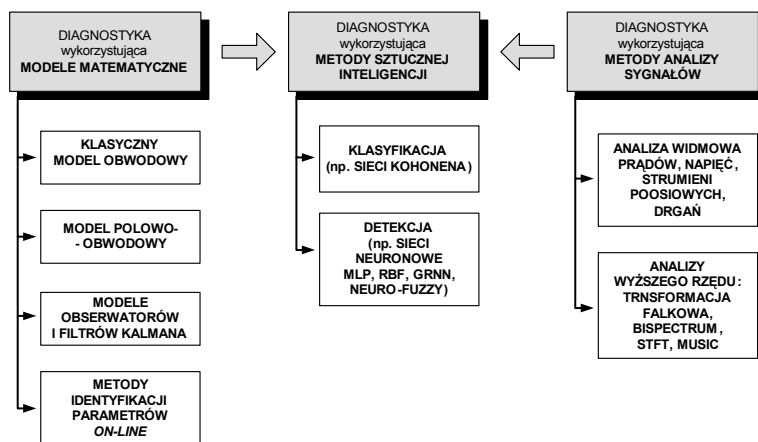
Monitorowanie ciągłe należy realizować na newralgicznych układach napędowych lub napędach działających w bardzo kosztownych lub niebezpiecznych instalacjach przemysłowych. Wyspecjalizowane i złożone systemy diagnostyczne analizują sygnały w czasie rzeczywistym, umożliwiając określenie zachowań anormalnych (według określonych kryteriów lub norm) oraz tworzenie baz danych i ich wykorzystanie do interpretacji wyników monitorowania.

Monitorowanie okresowe realizowane jest zwykle za pomocą przenośnych systemów diagnostycznych na ważnych instalacjach przemysłowych, których awarie bywają kosztowne i destabilizują cykl produkcyjny [1.2, 1.22]. Ten rodzaj monitorowania wiąże się zwykle ze zwiększonym zakresem diagnostyki eksploatacyjnej, która ma dostarczać informacji o aktualnym stanie technicznym w postaci widma sygnałów diagnostycznych, trendów, stopnia korelacji itp. Dane te służą do budowy baz danych, które systematycznie przetwarzane, dostarczają obsłudze informacji o aktualnym stanie obiektu. Obecnie, dzięki rozwojowi techniki przetwarzania sygnałów oraz obniżeniu ceny aparatury diagnostycznej, ten rodzaj monitorowania i diagnostyki staje się bardzo atrakcyjny i opłacalny dla napędów elektrycznych coraz mniejszej mocy.

W przypadku mniej ważnych układów napędowych celowe jest monitorowanie o ograniczonym zakresie. Monitorowanie minimalne jest oparte na prostych kryteriach wynikających z norm, zaleceń producentów czy też warunków technicznych eksploatacji układu. Są to zwykle kryteria dopuszczenia maszyny do ruchu, poziomy alarmowe, których przekroczenie wymaga działań korekcyjnych. Tego typu monitorowanie zwykle jest realizowane za pomocą prostej aparatury kontrolno-pomiarowej.

Monitorowanie i diagnostyka maszyn elektrycznych realizowane są na podstawie wielkości fizycznych mierzonych bezpośrednio lub pośrednio. W trakcie pracy napędu elektrycznego mogą być monitorowane wielkości wejściowe (zasilające i sterujące) oraz wyjściowe (elektryczne i mechaniczne), w tym tzw. procesy resztkowe towarzyszące eksploatacji układu [1.2, 1.3, 1.16]. W rozdziale 3 omówiono szczegółowo wielkości fizyczne stosowane do monitorowania stanu technicznego napędów elektrycznych.

W warunkach przemysłowych diagnostyka eksploatacyjna dotyczy przede wszystkim silników indukcyjnych, ze względu na to, że stanowią one ponad 90% wszystkich silników elektrycznych zainstalowanych w przemyśle. W ograniczonym zakresie monitoruje się i diagnozuje stan energoelektronicznych układów przekształtnikowych, chociaż są prowadzone w tym zakresie intensywne badania [1.10, 1.11, 1.22]. Osobnym problemem jest wykrywanie uszkodzeń w maszynach elektrycznych zasilanych z przemienników częstotliwości, pracujących w strukturach sterowania skalarnego i wektorowego. Wybrane zagadnienia monitorowania napędów przekształtnikowych omówiono w dalszej części monografii.



Rys. 1.5. Kierunki rozwoju metod diagnostyki napędów z silnikami indukcyjnymi

Obserwując aktualne tendencje w zakresie rozwoju metod diagnostyki napędów z silnikami indukcyjnymi, można zauważyć, że są rozwijane trzy nurty badań w tej problematyce (rys. 1.5):

- badania nad zastosowaniem modelowania matematycznego i metod estymacji stanu i parametrów w diagnostyce [1.11, 1.12, 1.17],
- rozwój nowych metod analizy sygnałów w diagnostyce [1.1, 1.5, 1.15, 1.19, 1.23],
- zastosowanie metod i techniki sztucznej inteligencji w diagnostyce [1.4, 1.13, 1.15, 1.16, 1.24].

Podejście oparte na analizie sygnałów ma obecnie podstawowe znaczenie w diagnostyce napędów z silnikami indukcyjnymi. Diagnostyka wykorzystująca metody oparte na modelach matematycznych jest na etapie badań laboratoryjnych, rozwiązań prototypowych i jednostkowych wdrożeń. Natomiast trzecia droga rozwoju jest w fazie badań i rozpoznawania przydatności w praktyce przemysłowej.

1.3. Zastosowanie modeli matematycznych do diagnostyki silników indukcyjnych

Metody diagnozowania uszkodzeń wykorzystujące modele matematyczne (metody porównawcze) są wdrażane w systemach monitorowania procesów przemysłowych. Natomiast w diagnostyce uszkodzeń silników indukcyjnych metody te są jeszcze na etapie badań laboratoryjnych. Ich zastosowanie opiera się na spostrzeżeniu, że uszkodzenia silnika objawiają się nie tylko jako zmiany wartości zmiennych stanu, ale także jako zmiany parametrów silnika. Jeżeli wobec tego istnieje możliwość prowadzenia na bieżąco estymacji parametrów i zmiennych stanu silnika oraz porównywania ich z wartościami występującymi w silniku nieuszkodzonym, to uzyskane informacje o pojawiających się zmianach są dobrymi symptomami uszkodzeń. Zwrócenie się specjalistów od diagnostyki w stronę tych metod wynika z faktu, że dotychczas stosowane metody diagnozowania, oparte na analizie spektralnej sygnałów, są często niewystarczające i zawodne, w przypadkach gdy silnik jest zasilany z regulowanego źródła napięcia. Jeżeli prędkość silnika nie jest stała i dodatkowo występuje zmienny charakter momentu obciążenia, sygnały diagnostyczne stają się niestacjonarne i korzystniejsze staje się stosowanie metod parametrycznych opartych na ciągłej (on-line) identyfikacji parametrów i zmiennych stanu.

Pierwsze informacje o badaniach nad zastosowaniem modelowania i estymacji do monitorowania silników indukcyjnych zostały podane na przełomie lat 90. XX w. [1.11, 1.17, 1.23]. Dotyczyły one głównie estymacji (odtworzenia) niemierzalnych zmiennych stanu (momentu elektromagnetycznego i strumienia) oraz parametrów schematu zastępczego silnika indukcyjnego na podstawie znajomości obwodowego modelu matematycznego maszyny. Podstawowe zastosowanie tych metod wiąże się ze sterowaniem napędami indukcyjnymi, gdzie niedostępne pomiarowo zmienne stanu i parametry stosuje się do realizacji odpowiednich sprzężeń zwrotnych, w tym do

odtworzenia prędkości kątowej w różnych strukturach sterowania [1.12, 1.17, 1.19, 1.23, 1.24].

Dopiero w ostatnich latach obserwuje się duże zainteresowanie specjalistów z zakresu diagnostyki metodami identyfikacji i estymacji na bieżąco parametrów silnika indukcyjnego, z zastosowaniem teorii obserwatorów i filtru Kalmana, bazujących na modelach obwodowych maszyn.

Do realizacji diagnostyki on-line za pomocą metod estymacji niezbędne jest wcześniejsze opracowanie odpowiednich modeli matematycznych silnika indukcyjnego uwzględniających uszkodzenia obwodu elektrycznego i magnetycznego. Jednak dokładny model, sformułowany dla minimalnych założeń upraszczających na podstawie metody elementów skończonych, gwarantuje dużą dokładność, ale równocześnie wymaga dużego czasu obliczeń, w związku z czym nie nadaje się do obliczeń realizowanych on-line. Z kolei konwencjonalny obwodowy model dwuosiowy nie wymaga dużego czasu obliczeń, ale oparty jest na licznych ograniczających go założeniach upraszczających. Dokładność modelu i czas obliczania rozwiązania są w opozycji do siebie.

W praktyce diagnostycznej poszukuje się alternatywnych modeli matematycznych, które zapewniłyby pewną równowagę między czasem i dokładnością obliczeń, w związku z czym nadawałyby się do realizacji w czasie rzeczywistym w systemach diagnostycznych.

Oprócz nurtu związanego z zastosowaniem modeli matematycznych do estymacji zmiennych stanu i parametrów uszkodzonych maszyn, istnieją również silne tendencje do opracowywania coraz dokładniejszych modeli obwodowych i polowych silników indukcyjnych, uwzględniających asymetrię stojana i wirnika, spowodowaną uszkodzeniami elektrycznymi i mechanicznymi. Modele takie umożliwiają generowanie wzorców diagnostycznych i tworzenie odpowiednio bogatych baz wiedzy eksperckiej, niezbędnej do wnioskowania diagnostycznego.

Istnieje bardzo bogata literatura krajowa i zagraniczna dotycząca obwodowych modeli matematycznych silników indukcyjnych, uwzględniających w mniejszym lub większym stopniu różnego typu uszkodzenia maszyny, a zwłaszcza [1.4, 1.6, 1.18, 1.21, 1.25].

Obecnie dostępne obwodowe modele matematyczne silników są w większości przypadków ciągle za mało dokładne na potrzeby diagnostyki. Dla nieprecyzyjnego modelu bardzo prawdopodobne jest powstawanie fałszywych alarmów, wynikających z błędów estymacji zmiennych stanu lub parametrów charakteryzujących dane uszkodzenie. Ponadto, do stosowania tych modeli na większą skalę niezbędna jest dokładna znajomość dużej liczby parametrów konstrukcyjnych i materiałowych silnika, podczas gdy zwykle dostępne są tylko podstawowe parametry katalogowe. W związku z tym, tworzone są ostatnio dokładne modele połowo-obwodowe, które są coraz bardziej wiarygodne i mogą być wykorzystywane jako źródło wzorców diagnostycznych [1.6].

Rozbudowany model obwodowy lub połowo-obwodowy, uwzględniający budowę obwodów elektrycznych i magnetycznych, ich nieliniowe właściwości, umożliwia

badania zjawisk zachodzących w uszkodzonej maszynie i poszukiwanie zależności przyczynowo-skutkowych, wyjaśniających mechanizm powstawania uszkodzeń i ich symptomów. Jako wzorce diagnostyczne mogą być stosowane np. widma prądu stojana dla różnych rodzajów i stopni uszkodzeń obwodów silnika, uzyskiwane na drodze badań symulacyjnych. Problematykę modelowania silników z uszkodzeniami szczegółowo przedstawiono w rozdziale 5.

Zagadnienia diagnostyki porównawczej opartej na modelowaniu i estymacji są przedmiotem rozważań w rozdziale 6, w odniesieniu do przekształtnikowych układów napędowych ze sterowaniem wektorowym.

1.4. Diagnostyka silników indukcyjnych oparta na analizie sygnałów pomiarowych

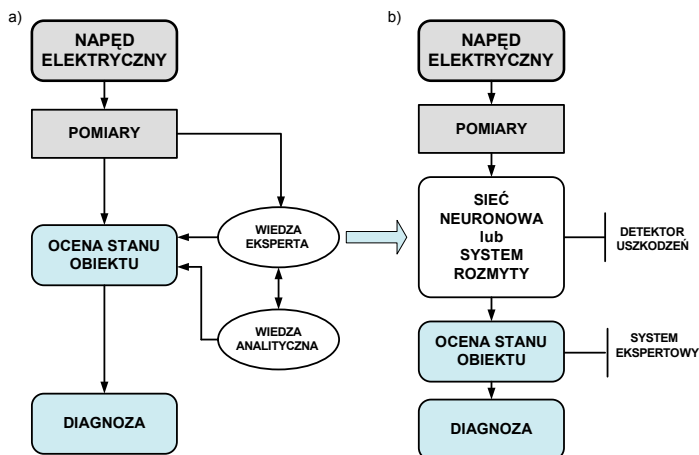
Obecnie, w monitorowaniu i diagnostyce uszkodzeń silników indukcyjnych, dominujące znaczenie ma analiza sygnałów bezpośrednio mierzonych na obiekcie. Proces takiego postępowania diagnostycznego zilustrowano na rysunku 1.4. W tej grupie metod diagnostyki, można zauważyć poszukiwania nowej techniki, która udoskonaliłaby problem wyodrębniania cech charakteryzujących uszkodzenia oraz oceny stopnia uszkodzenia. Dominujące znaczenie mają tzw. nieparametryczne metody wyznaczania cech sygnałów diagnostycznych, w tym przede wszystkim analiza widmowa oparta na algorytmie FFT. Analiza wykorzystująca szybką transformatę Fouriera (FFT) jest bardzo wygodnym narzędziem, ale w przypadkach wielu wariantów uszkodzeń, gdy sygnały mierzone zawierają skomplikowane nieliniowości lub są niestacjonarne, jej możliwości obliczeniowe stają się niewystarczające. Dlatego w wielu ośrodkach badawczych realizowane są badania nad zastosowaniem transformacji Fouriera wyższych rzędów lub o podwyższonej rozdzielczości oraz parametrycznych metod wyznaczania cech diagnostycznych [1.3–1.5, 1.15, 1.19].

Inną, testowaną obecnie drogą jest zastosowanie transformacji krótkoczasowej STFT (ang. *Short Time Fourier Transformation*) lub falkowej (ang. *Wavelet Transformation*) [1.1, 1.2, 1.5, 1.6, 1.15, 1.19, 1.20]. Metody te umożliwiają lokalną analizę i wyodrębnienie symptomów uszkodzeń w krótkim (informacja wysokoczęstotliwościowa) i długim czasie (informacja niskoczęstotliwościowa). Techniki te umożliwiają wykrywanie symptomów uszkodzeń we wczesnej fazie ich powstawania. Dzięki nim obecnie stosowane metody analizy sygnałów drgań, prądów stojana, momentu elektromagnetycznego, mocy elektrycznej i strumieni mogą być doskonałe i wzbogacone o nowe możliwości diagnostyczne. Należy oczekiwać, że w niedalekiej przyszłości przemysłowa aparatura diagnostyczna zostanie wzbogacona o nowe wymienione metody badawcze. Szczegółowe omówienie rozwijanych obecnie metod analizy sygnałów przedstawiono w rozdziale 4.

1.5. Diagnostyka silników indukcyjnych z zastosowaniem metod sztucznej inteligencji

W diagnostyce, opartej na metodach analizy sygnałów, wykorzystuje się wiedzę i doświadczenie człowieka–eksperta. To on dokonuje na bieżąco interpretacji aktualnych danych uzyskiwanych z pomiarów i analizy, realizowanych przez systemy pomiarowe. Podejście to ma jeden słaby punkt w postaci ludzkiego eksperta, który może się mylić i którego doświadczenie jest bardzo trudne do zautomatyzowania. Dlatego, oprócz doskonalenia metod analizy sygnałów, poszukuje się sposobu na zobiektywizowanie procesu wykrywania i oceny uszkodzenia. Można to osiągnąć przez wykorzystanie możliwości tkwiących w metodach i technikach sztucznej inteligencji.

Na rysunku 1.6 przedstawiono ideę klasycznego działania diagnostycznego opartego na wiedzy analitycznej i heurystycznej diagnosty oraz z zastosowaniem detektora uszkodzeń wykorzystującego sztuczną inteligencję. Do budowy tzw. detektorów i klasyfikatorów uszkodzeń najczęściej stosuje się sztuczne sieci neuronowe i logikę rozmytą. Zadaniem sieci neuronowej lub systemu rozmytego jest wykrycie uszkodzenia i jego klasyfikacja (ocena stopnia uszkodzenia) [1.4, 1.13, 1.15, 1.24].



Rys. 1.6. Diagnostyka obiektu z wykorzystaniem:
a) wiedzy analitycznej i heurystycznej b) detektora opartego na sztucznej inteligencji

Neuronowe i rozmyte detektory uszkodzeń można budować z wykorzystaniem danych uzyskiwanych z badań symulacyjnych (wykorzystanie informacji z modelowania matematycznego – generowanie wzorców diagnostycznych) lub z pomiarów na obiekcie rzeczywistym (wykorzystanie informacji z analizy sygnałów pomiarowych). Jedną z ważniejszych cech tego typu detektorów jest szybka realizacja procesu przetwarzania

nia wiedzy uzyskanej w procesie uczenia oraz udzielanie szybkiej odpowiedzi diagnostycznej. Problemem natomiast jest odpowiednio duża ilość informacji pomiarowej niezbędnej do trenowania i testowania sieci neuronowej. Dlatego duże znaczenie praktyczne mają bazy danych o uszkodzeniach, tworzone w czasie eksploatacji obiektów przemysłowych.

Metody i techniki sztucznej inteligencji umożliwiają w znacznym stopniu zobiektywizowanie procesu klasyfikacji i oceny uszkodzenia. Tym samym pojawia się możliwość zmniejszenia roli człowieka – eksperta w procesie diagnozowania oraz automatyzacji tego procesu.

W dalszej części monografii omówiono podstawowe problemy projektowania neuronowych detektorów uszkodzeń (rozdział 7) oraz przedstawiono przykłady praktycznej realizacji detektorów i klasyfikatorów podstawowych uszkodzeń silnika indukcyjnego (rozdziały 8–10). Jednak metody analizy sygnałów (klasyczne lub nowe) stanowiły zawsze punkt wyjściowy do uzyskiwania informacji diagnostycznej (symptomów uszkodzeń) z danych eksperymentalnych na obiektach rzeczywistych. Tak wyodrębnione symptomy są wykorzystywane do uczenia sieci neuronowych.

1.6. Podsumowanie

W ostatnim okresie obserwuje się gwałtowny rozwój badań w zakresie diagnostyki procesów przemysłowych, co jest niewątpliwie następstwem wzrastającego zainteresowania przemysłu zastosowaniami systemów diagnostycznych. Wynika ono z potencjalnie dużych korzyści ekonomicznych, które mogą przynieść wdrożenia takich systemów oraz pojawieniem się nowych rozwiązań systemów automatyki przemysłowej, umożliwiających zastosowanie zaawansowanych technik sterowania i diagnostyki obiektów.

Również w obszarze elektrycznych układów napędowych problematyka monitorowania i diagnostyki uszkodzeń zaczyna obejmować nie tylko tzw. napędy krytyczne o bardzo dużej mocy, ale również napędy małej i średniej mocy. Dotyczy to przede wszystkim tzw. napędów przekształtnikowych, tzn. wyposażonych w energoelektroniczny przekształtnik energii.

Obecnie w eksploatacji napędów elektrycznych dominują metody monitorowania i diagnostyki oparte na pomiarach wybranych wielkości fizycznych i porównywanie ich (lub parametrów na ich podstawie obliczonych) z wartościami granicznymi albo na analizie tych wielkości w dziedzinie czasu i częstotliwości. Brak jest natomiast zastosowania na szerszą skalę metod diagnostyki opartych na modelach jakościowych i jakościowo-ilościowych.

Ze względu na specyfikę nowoczesnych napędów elektrycznych, m.in. zmienną częstotliwość zasilania silników, odkształcenie prądów i napięć, zmienne warunki

obciążenia, duże wymagania dotyczące dokładności i dynamiki regulacji prędkości, bezpośrednie przeniesienie metod opracowanych na potrzeby diagnostyki procesów przemysłowych nie zawsze jest możliwe.

W przekształtnikowych układach napędowych występuje problem wykrywania uszkodzeń w strukturze przekształtnika energoelektronicznego oraz w silniku elektrycznym. Pierwsza grupa zagadnień nie jest omawiana w niniejszej monografii. Uwaga zostanie skupiona na problematyce wykrywania uszkodzeń w silniku indukcyjnym zasilanym z przemiennika częstotliwości, pracującym w strukturze sterowania skalarnego i wektorowego. Wykorzystując podejście oparte na analizie wybranych sygnałów diagnostycznych, zostaną przedstawione problemy ekstrakcji symptomów uszkodzeń silnika indukcyjnego oraz ich zastosowanie do projektowania neuronowych detektorów uszkodzeń oraz zautomatyzowanych systemów diagnostycznych.

Literatura

- [1.1] Bellini A., Filippetti F., Tassoni C., Cappolino G.A., *Advances in diagnostic techniques for induction machines*, IEEE Trans. Ind. Electron., Vol. 55, No. 12, 2008, 4109–4126.
- [1.2] Cempel C., Tomaszewski F., *Diagnostyka maszyn*, Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom 1992.
- [1.3] Cholewa W., Kiciński J., *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów*, Wyd. Politechniki Śląskiej, Gliwice 1993.
- [1.4] Chow M., *Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection*, World Scientific, 1993.
- [1.5] Chow T.W.S., Tan H., *HOS – based nonparametric and Parametric Methodologies for Machine Fault Detection*, IEEE Trans. on Ind. Electronics, Vol. 47, No. 5, 2000, 1051–1059.
- [1.6] Faiz J., Ebrahimi B. M., Sharifian M. B. B., *Different Faults and Their Diagnosis Techniques in Three-Phase Squirrel-Cage Induction Motors – A Review*, Electromagnetics, 26, 2006, 543–569.
- [1.7] Frank P., *Fault Diagnosis in Dynamic Systems Using Analytical and Knowledge-based Redundancy – A survey and Some New Results*, Automatica, Vol. 26, No. 3, 1990, 459–474.
- [1.8] Glinka T., *Badania diagnostyczne maszyn elektrycznych w przemyśle*, BOBRME Komel, Katowice 2002.
- [1.9] Isermann R., Balle P., *Trends in the application of model-based fault detection and diagnosis of technical processes*, Control Engineering Practice, Vol. 5, No. 5, 1997, 709–719.
- [1.10] Isermann R., *Fault-Diagnosis Systems. An Introduction from Fault Detection to Fault Tolerance*, Springer-Verlag, Berlin–Heidelberg 2006.
- [1.11] Isermann R., *Fault-Diagnosis Applications, Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-tolerant Systems*, Springer-Verlag, Berlin, Heidelberg 2011.
- [1.12] Kaźmierkowski M.P., Blaabjerg F., Krishnan R., *Control in Power Electronics – Selected Problems*, Academic Press, USA, 2002.
- [1.13] Kościelny J.M., *Diagnostyka zautomatyzowanych procesów przemysłowych*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2001.
- [1.14] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., (red.), *Diagnostyka Procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002.

-
- [1.15] Kowalski C.T., *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Nr 57, seria Monografie nr 18, Oficyna Wydawnicza PWr., 2005.
- [1.16] Morel J., *Drgania maszyn i diagnostyka ich stanu technicznego*, Polskie Towarzystwo Diagnostyki Technicznej, Warszawa 1994.
- [1.17] Orłowska-Kowalska T., *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.
- [1.18] Rusek J., *Komputerowa analiza maszyny indukcyjnej z wykorzystaniem bilansu harmoniczych*, AGH Uczelniane Wydawnictwa Naukowo-Techniczne, Kraków 2000.
- [1.19] Singh G.K., Sa'ad Ahmed Saleh Al. Kazzaz, *Induction machine drive condition monitoring and diagnostic research – a survey*, Electric Power Systems Research, Vol. 64, 2003, 145–158.
- [1.20] Singh G. K., Sa'ad Ahmed A. K., *Vibration signal analysis using wavelet transform for isolation and identification of electrical faults in induction machine*, Electric Power Systems Research, 2004, 119–136.
- [1.21] Sobczyk T.J., *Metodyczne aspekty modelowania matematycznego maszyn indukcyjnych*, WNT, Warszawa 2004.
- [1.22] Szymaniec S., *Badania, eksploatacja i diagnostyka zespołów maszynowych z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 333, Opole 2013.
- [1.23] Vas P., *Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines*, Oxford University Press, Oxford 1993.
- [1.24] Vas P., *Artificial-Intelligence-Based Electrical Machines and Drives*, Oxford University Press, 1999.
- [1.25] Vas P., *Electrical Machines and Drives. A Space-Vector Theory Approach*, Oxford University Press, 1992.

2. Przegląd podstawowych uszkodzeń napędów z silnikiem indukcyjnym

2.1. Rodzaje, przyczyny i statystyka uszkodzeń silników indukcyjnych

W trakcie eksploatacji napędów z silnikami indukcyjnymi powstają w nich uszkodzenia w obwodach elektrycznych stojana i wirnika oraz w układzie mechanicznym silnika, współpracującej maszyny roboczej i w elementach sprzęgających oraz w przekształtnikach zasilających, układach sterowania i czujnikach pomiarowych.

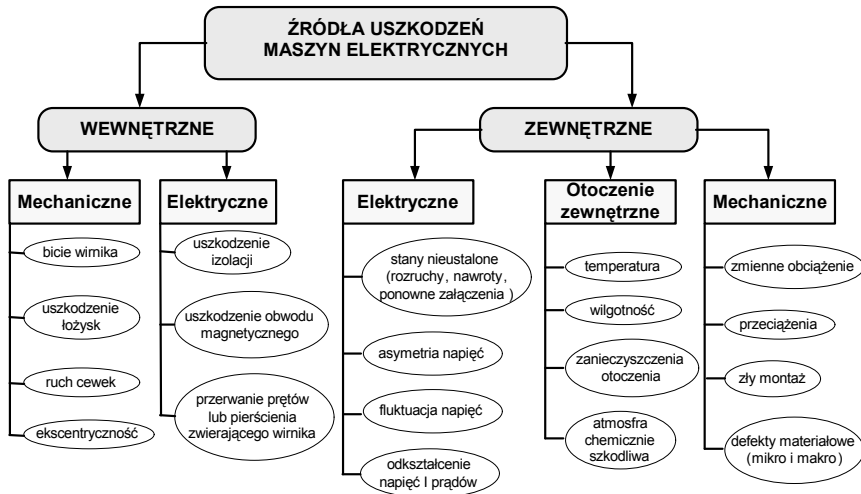
Przyczyny uszkodzeń silnika zależą od jego konstrukcji, jakości produkcji, montażu i instalacji, środowiska, w którym pracuje maszyna, charakteru obciążenia i technicznej obsługi (konserwacji). Silnik indukcyjny, jak każda maszyna elektryczna, jest poddawany działaniom sił elektromagnetycznych i mechanicznych. W normalnych warunkach pracy konstrukcja maszyny zapewnia stabilne współdziałanie tych sił z minimalnym poziomem zakłóceń i drgań. Jeżeli jednak pojawi się uszkodzenie, to znika równowaga między tymi siłami i następuje przyspieszony rozwój uszkodzenia. Możliwość wczesnego wykrywania rozwijających się uszkodzeń obwodów elektrycznych, magnetycznych i części mechanicznych jest jednym z ważniejszych problemów eksploatacyjnych silników indukcyjnych. Aby to było możliwe, konieczne jest ciągłe monitorowanie wielkości charakteryzujących stan techniczny maszyny.

Przyczyny uszkodzeń silników indukcyjnych mogą być: wewnętrzne i zewnętrzne (rys. 2.1).

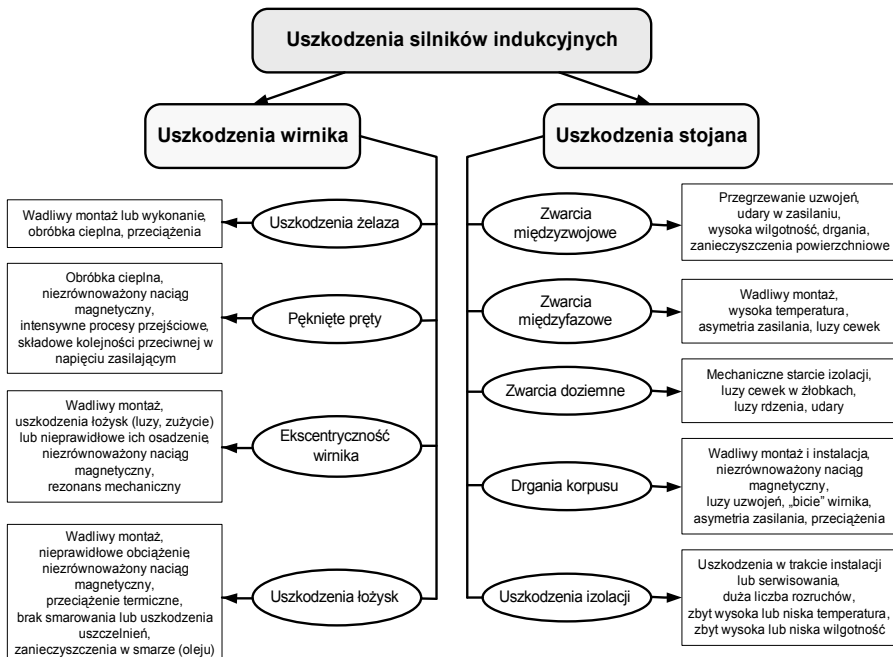
Wewnętrzne przyczyny uszkodzeń można podzielić na mechaniczne i elektryczne. Zewnętrzne przyczyny mogą również być typu elektrycznego i mechanicznego, ale należy do tej grupy zaliczyć również warunki związane ze środowiskiem pracy (otoczeniem). Ze względu na lokalizację można wydzielić trzy grupy uszkodzeń:

- uszkodzenia wirnika (pęknięte pręty lub pierścienie zwierające).
- uszkodzenia stojana (uszkodzenia izolacji uzwojeń i wynikające stąd zwarcia, uszkodzenia blach rdzenia).

- uszkodzenia sprzęgieł, przekładni zębatych lub pasowych, drgania maszyny roboczej itp.).



Rys. 2.1. Przyczyny uszkodzeń silników indukcyjnych [2.12]




Rys. 2.2. Uszkodzenia uzwojeń silników indukcyjnych oraz przyczyny ich powstawania [2.12]

Na rysunku 2.2 wyszczególniono najbardziej typowe uszkodzenia powstające w uzwojeniach stojana i wirnika oraz przyczyny je wywołujące.

W zależności od typu maszyny, rodzaju zasilania, napięcia i mocy, różna jest intensywność uszkodzeń poszczególnych jej części konstrukcyjnych (tzn. obwodów elektrycznego i magnetycznego oraz układów: izolacyjnego i mechanicznego). W maszynach indukcyjnych WN najczęściej ulega awariom układ izolacyjny uzwojeń, natomiast w maszynach NN małej mocy łożyska stanowią element najczęściej ulegający uszkodzeniom. Statystyka uszkodzeń i awarii silników indukcyjnych wysokiego i niskiego napięcia zmienia się w ostatnich latach. Wyraźnie następuje zwiększenie udziału uszkodzeń typu mechanicznego w stosunku do uszkodzeń obwodu elektrycznego oraz magnetycznego silników [2.4–2.6]. Wśród wszystkich uszkodzeń wyraźnie dominują uszkodzenia typu mechanicznego związane z łożyskami silników. Również stosunkowo często pojawiają się defekty fundamentów i mocowania silników oraz luzy w układzie wał-pakiet wirnika, niewywaga, nieosiowość, niesymetrie szczeliny pomiędzy stojanem a wirnikiem [2.18, 2.19].

Badania statystyczne uszkodzeń maszyn elektrycznych były w minionych latach prowadzone przez różne niezależne ośrodki i opublikowane wyniki w nieznacznym stopniu różniły się od siebie [2.6]. Ilościowy udział poszczególnych rodzajów uszkodzeń przedstawiono na rys. 2.3.



Rys. 2.3. Procentowy udział uszkodzeń silników indukcyjnych

Najczęstszym elektrycznym uszkodzeniem silnika indukcyjnego jest uszkodzenie uzwojeń stojana, zwłaszcza izolacji międzyzwojowej. Rzadziej występują uszkodzenia izolacji głównej i międzyfazowej. Zwarcie kilku zwojów nieznacznie zmienia prąd pobierany przez silnik, powoduje natomiast powstanie w zwartym obwodzie prądu o wartości nawet kilkadziesiąt razy większej od wartości znamionowej. Prowadzi to do szybkiego wzrostu temperatury izolacji, jej zniszczenia i rozprzestrzenienia się efektów zwarcia na całe uzwojenie [2.8].

Asymetrie uzwojenia stojana wywołane są bądź to błędami w budowie maszyny, bądź uszkodzeniami układu izolacyjnego w czasie eksploatacji. Uszkodzenia izolacji objawiają się nagle w postaci zwarcć i wymagają możliwie szybkiego odłączenia maszyny. Większość przypadków zwarcć jest wykrywana przez stosowane układy zabez-

pieczeń maszyn. Układy te nie reagują zwykle na zwarcia małej liczby zwojów w jednej fazie. Wykrywanie zwarć zwojowych w uzwojeniu stojana w trakcie normalnej eksploatacji silników indukcyjnych jest zagadnieniem trudnym i brak typowego rozwiązania przemysłowego [2.12, 2.13, 2.18, 2.19, 2.23].

Uszkodzenia wirników (pęknięcia prętów lub pierścienia zwierającego albo połączeń prętów z pierścieniami) i wynikająca stąd ich asymetria, należą do stosunkowo często spotykanych przyczyn awarii silników indukcyjnych WN. Występują one głównie w silnikach, które pracują w trudnych warunkach, mają częste i długie rozruchy. Uszkodzenia klatki (degeneracja spawów między prętami klatki a pierścieniem zwierającym, pęknięcia wycinków pierścienia, pęknięcia prętów) zaczynają się od uszkodzeń pojedynczych segmentów pierścieni lub kilku prętów, następnie rozszerzają się lawinowo. Uszkodzenia te rozszerzając się lawinowo, wywołują niekorzystne zjawiska w silniku: drgania spowodowane przemiennymi składowymi momentu elektromagnetycznego, nierównomierny naciąg magnetyczny, zwiększenie poślizgu silnika, niewyważenie i ekscentryczność wirnika. W efekcie, w trakcie dalszej eksploatacji prowadzi to do rozszerzenia uszkodzenia maszyny (np. mechaniczne uszkodzenie układu izolacyjnego stojana).

W grupie uszkodzeń mechanicznych najczęściej występują: uszkodzenia łożysk i związana z tym ekscentryczność wirnika. Źródłem ekscentryczności mogą być: niecentryczne osadzenie wirnika, luzy na łożyskach, ugięcie wału, niewyważenie wirnika, rezonans mechaniczny przy krytycznej prędkości obrotowej, zużycie łożysk [2.3, 2.6, 2.7]. W silnikach indukcyjnych najczęściej ulegają uszkodzeniu łożyska toczne i ślizgowe. Łożysko jest najbardziej odpowiedzialnym elementem mechanicznym w silniku. Jego głównym zadaniem jest bezpieczne przeniesienie obciążeń roboczych z elementu wirującego na korpus maszyny przy małych oporach ruchu. Z zasady działania jest więc ono generatorem drgań. Na skutek eksploatacji lub nieprawidłowego doboru łożyska ulegają przedwczesnemu zużyciu i w efekcie uszkodzeniu.

2.2. Uszkodzenia uzwojeń wirników klatkowych

Silniki indukcyjne klatkowe o mocy do ok. 100 kW mają wirniki z uzwojeniem wykonanym z aluminium. Ponieważ wypełnienie żłobków jest pełne i nie ma luzów między prętami a żłobkami wirnika oraz między pierścieniami zwierającymi i pakietem wirnika, nie ma więc możliwości powstania drgań w prętach oraz istnieje bardzo dobra wymiana ciepła. Dlatego uszkodzenia takich wirników są rzadko spotykane i zwykle są związane z błędem technologicznym lub wytopieniem uzwojenia. Stąd też dla takich silników potrzeba diagnozowania wirnika jest minimalna.

W przypadku silników klatkowych, o mocach większych od 100 kW lub w wykonaniu specjalnym, wirniki są wykonywane z klatką miedzianą, ewentualnie klatką

rozruchową mosięzną. Połączenia poszczególnych prętów z pierścieniami zwierającymi są wykonywane za pomocą lutów twardych. Dlatego mogą w nich występować luzy między prętami i żłobkami. Powoduje to, że:

- utrudniona jest wymiana ciepła między prętami i pakietem blach wirnika,
- powstają odkształcenia prętów w czasie ciężkich rozruchów na skutek działania sił termicznych i drgań prętów w żłobkach.

Wirniki takie powinny być diagnozowane przynajmniej okresowo, ze względu na częste występowanie w nich uszkodzeń.

Nawet bardzo drobne, praktycznie niezauważalne pęknięcie klatki, niewywołujące żadnego zauważalnego w eksploatacji obniżenia momentu obrotowego, wywołuje magnetyczną i prądową asymetrię w obwodach stojana i klatki wirnika. W wyniku asymetrii wirnika przeciążone są nie tylko uzwojenia. Wzrasta również naciąg magnetyczny między stojanem i wirnikiem, powodując zwiększenie obciążenia łożyska oraz zatarcie wirnika o stojan.

Głównym czynnikiem destrukcyjnym są szybkozmienne naprężenia dynamiczne będące wynikiem elektrodynamicznych sił żłobkowych działających na pręty w żłobkach wirnika oraz rezonansów mechanicznych klatki [2.1, 2.8]. Siły dynamiczne, występujące w pierwszej chwili po załączeniu, działają niszcząco na uzwojenie, wał i łożysko.

W czasie rozruchu silnika w uzwojeniach stojana i klatki wirnika wydzielają się duże ilości ciepła. Szybkie nagrzewanie się uzwojeń może prowadzić do zniszczenia izolacji stojana lub wytopienia fragmentów klatki. Nierównomierne nagrzewanie się prętów klatki jest przyczyną powstawania dużych naprężeń o charakterze termicznym. Ponadto groźne naprężenia wywołuje rozszerzalność cieplna pierścieni zwierających, które przy rozruchu nagrzewają się znacznie szybciej niż cały pakiet blach wirnika.

Stosując nowoczesne metody projektowania silników indukcyjnych, próbuje się zminimalizować wymienione niszczące oddziaływania, np. przez rozwiązania konstrukcyjne wirnika w postaci jednoklatkowej, głębokożłobkowej lub z prętami biernymi. Szczególnie to ostatnie rozwiązanie umożliwia zminimalizowanie większości strat rozruchowych, gdyż pręty bierne połączone ze sobą pierścieniami, przejmują je i w nich wydziela się ciepło. Związany z nim szybki wzrost temperatury nie powoduje niebezpiecznych naprężeń mechanicznych.

Wskutek uszkodzenia klatki uzwojenia wirnika lub pierścienia zwierającego powstaje asymetria, która powoduje nienormalne zachowanie się silnika. Eksploatacyjne objawy uszkodzenia wirnika są widoczne w charakterystykach mechanicznych silnika, wahaniami prądu stojana oraz w drganiach mechanicznych. Pogorszeniu ulegają podstawowe parametry silnika. Jednak typowe badania eksploatacyjne nie pozwalają wykryć uszkodzenia w początkowej fazie jego powstawania. Dlatego poszukuje się takich metod diagnozowania, które umożliwią skuteczne wykrywanie uszkodzenia we wczesnym etapie jego rozwoju.

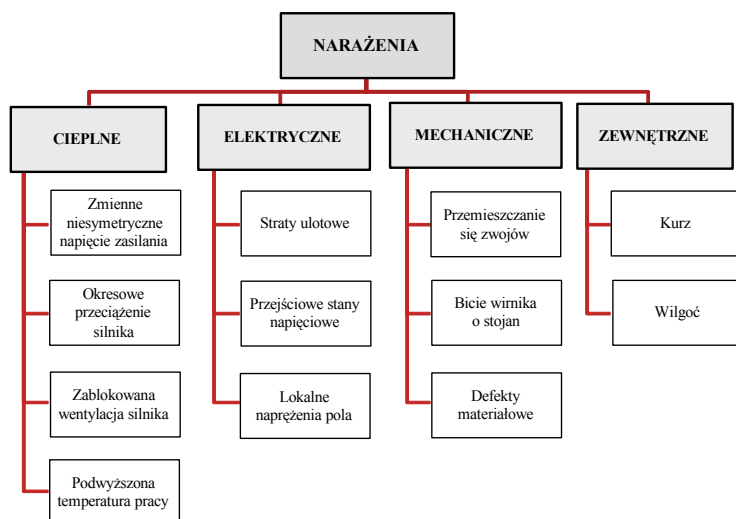
Obecnie rozwijane są trzy rodzaje metod:

- wykrywające uszkodzenie w trakcie normalnej eksploatacji maszyny [2.11, 2.12, 2.19],
- wymagające realizacji specjalnych warunków pracy silnika, przy których uwiadczniają się defekty uzwojenia [2.8],
- oparte na badaniu samego wirnika, polegające na szukaniu uszkodzonego pręta [2.8, 2.19].

Literatura, dotycząca metod diagnozowania uzwojeń wirnika klatkowego, jest bardzo bogata. W dalszych rozważaniach uwaga zostanie skupiona jedynie na metodzie nieinwazyjnej, umożliwiającej prowadzenie monitorowania i diagnostyki wirników w biegu, w trakcie normalnej eksploatacji silnika.

2.3. Uszkodzenia uzwojeń stojana

Najczęstszym elektrycznym uszkodzeniem silnika indukcyjnego są uszkodzenia uzwojeń stojana wynikające zazwyczaj z degradacji izolacji międzyzwojowej, międzyfazowej lub głównej [2.1, 2.6, 2.12, 2.13, 2.20, 2.21]. Na rysunku 2.4 przedstawiono schematycznie narażenia oddziałujące na system izolacji silnika.



Rys. 2.4. Narażenia oddziałujące na układ izolacyjny silnika

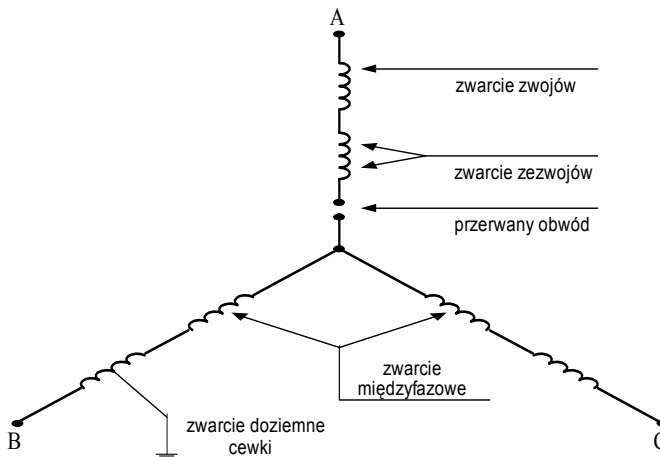
Czynnikami wpływającymi na zużycie lub zniszczenie izolacji są:

- temperatura uzwojeń, wynikająca między innymi z warunków eksploatacji silnika (częste ciężkie rozruchy, przeciążenia, zła wentylacja, duże straty itp.),

- czas eksploatacji silnika (starzenie się izolacji),
- warunki eksploatacji (praca w trudnych warunkach w obecności wilgoci, pyłu, gazów aktywnych itp.),
- napięciowe stany przejściowe oraz indukowane przez falownik PWM przebiecia,
- błędy konstrukcyjne i produkcyjne.

Na rysunku 2.5 przedstawiono podstawowe rodzaje zwarć możliwych do wystąpienia w uzwojeniach stojana połączonych w gwiazdę:

- 1° zwarcia zwojowe w obrębie jednej cewki,
- 2° zwarcia między cewkami w jednej fazie,
- 3° zwarcia międzyfazowe,
- 4° zwarcia doziemne cewki (zwarcia fazy do ziemi),
- 5° przerwa w fazie.



Rys. 2.5. Podstawowe rodzaje zwarć w uzwojeniach stojana silnika indukcyjnego

W przypadku 1° i 2° silnik będzie pracował jeszcze przez jakiś czas, trudny do oszacowania. W przypadku 3° i 4° silnik jest awaryjnie odłączany od sieci przez zabezpieczenia. Natomiast w przypadku 5° silnik może kontynuować pracę zależnie od warunków obciążenia. W przypadku 3° i 4°, czyli przy najpoważniejszych uszkodzeniach, wczesne ostrzeżenie ma tylko sens wówczas, gdy zwarcie jest w stadium początkowym (zwarcie 1–2 zwojów), a to z kolei wiąże się z koniecznością ciągłego monitorowania uszkodzeń typu 1° i 2°. Większość specjalistów uważa, że zwarcia międzyzwojowe są podstawowym uszkodzeniem występującym w czasie rozwoju pozostałych przypadków (rys. 2.5). Dlatego też na wykrywaniu zwarć międzyzwojowych jest skupiona uwaga w wielu ośrodkach badawczych. Czas przejścia od początków zaistnienia uszkodzenia w uzwojeniu stojana (zwarcie 1–2 zwojów w cewce)

do wystąpienia zwarć międzyfazowych i doziemnych jest trudny do oszacowania. Jest on funkcją wielu zmiennych i może być inny dla każdego silnika. Dlatego wielu producentów i użytkowników silników średniego i niskiego napięcia uważa, że ten czas jest zbyt krótki i neguje potrzebę ciągłego monitorowania i diagnostyki stanu uzwojeń stojana. Takie podejście jest coraz częściej uważane za przestarzałe i zbyt zachowawcze. W nowoczesnych systemach przemysłowych nawet ten dostępny krótki czas (od wystąpienia uszkodzenia do zdiagnozowania zwarcia kilku zwojów) może być wykorzystany do świadomego wyłączenia procesu produkcyjnego i wymiany uszkodzonego silnika.

Zagadnienie wpływu temperatury i czasu na trwałość izolacji jest szeroko opisane w literaturze, między innymi w [2.8, 2.18]. Jednak zależność stanu izolacji od czasu i temperatury nie może być wykorzystana do diagnostyki, czyli oceny jej stopnia zużycia. Na stan techniczny izolacji wpływają jednocześnie wszystkie wymienione czynniki. Ponadto w trakcie pracy silnika powstają siły elektrodynamiczne zawierające składową stałą i zmienną o częstotliwości 100 Hz, które powodują wzbudzenie drgań uzwojeń, szczególnie przy luźnym osadzeniu cewek w żłobkach. Powoduje to tarcie cewki o klin i ścianki żłobka, a w efekcie prowadzić może do mechanicznego zniszczenia izolacji.

Uszkodzenia izolacji objawiają się nagle w postaci zwarć w uzwojeniach i wymagają możliwie szybkiego odłączenia zasilania maszyny. Stosowane obecnie układy zabezpieczeń nie reagują na zwarcia małej liczby zwojów w uzwojeniu fazy, gdyż powodują one zbyt małe zmiany ilościowe w prądach fazowych. Natomiast prąd powstający w zwartym obwodzie, o wartości niekiedy kilkadziesiąt razy większej od prądu znamionowego, powoduje szybki wzrost temperatury, zniszczenie izolacji i rozprzestrzenienie się efektów zwarcia na całe uzwojenie.

Nie ma jednoznacznych kryteriów pozwalających określić stopień zużycia izolacji uzwojeń. Obowiązująca norma i przepisy dodatkowe określają tylko ogólne zalecenia i metody badań. Realizowane w zakładach przemysłowych badania izolacji można podzielić na następujące grupy:

- próba napięciowa, potwierdzająca poprawność wykonania izolacji i bezpieczeństwo urządzenia;
- badania diagnostyczne napięciem stałym lub przemiennym;
- badania diagnostyczne wykorzystujące wyładowania niezupełne.

Najczęściej stosowana jest metoda napięcia stałego, która jest prosta w realizacji i nie wymaga skomplikowanej aparatury [2.8, 2.18,]. Metoda wyładowań niezupełnych wymaga skomplikowanej aparatury diagnostycznej oraz dużego doświadczenia w interpretacji wyników [2.18–2.20]. Wszystkie wymienione metody wymagają odłączenia maszyny od zasilania i podłączenia do specjalnego źródła zasilania i układu pomiarowego. Są one stosowane przede wszystkim w diagnostyce silników wysokonapięciowych (powyżej 4 kV). Są to więc metody diagnostyczne inwazyjne i w ograniczonym zakresie nadają się do realizacji on-line i nie są przedmiotem rozważań w niniejszej pracy.

2.4. Uszkodzenia mechaniczne

Do głównych przyczyn powstawania uszkodzeń mechanicznych silników indukcyjnych należy zaliczyć: uszkodzenie łożysk, ekscentryczność wirnika, niewyważenie wirnika silnika lub maszyny napędzanej, niewłaściwe (niewspółosiowe) połączenie silnika z maszyną napędzaną, niewspółosiowo ustawione łożyska silnika [2.2, 2.6, 2.7, 2.12, 2.14, 2.23, 2.24].


Źródłem nierównomierności szczeliny powietrznej mogą być: niecentryczne osadzenie wirników w czasie montażu lub pojawienie się niecentryczności w trakcie eksploatacji na skutek luzów w łożyskach i ugięcia wału (ekscentryczność statyczna i dynamiczna). Ponadto w trakcie eksploatacji mogą wystąpić: niewyosiowanie napędu, niewyważenie wirnika, zużycie łożysk i rezonanse mechaniczne przy prędkościach krytycznych. Każda z przyczyn może występować osobno lub razem z innymi, a ich następstwem są liczne wtórne zjawiska i defekty:

- wzrost drgań na skutek niezrównoważonego naciągu magnetycznego,
- przedwczesne zużycie łożysk lub ich uszkodzenie,
- możliwe tarcie wirnika o stojan lub utknięcie podczas rozruchu, a w konsekwencji iskrzenie, wydzielanie ciepła, zniszczenie izolacji blach stojana i wirnika powodujące zwiększenie strat w żelazie lub zwarcia w uzwojeniach stojana,
- wibracje o dużej częstotliwości [kHz] przenoszone na stojan, zwiększające możliwość mechanicznego uszkodzenia (pęknięcia izolacji, połączeń czołowych) i powstanie zwarć lub przerw,
- wzrost indukowanego napięcia wałowego powodującego szybsze zużycie łożysk,
- zmniejszenie momentu krytycznego i rozruchowego silnika.


W eksploatacji maszyn elektrycznych jednym z częściej uszkadzających się zespołów są łożyska toczne (według szacunkowych danych ok. 80% urządzeń eksploatowanych przez człowieka zawiera w swej konstrukcji łożyska toczne [2.3]). Przyczyną uszkodzenia łożyska może być uszkodzenie silnika zarówno natury elektrycznej, jak i mechanicznej, również uszkodzenia maszyny napędzanej. Jak wskazują statystyki, łożyska toczne są najczęściej uszkadzającymi się elementami maszyn wirnikowych (rys. 2.6). Stąd też diagnostyka łożysk tocznych stała się od lat 50. XX w. dynamicznie rozwijającą się dziedziną badań [2.3, 2.14, 2.24].

Praktyka przemysłowa wskazuje, że problem skutecznej diagnostyki eksploatacyjnej węzłów łożyskowych silników elektrycznych jest jednym z najważniejszych zagadnień eksploatacji silników elektrycznych [2.6, 2.7, 2.18, 2.19]. O poprawności pracy łożyska tocznego decyduje spełnienie przez nie wymagań technicznych dla danego węzła konstrukcyjnego. Jeżeli w węźle łożyskowym zamontowano łożysko spełniające wymagane kryteria jakości, przyczynami jego niepoprawnej pracy mogą być:

- naturalne uszkodzenie łożyska na skutek przekroczenia jego nominalnej trwałości,
- przedwczesne uszkodzenie wynikające m.in. ze złego doboru łożyska lub jego złej eksploatacji.



Rys. 2.6. Przyczyny uszkodzeń mechanicznych maszyn elektrycznych



Rys. 2.7. Procentowy udział przyczyn awarii łożysk tocznych

Pierwszą istotną informacją diagnostyczną jest więc czas pracy łożyska w odniesieniu do jego zakładanej trwałości. Inną przyczyną naturalnej utraty właściwości łożyska może być zużycie powierzchni tocznych, narastające przez cały okres eksploatacji. Znaczna część uszkodzeń łożysk to uszkodzenia przedwczesne, wynikające bezpośrednio z:

- nieprawidłowości powstałych w trakcie produkcji: niejednorodność materiału, tolerancja wykonania,
- błędnego magazynowania i transportu: nieostrożne pakowanie, wpływ drgań,
- nieprawidłowych czynności montażowych: deformacja łożyska, złe zamontowanie, tolerancja wymiarów.

Badania statystyczne wskazują na to, że tylko 25% uszkodzeń łożyska jest skutkiem naturalnego zużycia (rys. 2.7) [2.3, 2.6]. Najczęstsze poważne uszkodzenia wtórne powodowane uszkodzeniem łożysk to:

- uszkodzenie gniazda łożyska,
- deformacja lub pęknięcie wału,
- rozerwanie sprzęgła powodujące uszkodzenie uzwojenia silnika,
- uszkodzenie obudowy maszyny,
- zapłon czynnika smarującego i w konsekwencji pożar.

Typowymi objawami towarzyszącymi efektom związanym z uszkodzeniami łożysk są: wzrost temperatury, wzrost oporów ruchu, zanieczyszczenie oleju, wzrost hałasu, wzrost generowanych drgań, emisja akustyczna.

W silnikach indukcyjnych dużej mocy, zwłaszcza o mocach powyżej 1 MW, stosowane są łożyska ślizgowe. Ich uszkodzenia spowodowane są przede wszystkim zużyciem panewek, czopów, elementów oporowych. Do najczęstszych przyczyn zniszczenia warstwy ślizgowej zalicza się: nieosiowość, wysoki poziom drgań, zaburzenia lub/i przerwy w smarowaniu powodujące zanik filmu olejowego. Do przyspieszonego zużycia prowadzi obecność twardych cząstek w oleju (obecnie ciała), a w przypadku maszyn elektrycznych, prąd przepływający przez łożysko powodujący uszkodzenia punktowe, tzw. wżery (tzw. efekt prądów łożyskowych, który jest również zauważalny w przypadku silników indukcyjnych zaopatrzonych w łożyska toczne). Efekt ten jest dość wyraźnie zauważalny w przypadku zasilania silników z falowników. W przypadku uszkodzeń łożysk może niejednokrotnie dojść do urwania końcówki wału (efekt wtórny uszkodzenia łożyska). Występuje to zwłaszcza wówczas, gdy uszkodzony wcześniej czop wału poddany został naprawie przez napawanie, a następnie obróbkę skrawaniem (dotyczy to głównie strony napędowej silnika).

Bez względu na staranność zabiegów w trakcie wytwarzania, nie udaje się sprawić, by środki masy wszystkich elementarnych części wirnika leżały na osi obrotu. W rezultacie siły odśrodkowe powodują jego deformację. Występuje zjawisko niewyważenia wirnika, któremu towarzyszą drgania. Główne przyczyny powstawania niewyważenia to wady obróbki fabrycznej lub montażu wirników. W czasie pracy mogą również występować deformacje wywołane nierównomiernym nagrzewaniem się wirnika.

Jednym z najważniejszych warunków bezawaryjnej pracy zespołów maszynowych jest prawidłowe ustawienie sprzęgniętych ze sobą maszyn. W zakres czynności związanych z ustawieniem zespołu maszynowego wchodzi tzw. osiowanie maszyn (centrowanie). Osiowanie to zespół działań technicznych, który sprowadza się do takiego ustawienia wałów maszyn, aby powierzchnie czołowe obydwu połówek sprzęgła były względem siebie równoległe, a osie wałów stanowiły przedłużenie jedna drugiej w obrębie przyjętych tolerancji. Weryfikacja następuje w dwu płaszczyznach, poziomej i pionowej. Przy prawidłowo przeprowadzonym procesie osiowania są spełnione dwa warunki [2.6, 2.7, 2.14, 2.19]:

- osie obrotu pokrywają się, nie powstaje więc niewyważenie,
- reakcje podpór odpowiadają statycznemu rozkładowi ciężarów wirników.

Przedwczesne uszkodzenia maszyn, w tym przede wszystkim uszkodzenia łożysk oraz sprzęgieł mają swoją przyczynę w niewłaściwym ustawieniu zespołu maszynowego (maszyna napędzana i napędzający ją silnik indukcyjny). Niewłaściwe ustawienie powoduje:

- wzrost drgań maszyn,
- przyspieszone zużycie łożysk,
- nieprawidłową pracę sprzęgieł i ich szybsze zużycie,
- niesymetrię szczeliny powietrznej w silnikach,
- przyspieszone zużycie uszczelnień,
- wzrost zużycia energii elektrycznej.

Defekty mocowania maszyny na fundamentach i podstawach są przyczyną wielu zmian w wibracjach maszyn. Wyraźny wzrost częstotliwości obrotowej f_r może świadczyć o wystąpieniu luzów montażowych w mocowaniu układu napędowego do fundamentów.

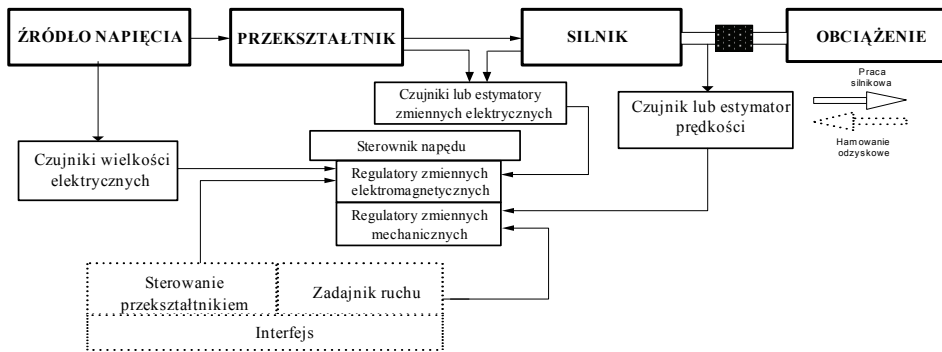
2.5. Specyficzne uszkodzenia przekształtnikowych układów napędowych z silnikiem indukcyjnym

Obecnie od przekształtnikowych układów napędowych (PUN), nawet powszechnego użytku, wymaga się niezawodnego i bezpiecznego działania. Rosnące wymagania w stosunku do właściwości napędów elektrycznych doprowadziły do znacznego skomplikowania ich struktur, jednocześnie zwiększając istotnie ryzyko awarii [2.10, 2.22]. Współczesny PUN, składający się z silnika indukcyjnego, układów zasilania i energoelektroniki (przekształtnik częstotliwości z modulacją PWM), układów pomiarowych oraz cyfrowego układu sterowania, narażony jest na wystąpienie innych dodatkowych uszkodzeń, niewyszczególnionych we wcześniejszych rozważaniach dotyczących silników zasilanych z sieci (rys. 2.8). Dotyczą one głównie uszkodzeń przemiennika częstotliwości oraz czujników pomiarowych.

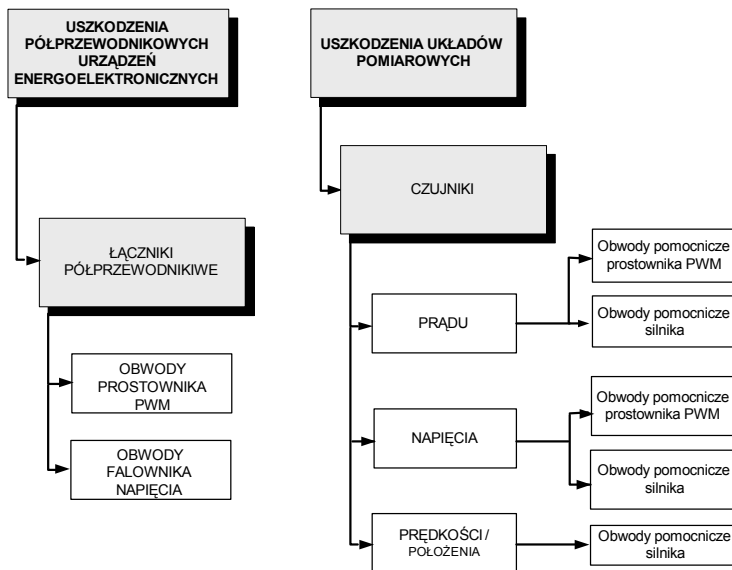
Na rysunku 2.9 przedstawiono klasyfikację uszkodzeń najczęściej spotykanych w PUN oraz ich lokalizację.

Ponad 80% awarii występujących w PUN spowodowanych jest nieprawidłowościami pracy łączników tranzystorowych IGBT, które polegają na zwarciach bądź braku przewodzenia prądu (ang. *short/open switch fault*) [2.9, 2.15, 2.16]. Najczęstszą przyczyną tego rodzaju uszkodzenia jest nadmierna eksploatacja napędu, która naraża przekształtnik na przeciążenia. Zwarcie jednego z łączników zawsze prowadzi do uszkodzenia modułu mocy przemiennika i zatrzymania napędu. Natomiast brak

przewodzenia jest możliwy do wykrycia i szybkiego skompensowania, gdyż prowadzi nieuchronnie do wystąpienia udarów prądu i momentu elektromagnetycznego uszkadzających napęd [2.15, 2.16]. Awaria przemiennika częstotliwości nie powinna prowadzić do natychmiastowego zatrzymania napędu, jak to obecnie najczęściej występuje. Możliwe jest zastosowanie odpowiedniej redundancji w strukturze modułu energoelektronicznego, ale wiąże się to ze znacznym wzrostem kosztów przemiennika [2.17]. Obecnie w wielu ośrodkach badawczych trwają prace nad ograniczeniem awaryjności układów energoelektronicznych [2.9, 2.15, 2.16].



Rys. 2.8. Struktura ideowa współczesnego napędu elektrycznego z silnikiem indukcyjnym odpornego na uszkodzenia czujników




Rys. 2.9. Rodzaje uszkodzeń najczęściej występujące w PUN

Drugą grupę stanowią uszkodzenia układów pomiarowych. Na rysunku 2.9 pokazano rodzaje czujników oraz ich lokalizację w PUN. Uszkodzenia tego typu mogą mieć różny charakter w zależności od rodzaju czujnika. Uszkodzenia czujników wielkości elektrycznych mogą być typu: przerwanie pętli pomiarowej, wystąpienia offsetów – składowej stałej, nasycenia, szumów pomiarowych lub błędów wzmocnienia. Natomiast w przypadku czujników wielkości mechanicznych (najczęściej dotyczy to czujnika prędkości obrotowej) występują uszkodzenia rodzaju: brak impulsów wyjściowych spowodowany przerwaniem pętli sprzężenia zwrotnego, nieprawidłowa liczba impulsów, cyklicznie przerywany sygnał wyjściowy.

Uszkodzenia tranzystora falownika napięcia, polegające na braku przewodzenia prądu, powoduje przepływ odkształconego prądu wszystkich faz silnika. Prowadzi to do zniekształcenia strumienia oraz powstania pulsacji momentu elektromagnetycznego o dużej amplitudzie [2.15]. Wywołane jest to pojawieniem się składowych stałych o dużych wartościach amplitudy w prądzie fazowym.

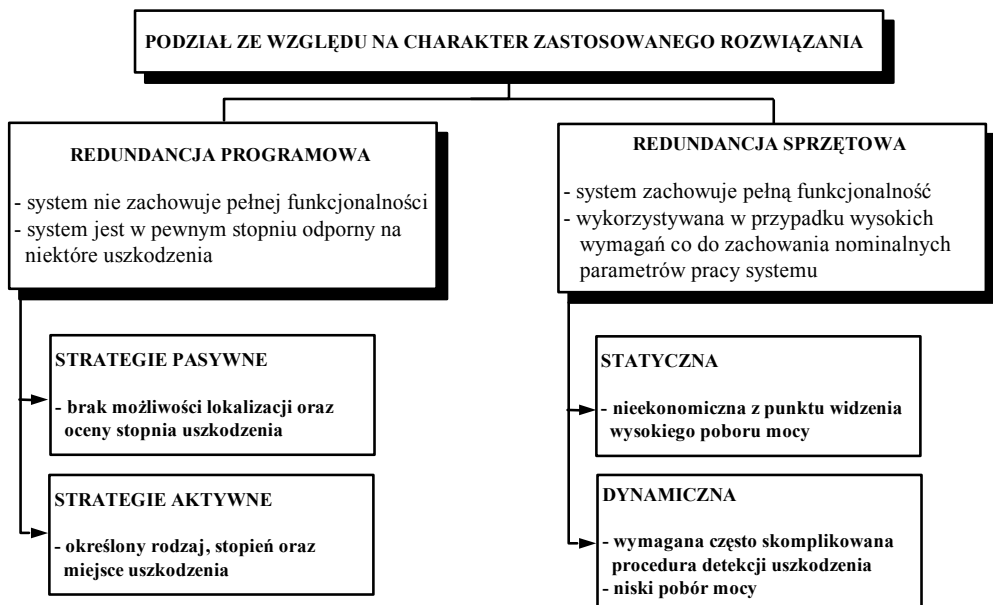
W przypadku monitorowania PUN szczególnie ważna jest jak najszybsza lokalizacja uszkodzenia, a następnie kompensacja jego skutków. Na rysunku 2.10 przedstawiono kolejność działań w PUN odpornym na uszkodzenia.



Rys. 2.10. Kolejność działań w PUN odpornym na uszkodzenia

Elektromagnetyczna stała czasowa napędu jest mała w stosunku do stałej czasowej mechanicznej. Dlatego najczęściej sygnałami diagnostycznymi są prądy fazowe silnika, w których symptomy uszkodzeń są widoczne najwcześniej. Na podstawie [2.9, 2.17] można stwierdzić, że proces izolacji uszkodzonej części napędu ($t_1 \div t_2$) jest zwykle najdłuższym spośród trzech wyszczególnionych na rysunku 2.10. Wynika to przede wszystkim z konieczności uwzględnienia zjawisk komutacyjnych w obwodach napędu. Odseparowanie w nieodpowiednim czasie części obwodu, która uległa uszkodzeniu, może skutkować nie tylko wydłużeniem czasu osiągnięcia przez PUN założonej funkcjonalności, ale ponadto zniszczeniem innych elementów układu napędowego [2.17]. Czas potrzebny do realizacji procesu lokalizacji uszkodzenia ($t_1 \div t_2$) nie przekracza wartości dwóch okresów przebiegu prądu. Podobnie kompensacja wpływu uszkodzenia ($t_2 \div t_3$) jest procesem z reguły nieco przekraczającym czas trwania dwóch okresów przebiegu prądu. Z chwilą t_3 PUN pracuje z zachowaniem funkcjonalności zgodnej z założoną strategią sterowania.

Układy sterowania nowoczesnych napędów powinny zapewnić możliwie niezawodne oraz bezpieczne działanie w sytuacjach zaistnienia awarii. Uszkodzenia czujników pomiarowych mogą w złożonym układzie napędowym wywoływać różne skutki, jednak ich wystąpienie powoduje, że konieczna staje się zmiana topologii sterowania układu napędowego. W przypadku awarii elementów energoelektroniki konieczna jest reorganizacja wewnętrznej struktury układu zasilania i układu sterowania. Układy, w których możliwa jest zmiana topologii układu sterowania i reorganizacja struktury falownika, w literaturze są nazywane **układami bezpiecznymi** lub **odpornymi na uszkodzenia** (ang. *fault tolerant drives*) [2.9]. Zadaniem układu odpornego na uszkodzenia, w zależności od rodzaju powstałego uszkodzenia oraz stopnia zagwarantowanego bezpieczeństwa, jest zapewnienie dalszej stabilnej pracy napędu (z zachowaniem jego pełnej bądź częściowej funkcjonalności) lub bezpieczne jego zatrzymanie. Ze względu na charakter zastosowanego rozwiązania problemu sterowania PUN odpornego na uszkodzenia, można wyróżnić różne strategie działania (rys. 2.11). W zależności od charakteru uszkodzenia powinna zostać wybrana taka metoda kompensacji uszkodzenia, która pozwoli zachować podstawowe cechy funkcjonalności napędu. Zwykle zastosowanie redundancji programowej nie umożliwia zachowania poprzedniej funkcjonalności napędu. Środki programowe umożliwiają określenie rodzaju, stopnia i miejsca uszkodzenia. Dlatego w większości przypadków, ze względu na korzyści płynące z wiedzy o lokalizacji uszkodzenia, stosuje się strategie aktywne stero-



Rys. 2.11. Podział strategii sterowania odpornego PUN

wania odpornego. Do przywrócenia funkcjonalności PUN niezbędne jest zastosowanie redundancji sprzętowej dynamicznej. Do realizacji podanych strategii sterowania odpornego PUN konieczne jest zastosowanie określonych metod matematycznych. Mogą to być metody algorytmiczne (np. analiza sygnałów diagnostycznych, estymacja parametrów i zmiennych stanu) lub metody sztucznej inteligencji (sieci neuronowe, logika rozmyta, sieci neuronowe-rozmyte).

Gdy napęd pracuje w strukturze sterowania wektorowego, wykorzystującej czujniki pomiarowe, w przypadku ich awarii struktura odporna powinna przełączyć się na sterowanie oparte na odtwarzaniu zmiennych stanu (np. obserwatory, filtr Kalmana). Nieprawidłowe działanie struktury z estymacją powinno spowodować przełączenie się napędu na sterowanie skalarnie. Przejście na sterowanie skalarnie może również wystąpić w sytuacji awarii czujnika prądu w torze sprzężenia zwrotnego. Zmiana struktury sterowania spowoduje pogorszenie jakości pracy napędu, ale gwarantuje stabilność i bezpieczeństwo użytkowników i procesu technologicznego.

Ze względu na specyfikę opisanych uszkodzeń występujących w PUN oraz metod ich wykrywania i kompensowania, w dalszej części monografii nie będą one analizowane. Część z metod wykrywania uszkodzeń, przedstawionych w dalszej części pracy (np. w rozdziale 6 i 7), może być z powodzeniem stosowana w diagnostyce PUN odpornych na uszkodzenia.

W dalszych rozważaniach uwaga została skupiona na uszkodzeniach występujących w silniku indukcyjnym zasilanym z sieci lub przekształtnika częstotliwości typu PWM, pracującym w strukturze sterowania skalarnego i wektorowego. Zostaną więc uwzględnione następujące oddziaływania:

- wpływ odkształcenia napięć i prądów zasilających silnik indukcyjny,
- wpływ regulacji częstotliwości napięcia zasilającego,
- kompensujące uszkodzenie działanie regulatorów w zamkniętej strukturze sterowania wektorowego.

2.6. Podsumowanie

W rozdziale 2 przedstawiono przegląd podstawowych uszkodzeń występujących w napędach przekształtnikowych z silnikami indukcyjnymi. Scharakteryzowano uszkodzenia występujące w obwodach uzwojenia stojana i wirnika oraz uszkodzenia typu mechanicznego. Omówiono uszkodzenia specyficzne dla przekształtnikowych układów napędowych występujące w układzie energoelektronicznym oraz w układach pomiarowych.

W dalszych rozważaniach w niniejszej monografii będą analizowane uszkodzenia uzwojeń stojana i wirnika oraz wybrane uszkodzenia mechaniczne (uszkodzenia łożysk tocznych, niewyosiowanie i ekscentryczność), przy czym w przypadku wszyst-

kich tych uszkodzeń zwrócona jest uwaga na fakt, że obecnie silnik jest zazwyczaj zasilany z przemiennika częstotliwości i pracuje w strukturze sterowania skalarnego lub wektorowego.

Literatura

- [2.1] Antal M., *Badanie zjawisk elektromagnetycznych i cieplnych w silnikach indukcyjnych z uszkodzonymi obwodami elektrycznymi*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i pomiarów Elektrycznych, Wrocław 2007.
- [2.2] Cempel C., *Diagnostyka wibroakustyczna maszyn*, PWN, Warszawa 1989.
- [2.3] Cempel C., Tomaszewski F., *Diagnostyka maszyn*, Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom 1992.
- [2.4] Drak B., *Statystyka uszkodzeń silników wysokonapięciowych prądu przemiennego w elektrowniach zawodowych*, Zeszyty Problemowe Maszyny Elektryczne, BOBRME Komel, Nr 65, 2003, 41–46.
- [2.5] Drak B., *Analiza awarii silników indukcyjnych dużej mocy*, Zeszyty Problemowe Maszyny Elektryczne, BOBRME Komel, Nr 54, 1997, 82–87.
- [2.6] Dwojak J., Szymaniec S., *Diagnostyka eksploatacyjna zespołów maszynowych w energetyce*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 344, Opole 2013.
- [2.7] Ewert P., *Diagnostyka mechanicznych uszkodzeń napędów z silnikami indukcyjnymi przy wykorzystaniu sieci neuronowych*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2012.
- [2.8] Glinka T., *Badania diagnostyczne maszyn elektrycznych w przemyśle*, BOBRME Komel, Katowice 2002.
- [2.9] Isermann R., *Fault-Diagnosis Applications, Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-tolerant Systems*, Springer-Verlag, Berlin–Heidelberg 2011.
- [2.10] Kaźmierkowski M.P., Blaabjerg F., Krishnan R., *Control in Power Electronics – Selected Problems*, Academic Press, USA, 2002.
- [2.11] Kliman G.B., Stein J., *Methods of motor current signature analysis*, Electric Machines and Power Systems, No. 20, 1992, 463–474.
- [2.12] Kowalski C.T., *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wroclawskiej, Nr 57, seria Monografie nr 18, Oficyna Wydawnicza PWr., Wrocław 2005.
- [2.13] Kowalski C.T., Wolkiewicz M., Ewert P., *Analiza zwarć zwojowych stojana silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości*, Przegląd Elektrotechniczny, Vol. 84, nr 12, 2008, 64–67.
- [2.14] Morel J., *Drgania maszyn i diagnostyka ich stanu technicznego*, Polskie Towarzystwo Diagnostyki Technicznej, Warszawa 1994.
- [2.15] Orłowska-Kowalska T., Sobański P., *Wpływ uszkodzenia tranzystora IGBT falownika napięcia na przebiegi zmiennych stanu silnika indukcyjnego ze sterowaniem wektorowym*, Przegląd Elektrotechniczny, vol. 89, nr 2b, 2013, 162–165.
- [2.16] Pires V.F., Amaral T.G., Sousa D., Marques G.D., *Fault detection of voltage-source inverter using pattern recognition of the 3D current trajectory*, 8th IEEE Reg. Int. Conf. Comp. Tech., 2010, 617–621.

-
- [2.17] Rodrigues M.A., Claudio A., Theilliol D., Vela L.G., Hernandes L., *A strategy to replace the damaged element for fault-tolerant induction motor drive*, Proc. 5th Int. Conf. on Electrical Engineering, Computing Science and Automatic Control CCE 2008, Mexico, 2008, 51–55.
- [2.18] Szymaniec S., *Diagnostyka stanu izolacji uzwojeń i stanu łożysk silników indukcyjnych klatkowych w warunkach przemysłowej eksploatacji*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 193, Opole 2013.
- [2.19] Szymaniec S., *Badania, eksploatacja i diagnostyka zespołów maszynowych z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 333, Opole 2013.
- [2.20] Tallam R. M., Lee S.B., Stone G.C., Kliman G.B., Yoo J., Habetler T.G., Harley R.G., *A Survey of Methods for Detection of Stator-Related Faults in Induction Machine*, IEEE Transactions on Industry Applications, Vol. 43, No. 4, 2007, 920–933.
- [2.21] Wolkiewicz M., *Monitorowanie stanu uzwojeń stojana silnika indukcyjnego*, Rozprawa doktorska, Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2012.
- [2.22] Vas P., *Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines*, Oxford University Press, Oxford 1993.
- [2.23] Zhang P., Du Y., Habetler T.G., Lu B., *A survey of condition monitoring and protection methods for medium-voltage induction motors*, IEEE Trans. Ind. Appl., Vol. 47, No. 1, Jan./Feb. 2011, 34–46.
- [2.24] Zhou W., Habetler T.G., Harley R.G., *Bearing condition monitoring methods for electric machines: A general review*, Proc. IEEE Int. Symp. Diagn. Elect. Mach. Power Electron. Drives, 2007, 3–6.

3. Charakterystyka sygnałów diagnostycznych

3.1. Wielkości elektryczne i mechaniczne stosowane w diagnostyce układów napędowych

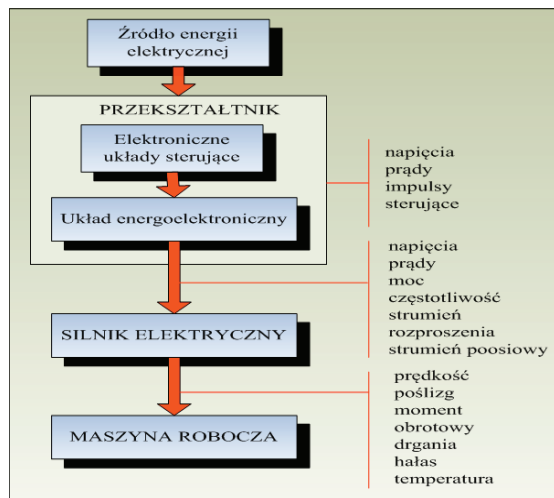
W badaniach diagnostycznych silników indukcyjnych stosuje się metody polegające na tym, że oceny stanu technicznego dokonuje się na podstawie obserwacji sygnałów związanych z działaniem maszyny. Sygnałami diagnostycznymi (tzn. sygnałami zależnymi od stanu obiektu) powinny być wielkości fizyczne przenoszące możliwie dużo informacji o stanie diagnozowanego obiektu. Na ogół tylko niektóre cechy sygnału niosą informacje diagnostyczne. Są to tzw. czynne cechy sygnału, czyli symptomy (objawy) uszkodzenia. Nie powinno się utożsamiać symptomów stanu ze stanem technicznym. Symptomy są uwarunkowane między innymi (a nie wyłącznie) stanem technicznym maszyny. Od sygnałów diagnostycznych wymaga się ponadto, aby ich pomiar w miarę możliwości był nieinwazyjny, szybki i nieskomplikowany (bez montowania złożonych układów), odbywał się w naturalnych warunkach pracy obiektu, był wielowymiarowy (umożliwiał kontrolowanie stanu wielu części maszyny) oraz ekonomiczny.

Złożoność budowy maszyny elektrycznej, właściwości losowe procesów technologicznych i warunków eksploatacji powodują, że bezpośrednie przewidywanie relacji między cechami sygnałów diagnostycznych i cechami stanu technicznego maszyny jest na ogół trudne. Każdemu sygnałowi przyporządkowany jest pewien opis, na który składa się zbiór cech (ocen). Zbiór cech sygnału otrzymuje się na podstawie szeroko rozumianej analizy sygnału. Wybór metod analizy oraz wybór cech sygnału, ocenianych podczas analizy, powinien być dokonywany w zależności od charakteru sygnału (jego właściwości) oraz typu uszkodzenia i celu jego wykrywania (np. monitorowanie czy diagnostyka).

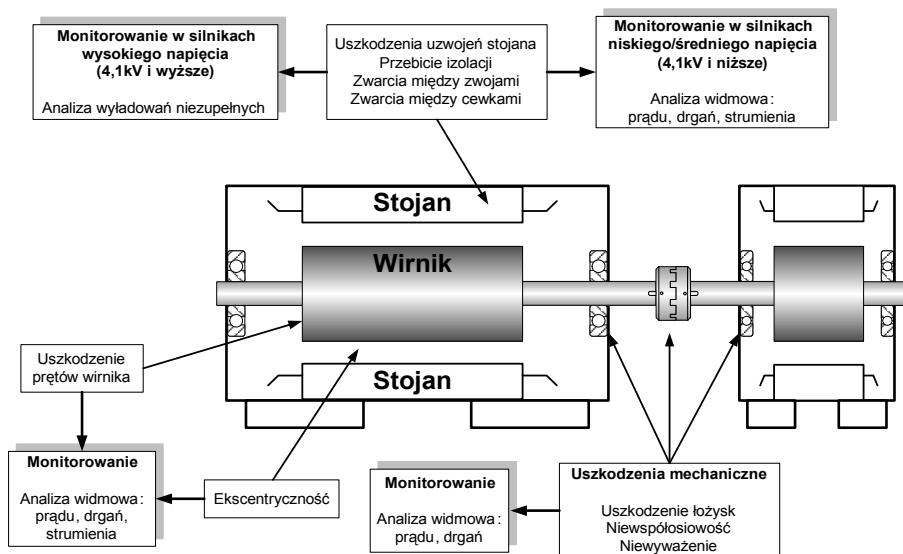
Podstawowe wielkości fizyczne wykorzystywane w monitorowaniu i diagnostyce silników indukcyjnych (rys. 3.1 i 3.2), uszeregowane według częstości stosowania, to:

- drgania mechaniczne,
- prąd fazowy stojana,

- temperatura,
- moc elektryczna,
- strumień poosiowy,
- moment elektromagnetyczny.



Rys. 3.1. Wielkości fizyczne stosowane do monitorowania układu napędowego z silnikiem indukcyjnym




Rys. 3.2. Uszkodzenia oraz wielkości fizyczne służące do ich monitorowania w napędach z silnikami indukcyjnymi [3.8]

Dominujące znaczenie mają sygnały drgań mechanicznych oraz prądu stojana (rys. 3.2). Są to sygnały, które można mierzyć nieinwazyjnie i które odzwierciedlają wszystkie nienormalne zjawiska zachodzące w maszynie i napędzie elektrycznym. Również w innych sygnałach dostępnych w maszynie elektrycznej jest dużo cech umożliwiających dokonywanie oceny symptomów uszkodzeń. Dotyczy to przede wszystkim: elektrycznej mocy chwilowej, momentu elektromagnetycznego oraz strumienia rozproszenia poosiowego.

Wydaje się, że szczególnie moc elektryczna, ze względu na łatwość i nieinwazyjność pomiaru, jest sygnałem szczególnie przydatnym w diagnostyce silników elektrycznych. Bezpośredni pomiar momentu elektromagnetycznego jest kłopotliwy w praktyce i w związku z tym korzystniejsze wydają się metody pośrednie, oparte na jego estymacji, na podstawie łatwo mierzalnych wielkości elektrycznych (prądu i napięcia). Również pomiar strumienia poosiowego wiąże się z koniecznością wbudowywania w maszynę dodatkowych cewek pomiarowych, co zwykle nie jest możliwe do zrealizowania w czasie eksploatacji napędu. Oprócz wymienionych, duże znaczenie w praktyce eksploatacyjnej odgrywa diagnostyka cieplna oparta na analizie zmian temperatury wybranych elementów konstrukcyjnych maszyny elektrycznej, np. temperatura uzwojenia, korpusu, łożyska itp. Szczególnie przydatna do tego celu jest nieinwazyjna diagnostyka oparta na informacji uzyskiwanej z kamery termowizyjnej.

W wymienionych sygnałach diagnostycznych poszukuje się przede wszystkim charakterystycznych częstotliwości, których amplituda jest cechą służącą do oceny poziomu uszkodzenia. Na rysunku 3.3 przedstawiono etapy przetwarzania informacji diagnostycznej z wykorzystaniem metody opartej na analizie widmowej sygnałów diagnostycznych, począwszy od pomiaru wybranych sygnałów. Kolejnym etapem jest



Rys. 3.3. Etapy przetwarzania informacji diagnostycznej z wykorzystaniem analizy widmowej sygnałów [3.27]

przetworzenie sygnału zmierzonego bezpośrednio na obiekcie (lub uzyskanego pośrednio), w wyniku którego otrzymuje się widmo. Następnym etapem jest ekstrakcja symptomów uszkodzenia, a więc wyodrębnienie z badanego sygnału diagnostycznego charakterystycznych częstotliwości uszkodzenia, a następnie określenie zmian ich amplitudy. Ostatnim etapem jest wnioskowanie o stanie obiektu („zdrowy” czy uszkodzony), a w przypadku wykrycia uszkodzenia – ocena jego stopnia.

Przedstawiono ogólną charakterystykę sygnałów prądu, mocy, momentu elektromagnetycznego, strumienia poosiowego, drgań mechanicznych i temperatury pod względem występowania w tych sygnałach symptomów uszkodzenia napędu elektrycznego z silnikiem indukcyjnym.

3.2. Prąd stojana jako sygnał diagnostyczny

Prąd fazowy stojana, ze względu na łatwy, tani i bezinwazyjny pomiar, jest podstawowym sygnałem diagnostycznym. Najczęściej spotykaną metodą wykorzystującą sygnały prądu fazowego stojana w diagnostyce silników indukcyjnych jest **analiza widmowa prądu stojana**, często określana skrótem **MCSA** (ang. *Motor Current Signature Analysis*) [3.3–3.5]. W metodzie MCSA poszukuje się charakterystycznych częstotliwości, które są symptomami uszkodzenia, a amplituda tych harmonicznych jest cechą służącą do oceny stopnia uszkodzenia.

W układzie napędowym zazwyczaj są mierzone jedynie dwa prądy fazowe:

$$\begin{aligned} i_A(t) &= \sqrt{2}I_A \cos\left(\omega_s t - \varphi - \frac{\pi}{6}\right) \\ i_C(t) &= \sqrt{2}I_C \cos\left(\omega_s t - \varphi + \frac{\pi}{2}\right) \end{aligned} \quad (3.1)$$

gdzie:

I_A, I_C – wartość skuteczna prądu fazowego,

$\omega_s = 2\pi f_s$ – pulsacja synchroniczna stojana.

W sytuacjach gdy następuje uszkodzenie silnika, wówczas w prądzie, momencie i prędkości pojawiają się oddziaływania o charakterze modulacji okresowej. Prąd zawiera dodatkową składową okresową o postaci:

$$\begin{aligned} i'_A(t) &= i_A(t)[1 + M \cos(\omega_{osc} t)] \\ i'_C(t) &= i_C(t)[1 + M \cos(\omega_{osc} t)] \end{aligned} \quad (3.2)$$

gdzie:

M – parametr modulacji zależny od rodzaju uszkodzenia,

$\omega_{osc} = 2\pi f_{osc}$ – pulsacja oscylacji.


Po podstawieniu (3.2) do zależności (3.1) otrzymuje się:

$$i'_A(t) = i_A(t) + \frac{M}{\sqrt{2}} I_A \left\{ \cos\left[\left(\omega_s + \omega_{osc}\right)t - \varphi - \frac{\pi}{6}\right] + \cos\left[\left(\omega_s - \omega_{osc}\right)t - \varphi - \frac{\pi}{6}\right] \right\} \quad (3.3)$$

Z zależności (3.3) wynika, że prąd stojana, oprócz podstawowej harmonicznej sieciowej f_s , zawiera dwie harmoniczne pasmowe $f_s \pm f_{osc}$.

Metoda analizy prądu stojana ma, oprócz oczywistych zalet, również kilka niedogodności związanych z rozdzieleniem wpływu uszkodzenia od efektów wtórnych wywołanych przez oscylacje momentu i prędkości.

Innym podejściem, wykorzystującym nieinwazyjny pomiar prądu fazowego stojana, jest **metoda analizy widma modułu wektora przestrzennego prądu stojana EPVA** (ang. *Extended Park's Vector Approach*) [3.6, 3.7, 3.25]. Wykorzystanie wektora przestrzennego prądu stojana w diagnostyce może sprowadzać się do obserwacji kształtu i położenia hodografu wektora prądu w układzie współrzędnych prostokątnych α - β lub analizy widmowej modułu wektora przestrzennego prądu [3.6, 3.7, 3.14, 3.15]. Na rysunku 3.4 przedstawiono schemat ilustrujący algorytm diagnozowania oparty na analizie widmowej modułu wektora przestrzennego prądu stojana.



Rys. 3.4. Algorytm obliczania modułu wektora przestrzennego prądu stojana oraz częstotliwości charakterystycznych dla uszkodzeń

W warunkach idealnego zasilania „zdrowej” maszyny, wektor przestrzenny prądu stojana można opisać zależnością:

$$\mathbf{i}_s = \sqrt{\frac{2}{3}} (\mathbf{1}i_{sA} + \mathbf{a}i_{sB} + \mathbf{a}^2i_{sC}) \quad (3.4)$$

gdzie:

$$\mathbf{a} = e^{j2\pi/3}, \quad \mathbf{a}^2 = e^{-j2\pi/3},$$

i_{sA}, i_{sB}, i_{sC} – wartość chwilowa prądu stojana w fazach A, B, C.

Składowe wektora przestrzennego prądu stojana \mathbf{i}_s w prostokątnym, nieruchomym względem stojana układzie współrzędnych α - β są związane z prądem fazowym stojana zależnościami wynikającymi z przekształcenia Clarka-Parka:

$$i_{s\alpha} = \sqrt{\frac{2}{3}} \left(i_{sA} - \frac{1}{2}(i_{sB} + i_{sC}) \right) \quad (3.5a)$$

$$i_{s\beta} = \frac{1}{\sqrt{2}} (i_{sB} - i_{sC}) \quad (3.5b)$$

Moduł wektora przestrzennego prądu stojana można natomiast obliczyć z zależności:

$$|\mathbf{i}_s| = \sqrt{i_{s\alpha}^2 + i_{s\beta}^2} \quad (3.6)$$

Składowe ($i_{s\alpha}$, $i_{s\beta}$) wektora przestrzennego są jednoznacznie związane z chwilowymi wartościami prądu fazowego silnika (3.5). W idealnych warunkach, w stanie ustalonym, składowe wektora przestrzennego można wyrazić w postaci:

$$i_\alpha = \frac{\sqrt{3}}{\sqrt{2}} I_m \cos(\omega_s t) \quad (3.7a)$$

$$i_\beta = \frac{\sqrt{3}}{\sqrt{2}} I_m \sin(\omega_s t) \quad (3.7b)$$

gdzie I_m – amplituda prądu fazowego.

Po założeniu symetrycznej budowy silnika oraz pełnej symetrii napięcia zasilania, moduł wektora przestrzennego stanowi wartość stałą i jest równy $I_m \sqrt{3/2}$, a hodograf ma kształt idealnego okręgu. Pojawienie się uszkodzenia i związanych z nim charakterystycznych częstotliwości powoduje zmianę kształtu hodografu i pojawienie się tych częstotliwości w widmie modułu wektora prądu.

Metoda EPVA ma te same cechy pozytywne co konwencjonalna analiza widmowa prądu stojana (MCSA) i jednocześnie eliminuje niektóre ograniczenia i niedogodności widoczne w klasycznym podejściu. Przede wszystkim uwalnia od dodatkowych oddziaływań zmiennego momentu obciążenia na amplitudy częstotliwości poślizgowych, które oddalone są wyraźnie od harmonicznej podstawowej. Amplitudy są wyraźnie większe od podstawowej harmonicznej zredukowanej przez transformację Clarka–Parka. Należy podkreślić, że metodą tą można wykryć również inne uszkodzenia typu elektrycznego (np. asymetrię zasilania) lub typu mechanicznego (np. niewyosiowanie napędu, niecentryczne osadzenie wirnika). Szczegółowe zastosowanie tej metody przedstawiono w rozdziale 8 i 9.

3.3. Moc chwilowa, strumień stojana i wirnika oraz moment elektromagnetyczny jako sygnały diagnostyczne

Przyjmując, że najprostsza metoda pomiaru mocy oparta jest na dwóch watomierzach oraz zakładając symetrię zasilania i stałe obciążenie, otrzymuje się:

$$\begin{aligned}
 u_{AB}(t) &= \sqrt{2}U_{AB} \cos \omega_s t \\
 u_{CB}(t) &= \sqrt{2}U_{CB} \cos \left(\omega_s t + \frac{\pi}{3} \right) \\
 i_A(t) &= \sqrt{2}I_A \cos \left(\omega_s t - \varphi - \frac{\pi}{6} \right) \\
 i_C(t) &= \sqrt{2}I_C \cos \left(\omega_s t - \varphi + \frac{\pi}{2} \right)
 \end{aligned} \tag{3.8}$$

gdzie:

U_{AB}, U_{BC}, I_A, I_C – wartości skuteczne napięcia międzyfazowego i prądu fazowego,

$\omega_s = 2\pi f_s$ – pulsacja synchroniczna stojana.

Wyrażenia na chwilową moc częściową i całkowitą mają postać:

$$\begin{aligned}
 p_{AB}(t) &= U_{AB}I_A \left[\cos \left(\varphi + \frac{\pi}{6} \right) + \cos \left(2\omega_s t - \varphi - \frac{\pi}{6} \right) \right] \\
 p_{CB}(t) &= U_{CB}I_C \left[\cos \left(\varphi - \frac{\pi}{6} \right) - \cos \left(2\omega_s t - \varphi - \frac{\pi}{6} \right) \right] \\
 p_{ABC}(t) &= p_{AB}(t) + p_{CB}(t) = \sqrt{3}U_{AB}I_A \cos(\varphi) = P_{ABC}
 \end{aligned} \tag{3.9}$$

Całkowita moc chwilowa pobierana z sieci jest stała i równa wartości rzeczywistej mocy średniej P_{ABC} .

Wyrażenia na moc chwilową, w przypadku modulacji prądu przez uszkodzenia, przyjmują postać:

$$\begin{aligned}
 p'_{AB}(t) &= p_{AB}(t) + \frac{1}{2}MU_{AB}I_A \left\{ 2 \cos \left(\varphi + \frac{\pi}{6} \right) \cos(\omega_{osc}t) \right. \\
 &\quad \left. + \cos \left[(2\omega_s + \omega_{osc})t - \varphi - \frac{\pi}{6} \right] + \cos \left[(2\omega_s - \omega_{osc})t - \varphi - \frac{\pi}{6} \right] \right\} \\
 p'_{CB}(t) &= p_{CB}(t) + \frac{1}{2}MU_{CB}I_C \left\{ 2 \cos \left(\varphi + \frac{\pi}{6} \right) \cos(\omega_{osc}t) \right. \\
 &\quad \left. + \cos \left[(2\omega_s + \omega_{osc})t - \varphi + \frac{\pi}{6} \right] + \cos \left[(2\omega_s - \omega_{osc})t - \varphi + \frac{\pi}{6} \right] \right\} \\
 p'_{ABC}(t) &= P_{ABC} + \sqrt{3}U_{AB}I_A M \cos(\varphi) \cos(\omega_{osc}t)
 \end{aligned} \tag{3.10}$$

Z zależności (3.10) wynika, że w widmie mocy chwilowej częściowej występują trzy charakterystyczne częstotliwości: $2f_s + f_{osc}$, $2f_s - f_{osc}$ oraz f_{osc} . W spektrum

mocy całkowitej występuje składowa stała P_{ABC} oraz harmoniczna o częstotliwości f_{osc} .

Częstotliwość f_{osc} jest symptomem konkretnego rodzaju uszkodzenia. Amplituda składowej pochodzącej od uszkodzenia jest różna dla mocy całkowitej i częściowej, a ponadto zależy od wartości kąta φ . Dla $0 < \varphi < \pi/3$ największą wartość ma moc całkowita $p'_{ABC}(t)$, natomiast dla $\pi/3 < \varphi < \pi/2$ największą wartość przyjmuje moc częściowa $p'_{CB}(t)$. Należy zauważyć, że w praktyce prąd fazowy jest modulowany w sposób bardziej złożony, nie tylko w zależności od amplitudy (3.3), ale również od fazy [3.4, 3.10, 3.25]. Oprócz oddziaływań elektrycznych w prądzie fazowym widoczne są modulacje od uszkodzeń mechanicznych. Zostanie to szczegółowo wyjaśnione przy omawianiu konkretnych rodzajów uszkodzeń.

W momencie elektromagnetycznym, który jest w przybliżeniu proporcjonalny do mocy p_{ABC} , można oczekiwać rozkładu częstotliwości charakterystycznych podobnego jak w przypadku mocy elektrycznej. Jednak jest on kombinacją oddziaływań strumieni rozproszenia i prądu stojana i w związku tym zawartość harmonicznych może być bardziej bogata. Bezpośredni pomiar momentu jest rzadko stosowany w praktyce i w diagnostyce obserwuje się tendencję do estymowania wartości momentu na podstawie pomiaru prądu fazowego i napięcia międzyfazowego [3.12, 3.13, 3.18].

Na podstawie modelu matematycznego silnika indukcyjnego w układzie α - β [3.12, 3.22, 3.27] można napisać równania umożliwiające obliczenie składowych strumienia stojana lub wirnika. W przypadku korzystania z modelu napięciowego składowe strumienia skojarzonego z uzwojeniem stojana mają postać:

$$\begin{aligned}\Psi_{s\beta} &= \int (u_{s\alpha} - R_s i_{s\alpha}) dt \\ \Psi_{s\beta} &= \int (u_{s\beta} - R_s i_{s\beta}) dt\end{aligned}\tag{3.11}$$

Składowe wektora strumienia skojarzonego z uzwojeniem wirnika mogą być obliczone na podstawie modelu (symulatora) prądowego:

$$\begin{aligned}\Psi_{r\alpha} &= \int \left[\frac{R_r}{L_r} (L_M i_{s\alpha} - \Psi_{r\alpha}) - \omega_m \Psi_{r\beta} \right] dt \\ \Psi_{r\beta} &= \int \left[\frac{R_r}{L_r} (L_M i_{s\beta} - \Psi_{r\beta}) + \omega_m \Psi_{r\alpha} \right] dt\end{aligned}\tag{3.12}$$

gdzie ω_m – prędkość kątowna wirnika [rad/s].

Wartości składowych strumienia stojana lub wirnika są niezbędne do wyznaczenia wartości chwilowej momentu elektromagnetycznego silnika indukcyjnego. Wzory na moment elektromagnetyczny przedstawiają się następująco:

- moment elektromagnetyczny obliczany ze składowych osiowych wektora strumienia skojarzonego z uzwojeniem stojana:

$$M_e = \frac{3}{2} p_b (i_{s\beta} \Psi_{s\alpha} - i_{s\alpha} \Psi_{s\beta}) \quad (3.13)$$

- moment obliczany ze składowych osiowych wektora strumienia skojarzonego z uzwojeniem wirnika:

$$M_e = \frac{3}{2} p_b \frac{L_M}{L_r} (i_{s\beta} \Psi_{r\alpha} - i_{s\alpha} \Psi_{r\beta}) \quad (3.14)$$

Z podanych zależności wynika, że składowe uszkodzeniowe, występujące w sygnale strumienia, w porównaniu do prądu, mają amplitudę zredukowaną co najmniej o rząd, co pozwala z wystarczającą dokładnością przyjąć, że w momencie elektromagnetycznym podstawowe znaczenie mają częstotliwości charakterystyczne f_{osc} modulujące prąd stojana oraz częstotliwości pasmowe $2f_s + f_{osc}$ oraz $2f_s - f_{osc}$.

W zależności od rodzaju uszkodzenia częstotliwość charakterystyczna f_{osc} ma różne przyczyny powstawania, a tym samym różną wartość i amplitudę. Na przykład, przy asymetrii wirnika $f_{osc} = 2f_s$ (patrz rozdział 8), podczas uszkodzenia mechanicznego typu ekscentryczność, niewyważenie lub nieosiowość wałów $f_{osc} = f_r$ (f_r – częstotliwość obrotowa – rozdział 10). W przypadku uszkodzeń łożysk $f_{osc} = f_{łoż} - f_{u,łoż}$ ($f_{u,łoż}$ – częstotliwość charakterystyczna dla uszkodzeń elementów łożyska – rozdział 10). Oprócz podstawowej częstotliwości f_{osc} może również wystąpić jej krotność i częstotliwość pasmowa.

3.4. Sygnały chwilowej mocy czynnej i biernej

W przypadku zasilania silnika napięciem odkształconym z przekształtnika częstotliwości, do obliczania mocy chwilowej można zastosować pojęcia wprowadzone przez Akagi i Nabae w [3.1]. Sygnały chwilowej mocy czynnej $p(t)$ oraz chwilowej mocy biernej $q(t)$ (*instantaneous active and reactive power*) wprowadzono w celu uogólnienia klasycznego pojęcia mocy elektrycznej w niesinusoidalnych systemach trójfazowych. Jak wykazano w [3.9, 3.16–3.18, 3.26] sygnały te mogą być również bardzo przydatne w diagnostyce silnika indukcyjnego.

Dla trójfazowych systemów, zgodnie z [3.1, 3.9, 3.26], chwilowe wartości napięcia u_A, u_B, u_C i prądu i_A, i_B, i_C tworzą wektory przestrzenne odpowiednio \mathbf{i} i \mathbf{u} :

$$\mathbf{u} = [u_A \ u_B \ u_C]^T, \quad \mathbf{i} = [i_A \ i_B \ i_C]^T \quad (3.15)$$

Chwilowa moc czynna wyrażona jest jako iloczyn skalarny wektorów \mathbf{i} w przypadku prostokątnego układu współrzędnych α - β wyrażona jest przez:

$$p = \mathbf{u} \cdot \mathbf{i} \quad (3.16)$$

$$p = \mathbf{u}_{(ABC)} \cdot \mathbf{i}_{(ABC)} = \mathbf{u}_{(\alpha\beta)} \cdot \mathbf{i}_{(\alpha\beta)} = \frac{3}{2}(u_\alpha i_\alpha + u_\beta i_\beta) \quad (3.17)$$

natomiast wektor przestrzenny chwilowej mocy biernej \mathbf{q} jako iloczyn wektorowy:

$$\mathbf{q} = \mathbf{u} \times \mathbf{i} \quad (3.18)$$

czyli

$$\mathbf{q} = \mathbf{u}_{(ABC)} \times \mathbf{i}_{(ABC)} = \mathbf{u}_{(\alpha\beta)} \times \mathbf{i}_{(\alpha\beta)} \quad (3.19)$$

Chwilowa moc bierna definiowana jest jako moduł (lub długość) chwilowego wektora mocy biernej \mathbf{q} , a więc:

$$q = \|\mathbf{q}\| = \|\mathbf{u} \times \mathbf{i}\| \quad (3.20)$$

$$q_{(ABC)} = \|\mathbf{q}_{(ABC)}\| = q_{(\alpha\beta)} = \|\mathbf{q}_{(\alpha\beta)}\| = \frac{3}{2}(u_\alpha i_\beta - u_\beta i_\alpha) \quad (3.21)$$

Przejścia z układu trójfazowego ABC do układu współrzędnych α - β dokonuje się za pomocą transformacji Parka [3.22].


W przypadku wystąpienia uszkodzeń w wymienionych sygnałach pojawiają się dodatkowe charakterystyczne częstotliwości. Przykłady zastosowania sygnałów mocy w diagnostyce przedstawiono w dalszych rozdziałach przy omawianiu konkretnych rodzajów uszkodzeń.

3.5. Sygnał strumienia poosiowego

We wszystkich maszynach elektrycznych nieuniknione są pewne asymetrie magnetyczne i geometryczne, które powodują powstawanie poosiowych strumieni rozproszenia. Są one generowane przez prąd płynący przez uzwojenie stojana i wirnika. Konsekwencją występowania asymetrii jest różnica w prądzie płynącym w różnych miejscach połączeń czołowych. Wynikiem tego jest strumień poosiowy (rys. 3.5a.)

W idealnej maszynie strumień poosiowy powinien być równy zero. W praktyce w obwodach stojana i wirnika istnieją asymetrie związane z nieidealną geometrią uzwojeń i niejednorodnością zastosowanych do konstrukcji materiałów. Powoduje to, że powstaje mały, ale mierzalny strumień poosiowy. Uszkodzenie stojana powoduje

asymetrię uzwojenia, wywołując duże zmiany strumienia poosiowego. Powstałe uszkodzenie powoduje zmianę rozkładu harmoniczných przestrzenných indukcji w szczelinie. Harmoniczne przestrzenne nie mogą być wykryte bezpośrednio przez pomiar strumienia poosiowego. Natomiast w strumieniu tym można wykryć harmoniczne czasowe, które są pomieszane z harmonicznymi przestrzennymi pola. W zwoju zwartym stojana indukuje się napięcie, które powoduje przepływ prądu ograniczonego tylko impedancją własną zwoju. Prąd ten jest źródłem pulsacji sił magnetomotorycznych, które mają wpływ na harmoniczne przestrzenne pola.



Rys. 3.5. Rozpływ strumienia w silniku indukcyjnym (a) oraz sposoby rozmieszczenia cewek pomiarowych do detekcji strumienia poosiowego (b)

Ponieważ strumień poosiowy może być wytwarzany przez prąd stojana i wirnika, to charakterystyczne częstotliwości w nim występujące są związane z częstotliwościami sieci f_s oraz wirnika sf_s . Zawartość harmoniczných w poosiowych strumieniach rozproszenia stojana i wirnika jest bezpośrednio związana z zawartością harmoniczných w prądzie stojana i wirnika. Do pomiaru strumienia poosiowego instaluje się cewki pomiarowe, w których indukuje się napięcie proporcjonalne do strumienia (rys. 3.5b). W przypadku powstania zwarcia nawet niewielkiej liczby zwojów, następuje wyraźny wzrost napięcia indukowanego w cewce i wzrost charakterystycznych częstotliwości w widmie tego napięcia.

W przypadku uszkodzenia pierścienia zawierającego wirnika klatkowego, w cewce indukuje się napięcie o częstotliwości prądu wirnika, przy czym istotny wzrost występuje po stronie uszkodzonego pierścienia. Zmienna częstotliwość i jednostronny wzrost pozwalają odróżnić asymetrie pierścienia klatki od zwarcia zwojowego w stojanie.

Do monitorowania różnych typów asymetrii niezbędna jest wiedza o tych charakterystycznych częstotliwościach. Według [3.2, 3.11, 3.21, 3.24] detekcja strumienia poosiowego może być przydatna w diagnostyce do:

- wykrywania zwarcia zwojowego w stojanie,
- wykrywania uszkodzenia prętów wirnika i uszkodzenia uzwojeń wirników zwojonych,
- wykrywania składowej kolejności przeciwnej w napięciu zasilania,
- wykrywania ekscentryczności wirnika.

Szczegółową analizę częstotliwości charakterystycznych dla poszczególnych rodzajów uszkodzeń przedstawiono w dalszych rozdziałach.

3.6. Sygnał drgań mechanicznych

Drgania są zazwyczaj produktem ubocznym użytecznych działań i trudno je całkowicie wyeliminować. Mają one negatywny wpływ na elementy maszyn, powodując ich szybsze zużycie, naprężenia zmęczeniowe i dodatkowe obciążenia dynamiczne. Przyczyny powstawania drgań zaburzających założone normalne funkcjonowanie układów napędowych są bardzo różnorodne. Część z nich jest uwarunkowana tokiem realizacji procesu technologicznego przez daną maszynę. Inne wynikają z niedokładności elementów czy ich niewłaściwego montażu lub wskutek zużycia lub uszkodzenia się części. Oddziaływania zewnętrzne pochodzące od otoczenia stanowią dodatkową grupę przyczyn. Można powiedzieć, że maszyna elektryczna jest generatorem drgań, wynika to z zasady jej działania, ale wzrost poziomu drgań powyżej wartości dopuszczalnej może wynikać z:

- asymetrii pola spowodowanej uszkodzeniami elektrycznymi i mechanicznymi,
- niewyważenia wirnika,
- uszkodzenia łożyska,
- niewyosiowania napędu,
- złego posadowienia na fundamencie,
- charakteru pracy maszyny roboczej,
- oddziaływania otoczenia.

Ze względu na to, że układy napędowe z silnikami indukcyjnymi mogą mieć skomplikowaną strukturę, z łańcuchami kinematycznymi zamkniętymi, otwartymi lub rozgałęzionymi, z więzami holonomicznymi i nieholonomicznymi, z elementami sprężystymi i elementami o zmiennej masie i zmiennej bezwładności, z luzami w parach kinematycznych, pomiar i analiza drgań ma podstawowe znaczenie w ich monitorowaniu i diagnostyce.

Drgania można scharakteryzować za pomocą jednej z następujących wielkości fizycznych:

- przemieszczenia, przemieszczenia względnego,
- prędkości,
- przyspieszenia,
- przesunięcia fazowego wielkości harmoniczej.

Wybór wielkości fizycznej, którą należy zmierzyć, wynika najczęściej z założenia, jakie zjawiska chce się diagnozować [3.20, 2.23, 3.24]. Przesunięcie drgań najlepiej odzwierciedla drgania w zakresie niskich częstotliwości (10 Hz) i stosuje się wtedy, gdy interesujące są przemieszczenia bezwzględne lub względne, wielkości luzów i deformacji geometrycznych. Prędkość drgań najlepiej informuje o stanie maszyny przy częstotliwościach drgań od około 30 Hz do 1500 Hz. Natomiast przyspieszenie drgań dobrze odzwierciedla stan maszyn w zakresie wysokich częstotliwości. Pomiar prędkości pozwala ocenić stan dynamiczny na podstawie znanych norm i przepisów (tabela 3.1). Normy wykorzystują wartości skuteczne prędkości drgań elementów, gdyż prędkości są proporcjonalne do energii mechanicznej przechodzącej przez układ. Pomiar przyspieszeń dobrze obrazuje obciążenia wysokoczęstotliwościowe spowodowane zjawiskami udarów. Między przemieszczeniem, prędkością i przyspieszeniem występują proste zależności umożliwiające pomiar dowolnej wielkości i następnie obliczenie pozostałych [3.19, 3.20].

Tabela 3.1. Graniczna intensywność prędkości drgań o różnych wzniosach osi wału H [mm] (na podstawie normy PN-EN 60034-14:2004) [3.30]

Klasa wibracji	Mocowanie	Wznios osi wału H [mm]		
		$56 \leq H \leq 132$	$132 < H \leq 280$	$H > 280$
A	Zawieszenie swobodne	1,6	2,2	2,8
	Montaż sztywny	1,3	1,8	2,3
B	Zawieszenie swobodne	0,7	1,1	1,8
	Montaż sztywny	–	0,9	1,5

Klasa A jest stosowana do maszyn bez specjalnych wymagań drgań.
Klasa B jest stosowana do maszyn o specjalnych wymaganiach drgań. Sztywne mocowanie nie jest stosowane do maszyn o wzniosie wału mniejszym niż 132 mm.

Chwilowe przemieszczenie jest opisane równaniem:

$$x = x_m \sin\left(2\pi \frac{t}{T}\right) = x_m \sin(2\pi f t) = x_m \sin(\omega t) \quad (3.22)$$

gdzie:

$\omega = 2\pi f$ – prędkość kątowna [1/s],

x_m – wartość szczytowa przemieszczenia drgań [m],

t – czas [s].

Prędkość drgań jest zmianą przemieszczenia w czasie, więc drgania mogą być opisane następująco:

$$v = \frac{dx}{dt} = \omega x_m \cos(\omega t) = v_m \cos(\omega t) = v_m \sin\left(\omega t + \frac{\pi}{2}\right) \quad (3.23)$$

Przyspieszenie jest zmianą prędkości w czasie, więc drgania można opisać następująco:

$$a = \frac{dv}{dt} = \frac{d^2x}{dt^2} = -\omega^2 x_m \sin(\omega t) = -a_m \sin(\omega t) = a_m \sin(\omega t + \pi) \quad (3.24)$$

Wielkości opisujące drgania są związane ze sobą zależnościami przedstawionymi w tabeli 3.2.

Tabela 3.2. Przekształcanie wielkości przemieszczenia, prędkości i przyspieszenia drgań

		Przemieszczenie drgań	Prędkość drgań	Przyspieszenie drgań
Przemieszczenie drgań	$x =$	1	v/ω	a/ω^2
Prędkość drgań	$v =$	$x\omega$	1	a/ω
Przyspieszenie drgań	$a =$	$x\omega^2$	$v\omega$	1

Metoda oparta na analizie wartości skutecznej prędkości drgań (V_{RMS}) jest w praktyce przemysłowej podstawowym sposobem oceny stanu technicznego maszyn. Obecnie najczęściej stosuje się następujące normy: PN-ISO 10816-1:1998, PN-EN 60034-14:2004, PN-EN 60034-14:2004/A1:2007 [3.28–3.30]. Zgodnie z zaleceniami tych norm ocenę stanu technicznego maszyny należy wykonywać przez pomiar wartości skutecznej prędkości drgań w pasmie częstotliwości 10–1000 Hz.

W tabeli 3.1 zestawiono graniczne intensywności prędkości drgań dla różnych wzniosów osi wału H , które powinny spełniać silniki opuszczające zakład producenta (PN-EN 60034-14:2004). Natomiast na rysunku 3.6 przedstawiono ocenę stanu dynamicznego maszyn wirnikowych ze względu na prędkość drgań bezwzględnych według normy PN-ISO 10816-1:1998, którą posługują się diagnostycy w zakładach przemysłowych.


W pracach [3.8, 3.24] wykazano, że kontrolowanie jedynie wartości skutecznej drgań zgodnie z wytycznymi normy PN-ISO 10816-1:1998 może być nieskuteczne we wczesnym wykrywaniu uszkodzeń łożysk. Wynika to z faktu, że normy te nie uwzględniają np. indywidualnych cech poszczególnych maszyn. Zaleca się branie pod uwagę różnic we wskazaniach poziomu drgań między kolejnymi ocenami stanu technicznego. Okazuje się, że 2,5-krotny wzrost wartości skutecznej prędkości drgań (lub o 8 dB) odpowiada zmianie (pogorszeniu się) stanu maszyny o jedną klasę jakości. Co najmniej 10-krotny wzrost wartości V_{RMS} (lub o 20 dB) odpowiada zmianie klasyfikacji maszyny ze stanu dobrego na niedopuszczalny.

Jak wynika z [3.24], również tradycyjne (według obowiązujących norm) podejście do pomiaru wartości skutecznej prędkości drgań w pasmie 10–1000 Hz zdecydowanie obniża możliwość wykrycia początkowej fazy uszkodzenia łożyska (tzw. faza szumowa lub początkowa faza drganiowa). Badania te powinno się wykonywać w zdecydo-

wanie szerszym pasmie (obejmującym zakres widma częstotliwościowego maszyny). Zakres widma częstotliwościowego zależy od rodzaju maszyny. Norma PN-ISO 10816-1:1998 zaleca pomiary w szerokim pasmie częstotliwości.

		Klasa I Maszyny wytwarzane seryjnie o mocy do 15kW	Klasa II Maszyny średniej wielkości (silniki o mocy 15÷75kW) bez specjalnego fundamentowania oraz sztywno zamontowane maszyny (do 300kW) na specjalnych fundamentach	Klasa III Wielkie maszyny z masami wirującymi, zamontowane na sztywnych i ciężkich fundamentach o małej podatności w kierunku pomiaru drgań	Klasa IV Wielkie maszyny z masami wirującymi, zamontowane na fundamentach stosunkowo miękkich w kierunku pomiaru drgań		
Prędkość drgań V_{RMS} [mm/s]	0,28	Stan dobry	Stan dobry	Stan dobry	Stan dobry		
	0,45						
	0,71						
	1,12	Stan zadawalający	Stan zadawalający	Stan zadawalający	Stan dobry		
	1,8						
	2,8	Stan przejściowo dopuszczalny	Stan przejściowo dopuszczalny	Stan zadawalający	Stan zadawalający		
	4,5						
	7,1	Stan niedopuszczalny	Stan niedopuszczalny	Stan przejściowo dopuszczalny	Stan zadawalający	Stan przejściowo dopuszczalny	
	11,2						
	18			Stan niedopuszczalny	Stan niedopuszczalny	Stan niedopuszczalny	Stan niedopuszczalny
	28						
	45						

Rys. 3.6. Klasyfikacja stanu dynamicznego maszyn wirnikowych ze względu na prędkość drgań bezwzględnych (na podstawie normy PN-ISO 10816-1:1998) [3.28]



Rys. 3.7. Estymaty opisujące sygnały drganiowe (wartość szczytowa x_m , wartość międzyszczytowa x_{m-m} , wartość skuteczna x_{sk} , wartość średnia x_{sr})

Sygnal drganiowy jest obserwowany i rejestrowany w dziedzinie czasu (przebieg czasowy). Do opisu ilościowego drgań w dziedzinie czasu są stosowane następujące podstawowe estymaty sygnałów drganiowych (rys. 3.7):

- wartość międzyszczytowa x_{m-m} (ang. *peak-to-peak*),
- wartość szczytowa x_m (ang. *peak level*),
- wartość średniego poziomu drgań x_{sr} (ang. *average level*),
- wartość skuteczna drgań x_{sk} (ang. *root mean square RMS*).


Wartość międzyszczytowa x_{m-m} jest użyteczna, gdy ocenie podlegają maksymalne wartości naprężeń lub przemieszczenia. Wartość szczytowa x_m określa maksymalną wartość poziomu drgań i jest użyteczna do określania krótkotrwałych drgań wywołanych obciążeniami udarowymi. Estymata wartości średniej x_{sr} (całka z wartości bezwzględnej przebiegu drgań w okresie T lub w zadanym przedziale czasu) nie określa istotnych wielkości w analizie drgań. Estymata wartości skutecznej drgań x_{sk} wprowadza informację o poziomie drgań, gdyż uwzględnia historię przebiegu oraz jest proporcjonalnie zależna od energii przenoszonej przez sygnał.

Jednak użyteczność wymienionych estymat w diagnostyce maszyn elektrycznych jest ograniczona. Podstawowe znaczenie jako źródło wartościowych informacji o stanie technicznym maszyny ma analiza częstotliwościowa sygnału drganiowego. Na podstawie zawartości widma uzyskuje się możliwość identyfikacji rodzaju i lokalizacji uszkodzenia oraz oceny poziomu uszkodzenia. Jednak bardzo często wyodrębnienie symptomów związanych z uszkodzeniem jest bardzo utrudnione ze względu na szum i niską amplitudę charakterystycznych częstotliwości. Dlatego w badaniach naukowych ciągle poszukuje się bardziej doskonałych metod przetwarzania sygnału drganiowego. W dalszej części monografii przedstawiono inne, niż klasyczna analiza widmowa, sposoby przetwarzania sygnału drgań na potrzeby diagnostyki.

3.7. Temperatura jako sygnał diagnostyczny

Temperatura jest wielkością mającą wpływ na przebieg zjawisk fizycznych w obiektach. W znacznej liczbie urządzeń technicznych, w tym również w maszynach elektrycznych, nieprawidłowa ich praca objawia się zmianą temperatury elementu bądź jej rozkładu. Znajomość temperatury (lub jej rozkład) na podstawie przeprowadzonego pomiaru umożliwia wnioskowanie o prawidłowej pracy obiektu lub jego elementu. Określenie zależności między wartością temperatury bądź obrazem termalnym obiektu a jego poprawnym lub niewłaściwym stanem jest istotą *diagnostyki termicznej pasywnej*. Analogiczne działania stosuje się w *diagnostyce termicznej aktywnej*, gdy pomiar temperatury (rozkład temperatury) jest poprzedzony wstępnym nagrzewaniem obiektu. Oba rodzaje diagnostyki stosuje się w przypadku maszyn i napędów elektrycznych.

Problemy z nadmiarem ciepła w maszynach elektrycznych są wynikiem ciągłego dążenia producentów do ich miniaturyzacji i maksymalnego wykorzystania zastosowanych materiałów. Częste przegrzewanie maszyny powoduje znaczne skrócenie czasu jej prawidłowego działania. Dlatego należy kontrolować temperaturę poszczególnych części urządzenia, szczególnie istotnymi elementami są uzwojenia, których temperatura nie może przekraczać określonych wartości maksymalnych. Temperatura nie jest idealnym sygnałem diagnostycznym we wszystkich rodzajach uszkodzeń. Bardzo często ze względu na tzw. bezwładność cieplną istotna zmiana temperatury pojawia się zbyt późno, aby zapobiec awarii. Na rysunku 3.7 przedstawiono orientacyjny przebieg zmian temperatury i drgań mechanicznych w trakcie eksploatacji maszyny.



Rys. 3.8. Orientacyjne porównanie zmian sygnału temperatury i drgań w trakcie eksploatacji obiektu

W sygnale drganiowym zmiany wynikające z powstania i rozwoju uszkodzenia są widoczne znacznie wcześniej niż w przypadku zmian temperatury, które zwykle pojawiają się tuż przed awarią. W łożyskach tocznych wartość szczytowa x_m rośnie szybciej przy pojawieniu się usterki niż wartość skuteczna x_{sk} . Wartość skuteczna wzrasta znacznie później.

Ze względu na prawidłową eksploatację maszyny elektrycznej i jej pełne wykorzystanie istotna jest znajomość parametrów cieplnych określanych w trakcie diagnostyki aktywnej:

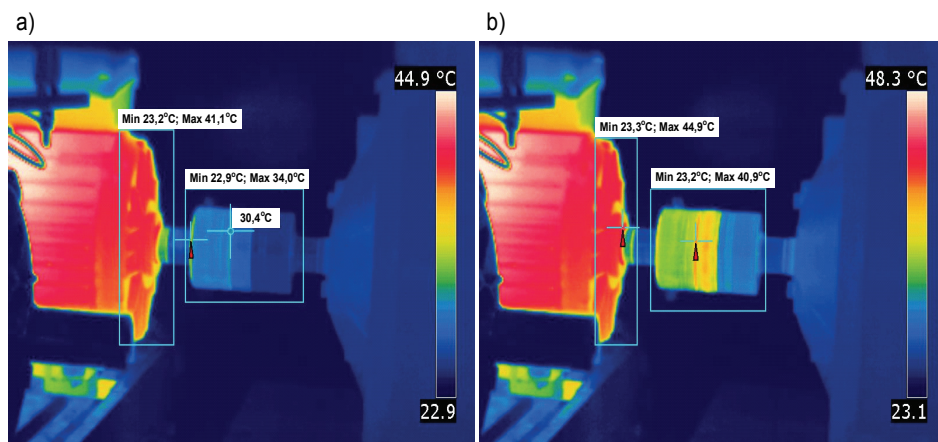
- ustalone przyrosty temperatury Δv_{ust} (w praktyce przyjmuje się, że maszyna znajduje się w stanie ustalonym, jeżeli jej temperatura nie zmienia się więcej niż o 1 °C w ciągu jednej godziny);
- stałe czasowe nagrzewania oraz stygnięcia maszyny (odpowiada czasowi, w którym ciało osiągnęłoby przyrost temperatury równy ustalonemu w przypadku pochłaniania przez ciało całej energii strat).

Podane parametry mają znaczenie w projektowaniu napędu i kontrolowaniu przebiegu jego eksploatacji. Natomiast ze względu na monitorowanie i diagnostykę maszyny elektrycznej istotna jest znajomość aktualnej temperatury w newralgicznych


punktach maszyny oraz globalny rozkład temperatury na obiekcie. W tym celu stosowana jest diagnostyka pasywna oparta na pomiarze temperatury za pomocą czujników wbudowanych (czujniki rezystancyjne, termopary, termistory), instalowanych w różnych miejscach w maszynie (w czołach uzwojeń, żłobkach, pod łożyskami) lub metodą termometrową, przez bezpośredni dotyk czujnika do elementu maszyny. W przypadku obu tych metod główną niedogodnością jest wzajemne oddziaływanie układu pomiarowego na obiekt i odwrotnie. Zastosowanie takiego podejścia wymaga, oprócz prawidłowego doboru metody pomiaru temperatury, określenie algorytmów diagnozowania opartych na wiedzy heurystycznej operatora, modelach matematycznych procesu, wzorcach rozkładu temperatury, przepisach i normach itp. Zwykle wymaga to wcześniejszych badań umożliwiających ustalenie zależności między wartością temperatury określonego punktu bądź obrazu termalnego maszyny a jej prawidłowym stanem technicznym.

Obecnie podstawowe znaczenie w diagnostyce pasywnej maszyn elektrycznych mają bezstykowe metody pomiaru temperatury oparte na zastosowaniu mierników promieniowania całkowitego lub częściowego (tzw. pirometry) lub na systemach do zobrazowań termalnych (termografy, kamery termowizyjne) wykorzystujące widmo promieniowania elektromagnetycznego w zakresie podczerwieni. W warunkach przemysłowych nieinwazyjna diagnostyka termowizyjna umożliwia zdalną i bardzo często bezdemontażową ocenę stanu termicznego i technicznego maszyny. Systematyczna okresowa analiza obrazów termalnych eksploatowanych maszyn elektrycznych pozwala ujawnić stany przedawaryjne i prognozować konieczność remontu.

Przykłady zastosowania obrazu rozkładu temperatury uzyskanego z kamery termowizyjnej do wykrywania złego wyosiowania napędu elektrycznego oraz zwarcia zwojowego w stojanie silnika indukcyjnego przedstawiono na rysunkach 3.9 i 3.10.



Rys. 3.9. Zdjęcia z kamery termowizyjnej układu napędowego: a) wyosiowanego, b) niewyosiowanego (z poziomym przesunięciem równoległym)



Rys. 3.10. Zdjęcie z kamery termowizyjnej silnika ze zwarcieniem zwojowym

Zastosowanie diagnostyki termowizyjnej daje duże korzyści ekonomiczne wynikające z możliwości prowadzenia profilaktyki pomiarowej dotyczącej prawidłowości funkcjonowania kontrolowanego napędu i optymalizacji procesu technologicznego.

3.8. Podsumowanie

W diagnostyce uszkodzeń silników podstawowe znaczenie mają od dawna dwa sygnały: prąd fazowy i drgania mechaniczne. Pomiar tych wielkości jest nieinwazyjny i łatwy do zrealizowania. Dzięki technice komputerowej coraz częściej wykorzystuje się sygnały diagnostyczne mierzone pośrednio (odtworzane lub obliczane według zależności matematycznych). Dotyczy to takich wielkości, jak: moduł wektora przestrzennego prądu stojana, estymowany moment elektromagnetyczny, moc chwilowa czynna i bierna. Zwiększenie liczby sygnałów diagnostycznych umożliwia wyodrębnienie większej liczby cech przydatnych w wykrywaniu uszkodzeń i ocenie ich poziomu.

Ze względu na nowe możliwości pomiaru i wizualizacji rośnie znaczenie temperatury jako sygnału diagnostycznego. W diagnostyce cieplnej pasywnej maszyn elektrycznych odgrywają znaczącą rolę bezstykowe metody pomiaru temperatury oparte na systemach termowizyjnych.

Literatura

- [3.1] Akagi H., Kanazawa Y., Nabae A., *Instantaneous Reactive Power Compensators Comprising Switching Devices without Energy Storage Components*, IEEE Trans. on Industrial Applications, Vol. IA-20, 1984, 625–630.

- [3.2] Assaf T., Henao H., Capolino G.A., *Simplified axial flux spectrum method to detect incipient stator inter-turn short-circuits in induction machine*, IEEE Int. Symp. on Industrial Electronics, Vol. 2, 2004, 815–819.
- [3.3] Benbouzid M., *A Review of Induction Motors Signature Analysis as a Medium for Faults Detection*, IEEE Trans. on Ind. Electronics, Vol. 47, No. 5, 2000, 984–993.
- [3.4] Benbouzid M., Kliman G.B., *What Stator Current Processing-Based Technique to Use for Induction Motor Rotor Faults Diagnosis*, IEEE Trans. on Energy Conversion, Vol. 18, No. 2, June 2003, 238–244.
- [3.5] Bellini A., Filippetti F., Franceschini G., Tassoni C., Passaglia R., Saottini M., Giovannini M., Rossi A., *On-field Experience With Online Diagnosis of Large Induction Motors Cage Failures Using MCSA*, IEEE Trans. on Ind. Applications, Vol. 38, No. 4, 2002, 1045–1052.
- [3.6] Bellini A., Filippetti F., Tassoni C., Capolino G.A., *Advances in Diagnostic Techniques for Induction Machines*, IEEE Transactions on Industrial Electronics, Vol. 55, No. 12, 2008, 4109–4125.
- [3.7] Cruz S.M., Cardoso A.J.M., *Rotor cage fault diagnosis in three-phase induction motors by the synchronous reference frame current Park's Vector approach*, Int. Conf. on Electrical Machines ICEM '2000, Espoo, Finland, 2000, 776–780.
- [3.8] Ewert P., *Diagnostyka mechanicznych uszkodzeń napędów z silnikami indukcyjnymi przy wykorzystaniu sieci neuronowych*, Praca doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i pomiarów Elektrycznych, 2012.
- [3.9] Ferrero A., Superti-Furga G., *A New Approach to the Definition of Power Components in Three-Phase Systems Under Nonsinusoidal Conditions*, IEEE Trans. on Instrumentation and Measurement, Vol. 40, No. 3, 1991, 568–577.
- [3.10] Filippetti F., Franceschini G., Tassoni C., Vas P., *AI Techniques in Induction Machines Diagnosis Including the Speed Ripple Effect*, IEEE Trans. on Ind. Appl., Vol. 34, No. 1, 1998, 98–107.
- [3.11] Henao H., Demian C., Capolino G.A., *A Frequency-Domain Detection of Stator Winding Faults in Induction Machines Using an External Flux Sensor*, IEEE Trans. on Industry Applications, Vol. 39, No. 5, 2003, 1272–1279.
- [3.12] Kaźmierkowski M.P., Orłowska-Kowalska T., *Neural Network Estimation and Neuro-Fuzzy Control in Converter-Fed Induction motor Drives*, (w monografii Ovaska S., Sztandera L. – editors, *Soft computing in industrial electronics*, Physica-Verlag A, Springer-Verlag Company, 2002), 45–94.
- [3.13] Kowalski C.T., Orłowska-Kowalska T., Wojsznis P., *Indirect Torque Measurement of the Induction Motor Drive based on Flux Estimation*, Proc. 4th Intern. Symp. on Advanced Electromechanical Motion Systems, ELECTROMOTION'01, Vol. 1, 2001, Bologna, Italy, 137–140.
- [3.14] Kowalski C.T., Pawlak M., *Current Park's Vector Approach in the Induction Motor On-Line Monitoring and Diagnosis*, Proc. of 14th Int. Conf. EDPE'03, High Tatras, Slovak Rep., 2003.
- [3.15] Kowalski C.T., Pawlak M., *Zastosowanie metody analizy wektora przestrzennego prądu stojana do wykrywania uszkodzeń w silnikach indukcyjnych*, Przegląd Elektrotechniczny, Nr 7–8, 2004, 771–777.
- [3.16] Kowalski C.T., Wolkiewicz M., *Analiza możliwości zastosowania sygnałów mocy chwilowej i momentu elektromagnetycznego do diagnostyki silników indukcyjnych*, Zagadnienia maszyn, napędów i pomiarów elektrycznych, Oficyna Wydawnicza Politechniki Wroclawskiej, 2007, 248–259.
- [3.17] Kowalski C.T., Wolkiewicz M., *Rotor fault diagnosis of converter-fed induction motor using instantaneous active and reactive power signals*, XXI Symposium Electromagnetic Phenomena in Nonlinear Circuits, EPNC 2008, 127–128.
- [3.18] Kowalski C.T., Wolkiewicz M., *Converter-fed induction motor diagnosis using instantaneous electromagnetic torque and power signals*, IEEE Int. Conf. EUROCON 2009, Petersburg, 2009, 824–829.

-
- [3.19] Kucharski T., *System pomiaru drgań mechanicznych*, WNT, Warszawa 2002.
- [3.20] Morel J., *Drgania maszyn i diagnostyka ich stanu technicznego*, Polskie Towarzystwo Diagnostyki Technicznej, Warszawa 1994.
- [3.21] Nandi s., Toliyat A. T., Li X., *Condition Monitoring and Fault Diagnosis of Electrical Motors – A Review*, IEEE Trans. on Energy Conversion, Vol. 20, No. 4, 2005, 719–729.
- [3.22] Orłowska-Kowalska T., *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.
- [3.23] Szymaniec S., *Diagnostyka stanu izolacji uzwojeń i stanu łożysk silników indukcyjnych klatkowych w warunkach przemysłowej eksploatacji*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 193, Opole.
- [3.24] Szymaniec S., *Badania, eksploatacja i diagnostyka zespołów maszynowych z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 333, Opole 2013.
- [3.25] Trzynadlowski A., Ghassemzadeh M., Legowski S.F., *Diagnostics of Mechanical Abnormalities in Induction Motors Using Instantaneous Electric Power*, IEEE Trans. on Energy Conversion, Vol. 14, No. 4, Dec. 1999, 1417–1423.
- [3.26] Watanabe E.H., Akagi H., Aredes M., *Instantaneous p-q Power Theory for Compensating Nonsinusoidal Systems*, Przegląd Elektrotechniczny, 2008, R. 84, nr 6, 12–21.
- [3.27] Wolkiewicz M., *Monitorowanie stanu uzwojeń stojana silnika indukcyjnego*, Praca doktorska, Politechnika Wrocławska, Instytut Maszyn, Napędów i pomiarów Elektrycznych 2012.
- [3.28] Norma PN-ISO 10816-1:1998, *Drgania mechaniczne – Ocena drgań maszyny na podstawie pomiarów na częściach niewirujących – Wytyczne ogólne*, 12.01.1998.
- [3.29] Norma PN-EN 60034-14:2004, *Maszyny elektryczne wirujące – Część 14: Drgania mechaniczne określonych maszyn o wzniosach osi wału 56 mm i większych – Pomiar, ocena i wartości graniczne intensywności drgań*, 6.09.2004.
- [3.30] Norma PN-EN 60034-14:2004/A1:2007, *Maszyny elektryczne wirujące – Część 14: Drgania mechaniczne określonych maszyn o wzniosach osi wału 56 mm i większych – Pomiar, ocena i wartości graniczne intensywności drgań*, 10.08.2007.

4. Analiza sygnałów – podstawowa metoda diagnostyki napędu elektrycznego

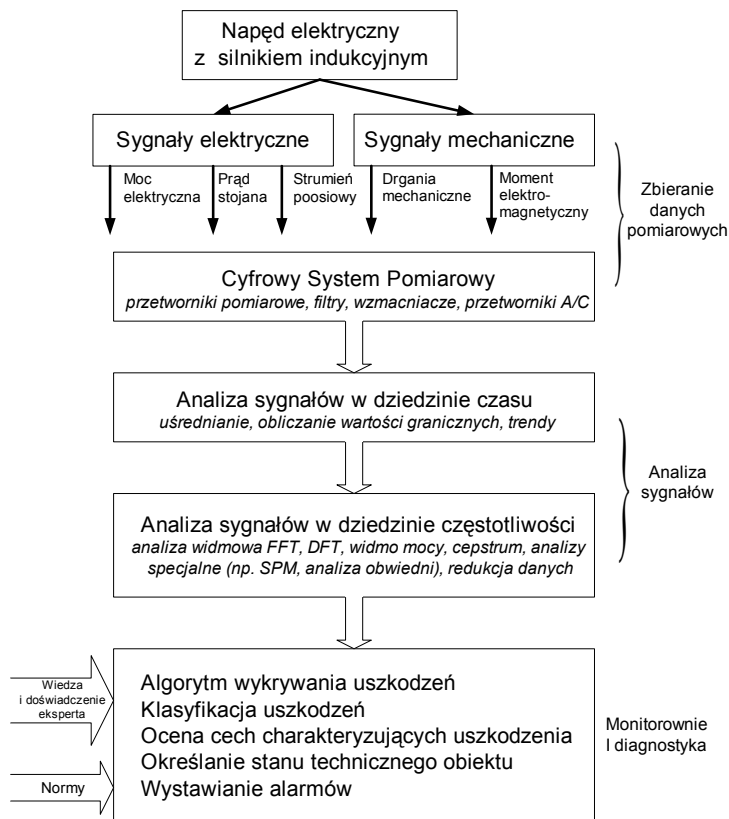
4.1. Wprowadzenie

W diagnostyce napędów elektrycznych z silnikiem indukcyjnym dominują obecnie metody oparte na kontroli i analizie sygnałów, gdy korzysta się z pomiarów wybranych wielkości fizycznych, elektrycznych i mechanicznych. Następnie są poddawane matematycznemu przetwarzaniu, a otrzymane wyniki porównuje się z parametrami granicznymi lub służą do określania trendów. Schemat ideowy ilustrujący algorytm diagnostyki opartej na analizie sygnałów diagnostycznych przedstawiono na rysunku 4.1.

Wielkości fizyczne mierzone odpowiednimi czujnikami i przetwornikami pomiarowymi są zbierane za pomocą systemów pomiarowych wyposażonych w analogowe filtry sieciowe i antyaliasingowe, wzmacniacze pomiarowe i przetworniki analogowo-cyfrowe, próbujące sygnały z odpowiednią częstotliwością zgodną z wymaganiami analizy widmowej (twierdzenie Shannona). Przetworzone na postać cyfrową sygnały są poddawane analizie w dziedzinie czasu i częstotliwości. Analiza sygnałów w dziedzinie czasu ma bardzo ograniczony zasięg i najczęściej sprowadza się do monitorowania wartości wybranych wielkości i alarmowania, gdy zostaną przekroczone wartości graniczne.

Dominujące znaczenie ma analiza sygnałów w dziedzinie częstotliwości, wykorzystująca przede wszystkim szybką transformatę Fouriera FFT. Informacja diagnostyczna zawarta w widmie (amplitudach harmonicznym) lub wskaźnikach obliczonych na podstawie składowych harmonicznym musi być następnie zredukowana. Redukcja w najprostszym przypadku oparta jest na uśrednianiu. Uśrednianie minimalizuje również wpływ zakłóceń. Spektra mogą być obliczane z wielokrotnych zestawów próbek lub obliczane wielokrotnie dla wybranych przedziałów (okien) z jednego dużego zestawu danych.

Dla poszczególnych uszkodzeń i związanych z nimi symptomów, zawartych w konkretnych sygnałach pomiarowych, istnieją charakterystyczne częstotliwości lub przedziały częstotliwości w widmie. W przedziałach tych widmo musi być obliczone z wystarczającą rozdzielczością, która umożliwi wyodrębnienie charakterystycznych składowych harmonicznym.



Rys. 4.1. Schemat ideowy algorytmu diagnostyki opartej na analizie sygnałów fizycznych

Aby możliwe było określenie aktualnego stanu technicznego silnika, czyli postawienie diagnozy, niezbędna jest dalsza redukcja informacji zawartej w widmie. Redukcja harmonicznych opiera się na odpowiednim algorytmie (filtre), który eliminuje składowe niezawierające informacji o uszkodzeniu, a wyodrębnia te składowe, które są charakterystyczne dla danego typu uszkodzenia. W algorytmie muszą być uwzględnione warunki pracy napędu, które mogą się zmieniać (np. wahania obciążenia), co powoduje, że charakterystyczne harmoniczne mogą zmieniać swoje częstotliwości w pewnym pasmie.

Obecnie można zauważyć wzrost zainteresowania złożonymi metodami cyfrowego przetwarzania sygnałów pomiarowych na potrzeby monitorowania i diagnostyki maszyn i napędów elektrycznych [4.1, 4.4, 4.6, 4.7, 4.12, 4.21]. Ogólnie metody te można podzielić na parametryczne i nieparametryczne [4.11, 4.23]. W diagnostyce najczęściej stosuje się metody nieparametryczne. Metody parametryczne pojawiły się jako metody modelowania systemów, zwykle liniowych [4.11]. Ich zaletą jest mały rozmiar zbiorów wyznaczonych wartości cech.

W metodach nieparametrycznych korzysta się oprócz klasycznych FFT, z bardziej złożonych transformacji czasowo-częstotliwościowych sygnałów diagnostycznych, np. transformaty krótkoczasowe, falkowe, MUSIC, transformaty wyższych rzędów (bispectrum). Odejście od analiz opartych na podstawowym, szybkim przekształceniu Fouriera FFT wynika z niedoskonałości tych metod w przypadkach występowania krótkoczasowych osobliwości w sygnałach pomiarowych. Niestacjonarny charakter tych sygnałów powoduje, że metody klasyczne stają się niewystarczające we współczesnych systemach pomiarowo-diagnostycznych [4.9, 4.19, 4.20, 4.22].

Najczęściej stosuje się analizy krótkoczasowe i falkowe, które umożliwiają skuteczniejsze wydobycie osobliwych, krótkoczasowych cech analizowanych sygnałów świadczących o wystąpieniu uszkodzeń. Za pomocą metod czasowo-częstotliwościowych można z sygnałów diagnostycznych wyodrębnić symptomy uszkodzeń w krótkim i długim czasie (informacje wysoko- i niskoczęstotliwościowe). Ułatwia to wykrywanie symptomów uszkodzeń we wczesnej fazie ich powstawania.

Zastosowanie tego typu analizy nie jest obecnie możliwe z zastosowaniem przemysłowej aparatury diagnostycznej i profesjonalnych analizatorów częstotliwościowych. Z drugiej strony, w klasycznych stacjonarnych i przenośnych komputerach, dostępne są środowiska programistyczne wyposażone w gotowe pakiety programów realizujących coraz bardziej złożone algorytmy cyfrowego przetwarzania sygnałów (np. Matlab, LabView). Pakiety te mogą współpracować z różnego rodzaju zewnętrznymi systemami pomiarowymi, umożliwiającymi cyfrową akwizycję próbek sygnałów. Rozwiązania sprzętowo-programowe są stosunkowo tanie, a jednocześnie dostarczają nowych możliwości w zakresie wykrywania uszkodzeń i są stosowane z powodzeniem w pracach diagnostycznych autora i zespołu. W ostatnich latach można zauważyć odchodzenie od stosowania drogich analizatorów sprzętowych na rzecz systemów akwizycji danych i analizy programowej.

W następujących podrozdziałach scharakteryzowano najczęściej stosowane w monitorowaniu i diagnostyce napędów elektrycznych metody wyznaczania cech sygnałów diagnostycznych.

4.2. Wstępne przetwarzanie sygnałów

Analizowane sygnały są generowane przez różne czujniki i przetworniki umożliwiające obserwację działania napędu. Wstępne przetwarzanie sygnałów powinno zapewnić odpowiedni stosunek sygnału do szumu, z jednoczesnym eliminowaniem nieodpowiednich właściwości statycznych i dynamicznych występujących w charakterystykach czujników lub przetworników pomiarowych. Dotyczy to między innymi eliminowania za pomocą filtrów pasmowych składowych spoza interesującego użytkownika zakresu częstotliwości. Optymalizacja działań związanych z

wstępnym przetwarzaniem sygnałów powinna być realizowana na wstępnym etapie projektowania układów pomiarowych.

Obecne układy pomiarowe i analiza sygnałów, stosowana w diagnostyce maszyn i napędów elektrycznych, są oparte na sygnałach cyfrowych otrzymywanych bezpośrednio z przetworników cyfrowych lub za pośrednictwem cyfrowego systemu z przetwornikiem analogowo-cyfrowym. Problemy związane z prawidłowym doбором i konfiguracją systemu cyfrowego przedstawiono w rozdziale 4.3. Oprócz problemów związanych z przetwarzaniem analogowo-cyfrowym, do wstępnego przetwarzania sygnałów diagnostycznych można zaliczyć następujące działania:

- filtrację,
- wygładzanie,
- uśrednianie,
- analizę składowych głównych.

Dane pomiarowe zebrane na obiekcie rzeczywistym zawierają uboczne składowe, takie jak trendy, zakłócenia wolno- i szybkozmiennie, szумы. Przed przystąpieniem do diagnostyki należy wyeliminować wpływ ubocznych czynników. Wygodnym i stosunkowo prostym narzędziem umożliwiającym eliminację zakłóceń występujących w pewnym przedziale częstotliwości są **filtry cyfrowe** [4.11, 4.23]. Wstępna faza projektowania filtrów obejmuje zdefiniowanie ich właściwości w dziedzinie częstotliwości: filtry cyfrowe dolnoprzepustowe, górnoprzepustowe, pasmowo-przepustowe i pasmowo-zaporowe. Ze względu na nieliniową charakterystykę w obszarze przepustowym filtry nieoptymalne wprowadzają zniekształcenia do składowej użytecznej sygnałów co powoduje, że w układach diagnostyki bardzo ważnym zagadnieniem jest wybór właściwego typu filtra oraz jego parametrów. Odrębnym problemem jest stosowanie w układach diagnostyki filtrów optymalnych (np. filtru Kalmana), które są wykorzystywane do odtwarzania zmiennych stanu i parametrów, a nie do wstępnego przetwarzania sygnałów. Zagadnienie to przedstawiono w rozdziale 6.

Proces **wygładzania sygnałów** polega na usunięciu z nich składowych o dużych częstotliwościach. W odróżnieniu od filtracji, w algorytmach wygładzania dopuszcza się wykorzystanie zarówno **pomiary przeszłe i przyszłe** w stosunku do wygładzanego punktu [4.11]. Jedną z podstawowych metod wygładzania jest tzw. wygładzanie stałopunktowe wykorzystujące wielomiany aproksymujące. Polega ono na aproksymacjach wielomianami M -tego stopnia pomiarów leżących w pewnym przedziale szerokości $(2K + 1)\Delta t$, położonym symetrycznie względem wygładzanego punktu. Wartość wielomianu w środku przedziału daje jeden punkt wygładzanego sygnału. Przesunięcie przedziału o jeden punkt i powtórzenie obliczeń daje możliwość wyznaczenia następnego punktu wygładzanego sygnału.

Operacja **uśredniania sygnałów** zwykle jest realizowana w dziedzinie czasu. Można wyróżnić tzw. uśrednianie wygładzające i synchroniczne. Celem uśredniania wygładzającego jest usunięcie krótkotrwałych, wysokoczęstotliwościowych fluktuacji występujących w sygnale. Najczęściej jest to filtracja dolnoprzepustowa.

Uśrednianie synchroniczne służy do wykrycia powtarzających się sekwencji zmian wartości amplitudy sygnału i jest stosowane w analizie sygnałów generowanych przez zjawiska powtarzające się cyklicznie (np. sygnały generowane przez przekładnie zębate lub maszyny wirnikowe). Uśrednianie synchroniczne wymaga równoległej obserwacji sygnału mierzonego oraz sygnału synchronizującego dostarczającego informację o początku lub określonej fazie każdego kolejnego cyklu działania urządzenia (np. sygnał synchronizujący zawierający impulsy generowane przez znacznik położenia kąтового wirnika).

Analiza składowych głównych (ang. *Principal Component Analysis*, PCA) jest metodą statystyczną umożliwiającą odrzucanie nieistotnych składowych sygnału [4.11]. Idea tej metody polega na redukcji rozmiaru zestawu danych (zbioru) zawierających dużą liczbę powiązanych ze sobą zmiennych. Zostaje to osiągnięte przez transformację danych pomiarowych do nowego zestawu danych, które już nie są skorelowane.

Jeżeli przyjmie się, że \mathbf{X} jest macierzą zawierającą dużą liczbę m losowych zmiennych (sygnał mierzony) $x_i(k)$:

$$\mathbf{X} = [\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_m] \quad (4.1)$$

której każdy wektor zawiera N pomiarów; $k = 1, 2, \dots, N$, to można zrealizować jej transformację do nowej postaci:

$$\mathbf{T} = [\mathbf{t}_1 \quad \mathbf{t}_2 \quad \dots \quad \mathbf{t}_r] \quad (4.2)$$

zawierającej również N pomiarów, ale o mniejszym wymiarze $r < m$. Można to uzyskać za pomocą macierzy transformacji \mathbf{P} , która spełnia następujące równanie:

$$\mathbf{T}_{[N \times r]} = \mathbf{X}_{[N \times m]} \mathbf{P}_{[m \times r]} \quad (4.3)$$

$$\mathbf{P} = [\mathbf{p}_1 \quad \mathbf{p}_2 \quad \dots \quad \mathbf{p}_r] \quad (4.4)$$

Ponieważ macierz \mathbf{P} jest macierzą ortonormalną, więc spełnia warunek:

$$\mathbf{P}^T \mathbf{P} = \mathbf{1} \quad (4.5)$$

Dlatego jest również spełnione następujące równanie:

$$\mathbf{X} = \mathbf{T} \mathbf{P}^T \quad (4.6)$$

Można wykazać, że macierz transformacji \mathbf{P} można wyznaczyć, obliczając wartości własne λ_i macierzy korelacji:

$$\mathbf{A} = \mathbf{X}^T \mathbf{X} \quad (4.7)$$

Po założeniu zerowych wartości średnich oczekiwanych: $E\{x_i(k)\} = 0$ i $E\{x_i^2(k)\} = 1$, a następnie obliczyć wektory wartości własnych \mathbf{p}_j z równania:

$$(\mathbf{A} - \lambda_j \mathbf{I}) \mathbf{p}_j = 0 \quad j = 1, \dots, m \quad (4.8)$$

Ustawiając wartości własne λ_i w kolejności malejącej i wybierając największe (najbardziej znaczące) oraz odpowiadające im wektory własne \mathbf{p}_j ($j = 1, 2, \dots, r$), uzyskuje się aproksymację wyjściowej macierzy \mathbf{X} :

$$\mathbf{X}' = \mathbf{t}_1 \mathbf{p}_1^T + \mathbf{t}_2 \mathbf{p}_2^T + \dots + \mathbf{t}_r \mathbf{p}_r^T \quad (4.9)$$

Wobec tego macierz transformacji \mathbf{P} jest określona za pomocą wyznaczonych wektorów własnych \mathbf{p}_j i przyjmuje postać jak (4.4).

Obliczając zgodnie z (4.3):

$$\mathbf{T} = \mathbf{X}' \mathbf{P} = [\mathbf{t}_1 \quad \mathbf{t}_2 \quad \dots \quad \mathbf{t}_r] \quad (4.10)$$

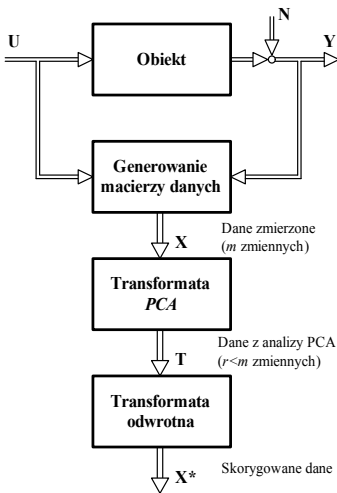
gdzie: $\mathbf{t}_j = \mathbf{X}' \mathbf{p}_j$, uzyskuje się nową macierz danych \mathbf{T} zawierającą wszystkie oryginalne dane dotyczące analizowanych zmiennych, ale o zredukowanej liczbie $m < r$, tzw. składowe główne. Macierz składowych głównych \mathbf{X}' zawiera te same informacje o wariancjach zmiennych losowych $x_i(k)$ co oryginalna macierz danych \mathbf{X} .

Przez odwrotną transformację (z uwzględnieniem (4.6) i (4.10) oraz (4.5)):

$$\mathbf{X}_{[N \times m]}^* = \mathbf{T}_{[N \times r]} \mathbf{P}_{[r \times m]}^T = \mathbf{X}_{[N \times m]} \mathbf{P}_{[m \times r]} \mathbf{P}_{[r \times m]}^T \quad (4.11)$$

uzyskuje się oryginalne zmienne, zawierające tylko istotne wariancje, nieistotne zakłócenia (np. szумы pomiarowe) zostały wyeliminowane.

Opisany algorytm przekształcenia PCA przedstawiono na rys. 4.2



Rys. 4.2. Schemat ideowy algorytmu PCA

Przekształcenie algorytmu PCA określa zbiór r wektorów ortogonalnych mających statystycznie największy wkład w wariancję danych wejściowych. Składowa główna,

związana największą wartością własną, reprezentuje kierunek w przestrzeni danych, w którym dane te wykazują największą wariancję. Metodą PCA można bezpiecznie usunąć dane, zmniejszając ich wymiarowość, bez istotnego pozbawienia informacji w nich zawartych. Przykład zastosowania metody PCA w diagnostyce układów napędowych przedstawiono w rozdziale 9.

4.3. Dobór i konfiguracja cyfrowego systemu akwizycji danych

Pierwszym etapem badań diagnostycznych jest automatyczna rejestracja zestawu próbek sygnałów pomiarowych w celu późniejszej ich analizy. Do tego celu niezbędny jest odpowiedni dobór przetworników mierzonych wielkości fizycznych oraz dobór i konfiguracja cyfrowego systemu akwizycji danych (rozdział 11). Aby odpowiednio dobrać aparaturę pomiarową, należy wyznaczyć podstawowe parametry mierzonych sygnałów, takie jak:

- maksymalna amplituda,
- dolna i górna granica częstotliwości,
- maksymalny czas rejestracji,
- parametry dynamiczne (wymagana rozdzielczość przetworników A/C).

Konfiguracja parametrów rejestracji systemu pomiarowego wymaga wprowadzenia odpowiednich nastaw, do których najczęściej należą:

- zakres mierzonych napięć wejściowych przetworników A/C – w przypadku aparatury pomiarowej wyposażonej w obwody wejściowe o nastawianym wzmacnieniu (tzw. wzmacniacze PGA – ang. *Programmable Gain Amplifier*),
- rozdzielczość przetworników A/C (niektóre karty pomiarowe umożliwiają zwiększenie częstotliwości próbkowania kosztem pogorszenia rozdzielczości przetworników A/C),
- częstotliwość próbkowania,
- czas rejestracji lub liczba rejestrowanych próbek,
- częstotliwość odcięcia opcjonalnego filtra dolnoprzepustowego.

Dobór rozdzielczości przetwornika A/C ma bezpośredni wpływ na dokładność uzyskanych wyników pomiarów. Zaleca się, aby rozdzielczość przetwornika była jak największa. Jest to szczególnie istotne w przypadku analizy sygnałów o dużej dynamice. Przykładem może być analiza częstotliwościowa sygnałów prądów fazowych silnika, która polega na wykrywaniu charakterystycznych składowych częstotliwościowych o bardzo małych amplitudach, występujących na tle dużego sygnału o częstotliwości podstawowej (50 Hz). W takim przypadku zaleca się stosowanie przetworników A/C o rozdzielczości nie mniejszej niż 14 bitów, które mają dobre parametry dynamiczne (odstępstwo sygnału od szumu > 80 dB).

Wybór częstotliwości próbkowania sygnałów pomiarowych zależy bezpośrednio od parametrów częstotliwościowych analizowanych sygnałów. W przypadku wielokanałowych systemów akwizycji danych, częstotliwość próbkowania dla wszystkich kanałów jest na ogół taka sama. Podstawowym kryterium wyznaczenia tego parametru jest ustalenie najwyższej częstotliwości pojawiającej się w rejestrowanych sygnałach. Przy wyznaczaniu częstotliwości próbkowania systemu pomiarowego należy pamiętać o spełnieniu podstawowego twierdzenia o próbkowaniu Kotelnikowa–Shanona [4.17, 4.18, 4.23].

W celu wiernej reprezentacji sygnału ciągłego $x(t)$ przez jego próbki $x[n]$, muszą być spełnione dwa warunki:

- sygnał $x(t)$ musi mieć ograniczone widmo, tzn. musi być ograniczone do pewnej skończonej wartości f_g ,
- zastosowana częstotliwość próbkowania f_p musi być co najmniej dwa razy większa od częstotliwości f_g :

$$f_p \geq 2f_g \quad (4.12)$$

Jednocześnie spełnienie tych warunków umożliwia odtworzenie sygnału ciągłego $x(t)$ na podstawie próbek $x[N]$. Na podstawie podanych warunków można określić minimalną częstotliwość próbkowania sygnału, która w ogólnym przypadku powinna być dwukrotnie wyższa od najwyższej częstotliwości harmonicznej pojawiającej się w mierzonym sygnale.

Stosowanie wejściowych filtrów dolnoprzepustowych może przynieść duże korzyści, w przypadku gdy w widmie analizowanego sygnału diagnostycznego znajdują się składowe wysokoczęstotliwościowe, leżące powyżej analizowanego zakresu częstotliwości. Odcięcie wyższych, niepożądanych częstotliwości za pomocą filtru pozwoli na obniżenie częstotliwości próbkowania, eliminując zjawisko aliasingu. Operacja ta pozwoli zredukować liczbę rejestrowanych próbek pomiarowych, ułatwiając wykonanie późniejszych operacji arytmetycznych.

Liczba zarejestrowanych próbek poszczególnych sygnałów pomiarowych powinna być odpowiednio duża, aby umożliwić dokładną analizę kształtu tych sygnałów w dziedzinie czasu oraz uzyskać odpowiednią rozdzielczość widma tych sygnałów w dziedzinie częstotliwości. Czas pomiaru t_p , częstotliwość próbkowania f_p oraz liczba próbek N są ze sobą powiązane następującą zależnością:

$$f_p = \frac{N}{t_p} \quad (4.13)$$

Rozdzielczość Δf w dziedzinie częstotliwości dla dyskretnego przekształcenia Fouriera można wyznaczyć, określając różnice między częstotliwościami związanymi z kolejnymi prążkami uzyskanego widma:

$$\Delta f = f_{k+1} - f_k = \frac{f_p}{N}(k+1) - \frac{f_p}{N}k = \frac{f_p}{N} \quad (4.14)$$

Rozdzielczość widma badanego sygnału w dziedzinie częstotliwości zależy bezpośrednio od czasu rejestracji, według następującej zależności:

$$\Delta f = \frac{f_p}{N} = \frac{1}{t_p} \quad (4.15)$$

Aby zapewnić dobrą rozdzielczość widma częstotliwościowego mierzonego sygnału, należy ustawić odpowiednio długi czas rejestracji. Przykładowo, chcąc uzyskać rozdzielczość częstotliwości na poziomie 0,1 Hz, należy przeprowadzić rejestrację sygnału w czasie nie krótszym niż 10 s. Długi czas rejestracji przy odpowiednio wysokiej częstotliwości próbkowania narzuca konieczność rejestracji bardzo dużej liczby próbek, co wymusza konieczność stosowania systemów akwizycji danych z odpowiednio dużą pamięcią. W praktycznych układach diagnostycznych sytuacja taka występuje w przypadku, gdy niezbędna jest analiza częstotliwościowa sygnałów o stosunkowo wysokich częstotliwościach (1 kHz i więcej), z jednoczesnym zapewnieniem wysokiej rozdzielczości (na poziomie 0,1 Hz i mniej). Wówczas niezbędną liczbę próbek pomiarowych N można obliczyć na podstawie następującego równania:

$$N = 2 \frac{f_{\max}}{\Delta f} \quad (4.16)$$

gdzie:

- f_{\max} – zakres analizowanych częstotliwości,
- Δf – rozdzielczość w dziedzinie częstotliwości.

Korzystając z zależności (4.16) można łatwo obliczyć wielkość potrzebnej pamięci do zarejestrowania sygnału pomiarowego. Przykładowo, gdy $f_{\max} = 1$ kHz, $\Delta f = 0,1$ Hz, z zastosowaniem przetwornika A/C o rozdzielczości 16 bitów (2 bajty na próbkę) ilość niezbędnej pamięci potrzebnej do zarejestrowania tego sygnału wynosi:

$$X [B] = 2 \frac{1000 \text{ Hz}}{0,1 \text{ Hz}} B = 20\,000 B$$

Z podanego przykładu wynika, że analiza częstotliwościowa sygnałów w zakresie wysokich częstotliwości, przy zapewnieniu jednocześnie dużej rozdzielczości wymaga stosowania systemów pomiarowych wyposażonych w dużą pamięć próbek pomiarowych. Ponadto, należy zdawać sobie sprawę z tego, że ze względu na dużą liczbę próbek pomiarowych analiza częstotliwościowa takich sygnałów pomiarowych wymaga przeprowadzenia bardzo wielu operacji arytmetycznych, co znacząco wpływa na czas obliczeń, uniemożliwiając wykonanie analizy częstotliwościowej w czasie rzeczywistym.

4.4. Nieparametryczne metody wyznaczania cech sygnałów diagnostycznych

4.4.1. Transformata Fouriera

W diagnostyce obiektów technicznych, a przede wszystkim maszyn wirujących, dominujące znaczenie mają nieparametryczne metody wyznaczania cech charakteryzujących uszkodzenia [4.3, 4.11, 4.18]. Szczególnie przydatna jest analiza widmowa bazująca na szybkim przekształceniu Fouriera (ang. *Fast Fourier Transform* – FFT). Wyniki transformaty Fouriera mogą być dostępne w kilku postaciach widma:

- amplitudowe (rzędną jest moduł transformaty Fouriera),
- fazowe (rzędną jest faza transformaty Fouriera),
- energetyczne (rzędną jest kwadrat modułu transformaty Fouriera),
- gęstość mocy (rzędną jest stosunek kwadratu modułu transformaty Fouriera do długości przedziału czasu realizacji sygnału).

W zależności od rodzaju obiektu i uszkodzenia wybierana jest jedna z możliwych postaci widma. Najczęściej w diagnostyce stosuje się widmo amplitudowe sygnału, którego wybrane amplitudy dla charakterystycznych częstotliwości są cechami uszkodzenia.

Transformacja Fouriera FT ma następującą postać:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi f t} dt \quad (4.17)$$

Informacja zawarta w widmie analizowanego sygnału $x(t)$ odnosi się do całego przedziału czasu (wynika to z granic całkowania w równaniu (4.6)). Oznacza to, że czas pojawienia się danej składowej częstotliwości nie wpływa na widmo analizowanego sygnału. Inaczej mówiąc, nie ma znaczenia czy dana składowa pojawi się w czasie t_1 czy w czasie t_2 ; w jednakowy sposób znajdzie ona odzwierciedlenie w widmie analizowanego sygnału. Przejście z układu *czas–wartość* do układu *częstotliwość–wartość* powoduje utratę informacji o czasie, tzn. nie można określić, kiedy dane zdarzenie częstotliwościowe nastąpiło. Oznacza to, że transformata Fouriera nie jest odpowiednim narzędziem analizowania sygnałów o zmiennej częstotliwości (sygnałach niestacjonarnych). Jeśli natomiast składniki występujące w analizowanym sygnale są stałe, to zastosowanie transformaty Fouriera jest jak najbardziej wskazane.

Ciągła transformacja Fouriera ma swój odpowiednik w postaci dyskretnej transformacji Fouriera DFT (ang. *Discrete Fourier Transform*) sygnału dyskretnego $X[k]$ o długości N , w jego dyskretne widmo o tej samej długości N :

$$X[k] = \sum_{k=0}^{N-1} x[k] \exp\left(-j \frac{2\pi k \Delta f}{N}\right) \Delta t, \quad 0 \leq k \leq N-1 \quad (4.18)$$

Równanie (4.18) przedstawia najczęściej spotykaną postać dyskretnego przekształcenia Fouriera. Sygnał wejściowy reprezentowany jest przez ciąg liczb. W wyniku transformacji powstaje dyskretne widmo częstotliwościowe, mające postać ciągu o tej samej długości i wartościach zespolonych. Praktyczne wyznaczenie widma $X[k]$ na podstawie zależności (4.18) jest dosyć skomplikowane obliczeniowo.

Ogólnie przekształcenie Fouriera transformuje próbkowany sygnał rzeczywisty w dziedzinie czasu $x[k]$ na dwa sygnały rzeczywiste w dziedzinie częstotliwości $\text{Re}\{X[k]\}$ i $\text{Im}\{X[k]\}$ według równań:

$$\text{Re}\{X[k]\} = \frac{2}{N} \sum_{k=0}^{N-1} x[k] \cos\left(\frac{2\pi kn}{N}\right) \quad (4.19a)$$

$$\text{Im}\{X[k]\} = -\frac{2}{N} \sum_{k=0}^{N-1} x[k] \sin\left(\frac{2\pi kn}{N}\right) \quad (4.19b)$$

gdzie $k = 0, 1, 2, \dots, N/2$.

W rzeczywistym przekształceniu Fouriera operuje się tylko częstotliwościami dodatnimi, zatem indeks k w dziedzinie częstotliwości zmienia się od 0 do $N/2$. W celu wyznaczenia amplitudy składowych harmonicznym sygnału rzeczywistego, należy przemnożyć uzyskane wyniki przekształcenia Fouriera przez czynnik normalizujący ($2/N$), znajdujący się na początku równania. Ponadto, należy pamiętać o jednym wyjątku – obliczając amplitudę składowej stałej (składowych $\text{Re}\{X[0]\}$ i $\text{Im}\{X[0]\}$) należy uzyskany wynik dodatkowo podzielić przez 2.

W praktyce, wyniki analizy częstotliwościowej sygnałów diagnostycznych najczęściej przedstawia się w formie widma częstotliwościowego sygnału, na którym znajdują się amplitudy poszczególnych składowych częstotliwościowych. W tym celu należy uzyskane wyniki przekształcenia DFT przeliczyć według następującej zależności:

$$|X[k]| = \sqrt{(\text{Re}\{X[k]\})^2 + (\text{Im}\{X[k]\})^2} \quad (4.20)$$


Wartości $|X[k]|$ można przedstawić w formie wykresu, na którym oś odciętych jest wyskalowana w jednostkach częstotliwości. W tym celu należy każdej próbce $|X[k]|$ przypisać wartość częstotliwości $f[k]$ obliczoną według następującego wzoru:

$$f[k] = k \frac{f_p}{N} \quad (4.21)$$

gdzie:

- f_p – częstotliwość próbkowania sygnału rzeczywistego,
- N – liczba wszystkich próbek sygnału rzeczywistego.

Podstawowym założeniem w dyskretnym przekształceniu Fouriera jest traktowanie sygnałów w dziedzinie czasu i częstotliwości jako sygnałów okresowych. Jest to założenie dosyć kłopotliwe, ponieważ rzeczywiste sygnały w większości przypadków nie są okresowe. Zaniedbanie tego założenia często może prowadzić do błędów i niewłaściwej interpretacji wyników uzyskanych podczas stosowania analizy częstotliwościowej sygnałów rzeczywistych. Wynikiem DFT jest rozkład analizowanego fragmentu sygnału na sinusoidalne składowe, o częstotliwościach wynikających z przyjętych parametrów analizy. Uzyskane wyniki reprezentują dokładnie widmo nieskończonego, okresowego sygnału, jeżeli sygnał został próbkowany w sposób koherentny (tj. synchronicznie z częstotliwością podstawową sygnału) oraz zgodnie z twierdzeniem o próbkowaniu, a długość analizowanego fragmentu sygnału jest całkowitą wielokrotnością okresu podstawowej harmonicznej. Niespełnienie dowolnego z wymienionych warunków skutkuje tzw. rozmyciem widma DFT.



Rys. 4.3. Przykłady widma sygnałów sinusoidalnych o częstotliwościach 10 Hz (a) oraz 10,5 Hz (b), próbkowanych z częstotliwością 200 Hz w czasie 1 s (skala częstotliwości zawężona do 20 Hz)

Przekształcenie Fouriera jest wrażliwe na sposób próbkowania analizowanego sygnału. W przypadku sygnałów okresowych, próbkowanych w sposób koherentny, uzyskane widmo częstotliwościowe jest prawidłowe (rys. 4.3a) zarówno pod względem kształtu (wąskie prążki spektralne odpowiadające poszczególnym harmonicznym sygnałom), jak i dokładności odwzorowania amplitudy. Natomiast sygnały, które nie spełniają założenia okresowości mają widmo rozmyte, które charakteryzuje się tzw. przeciekaniem widmowym (ang. *spectral leakage*) w postaci znacznego rozszerzenia prążka widmowego (rys. 4.3b) i niedokładnością wyznaczenia amplitudy. Zjawisko to mocno utrudnia, a czasem wręcz uniemożliwia prawidłową interpretację uzyskanych wyników przekształcenia DFT.

W celu poprawy właściwości analizy widmowej sygnałów nieokresowych stosuje się tzw. metodę okienkowania (ang. *windowing*), która polega na przemnożeniu prób-

kowanego sygnału pomiarowego przez funkcję okna w dziedzinie czasu, przed wykonaniem właściwej operacji przekształcenia Fouriera [4.17, 4.23].

Istnieje wiele rodzajów okien czasowych różniących się między sobą kształtem, z których każde ma charakterystyczne dla siebie właściwości. W większości przypadków okna czasowe mają tak dobrany kształt, aby funkcja miała maksimum w środku przedziału i symetrycznie opadała na obu końcach zakresu. Wymnożenie próbkowanego sygnału nieokresowego przez funkcję okna powoduje eliminację lub redukcję nieciągłości na obu krańcach przedziału czasu badanego sygnału. Prowadzi to bezpośrednio do zmniejszenia efektu rozmycia widmowego po wykonaniu transformacji DFT. W cyfrowym przetwarzaniu sygnałów najczęściej wykorzystuje się następujące funkcje okien:

- okno prostokątne (brak okna),
- okno Bartletta (trójkątne),
- okno Hanna,
- okno Hamminga,
- okno Blackmana,
- okno Kaisera–Bessela,
- okno eksponencjalne,
- okno z płaskim wierzchołkiem (*flat-top*).

Na podstawie analizy charakterystyki częstotliwościowej funkcji okna można wstępnie ocenić jego charakterystyczne parametry, które świadczą o jego przydatności do konkretnych zastosowań. W tabeli 4.1 zestawiono charakterystyczne parametry wybranych okien czasowych.

Tabela 4.1. Parametry wybranych okien czasowych

Rodzaj okna	Dynamika [dB]	Szerokość listka głównego (-3 dB)
Prostokątne	13,3	0,027
Bartletta	26,5	0,039
Hanna	31,5	0,043
Hamminga	42,5	0,039
Blackmana	58,1	0,050
Flat-top	67,9	0,117

Jednym z tych parametrów jest szerokość głównego listka, która ma związek z rozdzielczością okna w dziedzinie częstotliwości. Im szerszy jest główny listek, tym gorszą rozdzielczość ma okno, a zatem nie może być stosowane do analizy widmowej sygnałów zawierających składowe częstotliwościowe położone blisko siebie. Drugim, równie ważnym parametrem okna jest jego dynamika, a więc zdolność rozróżniania składowych spektralnych o bardzo małej amplitudzie. Dynamikę okna można określić na podstawie analizy jego charakterystyki częstotliwościowej – im większa jest różni-

ca amplitud listka głównego i pierwszego listka bocznego, tym lepszą dynamikę ma okno.

Tabela 4.2. Wybór okna czasowego w zależności od charakteru analizowanego sygnału

Rodzaj analizowanego sygnału	Okno czasowe
Sygnały sinusoidalne lub zawierające kilka składowych sinusoidalnych	Hanna
Sygnały sinusoidalne, w których dokładność wyznaczenia amplitudy jest istotna	Flat-Top
Sygnały wąsko-pasmowe, przypadkowe, sygnały wibroakustyczne	Hanna
Przypadkowe sygnały szerokopasmowe	Prostokątne
Blisko rozłożone składowe sinusoidalne	Prostokątne, Hanna
Sygnały odpowiedzi na impulsy udarowe	Eksponencjalne
Nieznana zawartość	Prostokątne, Hanna

Tabela 4.3. Zestawienie właściwości wybranych okien czasowych

Okno czasowe	Rozdzielczość częstotliwości	Redukcja przecieku widmowego	Dokładność pomiaru amplitudy
Bartletta	Dobra	Słaba	Średnia
Blackmana	Słaba	Najlepsza	Dobra
Flat-top	Słaba	Dobra	Najlepsza
Hanna	Dobra	Dobra	Średnia
Hamminga	Dobra	Średnia	Średnia
Kaiser-Bessela	Średnia	Dobra	Dobra
Prostokątne	Najlepsza	Słaba	Słaba
Tukeya	Dobra	Słaba	Słaba
Welcha	Dobra	Dobra	Średnia

Dobór odpowiedniego okna czasowego w analizie częstotliwościowej sygnałów diagnostycznych ma bardzo duże znaczenie. Typ okna czasowego musi być starannie dobrany na podstawie parametrów analizowanego sygnału w dziedzinie czasu. W zasadzie nie ma sztywnych reguł, jakimi należy się kierować przy wyborze typu okna, jednak znając charakter widma analizowanego sygnału, można dopasować do niego optymalne okno czasowe, które poprawi warunki analizy częstotliwościowej. Poniżej przedstawiono empiryczne reguły, które mogą być pomocne w wyborze kształtu okna czasowego:

- jeżeli w analizowanym sygnale znajdują się dwie lub więcej składowych spektralnych w bliskim sąsiedztwie, należy stosować wyłącznie takie okna czasowe, które mają najwęższy listek główny, zapewniając tym samym największą rozdzielczość w dziedzinie częstotliwości;
- jeżeli w widmie badanego sygnału występują składowe częstotliwościowe o bardzo małych amplitudach, które są istotne ze względu na analizę widmową, należy zastosować okno czasowe o dużej dynamice;

- jeżeli analiza częstotliwościowa badanego sygnału wymaga określenia amplitudy charakterystycznych składowych spektralnych z dużą dokładnością, należy stosować okna czasowe z szerokim listkiem głównym, uważając jednocześnie, aby nie pogorszyć zbyt mocno rozdzielczości widma; najdokładniejsze odzwierciedlenie amplitudy ma okno z płaskim wierzchołkiem (*flat-top*).

Przykładowe funkcje okien czasowych, odpowiednie dla wybranych typów sygnałów czasowych, zestawiono w tabeli 4.2. Z kolei w tabeli 4.3 przedstawiono właściwości wybranych okien czasowych. Ogólnie rzecz biorąc, użycie metody okna czasowego prowadzi do kompromisu między rozdzielczością widma (szerokością prążków) a przeciekiem widmowym (wielkością ogonów). W związku z tym, funkcja okna czasowego musi być odpowiednio dobrana, w zależności od charakteru sygnału czasowego i oczekiwanych właściwości widma częstotliwościowego.

Przy stosowaniu metody okien czasowych w analizie widmowej sygnałów należy pamiętać o odpowiednim przeskalowaniu sygnałów czasowych, aby amplituda składowych spektralnych widma miała prawidłową wartość. W tym celu, po wymnożeniu sygnału czasowego przez funkcję okna, należy dodatkowo podzielić każdą próbkę sygnału przez współczynnik korekcyjny okna, tzw. *scaling factor* (SF), zgodnie z równaniem:

$$w'(n) = \frac{w(n)}{SF} \quad (4.22)$$

Współczynnik korekcyjny każdego N -punktowego okna czasowego $w(n)$ można wyznaczyć z wartości średniej funkcji okna, korzystając z następującego wyrażenia:


$$SF = \sum_{n=1}^N \frac{w(n)}{N} \quad (4.23)$$

W tabeli 4.4 przedstawiono współczynniki korekcyjne wybranych okien czasowych. Należy jednak pamiętać, że operacja skalowania przebiegów czasowych przez współczynnik korekcyjny SF musi być przeprowadzona tylko w przypadku stosowania znormalizowanych okien czasowych, tzn. takich, których funkcja przyjmuje wartości z przedziału $(-1, \dots, 1)$. W literaturze można spotkać definicje okien czasowych, które już zawierają współczynnik skali.

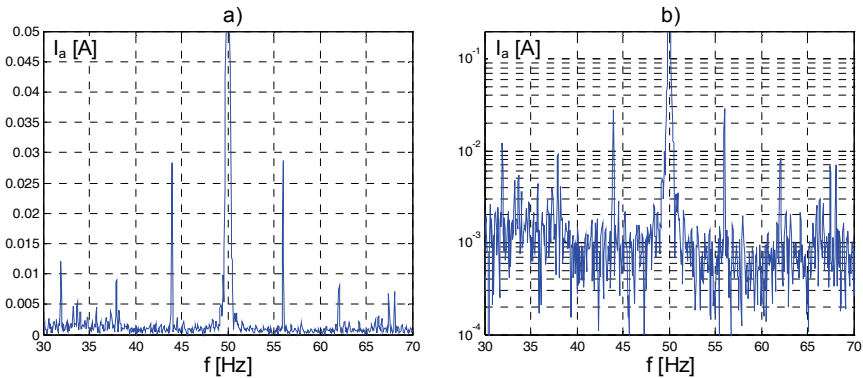
Tabela 4.4. Współczynniki korekcyjne wybranych okien czasowych

Rodzaj okna	Współczynnik korekcyjny (SF)
Prostokątne	1,0000
Bartletta	0,5000
Hanna	0,5000
Hamminga	0,5400
Blackmana	0,4200
Flat-top	0,2156

Na przykładzie analizy częstotliwościowej sygnałów prądu stojana przedstawiono zastosowanie okien czasowych do poprawy jakości analizy. Wybrano dwie funkcje – okno Hanna i okno flat-top.



Rys. 4.4. Widmo prądu stojana silnika z uszkodzonym wirnikiem w skali liniowej (a) i logarytmicznej (b), wyznaczone przy zastosowaniu okna prostokątnego

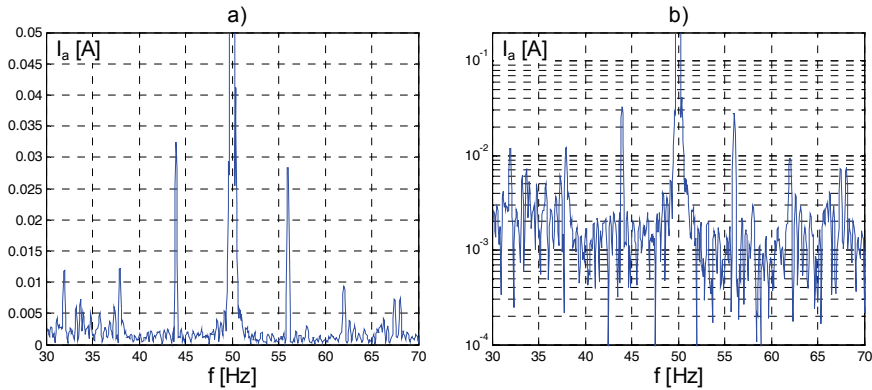


Rys. 4.5. Widmo prądu stojana silnika z uszkodzonym wirnikiem w skali liniowej (a) i logarytmicznej (b), wyznaczone przy zastosowaniu okna Hanna

Na rysunku 4.5 przedstawiono widma prądu stojana, wyznaczone na podstawie analizy fourierowskiej po uprzednim wymnożeniu sygnału diagnostycznego przez funkcję okna Hanna. W porównaniu z wynikami analizy spektralnej otrzymanymi przy zastosowaniu okna prostokątnego (rys. 4.4) uzyskano znaczną poprawę. Przeciek widmowy został wyraźnie zredukowany oraz uzyskano większą dynamikę. Charakterystyczne składowe częstotliwościowe związane z uszkodzonym wirnikiem stały się bardzo wyraźne, co umożliwiło poprawne odczytanie wartości ich amplitud.

W kolejnym etapie badań, sygnał prądu fazowego silnika z poprzednich przykładów został ponownie poddany analizie częstotliwościowej, tym razem przy zastoso-

waniu okna czasowego z płaskim wierzchołkiem (ang. *flat-top*), które z definicji odznacza się największą dokładnością odwzorowania amplitud. Wyniki tego przekształcenia przedstawiono na rysunku 4.6. Podobnie jak w przypadku analizy częstotliwościowej z oknem Hanna, uzyskano bardzo dużą czytelność widma – przeciek widmowy został niemal całkowicie wyeliminowany, zaś charakterystyczne składowe uszkodzeniowe stały się wyraźne.



Rys. 4.6. Widmo prądu stojana silnika z uszkodzonym wirnikiem w skali liniowej (a) i logarytmicznej (b), wyznaczone przy zastosowaniu okna *flat-top*

Pomimo że okno to posiada najgorszą rozdzielczość częstotliwościową, jednak przy odpowiednio dobranych parametrach rejestracji sygnałów diagnostycznych (długość czasu rejestracji) cecha ta ma mniejsze znaczenie. W związku z tym okno z płaskim wierzchołkiem jest szczególnie polecane do analizy częstotliwościowej prądu stojana, gdyż posiada najlepszą dokładność odwzorowanych amplitud składowych spektralnych.

Ze względu na stosunkowo słabą rozdzielczość widmową okna *flat-top*, należy zwrócić szczególną uwagę na parametry rejestracji sygnałów diagnostycznych. W celu uzyskania dobrej separacji składowych spektralnych czasu rejestracji sygnałów prądowych powinien być odpowiednio długi, aby zapewnić dobrą rozdzielczość w dziedzinie częstotliwości. Zwłaszcza dotyczy to diagnostyki silników dużej mocy, które z uwagi na małe wartości poślizgu wymuszają stosowanie analizy częstotliwościowej dużej rozdzielczości widmowej, na poziomie ułamka Hz.

Na podstawie przeprowadzonych badań można stwierdzić, że analiza częstotliwościowa prądu stojana silnika indukcyjnego wymaga stosowania odpowiednio dobranych okien czasowych, gdyż użycie standardowego okna prostokątnego prowadzi do powstania przecieku widmowego, który uniemożliwia prawidłowe odczytanie wartości amplitud składowych częstotliwościowych charakteryzujących dane uszkodzenie silnika.

4.4.2. Krótkoczasowa transformata Fouriera STFT

Jak już wspomniano, główną wadą transformaty Fouriera jest utrata informacji o czasie pojawienia się poszczególnych składowych częstotliwości. Z definicji dotyczy ona tylko sygnałów stacjonarnych o niezmiennych w czasie składowych. Sposobem umożliwiającym wprowadzenie dodatkowo czasu do transformaty Fouriera jest założenie, że sygnał niestacjonarny jest czasowo (w określonym czasie) stacjonarny. Takie podejście jest zmodyfikowaną wersją przekształcenia Fouriera i jest nazywane krótkoczasową transformatą Fouriera (ang. *Short Time Fourier Transform STFT*). Główna różnica między transformatą Fouriera a krótkoczasową transformatą Fouriera jest następująca: w STFT sygnał dzieli się na fragmenty, w których zakłada się, że jest on stacjonarny. Z tego powodu należy wybrać funkcję okna czasowego $w(t)$, którego długość jest równa długości fragmentu sygnału, w którym przyjmuje się, że jest on stacjonarny, przy czym $w(t) = 0$ dla $t < 0$ oraz $t > t_w$ [4.18, 4.23]. Krótkoczasowa transformata Fouriera jest określona następującą zależnością:

$$X(t, f) = \int_{-\infty}^{\infty} x(t)\omega(t - \tau)e^{-j2\pi f\tau} d\tau \quad (4.24)$$

gdzie τ jest czasem określonym względem środka okna $w(t)$ i zmienia się w granicach wyznaczonych przez zakres przetwarzania.

Jak wynika z porównania równań (4.17) i (4.24), krótkoczasowa transformata Fouriera różni się od klasycznej transformaty Fouriera jedynie pomnożeniem sygnału $x(t)$ przez funkcję okna $w(t)$. STFT przekształca analizowany sygnał $x(t)$ do dwuwymiarowej przestrzeni *czas–częstotliwość* (do trójwymiarowej jeśli uwzględni się amplitudę składowych). Rezultat tego przekształcenia w dużym stopniu zależy od parametrów wybranej funkcji okna – jego rodzaju i długości.

STFT umożliwia analizę sygnałów zmiennych w czasie. Przez wprowadzenie podziału sygnału $x(t)$ na okna czasowe umożliwia analizowanie składowych sygnału pojawiających się w kolejnych odcinkach czasu. W oryginalnej transformacie Fouriera (4.17) nie istnieje problem rozdzielczości częstotliwościowej; zapewnia ona jednoznaczną informację, które składowe istnieją, a które nie. Można to interpretować w następujący sposób: w FT (4.17) okno jest jądrem transformaty o czasie trwania od minus do plus nieskończoności. Ponieważ czas trwania okna jest nieskończony, rozdzielczość częstotliwościowa sygnału jest równa zero. W STFT okno czasowe ma skończoną długość, pokrywając jedynie fragment analizowanego sygnału. Sprawia to, że rozdzielczość częstotliwościowa sygnału jest większa od zera. Oznacza to, że w analizowanym widmie nie otrzymuje się poszczególnych składowych o dokładnie znanej częstotliwości, a jedynie uzyskuje się informację o zakresach częstotliwości (których długość wynika z rozdzielczości częstotliwościowej), w których składowe istnieją. Zależność między czasem trwania okna a rozdzielczością częstotliwościową

przybiera następującą formą w STFT: im węższe okno zostanie wykorzystane do analizy tym uzyskana jest lepsza rozdzielczość czasowa (dodatkowo można uzyskać lepsze założenie stacjonarności sygnału); jednak jednocześnie uzyskuje się gorszą rozdzielczość częstotliwościową. Oczywiście obowiązuje również odwrotna zależność; im czas trwania okna będzie dłuższy, tym gorsza będzie rozdzielczość czasowa analizowanego widma, a poprawi się rozdzielczość częstotliwościowa. Wydłużając czas trwania okna do nieskończoności uzyskuje się zerową rozdzielczość częstotliwościową, ale straci się informacje o czasie pojawienia się danej składowej; można wówczas traktować, że STFT staje się FT.

Konieczność wyboru okna o określonej długości czasowej determinuje rozdzielczość częstotliwościową; jest to wyraźna rozrzutność w sensie wykorzystania informacji zawartej w analizowanym przebiegu czasowym. Do identyfikacji parametrów harmonicznym wysokich rzędów nie potrzeba stosowania takiej długości okna czasowego jak do identyfikacji parametrów pierwszej harmonicznej.

Dyskretna postać krótkoczasowego przekształcenia Fouriera jest określona następującą zależnością:

$$X(n, m) = \sum_{k=0}^{M-1} x(k) w(k-m) e^{-jank} \quad (4.25)$$

gdzie:

- a – kąt między kolejnymi próbkami,
- M – liczba próbek w oknie $w(t)$.


Zmienna n odnosi się do częstotliwości (numer harmonicznej w odniesieniu do długości okna jako okresu składowej podstawowej), a indeks m wskazuje na czas (numer okna w sekwencji przetwarzania).

Krótkoczasową analizę Fouriera STFT można zrealizować wykorzystując rozwiązanie problemu lokalizacji zdarzenia występującego w sygnale diagnostycznym w funkcji czasu [4.15]. Umożliwia ona oprócz analizy częstotliwościowej sygnału lokalizację charakterystycznej składowej w czasie za pomocą tzw. okien czasowych. Najczęściej spotykanym sposobem prezentacji wyników analizy sygnałów za pomocą STFT jest przedstawienie ich na wykresach 2D oraz 3D. Wykresy 3D ułatwiają prezentację i analizę widm, w tym i lokalizację w czasie określonych zdarzeń. Na rysunku 4.7 przedstawiono analizę STFT prądu stojana silnika z 8 uszkodzonymi prętami dla dwóch wartości okna czasowego. Badania zostały wykonane przy założeniu, że rozdzielczość transformaty wynosi 0,05 Hz (20000 próbek, 20 s).


W przypadku okna czasowego 1 s uzyskuje się dokładniejszą informację w dziedzinie częstotliwości, co umożliwi bardziej precyzyjną ocenę stopnia uszkodzenia wirnika. Odbywa się to kosztem dokładności lokalizacji w czasie, która określona jest przez dobraną szerokość okna czasowego. Przyjęcie krótszego okna czasowego 0,5 s powoduje znaczne pogorszenie rozdzielczości w dziedzinie częstotliwości

(rozmycie widma), ale poprawie ulega dokładność lokalizacji w czasie symptomu uszkodzenia (z dokładnością do 0,5 s). Z analizy zamieszczonych na rys. 4.7 spektrogramów wynika, że poprawa lokalizacji zdarzenia w czasie odbywa się kosztem pogorszenia rozdzielczości w dziedzinie częstotliwości. W celu uzyskania zarówno dobrej lokalizacji symptomu uszkodzenia w dziedzinie czasu i częstotliwości, konieczne jest znaczne wydłużenie czasu rejestracji przebiegów. W STFT okno czasowe ma skończoną długość, pokrywając jedynie fragment analizowanego sygnału. Oznacza to, że w analizowanym widmie nie otrzymuje się poszczególnych składowych o dokładnie znanej częstotliwości, a jedynie uzyskuje się informację o zakresach częstotliwości (długość wynika z rozdzielczości częstotliwościowej), w których składowe istnieją. Wydłużając czas trwania okna do nieskończoności, uzyskuje się zerową rozdzielczość częstotliwościową, ale straci informację o czasie pojawienia się danej składowej. Można wówczas uważać, że STFT staje się FFT.

df = 0,4 Hz (2500 próbek, 2,5 s)



df = 0,05 Hz (20000 próbek, 20 s)



Rys. 4.7. Analiza STFT prądów stojana z wirnikiem o 8 uszkodzonych prętach, dla dwóch wartości okna czasowego (okno czasowe 0,5 s – po lewej, okno czasowe 1 s – po prawej)

4.4.3. Przekształcenie falkowe

Transformacja falkowa jest stosunkowo nowym i ciągle jeszcze odkrywaniem narzędziem do przetwarzania sygnałów. Coraz częściej jest używana do wykrywania uszkodzeń w silnikach indukcyjnych ze względu na niestacjonarność dostępnych sygnałów diagnostycznych [4.8, 4.9, 4.12–4.14, 4.21, 4.22]. Łączy ona w sobie zarówno cechy reprezentacji czasowej, jak i częstotliwościowej. Ciągła transformata falkowa (ang. *Continuous Wavelet Transform* – CWT) jest zdefiniowana za pomocą następującego równania [4.2, 4.5, 4.8]:

$$CWT x(a, b) = \int_{-\infty}^{\infty} x(t) \Psi_{a,b}^*(t) dt \quad (4.26)$$

gdzie:

- a – współczynnik skali,
- b – współczynnik przesunięcia,
- $*$ – oznacza sprzężenie funkcji zespolonej

oraz:

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right), \quad a, b \in R, \quad a \neq 0 \quad (4.27)$$

Ponadto musi być spełniony warunek:

$$C_{\Psi} = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (4.28)$$

Powyższa operacja, podobnie jak transformata Fouriera jest operacją o charakterze ciągłym, jednakże jądrem przekształcenia jest funkcja $\Psi(t)$, a nie $e^{-j 2\pi f t}$. Zapis $\Psi(\omega)$ w wyrażeniu (4.28) oznacza transformatę Fouriera funkcji $\Psi(t)$. Z warunku zdefiniowanego w (4.28) wynika, że $\Psi(0) = 0$, wobec tego średnia wartość funkcji $\Psi(t)$ musi wynosić zero:

$$\int_{-\infty}^{\infty} \Psi(t) dt = \Psi(0) = 0 \quad (4.29)$$

Funkcja $\Psi(t)$ jest nazywana falką – matką lub główną (ang. *mother wavelet*). Posiada ona zerową wartość średnią i nośnik zwarty. Oznacza to, że czas jej trwania jest skończony. Powszechnie stosowane falki są funkcjami rzeczywistymi, dla których zachodzi zależność $\Psi^*(t) = \Psi(t)$.

Współczynnik skali a występujący we wzorze (4.27) powoduje zmianę czasu trwania („rozciąganie” lub „ściskanie”) falki, natomiast współczynnik przesunięcia b zmienia położenie falki na osi czasu. Zgodnie z właściwością ciągłego przekształcenia Fouriera $\Psi(at) \leftrightarrow \frac{1}{|a|} \Psi\left(\frac{f}{a}\right)$ „rozciąganiu” i „ściskaniu” falki towarzyszy odwrotna zmiana jej widma, czyli odpowiednio jego „zawężanie” i „rozszerzanie”. Wyrażenie (4.26) można więc traktować jako pasmowo-przepustową filtrację sygnału $x(t)$ za pomocą kolejnych przeskalowanych falek, czyli za pomocą kolejnych filtrów o różnych pasmach przepuszczania. Wynikiem CWT są współczynniki $CWT_f(a, b)$, będące funkcją skali i pozycji.

Widmo falkowe $CWT_f(a, b)$ jest funkcją rzeczywistą dwóch zmiennych. Zmienna b określa czas, natomiast zmienna a jest proporcjonalna do odwrotności częstotliwości:

$$a \sim 1/f \quad (4.30)$$

Wykonanie analizy sygnału za pomocą STFT wymaga wprowadzenia stałego okna czasowego $w(t)$. Transformacja falkowa jest sama w sobie elastycznym oknem. Jej główną zaletą jest automatyczne dopasowanie długości falki do składowych częstotliwości sygnału. Niskie częstotliwości analizowane są przez dłuższe falki (rozciągnięte w czasie) niż częstotliwości wysokie, dla których falka jest krótkotrwała.

Szersza interpretacja przekształcenia falkowego jest następująca. Równanie (4.26) przedstawia korelacje analizowanej funkcji $x(t)$ z odpowiednimi falkami, czego rezultatem jest funkcja określająca stopień ich podobieństwa. Wynikiem transformacji (4.26) jest rozłożenie analizowanego sygnału na składowe falki, które po zastosowaniu transformacji odwrotnej złożą się na analizowany sygnał $x(t)$. Prowadzi to do reprezentacji sygnału w postaci rozwinięć falkowych. W zależności od rodzaju wybranych falek w (4.26), funkcje $CWT_f(a, b)$ reprezentują specyficzne cechy sygnału. Stanowi to podstawę jego dalszej analizy. Wykorzystuje się fakt, że przekształcenie (4.26) dla ustalonej wartości skali a jest filtrem środkowo-przepustowym, o częstotliwości środkowej związanej z ustalonym współczynnikiem skali a . Zakres zmian skali powinien pokrywać całe widmo analizowanego sygnału. Parametry funkcji $\Psi_{a,b}(t)$ są powiązane z właściwościami uzyskanych składowych w następujący sposób:

- duże wartości parametru a ($a \gg 1$) odpowiadają wolnozmiennym funkcjom bazowym; odpowiadające im składowe charakteryzują wolnozmiennne cechy sygnału;
- małe wartości parametru a ($0 < a < 1$) generują szybkozmiennne falki, posiadające wąskie okna, co daje możliwość wykrywania szybkich zmian w analizowanym sygnale (wąskie okno przetwarzania, duża częstotliwość funkcji bazowej);
- parametr b umożliwia dobrą lokalizację danego zdarzenia w czasie.

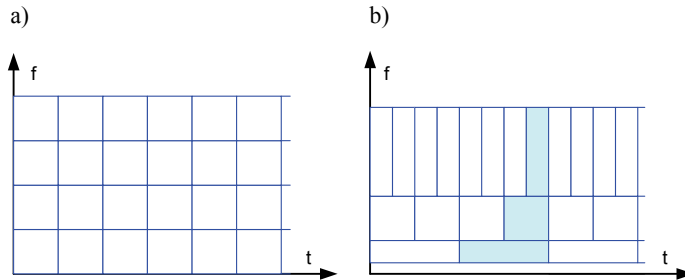
Transformata falkowa służy do lokalnej analizy częstotliwościowej sygnałów. Oznacza to, że każda falka ma wartości istotnie różniące się od zera w krótkim odcinku czasu, w celu zapewnienia wysokiej rozdzielczości analizy. Z drugiej strony oczekuje się, aby widmo pojedynczej falki było jak najwęższe. Jednak w odróżnieniu od STFT, w którym stosuje się okna jednakowej szerokości (funkcja bazowa wypełnia całe okno), w transformacie falkowej występują okna o zmiennej długości. Wąskie okno jest związane z falką o dużej częstotliwości. Wraz ze wzrostem współczynnika skali a rozszerzeniu ulega okno pomiarowe. Jest to zgodne z wymogiem zachowania stałości stosunku względnej rozdzielczości przekształcenia do częstotliwości sygnału:

$$\Delta\omega/\omega = c \quad (4.31)$$

gdzie: c – jest stałą, a $\Delta\omega$ określa rozdzielczość sygnału o pulsacji ω .

Na rysunku 4.8 przedstawiono przykłady konfiguracji najmniejszych możliwych do zidentyfikowania komponentów sygnału (często zwanych atomami) w STFT

i *CWT*. Komponent taki odpowiada prostokątowi w dwuwymiarowej dziedzinie czasowo-częstotliwościowej.



Rys. 4.8. Przykłady konfiguracji komponentów sygnału w dziedzinie czas-częstotliwość w STFT (a) i CWT (b)

W omawianym ciągłym przekształceniu falkowym zakłada się, że parametry przekształcenia: skala a oraz przesunięcie b są funkcjami ciągłymi. W przypadku, gdy skala a i przesunięcie b są funkcjami dyskretnymi, przekształcenie (4.26) wyznacza tzw. dyskretną transformatę falkową *DWT* (ang. *Discrete Wavelet Transform*). Dla wygody obliczeniowej przyjmuje się, że skala a ulega zmianie (jest próbkowana) z krotnością 2. Również krok przesunięcia będzie zmieniał się z krotnością 2. Tak więc uwzględniając, że $a = \frac{1}{2^j}, b = \frac{k}{2^j}$ $j, k \in Z$ (Z – zbiór liczb całkowitych), otrzymuje się inną formę zależności (4.16):

$$\Psi_{j,k}(t) = 2^{-j/2} \Psi(2^{-j}t - k) \tag{4.32}$$

Przekształcenie (4.26) w warunkach próbkowania skali a i przesunięcia b przyjmuje postać:

$$CWT x(a_j, b) = DWT x_{jk} = \int_{-\infty}^{\infty} x(t) \Psi_{jk}^*(t) dt \tag{4.33}$$

Przetwarzany sygnał można zrekonstruować bez strat informacji przez ważone sumowanie obliczonych współczynników $DWT x_{jk}$:

$$x(t) = \sum_j \sum_n DWT x_{jk} \Psi_{jk}(t) \tag{4.34}$$

Operacja ta nosi nazwę odwrotnej dyskretniej transformaty falkowej. W dyskretnych przekształceniach falkowych ((4.33) i (4.34)) analizowana funkcja i zastosowane falki są ciągłe względem czasu, czyli w praktyce próbkowanie analizowanego sygnału

będzie niezależne od dyskretyzacji skali i przesunięcia. W numerycznych obliczeniach praktyczna postać dyskretnej transformaty falkowej

$$DWT x_{jk} = \sum_{n=0}^{N-1} x(n) \Psi_{jk}^*(n) \quad (4.35)$$

gdzie:

$$\Psi_{j,k}(n) = 2^{-j/2} \Psi(2^{-j}n - k) \quad (4.36)$$

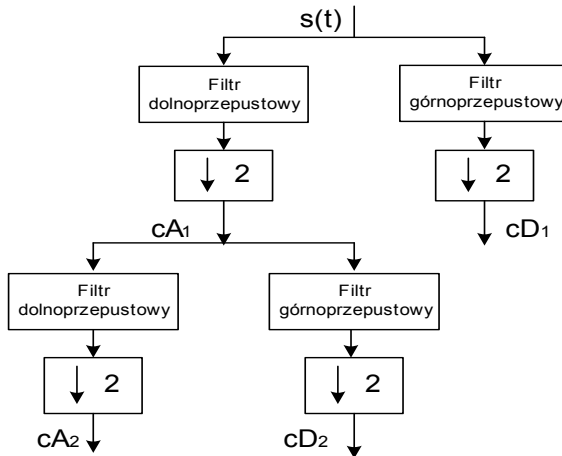
przy czym:

$nT = t_n$, T – okres próbkowania sygnału $x(t)$,

N – liczba próbek określona przez granice występowania falki $\Psi_{jk}(n)$.

Z dyskretną transformacją falkową łączy się pojęcie wielorozdzielczej analizy falkowej [4.2, 4.5, 4.22].

DWT umożliwia zbudowanie efektywnych algorytmów do numerycznego wyznaczenia współczynników transformacji przy wykorzystaniu faktu, że na każdym etapie analizy wielorozdzielczej sygnał może być rozdzielony na dwie składowe, których pasma częstotliwości zajmują połowę j -tego stopnia rozdzielczości. Składowe te uzyskuje się przez zastosowanie wielokrotnej filtracji sygnału, odpowiednio górno- i dolnoprzepustowego oraz operacji próbkowania sygnału przez wybieranie tylko próbek parzystych. Sygnał na wyjściu filtru dolnoprzepustowego jest aproksymowaną (wygładzoną) wersją sygnału wejściowego, natomiast sygnał na wyjściu filtru górnoprzepustowego zawiera detale (szczegóły) uzupełniające aproksymację. Ideę wielorozdzielczej analizy sygnału przedstawiono na rys. 4.9.




Rys. 4.9. Wielorozdzielcza analiza sygnału

W kroku początkowym sygnał czasowy $s(t)$ zostaje przez filtrowanie rozłożony na dwie składowe: cA_1 – zwaną *aproksymacją sygnału* i cD_1 – zwaną *detalem sygnału*. Aproksymacja sygnału reprezentuje składową stałą i części wolnozmienną sygnału, natomiast detal – składową wysokoczęstotliwościową. Symbol $\downarrow 2$ oznacza, że w przebiegu sygnału zostają zachowane tylko próbki o numerach parzystych. Aproksymacja sygnału cA_1 może zostać poddana analogicznej obróbce; zostać rozbita na dwie kolejne składowe: drugą aproksymację cA_2 i drugi detal cD_2 . Ważną właściwość przeprowadzonej obróbki sygnału opisuje zależność:

$$s(t) = cA_2 + cD_2 + cD_1 \tag{4.37}$$

Operacja rozbijania sygnału na kolejne aproksymacje i detale może być powtarzana wielokrotnie. W wielorozdzielczej analizie sygnału, rozbijaniu na kolejne składowe podlegają jedynie kolejne aproksymacje sygnału. Jej uogólnieniem jest całkowita dekompozycja sygnału (ang. *wavelet packet decomposition*). W kolejnych krokach filtruje się w niej nie tylko kolejne aproksymacje sygnału, lecz również jego detale. Na rysunku 4.10 przedstawiono przykładową dekompozycję sygnału do poziomu trzeciego (przy założeniu częstotliwości próbkowania sygnału 10 kHz).



Rys. 4.10. Przykład dekompozycji falkowej sygnału do poziomu trzeciego

Dzięki zastosowaniu dekompozycji sygnału możliwa jest analiza poszczególnych zakresów częstotliwości. Poszczególnym węzłom drzewa dekompozycji odpowiada ściśle określony zakres częstotliwości. Jednym z najczęściej spotykanych w diagnostyce wskaźników charakteryzujących poszczególne węzły jest wartość własna energii:

$$E = \sum_{k=1}^N |S_{j,k}|^2 \tag{4.38}$$

gdzie $S_{j,k}$ jest odpowiednim współczynnikiem DWT.

Wartości własne energii w poszczególnych węzłach mogą być wykorzystywane w dalszej analizie jako dane wejściowe (uczące i testujące) neuronowego detektora uszkodzeń.

4.4.4. Transformaty wyższych rzędów

Specjaliści od diagnostyki coraz chętniej sięgają po narzędzia programowe stosowane dotychczas jedynie do przetwarzania dźwięku i obrazu oraz analiz ekonomicznych. Oprócz wcześniej omówionych metod analizy czasowo-częstotliwościowej (krótko-czasowa STFT, welwetowa WT) coraz częściej sięga się do metod analizy częstotliwościowej wyższych rzędów HOS (ang. *High Order Spectra*). Metody te są już od lat 70. ubiegłego wieku szeroko wykorzystywane w różnych obszarach zastosowań cyfrowego przetwarzania sygnałów. W ostatnich latach HOS były wykorzystywane w różnego rodzaju aplikacjach, takich jak: radar, sonar, kodowanie, dekodowanie dźwięku i obrazu, odszumianie sygnałów, estymacja parametrów sygnałów, przetwarzanie obrazu i dźwięku. Stosunkowo niewiele jest prac dotyczących zastosowania analizy spektralnej wyższego rzędu do detekcji uszkodzeń mechanicznych i elektrycznych silnika indukcyjnego [4.4, 4.6, 4.7, 4.20, 4.21].

Do niedawna główną barierą stosowania tych metod była ich złożoność i zapotrzebowanie na dużą moc obliczeniową. Obecnie jednak dostępny jest sprzęt komputerowy umożliwiający zaimplementowanie metod HOS w systemach monitorowania i diagnostyki. Dostępne są również środowiska programowe, takie jak MATLAB i LabVIEW, realizujące złożone algorytmy transformat wyższych rzędów. Dlatego też możliwe jest coraz szersze ich zastosowanie do diagnostyki maszyn elektrycznych bez konieczności opracowywania indywidualnych procedur.

W trakcie wyznaczania widma, np. gęstości mocy, sygnał diagnostyczny jest przetwarzany w taki sposób, że wyznacza się rozkład mocy na poszczególne składowe analizowanego sygnału o różnych częstotliwościach. W takim procesie tracona jest informacja o przesunięciach fazowych pomiędzy składnikami analizowanego sygnału. Tak więc informacje zawarte w widmie mocy są wystarczające do opisu sygnału o rozkładzie normalnym. Jednakże w zastosowaniach praktycznych istnieje potrzeba wydobycia informacji o przesunięciach fazowych analizowanego sygnału lub oszacowaniu odchylenia rozkładu sygnału od rozkładu normalnego. Tego typu operacje umożliwiają statystyki wyższych rzędów.

Jeśli $X[n]$ jest sygnałem dyskretnym, to widma można ogólnie podzielić na:

- statystyki drugiego rzędu; wyznaczając autokorelację otrzymamy $c_2^x(\tau) \rightarrow F_1[*] \rightarrow C_2^x(\omega)$ – widmo mocy,
- statystyki trzeciego rzędu $c_3^x(\tau_1, \tau_2) \rightarrow F_2[*] \rightarrow C_3^x(\omega_1, \omega_2)$ – bispektrum,
- statystyki czwartego rzędu $c_4^x(\tau_1, \tau_2, \tau_3) \rightarrow F_3[*] \rightarrow C_4^x(\omega_1, \omega_2, \omega_3)$ – trispektrum,

- statystyki n -tego rzędu $c_n^x(\tau_1, \tau_2, \dots, \tau_{n-1}) \rightarrow F_n[*] \rightarrow C_n^x(\omega_1, \omega_2, \dots, \omega_{n-1})$ – widmo n -tego rzędu,

gdzie $F_n[*]$ – n -wymiarowa transformata Fouriera.

Statystyki wyższych rzędów zastosowane do sygnałów losowych wytwarzanych przez systemy o nieliniowej dynamice (sygnały nie posiadające rozkładu normalnego) poprawiają stosunek sygnału do szumu. Ponadto polispektra zawierają informacje o amplitudzie i fazie danego procesu, natomiast korelacja i widmo mocy zawiera informację jedynie o amplitudzie.

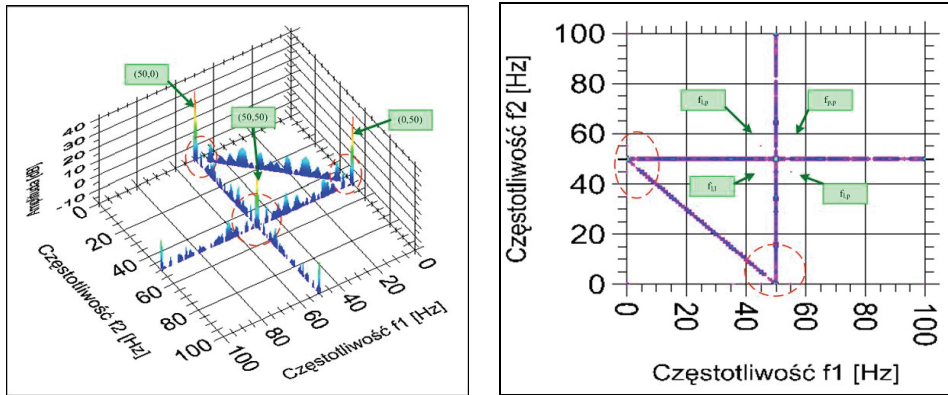
Analizy 2 rzędu (spectrum mocy i autokorelacja funkcji) nie dają informacji o fazie. Sygnał o rozkładzie gaussowskim jest w pełni scharakteryzowany przez wartość średnią oraz wariancję. Transformaty wyższych rzędów z sygnałów gaussowskich są zerowe (moment 3-go rzędu sygnału gaussowskiego jest zerowy). Wiele spotykanych w praktyce sygnałów posiada niezerowe HOS i wiele szumów pomiarowych jest pochodzenia gaussowskiego. Dlatego HOS są mniej czułe na szумы pochodzenia gaussowskiego niż analizy 2-go rzędu.

W pracach [4.6, 4.20] przedstawiono wykorzystanie transformat wyższych rzędów do detekcji uszkodzeń silników indukcyjnych. Autorzy wykorzystują sygnał drganiowy oraz prąd stojana jako źródło symptomów uszkodzeń. Badania T. Chow wykazały możliwość zastosowania spektralnej analizy trzeciego rzędu do diagnozowania łożysk na podstawie analizy drgań. Zastosowanie transformat wyższych rzędów jest w tym przypadku uzasadnione ze względu na nieliniowy (losowy) charakter sygnału diagnostycznego.

Transformaty wyższych rzędów (TWR), a w szczególności bispektra, są stosunkowo od niedawna stosowane w diagnostyce silników indukcyjnych i brak jest informacji o większych osiągnięciach w tym temacie. Z jednej strony Autorzy opisują widma trzeciego rzędu jako nowatorskie, a zarazem skuteczne narzędzie w dziedzinie diagnostyki, z drugiej strony prezentowane wyniki nie wykazują, że zastosowanie złożonych obliczeniowo transformat zdecydowanie zwiększyło skuteczność wykrywania uszkodzeń w maszynach elektrycznych.

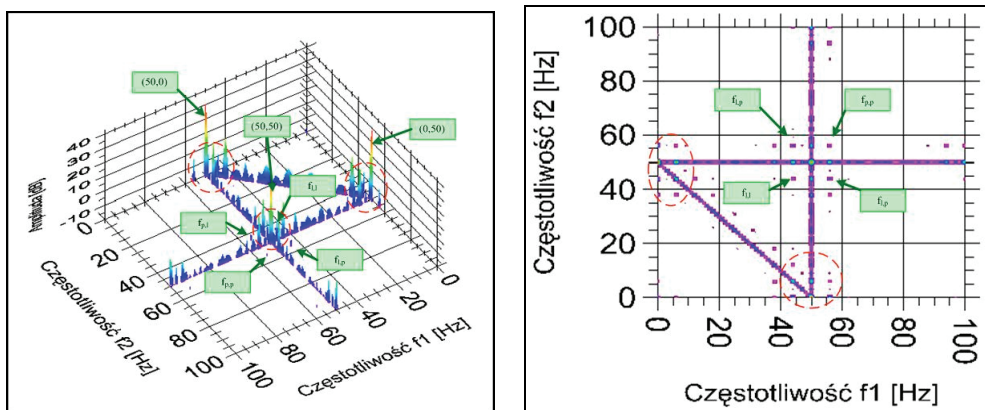
Poniżej przykładowo zostały przedstawione wyniki zastosowania bispektrum do analizy prądu stojana silnika z uszkodzonym wirnikiem oraz analizy drgań mechanicznych silnika z uszkodzonymi łożyskami tocznymi. Do obliczeń bispektrów i zobrazowania wyników zastosowano środowisko LabVIEW, w którym dostępne są algorytmy analiz trzeciego rzędu w postaci wirtualnych analizatorów bispektrum. Wszystkie sygnały poddane analizie spektralnej miały jednosekundowy czas rejestracji i były próbkowane częstotliwością 1 kHz (przyjęcie tej częstotliwości próbkowania wynikało z ograniczeń, jakie stawiają wirtualne przyrządy, dostępna moc obliczeniowa i czas obliczeń). We wszystkich przypadkach do obliczeń bispektrum zastosowano okno Hamminga z szerokością okna automatycznie dobieraną do liczby analizowanych próbek oraz z 50% nakładaniem się okien (*overlap*). Badania przeprowadzono na silniku małej mocy (SH90L-4), w którym instalowano wirniki oraz łożyska z różnym stopniem uszkodzenia, przy zasilaniu z falownika PWM.

Na rysunku przedstawiono bispektra prądu stojana dla silnika z wirnikiem bez uszkodzeń (rys. 4.11) i czterema uszkodzonymi prętami (rys. 4.12). Przedstawiono trójwymiarowe bispektra oraz rzut pionowy na płaszczyznę częstotliwości $f_1 - f_2$.



Rys. 4.11. Bispektrum prądu stojana dla wirnika bez uszkodzeń

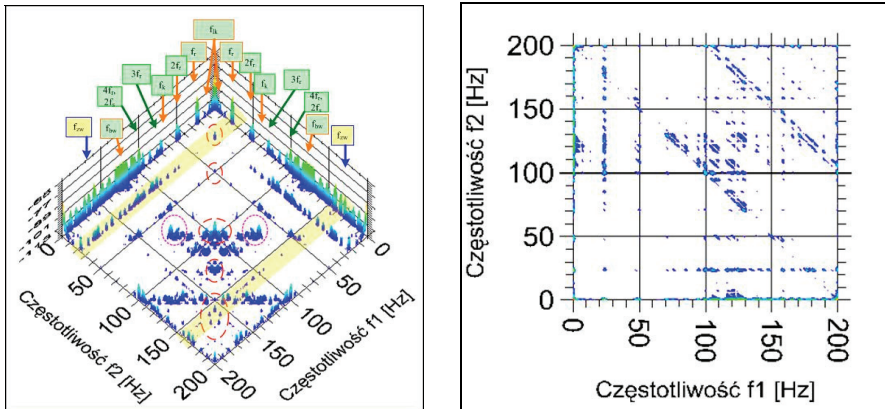
Na rysunkach strzałkami i kółkami zaznaczono regiony występowania charakterystycznych częstotliwości, które wiążą się ściśle z uszkodzeniem wirników. W rozpatrywanym przypadku symptomem uszkodzenia wirników w widmie prądu stojana jest wzrost amplitudy tak zwanych częstotliwości poślizgowych, z lewej i prawej strony częstotliwości sieciowej oraz jej 3 i 7 harmonicznej. Na rysunkach oznaczone zostały jako: f_l i f_p odpowiednio lewa i prawa, oraz f_{l-l} , f_{l-p} , f_{p-l} , f_{p-p} dla częstotliwości poślizgowych powstałych w wyniku zsumowania obu lewych, lewej i prawej, prawej i lewej oraz obu prawych składowych częstotliwości poślizgowych.



Rys. 4.12. Bispektrum prądu stojana dla wirnika z uszkodzonymi 4 prętami

Na bispektrum w postaci 3-D otrzymuje się pełne widmo trzeciego rzędu zależne od częstotliwości składowych sygnału. Na rysunkach ilustrujących trójwymiarowe bispektra kółkami zaznaczono regiony, w których należy szukać charakterystycznych częstotliwości poślizgowych związanych z uszkodzeniem prętów stojana. Wraz ze wzrostem uszkodzenia następuje wzrost amplitudy oraz wzrost liczby pików na zaznaczonych obszarach w okolicy częstotliwości sieciowej (50 Hz). Na rysunku 4.12 oznaczono również niewielkie prążki wynikające z sumowania częstotliwości poślizgowych (f_{p-p}). W celu zwiększenia (poprawienia) „widoczności” występowania i rozmieszczenia charakterystycznych częstotliwości związanych z uszkodzonymi prętami wirnika na rysunkach 4.11 i 4.12 przedstawiono również rzut płaszczyzny w osiach f_1 - f_2 , w których bardziej czytelne jest rozmieszczenie częstotliwości składowych oraz ich sum.

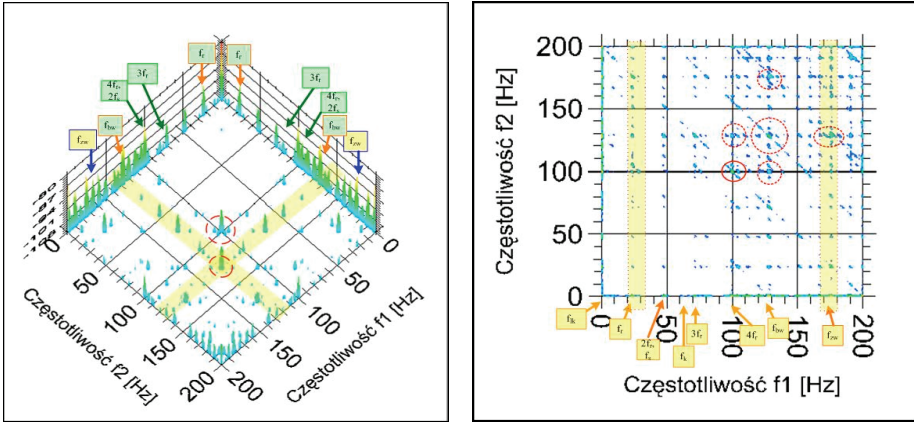
Przedstawione wyniki pokazują, iż możliwe jest wykorzystanie bispektrum w diagnozowaniu silników indukcyjnych, bazując na sygnale prądu stojana. Jednakże analiza spektralna trzeciego rzędu jest obciążona tymi samymi wadami co klasyczna analiza FFT, a mianowicie konieczność uzyskania dużej rozdzielczości częstotliwościowej wymaga długich czasów rejestracji sygnałów. W przypadku niskiej rozdzielczości prążki częstotliwości poślizgowych dla małych uszkodzeń robią się niewidoczne (zlewają się z częstotliwością sieciową).



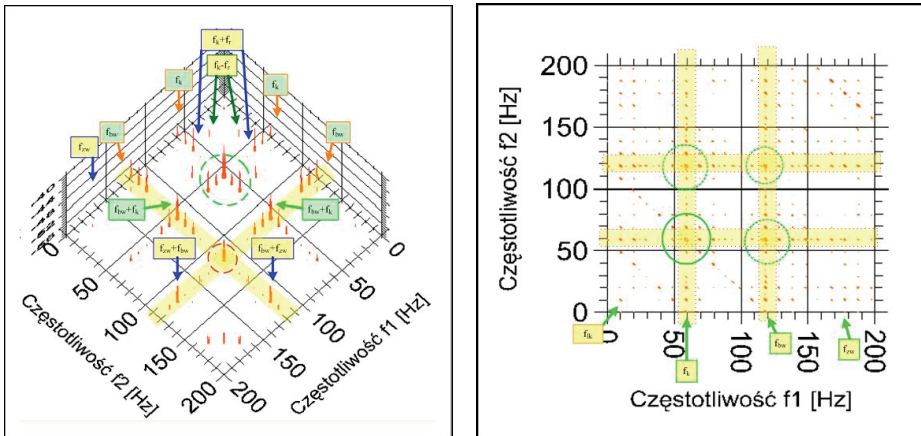
Rys. 4.13. Bispektrum drgań łożyska bez uszkodzeń, praca pod obciążeniem znamionowym

Najczęściej występującym uszkodzeniem silników jest uszkodzenie łożysk tocznych. W przeprowadzonych pomiarach zastosowano jednoosiowy akcelerometr DeltaTron firmy Bruel & Kjaer typ 4397. Czas zarejestrowanego i analizowanego sygnału wynosił 1 s i charakteryzował się takimi samymi parametrami jak w poprzednim przykładzie. Zarejestrowano przebiegi drgań dla łożyska: nieuszkodzonego, z uszkodzoną bieżnią zewnętrzną i uszkodzonymi kulkami. Wyniki przedstawiono i omówiono poniżej.

W widmach bispektrum występują charakterystyczne częstotliwości uszkodzeniowe (f_{bw} , f_{bz} , f_k), harmoniczne sieciowe oraz kolejne harmoniczne częstotliwości rotacyjnej f_r . Występują sumy lub różnice poszczególnych częstotliwości charakterystycznych, świadczące o nieliniowych sprzężeniach między nimi.



Rys. 4.14. Bispektrum drgań łożyska z uszkodzoną bieżnią wewnętrzną, praca pod obciążeniem znamionowym



Rys. 4.15. Bispektrum drgań łożyska z uszkodzonymi kulkami, praca bez obciążenia

Bispektrum umożliwia określenie zależności między istotnymi częstotliwościami badanego układu dynamicznego. Duża wartość bispektrum dla określonych par częstotliwości i kombinacjami ich sum lub różnic, wskazuje na istnienie sprzężenia częstotliwościowego między nimi. Może to oznaczać, że rozważane częstotliwości, będące składowymi sum mają wspólny generator, co w obecności nieliniowości wyższych

rzędów może prowadzić do syntetyzowania wspomnianych nowych składowych częstotliwościowych. Jednym z powodów występowania efektów nieliniowych jest kwadratowe sprzężenie fazy (ang. *Quadratic Phase Coupling* – QPC). QPC może być w ten sposób rozpatrywane jako wskaźnik zależności między dwoma składowymi harmonicznymi procesu nieliniowego. Własność ta może wykryć pewien związek fazowy między sumą lub różnicą dwóch częstotliwości. Jest to podstawowa różnica między analizą bispektralną a typowym podejściem do widma mocy, przy pomocy którego nie jest możliwe wykrycie istnienia QPC.

Jest powszechnie wiadomo, że informacja zawarta w fazie jest tłumiona (usuwana) przy stosowaniu widma mocy i metody opierające się na analizie widma mocy nie mogą wykryć zależności fazowych między różnymi składowymi częstotliwości. Zatem w przypadkach bardziej złożonych struktur mechanicznych konieczne jest poszukiwanie miar widmowych wyższych rzędów w celu wykrycia różnych postaci sprzężeń fazowych między składowymi częstotliwości.

4.5. Podsumowanie

Analiza sygnałów diagnostycznych jest podstawową czynnością w procesie monitorowania i diagnozowania obiektów. Od jej prawidłowej realizacji zależy trafność końcowej decyzji diagnostycznej. Duży wpływ na jakość analizy ma pierwszy etap, tzn. pomiar sygnałów, wstępne ich przetworzenia oraz przetworzenie analogowo-cyfrowe, a następnie wybór odpowiedniej metody analizy.

W niniejszym rozdziale zwrócono uwagę na podstawowe aspekty wstępnego przetwarzania sygnałów, prawidłowej konfiguracji systemu akwizycji sygnałów oraz nieparametryczne metody wyznaczania cech sygnałów diagnostycznych.

W badaniach diagnostycznych ciągle dominuje analiza widmowa oparta na klasycznym algorytmie FFT. Jednak coraz większą rolę zaczynają odgrywać analizy czasowo-częstotliwościowe (krótkoczasowa STFT, falkowa) oraz transformacje wyższych rzędów. W rozdziale przedstawiono podstawowe informacje o tych analizach.

Literatura

- [4.1] Arthur N., Penman J., *Induction machine condition monitoring with higher order spectra*, IEEE Transactions on Industrial Electronics, Vol. 47, No. 5, 2000, 1031–1041.
- [4.2] Augustyniak P., *Transformacje falkowe w zastosowaniach elektrodiagnostycznych*, AGH, Kraków 2003.
- [4.3] Bellini A., Filippetti F., Tassoni C., Capolino G.A., *Advances in Diagnostic Techniques for Induction Machines*, IEEE Transactions on Industrial Electronics, Vol. 55, No. 12, 2008, 4109–4125.

- [4.4] Benbouzid M., Beguenane R., Vieira M., *Induction Motor Asymmetrical Faults Detection Using Advanced Signal Processing Techniques*, IEEE Trans. on Energy Conversion, Vol. 14, No. 2, June 1999, 147–152.
- [4.5] Białasiewicz J.T., *Falki i aproksymacje*, WNT, Warszawa 2000.
- [4.6] Chow T.W.S., *Condition Monitoring of Electric Machines Using Third-Order Spectrum Analysis*, Conference Record of the IEEE Industry Applications Society, vol. 1, 1996, 679–686.
- [4.7] Chow T.W.S., Tan H., *HOS – based nonparametric and Parametric Methodologies for Machine Fault Detection*, IEEE Trans. on Ind. Electronics, Vol. 47, No. 5, 2000, 1051–1059.
- [4.8] Chow T.W.S., Shi H., *Induction machine fault diagnostic analysis with wavelet technique*, IEEE Transactions on Industrial Electronics, June 2004, 558–565.
- [4.9] Cusido J., Romeral L., Ortega J.A., Rosero J.A., Garcia Espinosa A., *Fault Detection in Induction Machines Using Power Spectral Density in Wavelet Decomposition*, IEEE Transactions on Industrial Electronics, Vol. 55, 2008, 633–643.
- [4.10] Garcia-Perez A., Romero-Troncoso R., Cabal-Yepez E., Osornio-Rios A., *The application of high-resolution spectra analysis for identifying multiple combined faults in induction motors*, IEEE Trans. Ind. Electron., Vol. 58, No. 5, 2002–2010, May 2011.
- [4.11] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., (red.), *Diagnostyka Procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002.
- [4.12] Kowalski C.T., *Zastosowanie analizy falkowej do budowy neuronowych detektorów uszkodzeń silnika indukcyjnego*, Proc. of 41th Intern. Symp. on Electrical Machines SME'2003, Opole 2003.
- [4.13] Kowalski C.T., Szabat K., *Zastosowanie analizy falkowej do wykrywania uszkodzeń w układach napędowych z silnikami indukcyjnymi*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME, KOMEL, nr 69, 2004.
- [4.14] Kowalski C.T., *Zastosowanie analizy falkowej w diagnostyce silników indukcyjnych*, Przegląd Elektrotechniczny, vol. 82, nr 1, 2006, 21–26.
- [4.15] Kowalski C.T., Kanior W., *Effectiveness of the frequency analysis of the stator current in the rotor fault detection on induction motors*, IEEE Int. Conf. on Industrial Technology (ICIT 2008) Chengdu, China, 2008.
- [4.16] Mendel J.M., *Tutorial on Higher Order Statistics (Spectra) in Signal Processing and System Theory: Theoretical Results and Some Applications*, Proceedings of the IEEE, Vol 79, No. 3, March 1991.
- [4.17] Pawlak M., *Zastosowanie funkcji okien czasowych w diagnostyce wirników silników indukcyjnych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, nr 28, 2008, 520–527.
- [4.18] Rosołowski E., *Cyfrowe przetwarzanie sygnałów w automatyce elektroenergetycznej*, Akademia Oficyna wydawnicza EXIT, Warszawa 2002.
- [4.19] Sun Q., Tang Y., *Singularity Analysis Using Continuous Wavelet Transform for Bearing Fault Diagnosis*, Mechanical Systems and Signal Processing, 16(6), 2002, 1025–1041.
- [4.20] Yang D.-M., Stronach A.F., MacConnell P., *Third-order spectral techniques for the diagnosis of motor bearing condition using artificial neural networks*, Mechanical Systems and Signal Processing, 16(2–3), 2002, 391–411.
- [4.21] Yang B.-S., Han T., Yin Z.-J., *Fault diagnosis system of induction motors using feature extraction, feature selection and classification algorithm*, JSME International Journal, Series C, Vol. 49, No. 3, 2006, 734–741.
- [4.22] Ye Z., Wu B., Sadeghian A., *Current signature analysis of induction motor mechanical faults by wavelet packet decomposition*, IEEE Transactions on Industrial Electronics, Vol. 50, No. 6, December 2003, 1217–1228.
- [4.23] Zieliński T.P., *Cyfrowe przetwarzanie sygnałów: Od teorii do zastosowania*, WKŁ, Warszawa 2007.

5. Modele matematyczne silnika indukcyjnego z uszkodzeniem

5.1. Podstawowy model obwodowy silnika indukcyjnego

Modelowanie matematyczne i symulacja komputerowa są obecnie skutecznymi narzędziami do testowania nowych metod i algorytmów do detekcji i oceny uszkodzenia w napędzie z silnikiem indukcyjnym, zanim zostaną one zweryfikowane na obiektach rzeczywistych. Dalej przedstawiono modele matematyczne silnika indukcyjnego umożliwiające symulowanie pracy w czasie uszkodzenia uzwojeń wirnika i stojana. Modele te były podstawą do syntezy algorytmów do estymacji zmiennych stanu i parametrów oraz służyły do wstępnego sprawdzania metod wykrywania uszkodzenia.

W modelowaniu maszyn z uszkodzeniami stosuje się obecnie trzy podejścia: zastosowanie modeli obwodowych, polowo-obwodowych i polowych. W modelowaniu polowo-obwodowym część modelu zrealizowana jest obwodowo, zazwyczaj zbudowana jest z elementów dokładnie odwzorowujących parametry silnika, natomiast pozostała część modelu (np. wirnik, szczelina powietrzna) zbudowana jest z wykorzystaniem metody elementów skończonych. Modele takie charakteryzuje bardzo dobra zbieżność z obiektami modelowanymi, jednak ich złożoność obliczeniowa oraz konieczność znajomości dokładnych parametrów konstrukcyjnych silników (rodzaje wykorzystanych materiałów, rozmiary elementów itp.) powodują, że szuka się prostszych metod umożliwiających symulację silnika indukcyjnego z uszkodzeniami. Alternatywą jest modelowanie obwodowe, obejmujące model silnika, przekształtnika oraz układu sterowania napędem. Prostota i uniwersalność ujęcia obwodowego, opierającego się na opisie za pomocą równań schematu zastępczego o stałych parametrach, znacznie ułatwia proces projektowania oraz skraca czas obliczeń numerycznych, co jest bardzo ważne w testowaniu systemów diagnostycznych czy projektowaniu lub optymalizacji układów sterowania. Modelowanie obwodowe dodatkowo zapewnia wystarczającą dokładność w praktyce inżynierskiej.

Utworzenie modeli obwodowych maszyny indukcyjnej klatkowej, wymaga przyjęcia kilku założeń upraszczających:

- rozłożone przestrzennie uzwojenia stojana i wirnika zostają zastąpione uzwojeniem skupionym (koncentrycznym),
- zakłada się równomierność szczeliny powietrznej,
- pomija się wpływ anizotropii, nasycenia magnetycznego, zjawiska histerezy oraz prądów wirowych,
- pomija się wyższe harmoniczne przestrzennego rozkładu pola w szczelinie powietrznej, uwzględniając tylko harmoniczną podstawową,
- rezystancje i reaktancje uzwojeń uważa się za stałe.

W klasycznym podejściu obwodowym zakłada się, że rozpatrywany silnik trójfazowy jest symetryczny. W przypadku modelowania silnika uszkodzonego nie jest to prawdziwe, ponieważ wystąpienie uszkodzenia (np. zwarcie zwojowe, pęknięty pręt klatki wirnika itp.) powoduje niesymetrię maszyny, którą należy uwzględnić w klasycznym modelu obwodowym.

Klasyczny obwodowy model matematyczny silnika indukcyjnego, zapisany za pomocą wektorów przestrzennych w układzie współrzędnych wirujących z prędkością ω_k , przyjmuje następującą postać w jednostkach względnych równania napięciowego obwodu stojana [5.25, 5.29]:

$$\mathbf{u}_{sk} = r_s \mathbf{i}_{sk} + T_N \frac{d}{dt} \Psi_{sk} + j \omega_k \Psi_{sk} \quad (5.1)$$

- równanie napięciowe obwodu wirnika:

$$\mathbf{u}_{rk} = r_r \mathbf{i}_{rk} + T_N \frac{d}{dt} \Psi_{rk} + j(\omega_k - \omega_m) \Psi_{rk} \quad (5.2)$$

- równania strumieniowo-prądowe:

$$\Psi_{sk} = x_s \mathbf{i}_{sk} + x_m \mathbf{i}_{rk} \quad (5.3)$$

$$\Psi_{rk} = x_r \mathbf{i}_{rk} + x_m \mathbf{i}_{sk} \quad (5.4)$$

- równanie ruchu:

$$\frac{d\omega_m}{dt} = \frac{1}{T_M} [m_e - m_o] \quad (5.5)$$

- równanie momentu elektromagnetycznego:

$$m_e = \mathbf{Im} \{ \Psi_{sk}^* \mathbf{i}_{sk} \} \quad (5.6)$$

gdzie:

$$T_M = \frac{J\Omega_b}{p_b M_b} \quad (5.7)$$

$$T_N = \frac{1}{\Omega_b} = \frac{1}{2\pi f_{sN}} \quad (5.8)$$

$$x_s = x_{\sigma s} + x_m \quad (5.9)$$

$$x_r = x_{\sigma r} + x_m \quad (5.10)$$

W teorii maszyn i napędów elektrycznych rozpatruje się trzy typy układów współrzędnych, stanowiące szczególny przypadek omówionego układu wirującego z dowolną prędkością ω_k [5.24]:

- układ $d-q$, w którym $\omega_k = \omega_m$ – układ osi jest nieruchomy względem wirnika i obraca się względem stojana z prędkością wirnika – zazwyczaj stosowany w teorii sterowania silnikami synchronicznymi;
- układ $x-y$, w którym $\omega_k = \omega_0$ – układ osi wirujący względem stojana z prędkością synchroniczną, tzn. nieruchomy względem pola maszyny indukcyjnej – układ wykorzystywany w złożonych wektorowych strukturach sterowania silnikiem indukcyjnym;
- układ $\alpha-\beta$, w którym $\omega_k = 0$ – układ osi nieruchomy względem stojana maszyny – przewagą tego układu jest to, że prąd $i_{s\alpha}$ jest równy rzeczywistemu prądowi w fazie A stojana.

W badaniach symulacyjnych przekształtnikowych układów napędowych z silnikiem indukcyjnym za podstawowy przyjmuje się model matematyczny silnika indukcyjnego w układzie współrzędnych $\alpha-\beta$. Model silnika po rozłożeniu wektora napięcia, prądu i strumienia stojana oraz wirnika na składowe prostokątne $\alpha-\beta$, można zapisać w postaci skalarnej i przedstawić w postaci kanonicznej za pomocą układu równań (w jednostkach względnych [p.u.]) [5.24, 5.29]:

- równania różniczkowe obwodu stojana:

$$T_N \frac{d\Psi_{s\alpha}}{dt} = u_{s\alpha} - r_s i_{s\alpha} \quad (5.11)$$

$$T_N \frac{d\Psi_{s\beta}}{dt} = u_{s\beta} - r_s i_{s\beta} \quad (5.12)$$

- równania różniczkowe obwodu wirnika:

$$T_N \frac{d\Psi_{r\alpha}}{dt} = u_{r\alpha} - r_r i_{r\alpha} - \omega_m \Psi_{r\beta} \quad (5.13)$$

$$T_N \frac{d\Psi_{r\beta}}{dt} = u_{r\beta} - r_r i_{r\beta} + \omega_m \Psi_{r\alpha} \quad (5.14)$$

- równania strumieniowo-prądowe obwodu stojana:

$$i_{s\alpha} = \frac{x_r}{w} \Psi_{s\alpha} - \frac{x_m}{w} \Psi_{r\alpha} \quad (5.15)$$

$$i_{s\beta} = \frac{x_r}{w} \Psi_{s\beta} - \frac{x_m}{w} \Psi_{r\beta} \quad (5.16)$$

- równania strumieniowo-prądowe obwodu wirnika:

$$i_{r\alpha} = \frac{x_s}{w} \Psi_{r\alpha} - \frac{x_m}{w} \Psi_{s\alpha} \quad (5.17)$$

$$i_{r\beta} = \frac{x_s}{w} \Psi_{r\beta} - \frac{x_m}{w} \Psi_{s\beta} \quad (5.18)$$

gdzie:

$$w = x_s x_r - x_m^2 \quad (5.19)$$

- równanie momentu elektromagnetycznego:

$$m_e = \Psi_{s\alpha} i_{s\beta} - \Psi_{s\beta} i_{s\alpha} \quad (5.20)$$

- równanie ruchu pozostaje niezmiennione (5.5).

Do projektowania i syntezy większości estymatorów znanych z teorii sterowania silnikami indukcyjnymi wykorzystuje się model zapisany za pomocą równań stanu:

$$\dot{\mathbf{x}}(t) = \mathbf{A}(\omega_m) \mathbf{x}(t) + \mathbf{B} \mathbf{u}(t) \quad (5.21)$$

$$\mathbf{y}(t) = \mathbf{C} \mathbf{x}(t) \quad (5.22)$$

w których:

- wektor elektromagnetycznych zmiennych stanu:

$$\mathbf{x}(t) = [i_{s\alpha} \quad i_{s\beta} \quad \Psi_{r\alpha} \quad \Psi_{r\beta}]^T \quad (5.23)$$

- wektor wyjścia:

$$\mathbf{y}(t) = [i_{s\alpha} \quad i_{s\beta}]^T \quad (5.24)$$

- wektor wejścia (sterowania):

$$\mathbf{u}(t) = [u_{s\alpha} \quad u_{s\beta}]^T \quad (5.25)$$

oraz odpowiednio:

- macierz wyjścia:

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (5.26)$$

- macierz wejścia:

$$\mathbf{B} = \begin{bmatrix} \frac{\Omega_b}{\sigma x_s} & 0 & 0 & 0 \\ 0 & \frac{\Omega_b}{\sigma x_s} & 0 & 0 \end{bmatrix}^T \quad (5.27)$$

- macierz stanu:

$$\mathbf{A}(\omega_m) = \begin{bmatrix} -\frac{1}{x_s \sigma} r_s \Omega_b - \frac{1-\sigma}{x_r \sigma} r_r \Omega_b & 0 & \frac{k_r r_r \Omega_b}{x_r x_s \sigma} & \frac{\omega_m k_r \Omega_b}{x_s \sigma} \\ 0 & -\frac{1}{x_s \sigma} r_s \Omega_b - \frac{1-\sigma}{x_r \sigma} r_r \Omega_b & -\frac{\omega_m k_r \Omega_b}{x_s \sigma} & \frac{k_r r_r \Omega_b}{x_r x_s \sigma} \\ \frac{x_m}{x_r} r_r \Omega_b & 0 & -\frac{r_r \Omega_b}{x_r} & -\omega_m \Omega_b \\ 0 & \frac{x_m}{x_r} r_r \Omega_b & \omega_m \Omega_b & -\frac{r_r \Omega_b}{x_r} \end{bmatrix} \quad (5.28)$$

gdzie $k_r = \frac{x_m}{x_r}$.

Przedstawiony model matematyczny silnika indukcyjnego może być stosowany do projektowania różnego typu obserwatorów stanu, rozszerzonych obserwatorów stanu i parametrów oraz do projektowania i optymalizacji algorytmów sterowania.

W rozdziale 6 model został wykorzystany do syntezy algorytmu rozszerzonego filtru Kalmana do estymacji rezystancji uzwojenia wirnika oraz rozszerzonego obserwatora Luenbergera do estymacji rezystancji uzwojenia stojana lub wirnika.

Do estymacji rezystancji uzwojenia stojana za pomocą algorytmu rozszerzonego filtru Kalmana wykorzystano model silnika o wektorze elektromagnetycznych zmiennych stanu złożonym z prądów oraz strumieni stojana, w którym:

- wektor elektromagnetycznych zmiennych stanu:

$$\mathbf{x}_R(k) = [i_{s\alpha} \quad i_{s\beta} \quad \Psi_{s\alpha} \quad \Psi_{s\beta}]^T \quad (5.29)$$

Wektory: wejścia \mathbf{u} i wyjścia \mathbf{y} oraz macierze: wejścia \mathbf{B} i wyjścia \mathbf{C} przyjmują postać jak (5.24)–(5.27), natomiast macierz stanu \mathbf{A} ulega zmianie do postaci:

$$\mathbf{A}(\omega_m) = \begin{bmatrix} -\left(\frac{r_s}{x_s \sigma} + \frac{x_s r_r}{w}\right) \Omega_b & -\omega_m \Omega_b & \frac{r_r \Omega_b}{w} & \frac{x_r \omega_m \Omega_b}{w} \\ \omega_m \Omega_b & -\left(\frac{r_s}{x_s \sigma} + \frac{x_s r_r}{w}\right) \Omega_b & -\frac{x_r \omega_m \Omega_b}{w} & \frac{r_r \Omega_b}{w} \\ -r_s \Omega_b & 0 & 0 & 0 \\ 0 & -r_s \Omega_b & 0 & 0 \end{bmatrix} \quad (5.30)$$

gdzie: $w = x_s x_r - x_m^2$.

5.2. Model silnika indukcyjnego ze zwartymi zwojami w uzwojeniu stojana

5.2.1. Model uwzględniający dodatkową macierz asymetrii w równaniach stanu

W literaturze można spotkać wiele propozycji obwodowych modeli silnika indukcyjnego z uszkodzonym uzwojeniem stojana w postaci zwarcia zwojowego w jednej fazie silnika [5.4, 5.5, 5.7, 5.25–5.27]. Proponowane podejścia różnią się między sobą metodologią tworzenia modelu. Przedstawiono trzy najbardziej rozpowszechnione, opisane w literaturze przedmiotu, metody modelowania matematycznego zwarc zwojowych w silniku indukcyjnym. Podejścia różnią się zasadniczo metodologią tworzenia modelu i zostały szczegółowo przetestowane w pracach badawczych zespołu Autora [5.16–5.18, 5.30, 5.31].

Punktem wyjściowym do modelowania uszkodzenia uzwojenia stojana jest wprowadzenie do klasycznego modelu silnika indukcyjnego obwodu związanego bezpośrednio z modelowanym zwarcie zwojowym (rys. 5.1). Obwód ten można zapisać równaniem napięciowym:

$$r_{zw}i_{zw} = \eta_{zw}r_s(i_{sd} - i_{zw}) + T_N \frac{d\Psi_{zw}}{dt} \quad (5.31)$$


$$\eta_{zw} = \frac{N_{zw}}{N_s} = \frac{N_s - N_{nz}}{N_s} \quad (5.32)$$

gdzie:


- r_{zw} – rezystancja punktu zwarcia,
- i_s – prąd fazowy stojana,
- i_{zw} – prąd płynący w zwartym obwodzie,
- Ψ_{zw} – strumień magnetyczny obwodu zwarciaowego,
- n_{zw} – parametr będący stosunkiem liczby zwojów zwartych silnika do całkowitej liczby zwojów w danej fazie nieuszkodzonego uzwojenia stojana,
- N_{zw} – liczba zwartych zwojów w danej fazie uzwojenia silnika,
- N_{nz} – liczba nieuszkodzonych zwojów w danej fazie uzwojenia silnika,
- N_s – liczba zwojów w danej fazie nieuszkodzonego uzwojenia silnika ($N_s = N_{zw} + N_{nz}$).

Model ten, zaproponowany w [5.4, 5.5], opiera się na założeniu, że w przypadku silników indukcyjnych małej i średniej mocy spadki napięć na rezystancji i indukcyjności stojana są małe w porównaniu do napięcia zasilającego silnik. Dzięki czemu możliwe jest umieszczenie pętli zwarciaowej Q_{zw} na wejściu schematu zastępczego

silnika (rys. 5.2). Umożliwia to wprowadzenie pewnej modyfikacji klasycznego modelu matematycznego silnika indukcyjnego i w prosty sposób modelowanie zwarcia zwojowego. Prądy płynące w układzie zasilającym $i_{s\alpha\beta}$ są sumą prądów płynących w zwartej części uzwojenia (i_{zw}) oraz w pozostałej nieuszkodzonej części uzwojenia stojana ($i'_{s\alpha\beta}$). Model ten został opisany oraz dokładnie zweryfikowany w [5.16, 5.18, 5.30, 5.31].



Rys. 5.1. Trójfazowe uzwojenie stojana silnika indukcyjnego ze zwarcem zwojowym modelowanym w fazie A



Rys. 5.2. Schemat zastępczy silnika indukcyjnego z uszkodzonym uzwojeniem stojana

Po uwzględnieniu powszechnie stosowanych założeń upraszczających, model matematyczny maszyny indukcyjnej w jednostkach względnych, uwzględniający zwarcie w fazie A stojana (rys. 5.1) można zapisać w postaci równań stanu, w układzie współrzędnych $(\alpha-\beta)$. Ogólnie równania zmiennych stanu dla modelu silnika indukcyjnego klatkowego ze zwarcem zwojowym w uzwojeniu stojana mają postać:

$$\dot{\mathbf{x}}(t) = \mathbf{A}(\omega_m)\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) \tag{5.33}$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{u}(t) \tag{5.34}$$

w których elementy macierzy: $\mathbf{x}(t)$, $\mathbf{y}(t)$, $\mathbf{u}(t)$, \mathbf{C} , \mathbf{B} , $\mathbf{A}(\omega_m)$ są tak określone, jak dla modelu silnika bez uszkodzenia (5.23)–(5.28). Natomiast prąd płynący w obwodzie

zwarciovym uzwojenia stojana zdefiniowany jest jako iloczyn macierzy symulującej uszkodzenie \mathbf{D} i wektora napięcia stojana:

$$i_{zw} = \mathbf{D}\mathbf{u}(t) \quad (5.35)$$

przy czym:

$$\mathbf{D}(n_{zw}, \theta_{zw}) = \left[\frac{1}{3} \frac{n_{zw}}{r_s} \sum_{k=1}^3 \mathbf{P}(-\theta) \mathbf{Q}(\theta_{zw}) \mathbf{P}(\theta) \right] \quad (5.36)$$

$$\mathbf{Q}(\theta_{zw}) = \begin{bmatrix} \cos^2(\theta_{zw}) & \cos(\theta_{zw}) \sin(\theta_{zw}) \\ \cos(\theta_{zw}) \sin(\theta_{zw}) & \sin^2(\theta_{zw}) \end{bmatrix} \quad (5.37)$$

$$\mathbf{P}(\theta) = \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \quad (5.38)$$

gdzie:

$$\omega_m = \frac{d\theta}{dt},$$

k – liczba uszkodzonych faz silnika,

θ_{zw} – parametr określający lokalizację uszkodzenia:

$\theta_{zw} = 0$ – zwarcie w fazie A ,

$\theta_{zw} = \frac{2\pi}{3}$ – zwarcie w fazie B ,

$\theta_{zw} = \frac{4\pi}{3}$ – zwarcie w fazie C .

Przykładowo dla zwarcia w fazie A (uszkodzona tylko jedna faza, więc $k = 1$):

$$\mathbf{Q}(\theta_{zw}) = \begin{bmatrix} \cos^2(\theta_{zw}) & \cos(\theta_{zw}) \sin(\theta_{zw}) \\ \cos(\theta_{zw}) \sin(\theta_{zw}) & \sin^2(\theta_{zw}) \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$$

$$\mathbf{D}(n_{zw}, \theta_{zw}) = \left[\frac{1}{3} \frac{n_{zw}}{r_s} \mathbf{P}(-\theta) \mathbf{Q}(\theta_{zw}) \mathbf{P}(\theta) \right]$$

$$\mathbf{D}(n_{zw}, \theta_{zw}) = \left[\frac{1}{3} \frac{n_{zw}}{r_s} \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \right]$$

$$\mathbf{D}(n_{zw}, \theta_{zw}) = \left[\frac{1}{3} \frac{n_{zw}}{r_s} \begin{bmatrix} \cos(\theta) & 0 \\ \sin(\theta) & 0 \end{bmatrix} \begin{bmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{bmatrix} \right]$$

$$\mathbf{D}(n_{zw}, \theta_{zw}) = \left[\frac{1}{3} \frac{n_{zw}}{r_s} \sum_{k=1}^3 \begin{bmatrix} \cos^2(\theta) & -\sin(\theta)\cos(\theta) \\ \sin(\theta)\cos(\theta) & -\sin(\theta) \end{bmatrix} \right]$$

Przedstawiony model matematyczny umożliwia prosty sposób modelowania asymetrii uzwojenia stojana osobno w każdej z faz silnika.

5.2.2. Model uwzględniający wektorowy współczynnik uszkodzenia

Innym rozwiązaniem obwodowego modelu silnika indukcyjnego z uszkodzonym uzwojeniem stojana, w postaci zwarcia zwojowego w dowolnej fazie, jest zastosowanie odpowiedniej modyfikacji parametrów schematu zastępczego w zależności od wielkości uszkodzenia [5.10, 5.31]. W tym celu został zdefiniowany wektorowy współczynnik uszkodzenia, określający procentowy udział zwartych zwojów oraz kierunek odpowiadający uszkodzonej fazie silnika:

$$\mu_{\alpha\beta} = [\mu_{\alpha} \quad \mu_{\beta}]^T \eta_{zw} \quad (5.39)$$

W przypadku zwarcia modelowanego kolejno w fazie A , B , C silnika można zapisać:

$$\mu_{\alpha\beta}|_A = [1 \quad 0]^T \eta_{zwA} \quad (5.40)$$

$$\mu_{\alpha\beta}|_B = \begin{bmatrix} -\frac{1}{2} & \frac{\sqrt{3}}{2} \end{bmatrix}^T \eta_{zwB} \quad (5.41)$$

$$\mu_{\alpha\beta}|_C = \begin{bmatrix} -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix}^T \eta_{zwC} \quad (5.42)$$

gdzie:

η_{zwA} , η_{zwB} , η_{zwC} – procentowy udział zwartych zwojów w fazie A , B , C silnika, odpowiednio (5.32).

Model matematyczny silnika indukcyjnego z uszkodzonym uzwojeniem stojana, uwzględniający możliwość modelowania zwarcia zwojowego osobno w każdej z faz silnika, przedstawia się następująco:

- równania różniczkowe obwodu stojana:

$$T_N \frac{d\Psi_{s\alpha}}{dt} = u_{s\alpha} - r_s i_{s\alpha} + \frac{2}{3} \mu_{\alpha} \eta_{zw} r_s i_{zw} \quad (5.43)$$

$$T_N \frac{d\Psi_{s\beta}}{dt} = u_{s\beta} - r_s i_{s\beta} + \frac{2}{3} \mu_\beta \eta_{zw} r_s i_{zw} \quad (5.44)$$

- równania różniczkowe (5.13), (5.14) obwodu wirnika pozostają niezmiennione,
- równanie różniczkowe obwodu zwarciovego:

$$T_N \frac{d\Psi_{zw}}{dt} = -r_s \eta_{zw} (\mu_\alpha i_{s\alpha} + \mu_\beta i_{s\beta}) + (|\mu_{\alpha\beta}| r_s + r_{zw}) i_{zw} \quad (5.45)$$

- równania strumieniowo-prądowe obwodu stojana:

$$i_{s\alpha} = \frac{x_r}{w} \Psi_{s\alpha} - \frac{x_m}{w} \Psi_{r\alpha} + \frac{2}{3} \mu_\alpha \eta_{zw} i_{zw} \quad (5.46)$$

$$i_{s\beta} = \frac{x_r}{w} \Psi_{s\beta} - \frac{x_m}{w} \Psi_{r\beta} + \frac{2}{3} \mu_\beta \eta_{zw} i_{zw} \quad (5.47)$$

- równania strumieniowo-prądowe obwodu wirnika (5.17), (5.18) pozostają niezmiennione,
- równanie strumieniowo-prądowe obwodu zwarciovego:

$$i_{zw} = \frac{\Psi_{zw} - \eta_{zw} (\mu_\alpha \Psi_{s\alpha} + \mu_\beta \Psi_{s\beta})}{\left(\frac{2}{3} |\mu_{\alpha\beta}|^2 - |\mu_{\alpha\beta}| \right) x_{\sigma s}} \quad (5.48)$$

- równanie momentu elektromagnetycznego:

$$m_e = \Psi_{s\alpha} \left(i_{s\beta} - \frac{2}{3} \mu_\beta \eta_{zw} i_{zw} \right) - \Psi_{s\alpha} \left(i_{s\alpha} - \frac{2}{3} \mu_\alpha \eta_{zw} i_{zw} \right) \quad (5.49)$$

- równanie ruchu (5.5) pozostaje niezmiennione.

Model ten umożliwia w bardzo prosty sposób modelowanie asymetrii uzwojenia stojana osobno w każdej z faz silnika [5.16].

5.2.3. Model wykorzystujący modyfikację parametrów schematu zastępczego silnika

W pracy [5.4], obwodowy model silnika z uszkodzonym uzwojeniem stojana (zwarcie zwojowym) wykorzystuje również odpowiednią modyfikację parametrów schematu zastępczego silnika, które zmieniane są w zależności od stopnia uszkodzenia. Po uwzględnieniu transformacji współrzędnych do nieruchomego układu związanego z polem stojana maszyny (α - β) i uwzględnieniu obwodu zwarciovego (5.35) i (5.36)

w fazie A silnika (rys. 5.1) model silnika ze zwarcie zwojowym w uzwojeniu stojana można zapisać w następujący sposób:

- równania obwodu stojana w osi α pozostają niezmiennione, natomiast w osi β :

$$u_{s\beta} = r_{s\beta} i_{s\beta} + T_N \frac{d\Psi_{s\beta}}{dt} + u_{\beta zw} \quad (5.50)$$

- równania obwodu wirnika pozostają niezmiennione (5.13) i (5.14):
- równania strumieniowo prądowe w osi α pozostają niezmiennione (5.15) i (5.17), natomiast w osi β :

$$i_{s\beta} = \frac{x_{r\beta}}{w} \Psi_{s\beta} - \frac{x_{m\beta}}{w} \Psi_{r\beta} + \frac{x_{m\beta} x_{sr\beta} - x_{r\beta} x_{ss\beta}}{w} i_{zw} \quad (5.51)$$

$$i_{r\beta} = \frac{x_{s\beta}}{w} \Psi_{r\beta} - \frac{x_{m\beta}}{w} \Psi_{s\beta} + \frac{x_{m\beta} x_{ss\beta} - x_{r\beta} x_{sr\beta}}{w} i_{zw} \quad (5.52)$$

gdzie:

$u_{\beta zw}$ – spadek napięcia na rezystancji dodatkowej r_d ograniczającej prąd zwarcioowy w zwartym obwodzie (przy czym, gdy $r_d \rightarrow 0$, $u_{\beta zw} = 0$),

- parametry uzwojeń w osi α :

$$r_{s\alpha} = r_s, \quad x_{s\alpha} = x_s, \quad x_{r\alpha} = x_{r\beta} = x_r, \quad x_{m\alpha} = x_m \quad (5.53)$$

- parametry uzwojeń w osi β :

$$r_{s\beta} = \frac{2}{3} \left(r_s \frac{N_{nz}}{N_s} + \frac{1}{2} r_s \right) \quad (5.54)$$

$$x_{s\beta} = \frac{2}{3} \left(\left(\frac{N_{nz}}{N_s} \right)^2 \left(x_{\sigma s} + \frac{2}{3} x_m \right) + \frac{1}{2} \left(\left(x_{\sigma s} + \frac{2}{3} x_m \right) - \frac{1}{3} x_m \right) + \frac{2}{3} \frac{N_{nz}}{N_s} x_m \right) \quad (5.55)$$

$$x_{m\beta} = \frac{1}{3} \frac{N_r x_m}{N_s^2} (2N_{nz} + N_s) \quad (5.56)$$

$$x_{m\beta} = \frac{2}{3} \left(\frac{2}{3} \frac{N_{zw} N_{nz}}{N_s^2} x_m + \frac{1}{3} \frac{N_{zw}}{N_s} x_m \right) \quad (5.57)$$

$$x_{sr\beta} = \frac{2}{3} \frac{N_{zw} N_r}{N_s^2} x_m \quad (5.58)$$

W modelu silnika indukcyjnego z uszkodzonym uzwojeniem stojana prąd zwarcioowy oblicza się na podstawie następujących zależności:

$$i_{zw} = \frac{\Psi_{zw} - x_{ss\beta} i_{s\beta} - x_{sr\beta} i_{r\beta}}{x_{zw}} \quad (5.59)$$

$$T_N \frac{d\Psi_{zw}}{dt} = u_{\beta zw} - r_{zw} i_{zw} \quad (5.60)$$

gdzie:


$$r_{zw} = r_s \frac{N_{zw}}{N_s} \quad (5.61)$$

$$x_{zw} = \frac{2}{3} \left(\frac{N_{nz}}{N_s} \right)^2 \left(x_{\sigma s} + \frac{2}{3} x_m \right) \quad (5.62)$$

Model ten umożliwia modelowanie asymetrii uzwojenia stojana tylko w fazie A silnika [5.16, 5.18].

5.2.4. Weryfikacja modeli matematycznych silnika indukcyjnego z uszkodzonym stojanem

Przedstawione modele matematyczne silnika indukcyjnego umożliwiają przeprowadzenie symulacji pracy silnika nieuszkodzonego i z uszkodzonym uzwojeniem stojana (zwarciami zwojowymi w wybranej fazie). Modele dobrze oddają zjawiska fizyczne powstające w silniku w przypadku wystąpienia zwarcia kilku zwojów. Jak wykazały badania porównawcze, dokładność omawianych modeli matematycznych jest bardzo zbliżona [5.31]. Ze względu na bardzo prosty sposób modelowania asymetrii uzwojenia stojana osobno w każdej z faz silnika, model silnika indukcyjnego przedstawiony w punkcie (5.2.2) został uznany za najkorzystniejszy w badaniach




Rys. 5.3. Przebieg prądu fazowego – badanie symulacyjne
(zwarcie 5 zwojów w fazie A w chwili $t = 0,15$ s)

asymetrii stojana. Na rysunku 5.3 przedstawiono wyniki symulacji zwarcia 5 zwojów w fazie A z zastosowaniem omawianego modelu matematycznego.

Na rysunku 5.4 przedstawiono wyniki badań eksperymentalnych na rzeczywistym silniku, w którym realizowano zwarcia zwojowe w fazie A. Uzyskano porównywalne (w jednostkach względnych) wartości amplitud prądów w fazie A w stanie ustalonym przed i po wystąpieniu uszkodzenia.

Przedstawione modele silnika indukcyjnego z uszkodzonym uzwojeniem stojana umożliwiają wstępne testowanie nowych metod diagnostycznych oraz sporządzanie zestawów wzorców diagnostycznych dla poszczególnych wariantów uszkodzeń uzwojeń stojana. Zostało to szczegółowo omówione w pracach [5.16, 5.30, 5.31].




Rys. 5.4. Przebieg prądu fazowego – badanie eksperymentalne
(zwarcie 5 zwojów w fazie A w chwili $t = 0,15$ s)

5.3. Modele matematyczne silnika indukcyjnego z uszkodzonym uzwojeniem wirnika klatkowego

5.3.1. Model I

Wirujący uszkodzony wirnik klatkowy powoduje modulację indukcji magnetycznej w szczelinie powietrznej, która pulsuje z częstotliwością równą podwójnej wartości poślizgu wirnika ($2sf_s$). Zmienny strumień magnetyczny indukuje w uzwojeniach fazowych stojana siłę elektromotoryczną, która wymusza przepływ prądu

o częstotliwości równej częstotliwości zasilania, pomniejszonej o podwójną wartość częstotliwości poślizgu $(1-2s)f_s$. Następstwem tego jest powstanie oscylacji w sygnale momentu elektromagnetycznego silnika i w rezultacie oscylacji prędkości, na amplitudę których tłumiąco wpływa moment bezwładności napędu. Zjawiskom tym towarzyszy efekt wtórny, polegający na pojawieniu się dodatkowej składowej częstotliwościowej $(1+2s)f_s$ w sygnale prądu fazowego oraz efekt zmniejszenia amplitudy składowej $(1-2s)f_s$ prądu stojana (rozdział 8).



Rys. 5.5. Schemat zastępczy uszkodzonego wirnika silnika indukcyjnego klatkowego

Do opisu podanych zjawisk, które zachodzą w silniku indukcyjnym z uszkodzoną klatką, niezbędne jest zastosowanie odpowiedniego modelu obwodowego, który uwzględni przerwę w obwodzie prętów klatki. Większość obwodowych modeli matematycznych silników indukcyjnych spotykanych w literaturze wywodzi się z klasycznych równań napięciowych obwodów elektromagnetycznych silnika indukcyjnego. Przyjmuje się, że obwód stojana jest trójfazowy, natomiast obwód wirnika jest złożony z $(n+1)$ równań, gdzie n oznacza liczbę prętów w klatce wirnika. Równanie obwodu wirnika dotyczy obwodu pierścieni zwierających. Na rysunku 5.5 przedstawiono schemat fragmentu tak opisanego obwodu elektrycznego wirnika [5.6, 5.8, 5.9, 5.13, 5.14].

Na podstawie schematu zastępczego wirnika (rys. 5.5) można sformułować następujące równania oczkowe:

- równanie napięciowe k -tej pętli wirnika:

$$0 = 2R_{ek}i_{rk} + R_{bk}i_{rk} + R_{b(k-1)}i_{rk} + \frac{d\Psi_k}{dt} \quad (5.63)$$

gdzie strumień Ψ_k oblicza się na podstawie indukcyjności własnych i wzajemnych obwodów stojana i wirnika oraz chwilowego prądu w tych obwodach:

$$\Psi_k = 2L_{ek}i_{rk} + L_{bk}i_{rk} + L_{b(k-1)}i_{rk} \quad (5.64)$$

- równanie napięciowe pierścienia zwierającego:

$$0 = \sum_{k=1}^N \left(R_{ek}i_{rk} + L_{ek} \frac{di_{rk}}{dt} \right) + R_{ek}i_e + L_{ek} \frac{di_{ek}}{dt} \quad (5.65)$$

Uszkodzenia poszczególnych prętów modeluje się przez odpowiednie zwiększenie rezystancji wybranych elementów macierzy wirnika R_{bk} . W rezultacie zmniejsza się prąd płynący w wybranej pętli obwodu wirnika. Wyznaczenie prądu płynącego w poszczególnych fazach uzwojeń stojana podczas uszkodzenia klatki wirnika wymaga rozwiązania układu równań macierzowych wysokiego rzędu, co znacznie wydłuża proces obliczeniowy.

Przyjmując za punkt wyjściowy klasyczny model silnika indukcyjnego symetrycznego (równania (5.1)–(5.5)), należy w każdej iteracji obliczać prąd oczkowy płynący w klatce wirnika [5.13, 5.14]. Wektor prądu oczkowego wirnika \mathbf{i}_r , którego wymiar jest równy liczbie prętów w klatce modelowanego wirnika, wyznaczany jest na podstawie prądu wirnika, obliczonego w danej iteracji z symetrycznego modelu silnika zgodnie z zależnością:

$$\mathbf{i}_r = \begin{bmatrix} i_{r,1} \\ i_{r,2} \\ i_{r,3} \\ \vdots \\ i_{r,n} \end{bmatrix} = \mathbf{T}^{-1} \begin{bmatrix} i_{r\alpha} \\ i_{r\beta} \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (5.66)$$

gdzie \mathbf{T} – macierz transformacji z układu współrzędnych $(\alpha-\beta)$ do układu n -wymiarowego związanego z równaniami wirnika [5.8].

Następnie oblicza się prąd oczkowy z uwzględnieniem przerwanych prętów wirnika. W przypadku przerwanego k -tego pręta, nowy wektor prądu oczkowego wirnika $\mathbf{i}_r^{\text{new}}$ przyjmuje postać:

$$\mathbf{i}_r^{\text{new}} = \begin{bmatrix} i_{r,1}^{\text{new}} \\ i_{r,2}^{\text{new}} \\ \vdots \\ i_{r,k}^{\text{new}} \\ i_{r,k+1}^{\text{new}} \\ \vdots \\ i_{r,n}^{\text{new}} \end{bmatrix} = \begin{bmatrix} i_{r,1} \\ i_{r,2} \\ \vdots \\ \frac{i_{r,k} + i_{r,k+1}}{2} \\ \frac{i_{r,k} + i_{r,k+1}}{2} \\ \vdots \\ i_{r,n} \end{bmatrix} \quad (5.67)$$

Ostatnim krokiem jest obliczenie prądu modelu dwuosioowego (α - β) z wykorzystaniem macierzy transformacji \mathbf{T} :


$$\begin{bmatrix} i_{r\alpha} \\ i_{r\phi} \\ i_{0,1} \\ \vdots \\ i_{0,k} \\ i_{0,k+1} \\ \vdots \\ i_{0,n-3} \\ i_{0,n-2} \end{bmatrix} = \mathbf{T} \begin{bmatrix} i_{r,1}^{\text{new}} \\ i_{r,2}^{\text{new}} \\ i_{r,3}^{\text{new}} \\ \vdots \\ i_{r,k}^{\text{new}} \\ i_{r,k+1}^{\text{new}} \\ \vdots \\ i_{r,n-1}^{\text{new}} \\ i_{r,n}^{\text{new}} \end{bmatrix} \quad (5.68)$$

Obliczony prąd $i_{r\alpha}$ i $i_{r\beta}$ wykorzystuje się do rozwiązywania równań strumieniowo-prądowych w klasycznym modelu silnika indukcyjnego (5.1)–(5.5). W prądzie wirnika, oprócz składowych $i_{r\alpha}$, $i_{r\beta}$, oblicza się także składowe kolejności zerowej, które występują w nieuszkodzonym silniku, ale nie są one stosowane do dalszych obliczeń.

5.3.2. Model II

Stosując nieco inne niż w poprzednim modelu matematycznym założenia upraszczające, możliwe jest zastosowanie obwodowego, dwuosioowego modelu matematycznego silnika indukcyjnego w badaniach symulacyjnych, których celem jest poznanie zjawiska występującego w przebiegu prądu fazowego stojana, dla różnych wariantów uszkodzenia wirnika. Ideą rozwiązania jest zastąpienie stałego parametru stanowiącego rezystancję zastępczą wirnika, wielkością zmienną, występującą pod postacią tzw. wirtualnego wektora rezystancji. Wektor ten jest nieruchomy względem wirnika, lecz jego moduł cyklicznie zmienia wartość w funkcji kąta położenia wirnika względem

stojana, oraz w zależności od geometrycznej lokalizacji uszkodzonych prętów na obwodzie wirnika. Interpretacja tego wektora nie ma sensu fizycznego, stanowi on wyłącznie współczynnik obliczeniowy, uwzględniający wpływ asymetrii wirnika, wynikającej z charakteru i stopnia jego uszkodzenia [5.19, 5.21–5.23].



Rys. 5.6. Schemat zastępczy silnika indukcyjnego (a) i schemat elektryczny klatki wirnika (b)

Przyjmuje się założenie, że wirnik silnika indukcyjnego można potraktować, jako obwód składający się z równolegle połączonych N prętów, o jednostkowych rezystancjach r_{p1}, \dots, r_{pN} (rys. 5.6b), który zastępuje statyczną rezystancję wirnika oznaczoną jako r_r na schemacie zastępczym silnika indukcyjnego w stanie ustalonym (rys. 5.6a). Rezystancja zastępcza tego wirnika jest wypadkową rezystancją zespoloną \mathbf{R}_z , którą można przedstawić jako wektor:

$$\mathbf{R}_z = R_\alpha + jR_\beta \tag{5.69}$$

W ogólnym przypadku powinna być spełniona równość:

$$|\mathbf{R}_z| = R_Z = \sqrt{R_\alpha^2 + R_\beta^2} = \frac{1}{\sum_{k=1}^N \frac{1}{R_{pk}}} \tag{5.70}$$

W klasycznym modelu silnika indukcyjnego, przekształconym do układu współrzędnych $(\alpha-\beta)$ (równania (5.11)–(5.20)), rezystancję wirnika r_α i r_β można przedstawić w postaci uwzględniającej stopień uszkodzenia wirnika [5.23]:

$$r_{r\alpha} = \frac{Nr_{rN}}{2 \sum_{k=1}^N G_w(k) \sin^2\left(\theta + \frac{2\pi k}{N}\right)} \tag{5.71}$$

oraz

$$r_{r\beta} = \frac{Nr_{rN}}{2 \sum_{k=1}^N G_w(k) \sin^2\left(\theta + \frac{2\pi k}{N} - \frac{\pi}{2}\right)} \tag{5.72}$$

przy czym:

r_{rN} – zastępcza rezystancja uzwojenia wirnika bez uszkodzeń,

θ – kąt położenia wirnika względem stojana,

N – całkowita liczba prętów wirnika,

$G_w = \sum_{k=1}^N G_{pk}$ – macierz konduktancji odpowiedzialna za stan kolejnego pręta; ele-

menty macierzy konduktancji przyjmują wartości z przedziału $G_{pk} \in \langle 0, 1 \rangle$.

Dla wirnika z 10 prętami, z których pierwszy, drugi i trzeci są całkowicie uszkodzone, szósty zaś ma 2-krotnie zwiększoną rezystancję, w wyniku częściowego pęknięcia, macierz konduktancji przyjmie postać:

$$G_w = [0 \ 0 \ 0 \ 1 \ 1 \ 0,5 \ 1 \ 1 \ 1 \ 1]$$

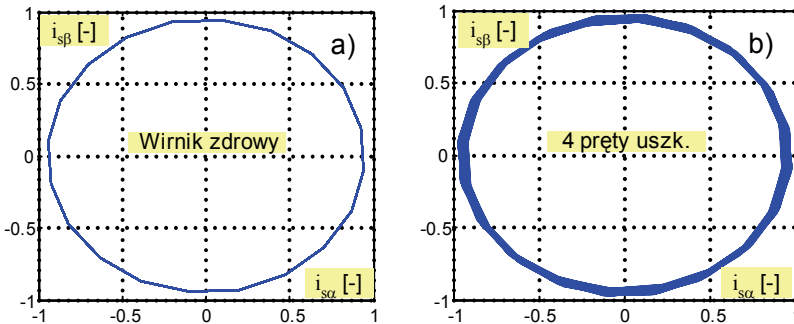
W przypadku symetrii wirnika spełniona jest zależność:

$$|\mathbf{R}_z| = \sqrt{R_\alpha^2 + R_\beta^2} = \frac{1}{\sum_{k=1}^N \frac{1}{R_{pk}}} = R_{rN} \quad (5.73)$$

Wprowadzając do klasycznego modelu silnika indukcyjnego do równań różniczkowych opisujących wirnik (5.13 i 5.14) rezystancję zastępczą \mathbf{R}_z , otrzymuje się:

$$T_N \frac{d\Psi_{r\alpha}}{dt} = -R_{r\alpha} i_{r\alpha} - \omega_m \Psi_{r\beta} \quad (5.74)$$

$$T_N \frac{d\Psi_{r\beta}}{dt} = -R_{r\beta} i_{r\beta} + \omega_m \Psi_{r\alpha} \quad (5.75)$$



Rys. 5.7. Hofograf wektora prądu stojana: a – wirnik nieuszkodzony, b – 4 pręty przerwane

Pozostałe równania dwuosowego modelu silnika indukcyjnego pozostają niezmiennicze. Model matematyczny umożliwia również przeprowadzenie symulacji pracy silnika nieuszkodzonego, a uzyskane wyniki nie różnią się od wyników uzyskanych

z klasycznego modelu dwuosowego, w układzie $(\alpha-\beta)$ o stałych parametrach. Model ten był wielokrotnie weryfikowany i stosowany w badaniach diagnostycznych realizowanych w zespole Autora i pomimo jego uproszczonej postaci dawał zadowalające wyniki w testowaniu metod wykrywania uszkodzeń wirnika klatkowego [5.21, 5.23, 5.30]. Na rysunku 5.7 przedstawiono hodograf wektora prądu stojana otrzymany w badaniach symulacyjnych zrealizowanych za pomocą przedstawionego modelu matematycznego. Uszkodzenie wirnika powoduje deformację trajektorii, jaką w układzie współrzędnych $\alpha-\beta$ określa wektor prądu stojana.

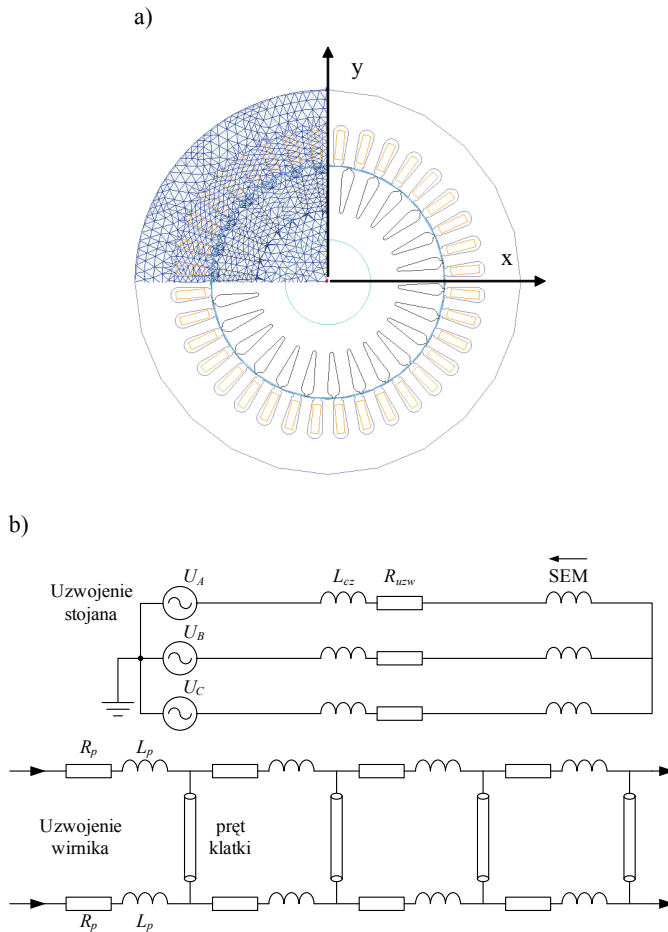
5.4. Modele polowo-obwodowe silnika indukcyjnego z uszkodzonym stojanem

Do projektowania oraz analizy działania maszyn elektrycznych coraz częściej wykorzystuje się programy, które umożliwiają numeryczne rozwiązanie pola elektromagnetycznego. Realizuje się to za pomocą dwuwymiarowych oraz trójwymiarowych metod polowych. Najbardziej rozpowszechnioną jest metoda elementów skończonych (FEM) [5.3, 5.12, 5.15].


Do analizy silników indukcyjnych przedstawiono model dwuwymiarowy polowo-obwodowy. Wadą takiego modelu jest to, że na etapie projektowania modelu nie uwzględnia się skosów żłobków i prętów klatki wirnika. Model polowo-obwodowy umożliwia wyznaczenie przebiegów czasowych wielkości elektrycznych i mechanicznych maszyny w stanach pracy dynamicznych oraz ustalonych. W tym celu tworzony jest układ równań składający się z równań pola elektromagnetycznego wraz z równaniami opisującymi połączenia uzwojeń, równaniami napięciowymi i prądowymi oraz równania ruchu. W każdym kroku obliczeniowym rozwiązywane są równania opisujące część polową (równania pola magnetycznego) oraz obwodową modelu (równania opisujące obwody elektryczne). Rozwiązanie równań części polowej umożliwia wyznaczenie sprzężeń, które stanowią źródło siły elektromotorycznej w równaniach części polowej modelu. Równania z części obwodowej umożliwiają wyznaczenie prądu, który z kolei jest źródłem pola magnetycznego w kolejnym kroku obliczeniowym części polowej modelu. Przykłady rozwiązań modeli polowych i polowo-obwodowych silników indukcyjnych z uszkodzeniami wirnika klatkowego oraz zwarć uzwojenia stojana przedstawiono m.in. w pracach [5.1–5.3].

W rozwiązaniu stanu dynamicznego, w każdym kroku obliczany jest elektromagnetyczny moment silnika. Ruch wirnika jest modelowany przez przesunięcie siatki wirnika przy braku jej jakichkolwiek modyfikacji. Niezmienna siatka stojana jest podłączona do ruchomej siatki wirnika za pomocą ruchomej szczeliny powietrznej. W szczelinie powietrznej jest pojedyncza warstwa siatki, która jest dyskretyzowana w każdym kroku obliczeniowym. W części polowej modelu silnika indukcyjnego

uwzględniona jest częstotliwość napięcia zasilającego, nieliniowość elementów magnetycznych oraz ruch wirnika, który jest odwzorowany przez wirującą szczelinę powietrzną. W części obwodowej uwzględnia się wymuszenie napięciowe i parametry elektryczne układu zasilania. Ponadto część obwodowa uwzględnia uzwojenia fazowe stojana o zmiennej indukcyjności i stałą rezystancję oraz połączenie czołowe tych uzwojeń o stałej rezystancji i indukcyjności. Klatka wirnika reprezentowana jest przez lite pręty, których parametry wynikają z rozwiązania polowego oraz przez rezystancje i reaktancje wycinków pierścienia zwierającego o stałej wartości. Wirująca szczelina powietrzna umożliwia obliczenia pola zarówno w stanach statycznych (ustalona prędkość silnika), jak i dynamicznych (rozruch silnika).



Rys. 5.8. Geometria modelu polowo-obwodowego wraz z fragmentem siatki dyskrytyzacyjnej (a) oraz schemat części obwodowej (b)



Rys. 5.9. Przykład żłobka stojana podzielonego na pojedyncze zwoje (a), część połowa modelu silnika indukcyjnego do badania zwarcń zwojowych (b)

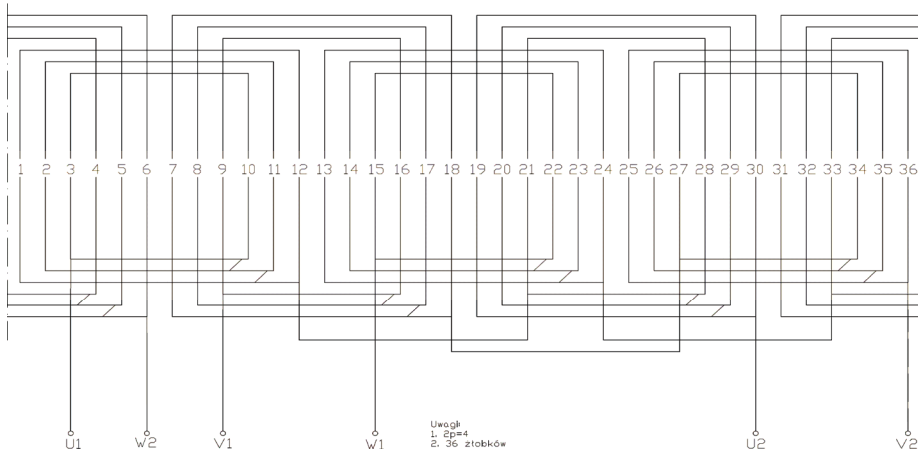
Model połowo-obwodowy silnika SH 90L4 (dane w załączniku 1) wykonano z wykorzystaniem komercyjnego programu Maxwell 2D (moduł *transient*). Na rysunku 5.8 przedstawiono geometrię części połowej wraz z fragmentem siatki dyskretyzacyjnej.

W części połowej uwzględniono czasową zmienność prądu, nieliniowość magnetowodu oraz ruch wirnika z wymuszoną prędkością obrotową. Część połowa jest odwzorowana w części obwodowej (rys. 5.8b) w postaci siły elektromotorycznej indukowanej w uzwojeniu stojana oraz litych prętów wirnika. Ze względu na zastosowanie modelu dwuwymiarowego w części obwodowej znajdują się parametry połączeń czołowych uzwojenia stojana (L_{cz}) oraz pierścienia zwierającego klatki wirnika (R_p , L_p), które wyznaczono z zależności konstrukcyjnych.


Aby była możliwa symulacja silnika z uszkodzonym stojanem, niezbędne jest wprowadzenie modyfikacji w podstawowym modelu połowo-obwodowym, który w podstawowej postaci uwzględnia tylko parametry całych uzwojeń faz A, B oraz C. Zmiany modelu muszą być zrealizowane zarówno w części połowej, jak i obwodowej. Założono, że model będzie umożliwiał badanie zwarcń zwojowych w trzech fazach i maksymalnie będzie możliwe zwarcie 12 zwojów. Przyjęto, że w każdej fazie jest 6 cewek a w każdej cewce są 52 zwoje. Wybrane żłobki stojana zostały podzielone na 13 obszarów: 12 małych i jeden duży. Obszary zostały podzielone proporcjonalnie.

W każdym małym obszarze znajduje się jeden zwoj, a w dużym 39 zwojów, co razem daje 51 zwojów w każdej cewce. Tak wykonany model połowo-obwodowy umożliwiał symulowanie zwarcń zwojowych od jednego do 12 zwojów w pierwszej cewce każdej fazy (patrzac od źródła zasilania). Na rysunku 5.9a przedstawiono propozycję rozwiązania żłobka, natomiast na rysunku 5.9b przedstawiono część połową

silnika z uszkodzonym stojanem. Uzwojenia stojana zostały połączone zgodnie z dokumentacją silnika Sh90L4. Schemat uzwojenia przedstawiono na rys. 5.10.



Rys. 5.10. Schemat uzwojenia stojana silnika SH 90L4




Rys. 5.11. Obwód zwarciaowy pierwszego zwoju, pierwszej cewki w fazie A


W części obwodowej wykonano połączenia elektryczne uzwojenia stojana razem z obwodami zwarciaowymi. Badany silnik był zasilany napięciem idealnie sinusoidalnym. Zwarcia zwojowe dokonywano za pomocą obwodu zwarciaowego przedstawionego na rysunku 5.11. W skład obwodu zwarciaowego wchodził stycznik (S_{A1_1}) oraz rezystor (R_{zwA1_1}), odpowiadający rezystancji punktu zwarcia również $1 \cdot 10^{-7} \Omega$. Jeden zwoj reprezentowany był przez rezystancję zwoju ($RR_{uzA1_1} = 15728,9 \mu\Omega$) i indukcyjność połączenia czołowego ($LL_{czA1_1} = 12866,4 \text{ nH}$) oraz cewkę ($L_{cewka_A1_1}$), której wartość jest obliczana w części polowej. W modelu każdy obwód zwarciaowy ma swój stycznik, zasilany z oddzielnego źródła. W parametrach źródła

napięciowego obwodu zasilania stycznika wprowadzono czas załączania, a więc moment wystąpienia zwarcia.

Na rysunku 5.12 przedstawiono przebiegi prądów fazowych uzyskanych z modelu polowo-obwodowego silnika indukcyjnego ze zwarciami zwojowymi w stanie, natomiast na rysunku 5.13 zależność wartości skutecznej prądów fazowych od liczby zwojów zwartych w stanie.



Rys. 5.12. Przebiegi prądów fazowych silnika nieobciążonego bez zwartych zwojów, uzyskane na drodze symulacji (model) oraz zmierzone na obiekcie rzeczywistym (silnik)




Rys. 5.13. Zależność skutecznego prądu w każdej fazie od liczby zwartych zwojów w fazie A (silnik nieobciążony)

Weryfikacji modelu polowo-obwodowego dokonano na podstawie porównania przebiegów chwilowych prądów w trzech fazach uzyskanych na drodze modelowania i pomiarów na obiekcie rzeczywistym. Porównanie zrealizowano dla przypadku silni-

ka nieobciążonego bez zwartych zwojów oraz z 5 zwartymi zwojami w fazie A. Czas trwania symulacja wynosił 2 s z krokiem próbkowania $500 \mu\text{s}$, natomiast czas realizacji pomiarów wynosił 10 s z krokiem próbkowania $40 \mu\text{s}$. Na rysunku 5.14 przedstawiono porównanie przebiegu prądu fazowego uzyskanego z modelu z pomiarami na rzeczywistym silniku.

Przebieg na rys. 5.12 i 5.14 ma zbliżony do siebie kształt, jednak różni się wartością skuteczną. Wartość skuteczna prądu rzeczywistego silnika jest większa od wartości skutecznej prądu silnika zamodelowanego. Maksymalne różnice są na poziomie ok. 12% (w fazie A). Rozbieżności te mogą być spowodowane między innymi odmiennymi materiałami użytymi do konstrukcji stojana (blachami) przyjętymi w modelu połowo-obwodowym w porównaniu do tych użytych w rzeczywistym silniku. Dodatkowo na wynik porównania miał wpływ również różny krok próbkowania. Ponadto zamodelowany silnik zasilany był napięciem idealnie sinusoidalnym, podczas gdy rzeczywisty silnik zasilano napięciem z sieci (niesymetrycznym i odkształconym).



Rys. 5.14. Przebieg prądu fazowego silnika nieobciążonego z 5 zwartymi zwojami, uzyskane na drodze symulacji (model – linia ciągła) oraz zmierzone na obiekcie rzeczywistym (silnik – linia przerywana)

Badania symulacyjne wykazały, że model połowo-obwodowy jest bardzo dobrym narzędziem do generowania wzorców diagnostycznych uszkodzeń w silniku (w tym przypadku zwarc zwojowych). Rozbudowany model matematyczny w środowisku programistycznym Maxwell umożliwia precyzyjnie symulowanie zwarc zwojowych o różnym poziomie uszkodzenia i w różnych fazach silnika. Analiza wartości skutecznej prądu fazowego oraz amplitudy harmonicznej f_s oraz $3f_s$ pozwala określić fazę, w której wystąpiło zwarcie.

5.5. Podsumowanie

Symulacja komputerowa jest obecnie podstawowym narzędziem do wstępnego sprawdzania, testowania i wdrażania metod wykrywania uszkodzeń w maszynach i napędach elektrycznych. Wiele uszkodzeń trudnych jest do bezpośredniego zaobserwowania we wstępnej fazie rozwoju na obiekcie rzeczywistym i tylko modelowanie matematyczne i badania symulacyjne pozwalają prześledzić rozwój uszkodzeń.

W badaniach diagnostycznych poszukuje się adekwatnych modeli matematycznych, które zapewniłyby pewną równowagę między czasem i dokładnością obliczeń, szczególnie gdy niezbędna jest realizacja obliczeń w czasie rzeczywistym.

Obecnie rozbudowane modele polowe i polowo-obwodowe dostarczają wielu nowych możliwości w dziedzinie poznania rozwoju i mechanizmów powstawania uszkodzeń oraz opracowywania wzorców diagnostycznych. Jednakże, ze względu na długi czas realizacji obliczeń w modelach polowych i polowo-obwodowych oraz konieczność dokładnej znajomości konstrukcji i technologii maszyny, chętniej w diagnostyce stosuje się modele obwodowe.

Przedstawione w rozdziale obwodowe modele matematyczne silnika indukcyjnego z uszkodzeniami stojana i wirnika okazały się w zupełności wystarczające do testowania metod wykrywania uszkodzeń.

Literatura

- [5.1] Antal L., Antal M., *Weryfikacja eksperymentalna obwodowo-polowego modelu silnika indukcyjnego*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych, Oficyna Wydawnicza Politechniki Wrocławskiej 2003, nr 54, seria: Studia i materiały nr 23, 39–48.
- [5.2] Antal M., Antal L., *Zwarcia zwojowe w uzwojeniu stojana klatkowego silnika indukcyjnego*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, nr 59, ser. Studia Materiały nr 27, 2006, 78–89.
- [5.3] Antal M., *Badanie zjawisk elektromagnetycznych i cieplnych w silnikach indukcyjnych z uszkodzonymi obwodami elektrycznymi*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2007.
- [5.4] Arkan M., Kostic-Perovic D., Unsworth P.J., *Modeling and simulation of induction motors with inter-turn faults for diagnostics*, Elsevier, Electric Power Systems Research, 75, 2005, 57–66.
- [5.5] Bachir S., Tnani S., Trigeassou J.C., Champenois G., *Diagnosis by Parameter Estimation of Stator and Rotor Faults Occurring in Induction Machines*, IEEE Transactions on Industrial Electronics, Vol. 53, No. 3, 2006, 963–973.
- [5.6] Bogalecka E., Kołodziejek P., *Modelowanie i symulacja uszkodzeń wirników silników klatkowych*, Wiadomości Elektrotechniczne, nr 11, 2006.
- [5.7] Bouzid M.B.K., Champenois G., Bellaaj N.M., Signac L., Jelassi K., *An Effective Neural Approach for the Automatic Location of Stator Interturn Faults in Induction Motor*, IEEE Transactions on Industrial Electronics, Vol. 55, No. 12, December 2008, 4277–4289.

- [5.8] Cunha C.C.M., Ribas Soares F.B., Oliviera P.S., Cardoso Filho B.J., *A new method to simulate induction machines with rotor asymmetries*, 28th Annual Conf. on Industrial Electronics Society IECON 2002, Vol. 1, Sevilla 2002, 72–76.
- [5.9] Cunha C.C.M., Lyra O.C., Cardoso Filho B.J., *Simulation and Analysis of Induction Machines With Rotor Asymmetries*, IEEE Trans. on Industry Applications, Vol. 41, No. 1, 2005, 18–24.
- [5.10] De Angelo C., Bossio G., Giaccone S., Garcia G.O., Solsona J., Valla M.I., *Model Based Stator Fault Detection in Induction Motors*, 32nd Annual Conf. on IEEE Industrial Electronics, IECON 2006, 1095–1100.
- [5.11] De Angelo C.H., Bossio G.R., Giaccone S.J., Valla M.I., Solsona J.A., Garcia G.O., *Online Model-Based Stator-Fault Detection and Identification in Induction Motors*, IEEE Trans. on Industrial Electronics, Vol. 56, No. 11, 2009, 4671–4680
- [5.12] Fisher R., Ferkolj S., *Application of a Finite Element Method to predict Damaged Induction Motor Performance*, IEEE Trans. on Magnetics, Vol. 37, No. 5, 2001, 3635–3639.
- [5.13] Kołodziejek P., Bogalecka E., *Broken rotor bar impact on sensorless control of induction machine*, The International Journal for Computation and Mathematics in Electrical and Electronic Engineering, Vol. 28, No. 3, 2009, 540–555.
- [5.14] Kołodziejek P., *Identyfikacja uszkodzeń wirnika silnika indukcyjnego z beczujnikowym układem regulacji dla celów diagnostycznych*, Rozprawa Doktorska, Politechnika Gdańska, Wydział Elektrotechniki i Automatyki, Gdańsk, 2009.
- [5.15] Kometani H., Sakabe S., Trutt F., *3-D analysis of induction motor with skewed slots using regular coupling mesh*, IEEE Trans. on Magnetics, Vol. 36, No. 4, 2000, 1769–1773.
- [5.16] Kowalski C.T., Wierzbicki R., Wolkiewicz M., *Modelowanie zwarć zwojowych silnika indukcyjnego zasilanego z przemiennika częstotliwości*, Przegląd Elektrotechniczny, vol. 86, nr 4, 2010, 220–224.
- [5.17] Kowalski C.T., Orłowska-Kowalska T., Wierzbicki R., Wolkiewicz M., *Analysis of inter-turn fault symptoms for the converter-fed induction motor based on the phase-shift calculation*, 36th Annual Conference of the IEEE Industrial Electronics Society, 2010, 760–765.
- [5.18] Kowalski C.T., Wolkiewicz M., Orłowska-Kowalska T., *Experimental verification of the inter-turn fault symptoms modeling for the converter-fed induction motor*, 10th International Conference on Modeling and Simulation of Electric Machines, Converters and System, Electrimacs, 2011, 1–6.
- [5.19] Pawlak M., *Uproszczony model silnika klatkowego z uszkodzonym wirnikiem*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, nr 56, ser. Studia i Materiały nr 24, 2004, 229–240.
- [5.20] Pawlak M., *Modelowanie uszkodzeń wirnika silnika klatkowego przy wykorzystaniu uproszczonego modelu dwuosowego*, Conf. Proc. of 41th Intern. Symp. on Electrical Machines, Vol. 1, Opole, Poland, 2005, 88–95.
- [5.21] Pawlak M., *Zastosowanie metod sztucznej inteligencji do wykrywania uszkodzeń wirnika silnika indukcyjnego*, Rozprawa Doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2005.
- [5.22] Pawlak M., *Modelowanie uszkodzeń wirnika silnika klatkowego przy wykorzystaniu uproszczonego modelu dwuosowego*, Proc. of 41th Int. Symp. on Electrical Machines SME'2005, Jarnołtówek, Poland, 2005.
- [5.23] Pawlak M., Orłowska-Kowalska T., *Zastosowanie uproszczonego modelu dwuosowego do modelowania uszkodzeń wirnika silnika klatkowego*, Przegląd Elektrotechniczny, R. 86, No. 4, 2006, 220–224.
- [5.24] Orłowska-Kowalska T., *Beczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.

-
- [5.25] Rusek J., *Komputerowa analiza maszyny indukcyjnej z wykorzystaniem bilansu harmoniczných*, AGH Uczelniane Wydawnictwa Naukowo-Techniczne, Kraków 2000.
 - [5.26] Sobczyk T.J., *Metodyczne aspekty modelowania matematycznego maszyn indukcyjnych*, WNT, Warszawa 2004.
 - [5.27] Tallam R.M., Habetler T.G., Harley R.G., *Transient Model for Induction Machines with Stator Winding Turn Faults*, IEEE Trans. on Industry Applications, Vol. 38, No. 3, 2002, 632–637.
 - [5.28] Tunia H., Kaźmierkowski M.P., *Automatyka Napędu Przekształtnikowego*, PWN, Warszawa 1987.
 - [5.29] Wierzbicki R., *Diagnostyka silników indukcyjnych z zastosowaniem estymatorów stanu i parametrów*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2011.
 - [5.30] Wierzbicki R., Kowalski Cz.T., *Wykrywanie uszkodzeń uzwojenia wirnika przekształtnikowego układu napędowego z silnikiem indukcyjnym*, Maszyny Elektryczne, Zeszyty Problemowe, nr 87, 2010, 179–184.
 - [5.31] Wolkiewicz M., *Monitorowanie stanu uzwojeń stojana silnika indukcyjnego*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2012.

6. Estymatory zmiennych stanu i parametrów w diagnostyce napędów przekształtnikowych

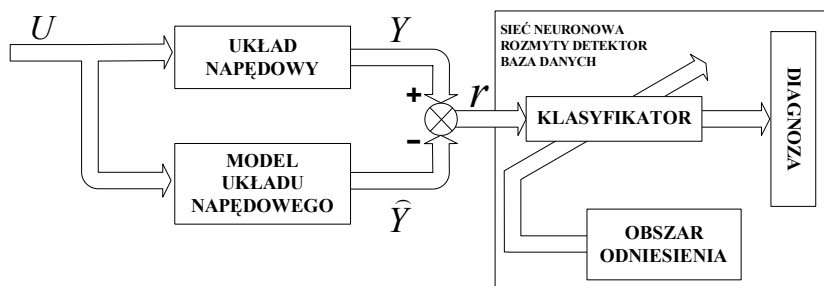
6.1. Wprowadzenie

W rozdziale 1 przedstawiono ideę detekcji uszkodzeń z wykorzystaniem modeli analitycznych (ang. *model-based fault detection methods*), zaproponowaną między innymi przez Isermana. Modele analityczne mogą mieć różną postać, m.in.: estymatorów, obserwatorów, filtrów Kalmana, równań parzystości.

Modele matematyczne w systemie diagnostycznym mogą być wykorzystane przynajmniej na trzy sposoby:

- 1 – do równoległej pracy modelu z obiektem rzeczywistym (porównywanie wyjść i obliczanie residuum),
- 2 – do estymacji (odtworzenia) zmiennych stanu,
- 3 – do identyfikacji parametrów charakteryzujących obiekt.

W pierwszym przypadku system diagnostyczny wyposażony jest w **model matematyczny obiektu, pracujący równoległe z obiektem diagnozowanym** (rys. 6.1). Podejście to opiera się na zasadzie redundancji analitycznej.

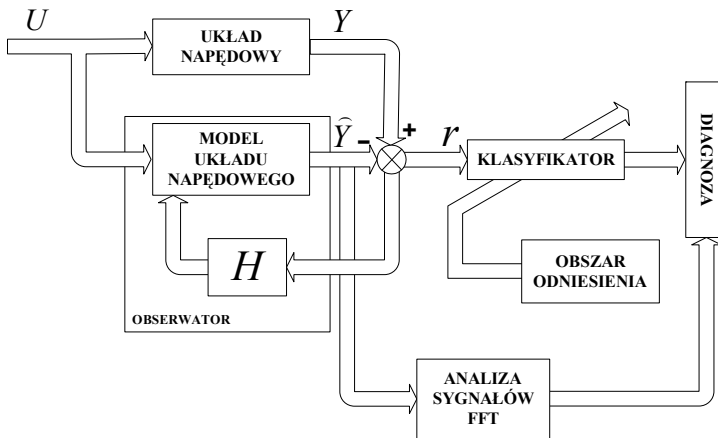


Rys. 6.1. Schemat ideowy systemu diagnostyki z równoległą pracą obiektu i modelu

Zastosowany model opisuje obiekt w stanie nieuszkodzonym. Wielkości wejściowe zarówno dla obiektu, jak i dla jego modelu matematycznego są takie same.

Informację o uszkodzeniu uzyskuje się na podstawie porównania sygnałów wyjściowych z modelu i obiektu rzeczywistego (obliczenie *residuum*). W przypadku dokładnego modelu, zachowującego parametry odpowiadające parametrom obiektu, wartość residuum oscyluje wokół zera tylko wtedy, gdy obiekt działa poprawnie. Wartości residuum znacznie odbiegające od zera są symptomami uszkodzenia. Podane podejście wymaga zastosowania możliwie dokładnego opisu matematycznego diagnozowanego obiektu. Systemy diagnostyczne oparte na równoległej pracy obiektu i modelu dobrze nadają się do wykrywania uszkodzeń w układach pomiarowych i obiektach, w których zachodzące procesy są wolnozmiennie, np.: procesy chemiczne, przetwórcze itp.

W drugim podejściu model matematyczny jest wykorzystywany do estymacji (odtworzenia) zmiennych stanu obiektu. Zakłada się, że uszkodzenia objawiają się jako zmiany wartości wyjść obiektu oraz innych wewnętrznych, wirtualnych zmiennych stanu, mających wpływ na przebieg procesu, ale nie będących dostępnymi pomiarowo. Schemat blokowy ilustrujący ideę diagnostyki z zastosowaniem estymacji wielkości fizycznych przedstawiono na rysunku 6.2.

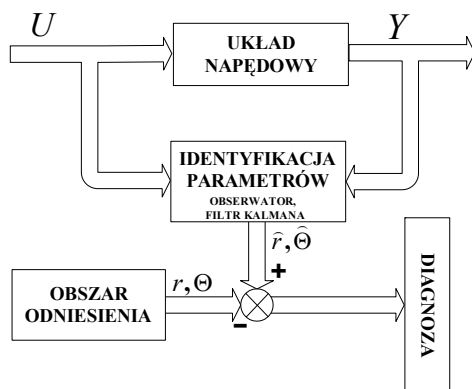


Rys. 6.2. Schemat ideowy systemu diagnostyki z zastosowaniem estymacji wielkości fizycznych

System diagnostyki składa się z układów estymacyjnych (np. obserwator, filtr Kalmana), które służą do wyznaczania niedostępnych pomiarowo sygnałów. Mając odtworzone, wirtualne wielkości charakteryzujące stan obiektu można dokonać ich analizy, w celu wyodrębnienia symptomów uszkodzeń. Podejście takie jest interesujące we współczesnych napędach przekształtnikowych, gdzie w cyfrowych układach sterowania, wykorzystywane są modele matematyczne do estymacji strumienia stojana lub wirnika, prądów i napięć, momentu elektromagnetycznego lub prędkości. W tych wirtualnych wielkościach, odtwarzanych za pomocą modeli matematycznych

na podstawie zmierzonych na obiekcie rzeczywistym prądu i napięcia, można poszukiwać symptomów uszkodzeń [6.1–6.9, 6.18, 6.19].

Innym podejściem jest **identyfikacja (estymacja) wewnętrznych parametrów obiektu**, które ulegają zmianie na skutek wystąpienia uszkodzenia. Metoda ta zakłada, że ograniczona liczba parametrów odpowiedzialna jest za jedno uszkodzenie. Estymacja wybranych parametrów oraz śledzenie ich zmian umożliwia wykrycie uszkodzenia. Głównym problemem jest zbudowanie systemu, który umożliwi dokładną estymację danego parametru. Przez porównanie wartości estymowanego parametru z wartością parametru w stanie normalnym pracy systemu uzyskuje się informację o ewentualnych uszkodzeniach [6.4, 6.9–6.13]. Na rysunku 6.3 przedstawiono schemat ilustrujący ideę diagnostyki z zastosowaniem estymacji parametrów. W przypadku napędów z silnikami indukcyjnymi identyfikacja może dotyczyć parametrów schematu zastępczego silnika, np. rezystancji uzwojeń stojana i wirnika.



Rys. 6.3. Schemat ideowy systemu diagnostyki z zastosowaniem identyfikacji parametrów

W przypadku złożonych napędów przekształtnikowych, pracujących w strukturach zamkniętych, sterowanych wektorowo, istnieją wewnętrzne estymatory do estymacji zmiennych wykorzystywanych w sprzężeniach zwrotnych lub do estymacji parametrów służących do korekcji nastaw regulatorów. Na bazie estymowanych parametrów i zmiennych stanu można stosunkowo łatwo zbudować system diagnostyczny.

Przedstawiono wybrane wyniki badań zrealizowanych w zespole badawczym Autora, wykorzystującym algorytm rozszerzonego filtru Kalmana oraz rozszerzonego obserwatora Luenbergera pełnego rzędu do zastosowań diagnostycznych. Oba algorytmy zaprojektowano w sposób umożliwiający monitorowanie rezystancji uzwojenia wirnika lub rezystancji uzwojenia stojana. Przedstawiono modele matematyczne estymatorów oraz metody ich syntezy.

6.2. Algorytm rozszerzonego filtru Kalmana

6.2.1. Podstawowy model matematyczny filtru Kalmana

Na podstawie teorii filtru Kalmana, model matematyczny nieliniowego obiektu dynamicznego, jakim jest silnik indukcyjny (przedstawiony w rozdz.5.1), po rozszerzeniu wektora stanu o dodatkowy element (prędkość wirnika, rezystancja stojana, rezystancja wirnika itp.), należy zapisać w postaci dyskretnej [6.5, 6.18, 6.22, 6.23]:

$$\mathbf{x}_R(k+1) = \mathbf{f}_R[\mathbf{x}_R(k), \mathbf{u}(k), k] + \mathbf{G}(k)\mathbf{w}(k) \quad (6.1)$$

$$\mathbf{y}_R(k) = \mathbf{C}_R(k)\mathbf{x}_R(k) + \mathbf{v}(k) \quad (6.2)$$

gdzie:

$\mathbf{x}_R(k)$ – rozszerzony wektor stanu silnika,

$\mathbf{u}(k) = [u_{s\alpha}(k) \ u_{s\beta}(k)]^T$ – wektor wejść,

$\mathbf{G}(k)$ – macierz współczynników wzmocnień zakłóceń,

$f_R[\mathbf{x}_R(k), \mathbf{u}(k), k]$ – funkcja stanowiąca nieliniową część modelu,

$\mathbf{v}(k)$ – macierz zakłóceń sygnałów wyjściowych,

$\mathbf{w}(k)$ – macierz zakłóceń zmiennych stanu.

Odnośnie do zakłóceń $\mathbf{v}(k)$, $\mathbf{w}(k)$ zakłada się, że są one szumami białymi, gausowskimi, niezależnymi, o wartościach oczekiwanych równych zeru:

$$E\{\mathbf{w}(k)\} = 0, \quad E\{\mathbf{v}(k)\} = 0 \quad (6.3)$$

Ponadto definiuje się macierze kowariancji zakłóceń \mathbf{Q} i \mathbf{R} :

$$E\{\mathbf{w}(k)\mathbf{w}(l)^T\} = \mathbf{Q}\delta(kl), \quad \mathbf{Q} \geq 0 \quad (6.4)$$

$$E\{\mathbf{v}(k)\mathbf{v}(l)^T\} = \mathbf{R}\delta(kl), \quad \mathbf{R} \geq 0 \quad (6.5)$$

gdzie δ – delta Kroneckera,

$E\{\mathbf{w}(k)\mathbf{v}(l)\}$ – szumy nieskorelowane.

Znane są również wartości początkowe $\mathbf{x}(0)$ i $\mathbf{P}(0)$:

$$E\{\mathbf{x}(0)\} = \hat{\mathbf{x}}(0/0) \quad (6.6)$$

$$\mathbf{P}(0/0) = E\{[\mathbf{x}(0) - \hat{\mathbf{x}}(0/0)][\mathbf{x}(0) - \hat{\mathbf{x}}(0/0)]^T\}$$

Uwzględniając podane założenia, estymacja parametrów odbywa się w kolejnych krokach:

- **krok 1** – obliczenie wartości predyktora wektora stanu w chwili $(k+1)$ na podstawie wejścia $\mathbf{u}(k)$ i estymaty stanu w poprzedniej chwili $\hat{\mathbf{x}}_R(k)$:

$$\hat{\mathbf{x}}_R(k+1/k) = f_R(\hat{\mathbf{x}}_R(k/k), \mathbf{u}(k), k) = \mathbf{A}_R(\hat{\mathbf{x}}_R(k/k))\hat{\mathbf{x}}_R(k/k) + \mathbf{B}_R\mathbf{u}(k) \quad (6.7)$$

– **krok 2** – obliczenie macierzy kowariancji błędu predykcji stanu:

$$\mathbf{P}(k+1/k) = \mathbf{F}_R(k)\mathbf{P}(k)\mathbf{F}_R(k)^T + \mathbf{Q}(k) \quad (6.8)$$

gdzie:

$$\mathbf{F}_R(k) = \left. \frac{\partial \mathbf{f}(\mathbf{x}_R(k/k), \mathbf{u}(k), k)}{\partial \mathbf{x}_R(k/k)} \right|_{\mathbf{x}_R = \hat{\mathbf{x}}_R(k/k)} \quad (6.9)$$

$\mathbf{F}_R(k)$ – macierz stanu układu zlinearyzowanego dla wartości estymaty obliczonej w poprzednim kroku,

$\mathbf{Q}(k)$ – macierz kowariancji zakłóceń,

– **krok 3** – obliczenie macierzy wzmocnienia filtra Kalmana:

$$\mathbf{K}(k+1) = \mathbf{P}(k+1/k) \cdot \mathbf{C}_R(k+1)^T [\mathbf{C}_R(k+1) \cdot \mathbf{P}(k+1/k) \cdot \mathbf{C}_R(k+1) + \mathbf{R}]^{-1} \quad (6.10)$$

gdzie \mathbf{R} – macierz kowariancji estymaty stanu,

– **krok 4** – obliczenie skorygowanej estymaty wektora stanu:


$$\hat{\mathbf{x}}_R(k+1/k+1) = \hat{\mathbf{x}}_R(k+1/k) + \mathbf{K}(k+1) \cdot [\mathbf{y}(k+1) - \mathbf{C}_R(k+1) \cdot \hat{\mathbf{x}}_R(k+1/k)] \quad (6.11)$$

– **krok 5** – obliczenie macierzy kowariancji błędu estymaty:

$$\mathbf{P}(k+1/k+1) = [\mathbf{I} - \mathbf{K}(k+1) \cdot \mathbf{C}_R(k+1)] \cdot \mathbf{P}(k+1/k), \quad (6.12)$$

– **krok 6** – powrót do kroku pierwszego.

Schemat ideowy rozszerzonego filtra Kalmana przedstawiono na rysunku 6.4.



Rys. 6.4. Schemat ideowy filtra Kalmana

6.2.2. Estymacja rezystancji wirnika

W celu estymacji rezystancji uzwojenia wirnika wektor elektromagnetycznych zmiennych stanu, zawierający prąd stojana oraz strumień wirnika w modelu matematycznym (5.21)–(5.28), rozszerzono o rezystancję wirnika:

$$\mathbf{x}_R^r(t) = [i_{s\alpha} \quad i_{s\beta} \quad \Psi_{s\alpha} \quad \Psi_{s\beta} \quad r_r]^T \quad (6.13)$$

Zgodnie z zależnością (6.1) oraz (6.2) rozszerzony dyskretny model silnika indukcyjnego (5.21), (5.22), wykorzystany w algorytmie rozszerzonego filtru Kalmana do estymacji rezystancji wirnika, po dyskretyzacji z krokiem T_p , przyjmuje postać równań stanu:

$$\mathbf{x}_R^r(k+1) = \mathbf{A}_R^r(\mathbf{x}_R^r(k), \omega_m(k))\mathbf{x}_R^r(k) + \mathbf{B}_R^r\mathbf{u}_R(k) + \mathbf{w}(k) \quad (6.14)$$

$$\mathbf{y}_R(k) = \mathbf{C}_R^r(k)\mathbf{x}_R^r(k) + \mathbf{v}(k) \quad (6.15)$$

w których:

- wektor wyjścia:

$$\mathbf{y}_R(k) = [i_{s\alpha}(k) \quad i_{s\beta}(k)]^T \quad (6.16)$$

- wektor wejścia (sterowania):

$$\mathbf{u}_R(k) = [u_{s\alpha}(k) \quad u_{s\beta}(k)]^T \quad (6.17)$$

oraz odpowiednio:

- rozszerzona macierz wyjścia:

$$\mathbf{C}_R^r(k) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \quad (6.18)$$

- rozszerzona macierz wejścia:

$$\mathbf{B}_R^r(k) = \begin{bmatrix} \frac{\Omega_b}{\sigma x_s} & 0 & 0 & 0 & 0 \\ 0 & \frac{\Omega_b}{\sigma x_s} & 0 & 0 & 0 \end{bmatrix}^T \quad (6.19)$$

- rozszerzona macierz stanu:

$$\mathbf{A}_R^r(k) = \Omega_b \begin{bmatrix} 1 - \left(\frac{1}{\sigma x_s} r_s + \frac{1-\sigma}{\sigma x_r} r_r(k) \right) T_p & 0 & \frac{k_r r_r(k)}{\sigma x_r x_s} T_p & \frac{\omega_m(k) k_r}{\sigma x_s} T_p & 0 \\ 0 & 1 - \left(\frac{1}{\sigma x_s} r_s + \frac{1-\sigma}{\sigma x_r} r_r(k) \right) T_p & -\frac{\omega_m(k) k_r}{\sigma x_s} T_p & \frac{k_r r_r(k)}{\sigma x_r x_s} T_p & 0 \\ \frac{x_m}{x_r} r_r(k) T_p & 0 & 1 - \frac{r_r(k)}{x_r} T_p & -\omega_m(k) T_p & 0 \\ 0 & \frac{x_m}{x_r} r_r(k) T_p & \omega_m(k) T_p & 1 - \frac{r_r(k)}{x_r} T_p & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (6.20)$$

Macierz stanu układu zlinearyzowanego dla wartości estymaty obliczonej w poprzednim kroku przyjmuje postać:

$$\mathbf{F}_R^r(k) = \Omega_b \begin{bmatrix} 1 - \left(\frac{1}{\sigma x_s} r_s + \frac{1-\sigma}{\sigma x_r} r_r(k) \right) T_p & 0 & \frac{k_r r_r(k)}{\sigma x_r x_s} T_p & \frac{\omega_m(k) k_r}{\sigma x_s} T_p & \left(\frac{1-\sigma}{\sigma x_r} i_{s\alpha}(k) + \frac{k_r}{\sigma x_r x_s} \Psi_{r\alpha}(k) \right) T_p \\ 0 & 1 - \left(\frac{1}{\sigma x_s} r_s + \frac{1-\sigma}{\sigma x_r} r_r(k) \right) T_p & -\frac{\omega_m(k) k_r}{\sigma x_s} T_p & \frac{k_r r_r(k)}{\sigma x_r x_s} T_p & \left(\frac{1-\sigma}{\sigma x_r} i_{s\beta}(k) + \frac{k_r}{\sigma x_r x_s} \Psi_{r\beta}(k) \right) T_p \\ \frac{x_m}{x_r} r_r(k) T_p & 0 & 1 - \frac{r_r(k)}{x_r} T_p & -\omega_m(k) T_p & \left(\frac{x_m}{x_r} i_{s\alpha}(k) - \frac{1}{x_r} \Psi_{r\alpha}(k) \right) T_p \\ 0 & \frac{x_m}{x_r} r_r(k) T_p & \omega_m(k) T_p & 1 - \frac{r_r(k)}{x_r} T_p & \left(\frac{x_m}{x_r} i_{s\beta}(k) - \frac{1}{x_r} \Psi_{r\beta}(k) \right) T_p \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (6.21)$$

6.2.3. Estymacja rezystancji stojana

W celu estymacji rezystancji uzwojenia stojana wektor elektromagnetycznych zmiennych stanu, zawierający prąd stojana oraz strumień stojana (5.29)–(5.30), rozszerzono o rezystancję stojana:

$$\mathbf{x}_R^s(t) = [i_{s\alpha} \quad i_{s\beta} \quad \Psi_{r\alpha} \quad \Psi_{r\beta} \quad r_s]^T. \quad (6.22)$$

Zgodnie z zależnością (6.1) oraz (6.2) rozszerzony dyskretny model silnika indukcyjnego, wykorzystany w algorytmie rozszerzonego filtru Kalmana do estymacji rezystancji stojana, po dyskretyzacji z krokiem T_p przyjmuje postać równań stanu:

$$\mathbf{x}_R^s(k+1) = \mathbf{A}_R^s(\mathbf{x}_R^s(k), \omega_m(k)) \mathbf{x}_R^s(k) + \mathbf{B}_R^s \mathbf{u}_R(k) + \mathbf{w}(k) \quad (6.23)$$

$$\mathbf{y}_R(k) = \mathbf{C}_R^s(k) \mathbf{x}_R^s(k) + \mathbf{v}(k) \quad (6.24)$$

gdzie:

- wektor wyjścia $\mathbf{y}_R(k)$ – jak (6.16),
- wektor wejścia (sterowania) $\mathbf{u}_R(k)$ – jak (6.17),
- rozszerzona macierz wyjścia $\mathbf{C}_R^s(k) = \mathbf{C}_R^r(k)$ – jak (6.18),
- rozszerzona macierz wejścia $\mathbf{B}_R^s(k) = \mathbf{B}_R^r(k)$ – jak (6.19),
- rozszerzona macierz stanu.

$$\mathbf{A}_R^s(k) = \Omega_b \begin{bmatrix} 1 - \left(\frac{r_s(k)}{\sigma x_s} + \frac{x_s r_r}{w} \right) T_p & -\omega_m(k) T_p & \frac{r_r}{w} T_p & \frac{x_r \omega_m(k)}{w} T_p & 0 \\ \omega_m(k) T_p & 1 - \left(\frac{r_s(k)}{\sigma x_s} + \frac{x_s r_r}{w} \right) T_p & -\frac{x_r \omega_m(k)}{w} T_p & \frac{r_r}{w} T_p & 0 \\ -r_s(k) T_p & 0 & 1 & 0 & 0 \\ 0 & -r_s(k) T_p & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (6.25)$$

Macierz stanu układu zlinearyzowanego dla wartości estymaty obliczonej w poprzednim kroku przyjmuje postać:

$$\mathbf{F}_R^s(k) = \Omega_b \begin{bmatrix} 1 - \left(\frac{r_s(k)}{\sigma x_s} + \frac{x_s r_r}{w} \right) T_p & -\omega_m(k) T_p & \frac{r_r}{w} T_p & \frac{x_r \omega_m(k)}{w} T_p & \frac{1}{\sigma x_s} T_p i_{s\alpha}(k) \\ \omega_m(k) T_p & 1 - \left(\frac{r_s(k)}{\sigma x_s} + \frac{x_s r_r}{w} \right) T_p & -\frac{x_r \omega_m(k)}{w} T_p & \frac{r_r}{w} T_p & \frac{1}{\sigma x_s} T_p i_{s\beta}(k) \\ -r_s(k) T_p & 0 & 1 & 0 & -T_p i_{s\alpha}(k) \\ 0 & -r_s(k) T_p & 0 & 1 & T_p i_{s\beta}(k) \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (6.26)$$

6.3. Algorytm obserwatora Luenbergera

6.3.1. Podstawowy model matematyczny obserwatora Luenbergera

Dla modelu silnika opisanego równaniami stanu (5.21)–(5.28) można zaprojektować liniowy niestacjonarny obserwator pełnego rzędu typu Luenbergera [6.11, 6.15–6.18, 6.23]. Obserwator odtwarza dwie elektromagnetyczne zmienne stanu silnika indukcyjnego – wektor strumienia wirnika oraz prądu stojana. Model matematyczny obserwatora przyjmuje postać:

$$\frac{d\hat{\mathbf{x}}}{dt} = \hat{\mathbf{A}}(\omega_m) \hat{\mathbf{x}} + \mathbf{B} \mathbf{u} + \mathbf{G}(\hat{\mathbf{i}}_s - \mathbf{i}_s) \quad (6.27)$$

w którym:

- wektor elektromagnetycznych zmiennych stanu \mathbf{x} – jak (5.23),
- wektor wejścia \mathbf{u} – jak (5.25),
- macierz wejścia \mathbf{B} – jak (5.27),

- macierz stanu \mathbf{A} – jak (5.28),
- wektor prądu stojana:

$$\mathbf{i}_s = [i_{s\alpha} \quad i_{s\beta}]^T \quad (6.28)$$

- macierz wzmocnienia obserwatora Luenbergera:

$$\mathbf{G} = \begin{bmatrix} g_1 & g_2 & g_3 & g_4 \\ -g_2 & g_1 & -g_4 & g_3 \end{bmatrix}^T \quad (6.29)$$

gdzie:

$$g_1 = -(k_o - 1) \left(\frac{r_s}{\sigma x_s} + \frac{1}{\sigma T_r} \right) \quad (6.30)$$

$$g_2 = (k_o - 1) \omega_m \quad (6.31)$$

$$g_3 = (k_o^2 - 1) \left(-c \left(\frac{r_s}{\sigma x_s} + \frac{1 - \sigma}{\sigma T_r} \right) + \frac{x_m}{T_r} \right) + c(k_o - 1) \left(\frac{r_s}{\sigma x_s} + \frac{1}{\sigma T_r} \right) \quad (6.32)$$

$$g_4 = -c(k_o - 1) \omega_m \quad (6.33)$$

$$c = \frac{\sigma x_s x_r}{x_m} \quad (6.34)$$

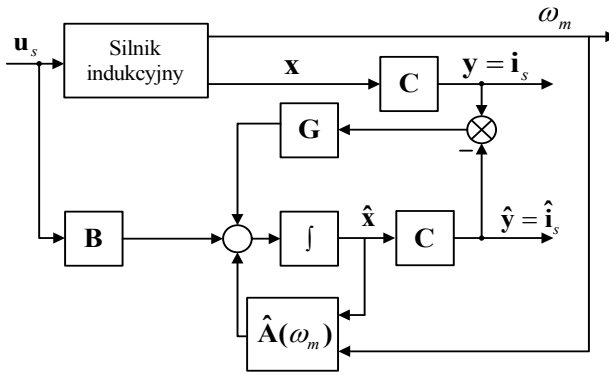
oraz

$$\sigma = 1 - \frac{x_m^2}{x_s x_r}, \quad T_r = T_N \frac{x_r}{r_r}$$

k_o – dodatnia stała.

Z postaci macierzy $\hat{\mathbf{A}}$ wynika, że obserwator wymaga informacji o aktualnej prędkości kątowej silnika, ponieważ elementy macierzy stanu są od niej zależne. Schemat ideowy obserwatora przedstawiono na rysunku 6.5.

Dla podanego obserwatora Luenbergera pełnego rzędu można zaprojektować wersję obserwatora stanu poszerzoną o parametry. Dalej przedstawiono algorytm postępowania dla układu rozszerzonego odpowiednio o rezystancję uzwojenia stojana lub rezystancję uzwojenia wirnika.



Rys. 6.5. Schemat blokowy liniowego obserwatora pełnego rzędu dla silnika indukcyjnego

6.3.2. Estymacja rezystancji wirnika

W celu estymacji rezystancji uzwojenia wirnika, wektor elektromagnetycznych zmiennych stanu, zawierający prąd stojana oraz strumień wirnika (5.23), rozszerzono o rezystancję wirnika:

$$\hat{\mathbf{x}}_R^r(t) = [\hat{i}_{s\alpha} \quad \hat{i}_{s\beta} \quad \hat{\psi}_{s\alpha} \quad \hat{\psi}_{s\beta} \quad \hat{r}_r]^T \quad (6.35)$$

Zgodnie z zależnością (6.27) model rozszerzonego obserwatora Luenbergera pełnego rzędu, wykorzystywany do estymacji rezystancji wirnika, przyjmuje postać:

$$\frac{d\hat{\mathbf{x}}_R^r}{dt} = \hat{\mathbf{A}}_R^r(\hat{\mathbf{x}}_R^r)\hat{\mathbf{x}}_R^r + \mathbf{B}_R^r \mathbf{u} + \mathbf{G}_R^r(\hat{\mathbf{i}}_s - \mathbf{i}_s) \quad (6.36)$$

w którym:

- wektor wejścia \mathbf{u} – jak (5.25),
- rozszerzona macierz wejścia:

$$\mathbf{B}_R^r = \begin{bmatrix} \frac{\Omega_b}{\sigma x_s} & 0 & 0 & 0 & 0 \\ 0 & \frac{\Omega_b}{\sigma x_s} & 0 & 0 & 0 \end{bmatrix}^T \quad (6.37)$$

- rozszerzona macierz stanu:

$$\mathbf{A}_R^r(\hat{r}_r, \omega_m) = \Omega_b \begin{bmatrix} -\left(\frac{1}{\sigma x_s} r_s + \frac{1-\sigma}{\sigma x} \hat{r}_r\right) & 0 & \frac{k_r \hat{r}_r}{\sigma x_r x_s} & \frac{\omega_m k_r}{\sigma x_s} & 0 \\ 0 & -\left(\frac{1}{\sigma x_s} r_s + \frac{1-\sigma}{\sigma x} \hat{r}_r\right) & -\frac{\omega_m k_r}{\sigma x_s} & \frac{k_r \hat{r}_r}{\sigma x_r x_s} & 0 \\ \frac{x_m \hat{r}_r}{x_r} & 0 & -\frac{\hat{r}_r}{x_r} & -\omega_m & 0 \\ 0 & \frac{x_m \hat{r}_r}{x_r} & \omega_m & -\frac{\hat{r}_r}{x_r} & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (6.38)$$

- rozszerzona macierz obserwatora:

$$\mathbf{G}_R^r = \begin{bmatrix} g_1 & g_2 & g_3 & g_4 & k_{or}(\hat{\psi}_{r\alpha} - x_m \hat{i}_{s\alpha}) \\ -g_2 & g_1 & -g_4 & g_3 & k_{or}(\hat{\psi}_{r\beta} - x_m \hat{i}_{s\beta}) \end{bmatrix}^T \quad (6.39)$$

gdzie:

- \hat{r}_r – wartość rezystancji wirnika wyznaczona w poprzednim kroku obliczeniowym,
- k_{or} – dodatnia stała.

6.3.3. Estymacja rezystancji stojana

W celu estymacji rezystancji uzwojenia stojana wektor elektromagnetycznych zmiennych stanu, zawierający prąd stojana oraz strumień wirnika (5.23), rozszerzono o rezystancję stojana:

$$\hat{\mathbf{x}}_R^s(t) = [\hat{i}_{s\alpha} \quad \hat{i}_{s\beta} \quad \hat{\psi}_{r\alpha} \quad \hat{\psi}_{r\beta} \quad \hat{r}_s]^T \quad (6.40)$$

Zgodnie z zależnością (6.24) model rozszerzonego obserwatora Luenbergera pełnego rzędu, wykorzystywany do estymacji rezystancji stojana, przyjmuje postać:

$$\frac{d\hat{\mathbf{x}}_R^s}{dt} = \hat{\mathbf{A}}_R^s(\hat{\mathbf{x}}_R^s) \hat{\mathbf{x}}_R^s + \mathbf{B}_R^s \mathbf{u} + \mathbf{G}_R^s(\hat{\mathbf{i}}_s - \mathbf{i}_s) \quad (6.41)$$

w którym:

- wektor wejścia \mathbf{u} – jak (5.25),
- rozszerzona macierz wejścia $\mathbf{B}_R^s = \mathbf{B}_R^r$ – jak (6.37),

- rozszerzona macierz stanu:

$$\mathbf{A}_R^s(\hat{r}_s, \omega_m) = \mathcal{Q}_b \begin{bmatrix} -\left(\frac{1}{\sigma x_s} \hat{r}_s + \frac{1-\sigma}{\sigma x} r_r\right) & 0 & \frac{k_r r_r}{\sigma x_r x_s} & \frac{\omega_m k_r}{\sigma x_s} & 0 \\ 0 & -\left(\frac{1}{\sigma x_s} \hat{r}_s + \frac{1-\sigma}{\sigma x} r_r\right) & -\frac{\omega_m k_r}{\sigma x_s} & \frac{k_r r_r}{\sigma x_r x_s} & 0 \\ \frac{x_m}{x_r} r_r & 0 & -\frac{r_r}{x_r} & -\omega_m & 0 \\ 0 & \frac{x_m}{x_r} r_r & \omega_m & -\frac{r_r}{x_r} & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (6.42)$$

- rozszerzona macierz obserwatora:

$$\mathbf{G}_R^s = \begin{bmatrix} g_1 & g_2 & g_3 & g_4 & k_{os} \hat{i}_{s\alpha} \\ -g_2 & g_1 & -g_4 & g_3 & k_{or} \hat{i}_{s\beta} \end{bmatrix}^T \quad (6.43)$$

gdzie:

- \hat{r}_s – wartość rezystancji stojana wyznaczona w poprzednim kroku obliczeniowym,
- k_{os} – dodatnia stała.

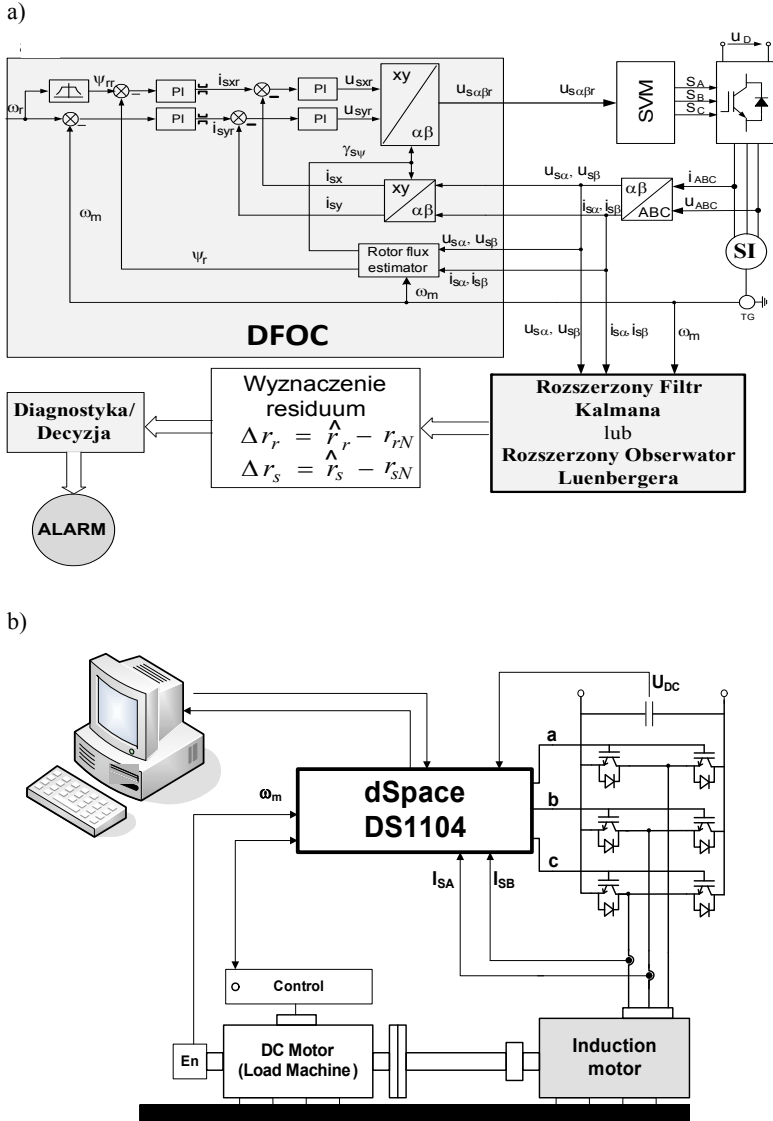
6.4. Zastosowanie filtru Kalmana do wykrywania uszkodzeń w układzie wektorowego sterowania prędkością DFOC

6.4.1. Wykrywanie uszkodzeń wirnika klatkowego

Przedstawione w poprzednich podrozdziałach modele matematyczne estymatorów wykorzystano do diagnostyki uszkodzeń wirnika i stojana w strukturze wektorowego sterowania DFOC (rys. 6.6a), w laboratoryjnym układzie napędowym z silnikiem indukcyjnym SH 90L4 z zamodelowanymi fizycznie uszkodzeniami klatki wirnika lub uzwojenia stojana [6.9, 6.10, 6.22, 6.23]. Parametry badanego silnika zamieszczono w załączniku 1.


Ze względu na złożoność algorytmu obliczeniowego estymatorów i duże wymagania odnośnie do dokładności obliczeń numerycznych, konieczne jest zastosowanie

w realizacji praktycznej nowoczesnego procesora sygnałowego. Badania zostały zrealizowane na stanowisku laboratoryjnym składającym się z komputera PC wyposażonego w kartę procesora sygnałowego dSpace DS1104 wraz z oprogramowaniem w języku C (rys. 6.6b).




Rys. 6.6. Schemat ideowy stanowiska badawczego:
 a) struktura sterowania wektorowego napędem DFOC z diagnostyką uszkodzeń uzwojeń on-line;
 b) stanowisko laboratoryjne

Krok obliczeń numerycznych wynosił $t = 100 \mu\text{s}$. Takie rozwiązanie umożliwiało sterowanie prędkością silnika indukcyjnego z wykorzystaniem specjalnie skonstruowanego falownika napięcia, do sterowania którego wykorzystano metodę modulacji napięcia wektora przestrzennego SVM. Falownik stanowił unikatowe rozwiązanie zespołu badawczego i umożliwiał bezpośrednie sterowanie łącznikami mostka tranzystorowego. W zamkniętej wektorowej strukturze sterowania DFOC rozszerzony filtr Kalmana pracował niezależnie od układu sterowania prędkością i był odpowiedzialny jedynie za estymowanie rezystancji uzwojenia wirnika, której wartość zmieniała się wraz ze stopniem uszkodzenia (rys. 6.6).




Rys. 6.7. Przebieg estymowanej rezystancji wirnika \hat{r}_r (a), prędkości silnika (b), prądu stojana w osi α - β (c) oraz prądu stojana w osi x - y (d) dla nieuszkodzonego silnika

Wyniki badań eksperymentalnych, przedstawione na rys. 6.7, rys. 6.8 wykazały, że algorytm rozszerzonego filtra Kalmana zastosowany do estymacji rezystancji wirnika jest niewrażliwy na skokowe zmiany momentu obciążenia. W pracach [6.22, 6.23] wykazano również, że algorytm w niewielkim stopniu reaguje na zmiany częstotliwości napięcia zasilania (regulacja prędkości). Na rysunku 6.9 przedstawiono jak zmienia się wartość estymowanej rezystancji wirnika \hat{r}_r w zależności od stopnia uszkodzenia wirnika (liczby uszkodzonych prętów wirnika).



Rys. 6.8. Przebieg estymowanej rezystancji wirnika \hat{r}_r (a), prędkości silnika (b), prądu stojana w osi α - β (c) oraz prądu stojana w osi x - y (d) dla silnika z uszkodzonymi 7 prętami wirnika




Rys. 6.9. Zależność estymowanej za pomocą filtra Kalmana rezystancji wirnika \hat{r}_r od liczby uszkodzonych prętów wirnika

Otrzymane wyniki potwierdzają, że dla silnika indukcyjnego pracującego w strukturze sterowania DFOC, wartość estymowanej rezystancji uzwojenia wirnika może być wskaźnikiem świadczącym o stanie uzwojenia wirnika.


6.4.2. Wykrywanie uszkodzeń stojana

W przypadku badań eksperymentalnych silnika indukcyjnego pracującego w zamkniętej wektorowej strukturze sterowania prędkością (DFOC) estymator rezystancji stojana (rozszerzony filtr Kalmana) pracuje niezależnie od układu sterowania i odpowiedzialny jest jedynie za śledzenie zmian rezystancji stojana.




Rys. 6.10. Przebiegi estymowanej rezystancji stojana \hat{r}_s przy zwarciu 16 zwojów dla znamionowego momentu obciążenia oraz zadanej znamionowej prędkości $\omega_2 = 1$ [p. u.]

Na rysunku 6.10 przedstawiono przebiegi estymowanej rezystancji uzwojenia stojana, a na rysunku 6.11 przedstawiono przebiegi prędkości silnika (a), prądu silnika w osi α - β (b) oraz prądu silnika w układzie współrzędnych polowych x - y (c), przy zwarciu 16 zwojów dla znamionowego momentu obciążenia oraz zadanej znamionowej prędkości silnika



Rys. 6.11. Przebiegi prędkości silnika (a), prądu stojana w osi α - β (b) oraz prądu stojana w osi x - y (c) przy zwarciu 16 zwojów dla znamionowego momentu obciążenia oraz zadanej znamionowej prędkości $\omega_2 = 1$ [p. u.]

$\omega_z = 1$ [p. u.]. Z badań wynika, że w sytuacji zwarcia zwojowego estymowana rezystancja stojana \hat{r}_s maleje, jednak zakres zmian jest dużo mniejszy w przypadku pracy silnika w zamkniętej wektorowej strukturze sterowania, niż w układzie otwartym [6.22, 6.23].



Rys. 6.12. Zależność estymowanej za pomocą filtru Kalmana rezystancji stojana \hat{r}_s od liczby zwartych zwojów uzwojenia stojana


Jak pokazują otrzymane wyniki, estymacja rezystancji stojana za pomocą filtru Kalmana wymaga stosunkowo długiego czasu obliczeń (około 6–8 s), co w przypadku wykrywania zwarcia, może spowodować trwałe uszkodzenie izolacji. Metoda ta jest skuteczna dopiero od 4–6 zwojów zwartych (rys. 6.12).

6.5. Zastosowanie obserwatora Luenbergera do wykrywania uszkodzeń w układzie wektorowego sterowania prędkością DFOC


6.5.1. Wykrywanie uszkodzeń wirnika klatkowego

Badania eksperymentalne z wykorzystaniem algorytmu rozszerzonego obserwatora Luenbergera do estymacji rezystancji wirnika \hat{r}_r silnika indukcyjnego pracującego w układzie zamkniętego sterowania DFOC zrealizowano w strukturze przedstawionej na rysunku 6.6. Na podstawie badań, których wyniki pokazano na rys. 6.13 i rys. 6.14,


można stwierdzić, że algorytm obserwatora Luenbergera jest niewrażliwy na skokowe zmiany momentu obciążenia. Podobnie wygląda sytuacja w przypadku zmian prędkości kątowej silnika, wynikającej ze zmiany częstotliwości napięcia zasilania [6.11–6.13, 6.21]. Zbiorcze zestawienie zmian estymowanej rezystancji wirnika \hat{r}_r w zależności od liczby przerwanych prętów przedstawiono na rys. 6.15.



Rys. 6.13. Przebieg estymowanej rezystancji wirnika \hat{r}_r (a), prędkości silnika (b), prądu stojana w osi α - β (c) oraz prądu stojana w osi x - y (d) dla nieuszkodzonego silnika




Rys. 6.14. Przebieg estymowanej rezystancji wirnika \hat{r}_r (a), prędkości silnika (b), prądu stojana w osi α - β (c) oraz prądu stojana w osi x - y dla silnika z uszkodzonymi 7 prętami wirnika



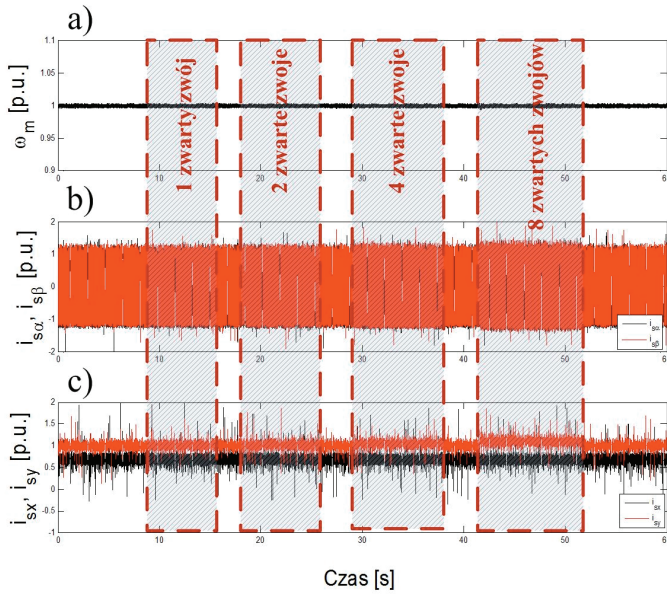
Rys. 6.15. Zależność estymowanej rezystancji wirnika \hat{r}_r od liczby uszkodzonych prętów wirnika

6.5.2. Wykrywanie uszkodzeń stojana


Estymator rezystancji stojana (rozszerzony obserwator Luenbergera) pracuje niezależnie od układu sterowania i odpowiedzialny jest jedynie za śledzenie zmian rezystancji stojana. Na rysunku 6.16 przedstawiono estymowaną rezystancję uzwojenia stojana, a na rysunku 6.17 przedstawiono przebiegi prędkości silnika (a), prądu silnika w osi α - β (b) oraz prądu silnika w osi x - y (c) podczas zwarcia różnej liczby zwojów dla znamionowego momentu obciążenia oraz zadanej znamionowej prędkości silnika $\omega_2 = 1$ [p. u.].



Rys. 6.16. Przebiegi estymowanej rezystancji uzwojenia stojana \hat{r}_s przy zwarciu różnej liczby zwojów dla znamionowego momentu obciążenia oraz zadanej znamionowej prędkości $\omega_2 = 1$ [p. u.]



Rys. 6.17. Przebiegi prędkości silnika (a), prądu stojana w osi α - β (b) oraz prądu stojana w osi x - y (c) przy zwarciu różnej liczby zwojów dla znamionowej prędkości $\omega_2 = 1$ [p. u.]



Rys. 6.18. Zależność estymowanej za pomocą obserwatora Luenbergera rezystancji stojana \hat{r}_s od liczby zwartych zwojów uzwojenia stojana

Z badań wynika, że w przypadku zastosowania rozszerzonego obserwatora Luenbergera do wykrywania zwarć zwojowych w silniku pracującym w układzie wektorowego sterowania prędkością DFOC możliwa jest detekcja uszkodzenia na poziomie zwarcia pojedynczych zwojów (rys. 6.18) [6.11, 6.13, 6.20, 6.23].

6.6. Podsumowanie

W rozdziale 6 przedstawiono możliwość zastosowania dwóch, najbardziej znanych z teorii sterowania, algorytmów estymacyjnych do wykrywania uszkodzeń w uzwojeniach silnika. Zbadano możliwości zastosowania rozszerzonego filtru Kalmana i rozszerzonego obserwatora Luenbergera do wykrywania uszkodzeń uzwojeń wirnika i stojana przekształtnikowego układu napędowego z silnikiem indukcyjnym, pracującego w otwartej skalarnej oraz zamkniętej wektorowej strukturze sterowania prędkością.

W wartościach estymowanych rezystancji zastępczych wirnika i stojana widoczne są zmiany wywołane uszkodzeniami. Dodatkowo zmiany te charakteryzują się stosunkowo dużą dynamiką (znacznie większą niż spowodowane wzrostem temperatury uzwojeń) i zakresem, co umożliwi wczesne wykrycie uszkodzenia.

Zastosowanie rozszerzonego filtru Kalmana i rozszerzonego obserwatora Luenbergera do wykrywania uszkodzeń wirnika w układach napędowych ze sterowaniem skalarnym i wektorowym silnika indukcyjnego daje bardzo zbliżone wyniki. Natomiast w przypadku uszkodzenia stojana lepsze właściwości diagnostyczne w zamkniętej strukturze sterowania prędkością napędu wykazuje obserwator Luenbergera.

W przypadku wykrywania zwarć za pomocą filtru Kalmana niezbędny jest znacznie dłuższy czas obliczeń (6–8 s), co może już spowodować trwałe uszkodzenie izolacji. Implementacja algorytmów estymacyjnych na obiekcie rzeczywistym wymaga zastosowania nowoczesnych procesorów sygnałowych umożliwiających realizację obliczeń numerycznych z krokiem poniżej 100 μ s.

Podany sposób monitorowania uzwojeń silnika pracującego w zamkniętych strukturach sterowania powinien być połączony z metodą wyznaczania parametrów schematu zastępczego silnika i stanowić uzupełnienie obecnie stosowanych algorytmów estymacyjno-sterujących w procesorach sygnałowych używanych w przekształtnikowych układach napędowych.

Literatura

- [6.1] Bachir S., Tnani S., Poinot T., Trigeassou J.C., *Stator fault diagnosis in induction machines by parameter estimation*, Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED '2001, Grado, Italy, 2001, 235–239.

- [6.2] Bachir S., Tnani S., Trigeassou J.C., *Stator fault diagnosis by parameter estimation without speed sensor*, Int. Conf. on Electrical Machines ICEM'02, Bruges, Belgique, 2002, CD.
- [6.3] Bachir S., Trigeassou J.C., Tnani S., *On-line stator faults diagnosis by parameter estimation*, European Conference on Power Electronics and Applications, Toulouse, France, 2003, CD.
- [6.4] Bachir S., Tnani S., Trigeassou J.C., Champenois G., *Diagnosis by parameter estimation of stator and rotor faults occurring in induction machines*, IEEE Trans. on Industrial Electronics, Vol. 53, No. 3, 2006, 963–973.
- [6.5] Barut M., Bogosyan S., Gokasan M., *Experimental Evaluation of Braided EKF for Sensorless Control of Induction Motors*, IEEE Trans. on Industrial Electronics, Vol. 55, No. 2, 2008, 620–632.
- [6.6] Kallesoe C.S., Vadstrup P., Rasmussen H., Izadi-Zamanabadi R., *Observer based estimation of stator winding faults in delta-connected induction motors, a LMI approach*, 41st IEEE-IAS Ann. Meeting Industry Applications Conf., Vol. 5, 2006, 2427–2434.
- [6.7] Kallesoe C.S., Izadi-Zamanabadi R., Vadstrup P., Rasmussen H., *Observer-based estimation of stator-winding faults in delta-connected induction motors: A linear matrix inequality approach*, IEEE Trans. on Industry Applications, Vol. 43, No. 4, 2007, 1022–1031.
- [6.8] Kallesoe C.S., *Model-based stator fault detection in induction motors*, Industry Applications Society Annual Meeting, IAS '08, 2008, 1–8.
- [6.9] Kowalski C.T., Wierzbicki R., *Application of the extended Kalman filter for rotor and stator fault detection of the induction motor*, Poznań University of Technology Academic Journals, Electrical Engineering, 2007, iss. 55, 145–155.
- [6.10] Kowalski C.T., Wierzbicki R., Dyrz K., *Zastosowanie filtru Kalmana do wykrywania uszkodzeń wirnika silnika indukcyjnego*, Zagadnienia maszyn, napędów i pomiarów elektrycznych, Wrocław, Oficyna Wyd. PWr., 2007, 158–167.
- [6.11] Kowalski C.T., Wierzbicki R., *Zastosowanie rozszerzonego obserwatora stanu i parametrów do wykrywania uszkodzeń uzwojenia wirnika oraz stojana silnika indukcyjnego*, Zeszyty Problelowe – Maszyny Elektryczne, nr 84, 2009, Komel, 65–69.
- [6.12] Kowalski C.T., Orłowska-Kowalska T., Wierzbicki R., *Application of the state estimators for stator and rotor fault monitoring of the inverter-fed induction motor drive*, 17th Int. Conf. on Electrical Drives and Power Electronics, EDPE 2011, High Tatras, Slovak Rep., 2011, CD.
- [6.13] Kowalski C., Wierzbicki R., Wolkiewicz M., *Stator and Rotor Faults Monitoring of the Inverter-Fed Induction Motor Drive using State Estimators*, Automatika – Intern. Journal for Control, Measurement, Electronics, Computing and Communications, Vol. 54, No. 3, 2013.
- [6.14] Kowalski C.T., Wierzbicki R., *Online stator and rotor fault detection in the inverter-fed induction motor drive*, XXI Symp. of Electromagnetic Phenomena in Nonlinear Circuits, EPNC 2010, Dortmund-Essen, Germany, 2010, 31–32.
- [6.15] Kubota H., Matsuse K., Nakano T.C., *DSP-based speed adaptive flux observer of induction motor*, IEEE Industry Applications Society Annual Meeting, Vol. 1, 1991, 380–384.
- [6.16] Kubota H., Tamura Y., *Stator resistance estimation for sensorless induction motor drives under regenerating condition*, 28th Ann. Conf. on Industrial Electronics Society IECON, Vol. 2, 2002, 426–430.
- [6.17] Orłowska-Kowalska T., *Application of extended Luenberger observer for flux and rotor time-constant estimation in induction motor drives*, IEE Proc. Part B – Control Theory and Applications, Vol. 136, No. 6, 1989, 324–330.
- [6.18] Orłowska-Kowalska T., *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.
- [6.19] Orłowska-Kowalska T., Dybkowski M., Kowalski Cz. *Rotor fault analysis in the sensorless field oriented controlled induction motor drive*, Automatika – Intern. Journal for Control, Measurement, Electronics, Computing and Communications, Vol. 51, No. 2, 2010, 149–156.

- [6.20] Wierzbicki R., *Diagnostyka uszkodzeń stojana i wirnika silnika indukcyjnego pracującego w zamkniętej wektorowej strukturze sterowania prędkością*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, nr 30, 2010.
- [6.21] Wierzbicki R., Kowalski C.T., *Wykrywanie uszkodzeń uzwojenia wirnika przekształtnikowego układu napędowego z silnikiem indukcyjnym*, Maszyny Elektryczne, Zeszyty Problemowe, nr 87, 2010, 179–184.
- [6.22] Wierzbicki R., Kowalski C.T., *Zastosowanie rozszerzonego filtru Kalmana do diagnostyki zwarć zwojowych w uzwojeniu stojana silnika indukcyjnego*, Przegląd Elektrotechniczny, R. 86, nr 2, 2010, 82–86.
- [6.23] Wierzbicki R., *Diagnostyka silników indukcyjnych z zastosowaniem estymatorów stanu i parametrów*, Rozprawa Doktorska, Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2011.

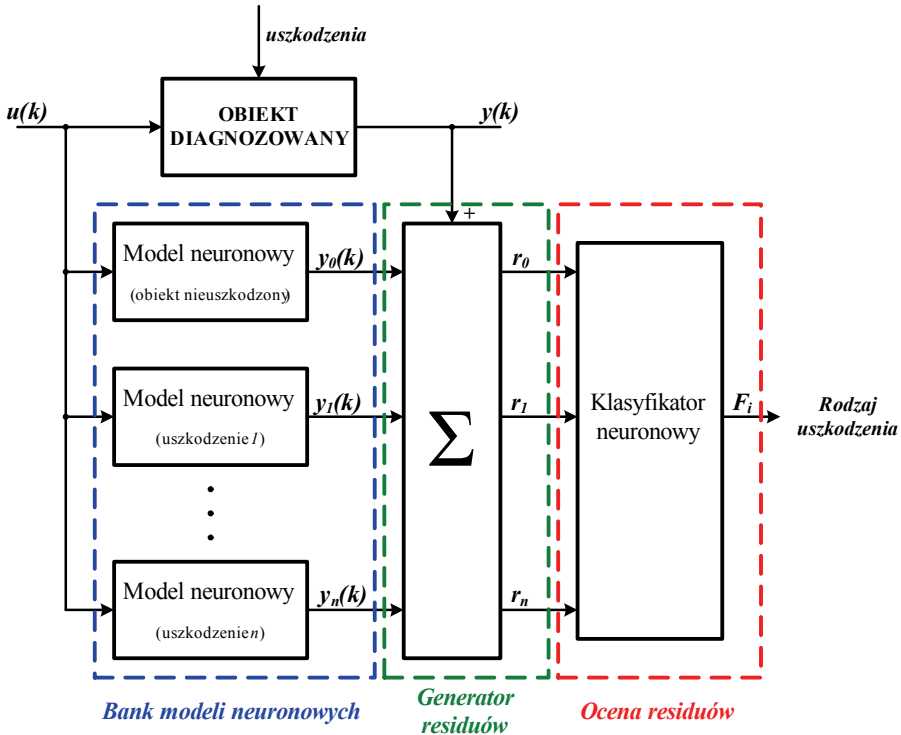
7. Metody sztucznej inteligencji w diagnostyce

7.1. Wprowadzenie

Monitorowanie stanu obiektu technicznego, w tym elektrycznego układu napędowego, polega na ciągłej obserwacji, gromadzeniu i przetwarzaniu licznych cech sygnałów diagnostycznych związanych z działaniem danego układu. Interpretacja wyników analizy sygnałów diagnostycznych jest procesem złożonym i wymagającym dużej wiedzy o budowie konstrukcyjnej i zjawiskach fizycznych zachodzących w napędzie. Brak ogólnych metod formalnego zapisu wiedzy diagnostycznej eksperta bardzo utrudnia automatyzację procesu wnioskowania diagnostycznego. Dodatkowym utrudnieniem jest brak wzorców diagnostycznych dla różnych przypadków uszkodzeń, rozwiązań konstrukcyjnych napędów oraz stanów pracy. Złożoność zagadnień diagnostycznych oraz trudności związane z wyznaczaniem dokładnych modeli matematycznych, stanowiących podstawę metod analitycznych w diagnostyce, powodują, że poszukuje się nowych metod i technik pomocnych w rozwiązywaniu problemów diagnostycznych. Coraz częściej do tego celu stosuje się metody sztucznej inteligencji wykorzystujące sztuczne sieci neuronowe, logikę rozmytą i sieci neuronowe rozmyte. W układach diagnostyki sieci neuronowe i logikę rozmytą można z powodzeniem stosować do modelowania czy identyfikacji uszkodzeń, jak również do podejmowania decyzji o stanach awaryjnych. O popularności metod sztucznej inteligencji świadczą liczne publikacje związane z badaniami naukowymi prowadzonymi w tej dziedzinie oraz informacje o zastosowaniach [7.2–7.5, 7.7–7.10, 7.12, 7.13, 7.15, 7.18].

Zadaniem układów detekcji uszkodzeń jest określenie stanu badanego obiektu na podstawie dostępnych danych pomiarowych oraz wiedzy opisującej zasady działania diagnozowanego obiektu (procesu), np. modeli matematycznych lub/i jakościowych. Wykorzystanie modeli neuronowych lub rozmyto-neuronowych w systemie diagnostycznym może być zrealizowane na wiele sposobów, ale najczęściej można wyróżnić dwa schematy postępowania. Pierwszy schemat (rys. 7.1) jest oparty na zastosowaniu sieci neuronowej do generacji residuów (patrz rozdz. 1) za pomocą banku neuronowych modeli odpowiadających różnym stanom diagnozowanego obiektu [7.9, 7.10]. Każdy model neuronowy reprezentuje jeden z przyjętych stanów pracy obiektu. Mo-

del 0 identyfikuje obiekt podczas pracy w warunkach normalnych, a każdy następny reprezentuje zachowanie się obiektu w przypadku wystąpienia określonego uszkodzenia F_i , $i = 1, \dots, n$. Korzystając z banku modeli neuronowych, można wyznaczyć wektor sygnałów residuum $\mathbf{r} = [r_0, r_1, \dots, r_n]$, porównując wyjścia obiektu $\mathbf{y}(k)$ i wyjścia modeli neuronowych. Dane uczące dla sieci neuronowych są pobierane w miarę możliwości bezpośrednio z obiektu lub pośrednio z symulatorów. Dostęp do danych opisujących różne warianty uszkodzeń jest bardzo ważny do zweryfikowania poprawności opracowanego modelu. W większości przypadków zebranie takich danych jest bardzo trudne lub wręcz niemożliwe i weryfikację modelu wykonuje się korzystając z danych z symulatora obiektu [7.10].



Rys. 7.1. Diagnostyka obiektu technicznego z wykorzystaniem sztucznych sieci neuronowych lub logiki rozmytej oparta na banku modeli stanów obiektu

Dlatego wydaje się, że w przypadku obiektów typu elektryczny układ napędowy większe praktyczne znaczenie ma inny schemat z zastosowaniem metod sztucznej inteligencji przedstawiony w rozdziale 1 na rys. 1.6b. Dotyczy on zastosowania sztucznych sieci neuronowych i logiki rozmytej do budowy tzw. detektorów i klasyfikatorów uszkodzeń. Zadaniem sieci neuronowej i/lub systemu rozmytego jest wykry-

cie uszkodzenia i jego klasyfikacja (ocena stopnia uszkodzenia) na podstawie informacji pomiarowej z obiektu, poddanej wcześniej odpowiedniej analizie w celu wyodrębnienia symptomów uszkodzeń.

Neuronowe i rozmyte detektory uszkodzeń można budować na podstawie danych uzyskiwanych z badań symulacyjnych (informacji z modelowania matematycznego – generowanie wzorców diagnostycznych) lub z pomiarów na obiekcie rzeczywistym (wykorzystanie informacji z analizy sygnałów pomiarowych). Jedną z ważniejszych cech tego typu detektorów jest szybka realizacja procesu przetwarzania wiedzy pozyskanej w procesie uczenia oraz udzielanie szybkiej odpowiedzi diagnostycznej. Metody i techniki sztucznej inteligencji umożliwiają w znacznym stopniu zobjektywizowanie procesu klasyfikacji i oceny uszkodzenia. Tym samym pojawia się możliwość zmniejszenia roli człowieka–eksperta w procesie diagnozowania oraz możliwość automatyzacji tego procesu.

W dalszej części monografii przedstawiono możliwości realizacji detektorów i klasyfikatorów podstawowych uszkodzeń silnika indukcyjnego z zastosowaniem metod sztucznej inteligencji, opracowane w badaniach prowadzonych w zespole Autora.

7.2. Podstawowe informacje o sieciach neuronowych

Rosnące wciąż zainteresowanie sieciami neuronowymi wynika z ich podstawowych atrakcyjnych właściwości, takich jak:

- aproksymacja dowolnych nieliniowych odwzorowań,
- adaptacja, czyli zdolność uczenia się,
- równoległe przetwarzanie danych, które zapewnia dużą szybkość działania w porównaniu z klasycznymi algorytmami sekwencyjnymi,
- generalizacja, tzn. możliwość obróbki danych niekompletnych lub nieco odmiennych od tych, dla których sieć była uczona.

Atutem sieci neuronowych jest możliwość zastosowania ich w sytuacji, kiedy zadowolą metody algorytmiczne, tzn. gdy algorytm rozwiązania zadania nie jest znany. Sieci neuronowych używa się do rozwiązywania problemów, które dotychczas nie znalazły satysfakcjonujących rozwiązań lub gdy istniejące metody algorytmiczne są bardzo skomplikowane i związane z dużymi nakładami realizacyjnymi.

Korzystne właściwości sztucznych sieci neuronowych spowodowały, że są one stosowane w takich dziedzinach, jak: rozpoznawanie i klasyfikacja obrazów, estymacja funkcji, systemy ekspertowe [7.6, 7.9, 7.11].

Sztuczna sieć neuronowa (SN) to system przetwarzania informacji, którego architektura i sposób funkcjonowania zaczerpnięto z modeli biologicznych układów nerwowych [7.3, 7.6, 7.14, 7.16, 7.19, 7.21]. Sieć neuronowa składa się z dużej liczby

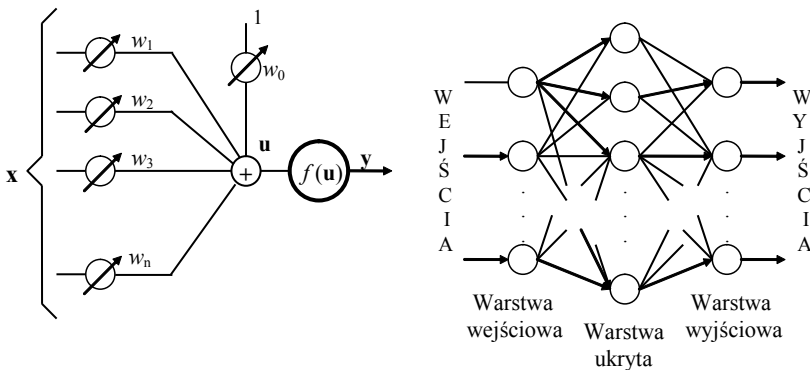
prosty element przetwarzający – neuron. Każdy neuron ma wiele wejść i jedno wyjście. Wyjście każdego neuronu jest w ogólności ważoną sumą n wejść x_j , przekształconą przez nieliniową funkcję aktywacji $f(u)$ (rys. 7.2). Sygnał ten jest następnie używany jako wejście dla innych neuronów. Schematowi z rys. 7.2 odpowiada następujący opis, traktowany jako model matematyczny neuronu:

$$u(x) = \sum_{j=1}^n w_j x_j + w_0 \quad (7.1)$$

$$y(x) = f(u(x))$$

gdzie: w_0 – wartość progowa, w_j – współczynniki wagowe.

Pojedyncze neurony można łączyć równolegle w dowolną liczbę poziomów, tzw. warstw. W każdym z poziomów wykorzystuje się taki sam typ połączenia oraz taką samą funkcję aktywacji neuronów. Liczba neuronów, połączenia oraz liczba warstw jest konfigurowana dowolnie i nosi nazwę architektury lub topologii sieci.



Rys. 7.2. Budowa neuronu i przykład sieci dwuwarstwowej

W przypadku sieci wielowarstwowych (rys. 7.3b) wejścia są transmitowane do wyjść zgodnie z następującym równaniem:

$$y_j^{(s)} = f \left(\sum_i (w_{ij}^{(s)} \cdot x_i^{(s-1)}) \right) \quad (7.2)$$

gdzie:

- $y_j^{(s)}$ – aktualny sygnał wyjściowy j -tego neuronu w warstwie s ,
- $w_{ij}^{(s)}$ – współczynnik wagowy połączenia i -tego neuronu w warstwie $s-1$ z j -tym neuronem w warstwie s ,
- f – funkcja aktywacji.

W dalszych rozważaniach, dotyczących sieci wielowarstwowych, warstwy wejściowej, w której nie następuje przetwarzanie przez funkcje aktywacji neuronów, nie bierze się pod uwagę. Za sieć np. dwuwarstwową uważa się sieć z jedną warstwą ukrytą, czyli składa się ona z warstwy wejściowej, warstwy ukrytej i warstwy wyjściowej.

Rozróżnia się sieci wielowarstwowe jednokierunkowe (ang. *feedforward neural networks*), w których kierunek przesyłania informacji jest od wejścia do wyjścia oraz sieci ze sprzężeniami zwrotnymi (ang. *feedback neural networks*).

Sieć neuronowa jest charakteryzowana przez typ składowych neuronów (ich funkcję aktywacji f (np. liniowa lub nieliniowa: skokowa, sigmoidalna, tangens hiperboliczny), sposób połączenia między neuronami oraz sposób, w jaki są dobierane wartości wag w_{ij} , czyli algorytm uczenia. Celem odpowiedniej modyfikacji wartości wag jest osiągnięcie pożądanej funkcji przetwarzania sieci widzianej jako całość. Proces ten to uczenie sieci. Zwykle proces uczenia sieci rozpoczyna się wartościami wag wybranymi losowo, przy czym podczas uczenia wagi są modyfikowane według wybranego algorytmu uczenia. Należy zaznaczyć, że algorytm uczenia sieci nie ma nic wspólnego z algorytmem, według którego wyuczona już sieć rozwiązuje zadany jej problem. Algorytm, którego sieć dopracowuje się podczas uczenia zwykle nie jest znany dla jej projektantów.

Podstawowe operacje wykonywane przez sieć neuronową można porównać do reakcji na bodźce. Gdy na wejście sieci wprowadzony zostaje jakiś wektor wejściowy (obraz), neurony stają się aktywne w stopniu zależnym od ich wag wejściowych i w efekcie generują odpowiedź adekwatną do wymuszenia. Sposób funkcjonowania typu *wymuszenie–aktywacja–odpowiedź* opisuje zarówno działanie pojedynczego neuronu, jak i całej sieci. Sieć użyteczna, to sieć nauczona, czyli taka, która na dane wymuszenie wygeneruje dobrą odpowiedź. Procesu uczenia sieci dokonuje się przez prezentację przykładów. Uczenie może przebiegać z nauczycielem lub bez niego. Jeżeli uczenie przebiega z nauczycielem, to zestaw przykładów składa się z par: *wymuszenie–pożądana odpowiedź*. W przypadku uczenia sieci neuronowej bez nauczyciela prezentowany jest jedynie odpowiedni zestaw wymuszeń. W praktyce inżynierskiej 80–90% stosuje uczenie się z nauczycielem [7.14]. W uproszczeniu procedura ta wygląda następująco:

Faza prezentacji: na wejście sieci jest podawane wymuszenie \mathbf{x} , a sieć udziela odpowiedzi $\mathbf{y}(\mathbf{x})$.

Faza porównania: odpowiedź sieci jest porównywana z odpowiedzią pożądaną $\mathbf{d}(\mathbf{x})$ i jest obliczany sygnał błędu, np.: $\boldsymbol{\varepsilon} = \mathbf{d}(\mathbf{x}) - \mathbf{y}(\mathbf{x})$.

Faza uczenia: na podstawie sygnału błędu, w sposób zależny od wybranego algorytmu uczenia, są modyfikowane wartości wag tak, aby kolejna odpowiedź stała się bliższa pożądanej.

Trójfazowy cykl jest stosowany dla całego zestawu przykładów i powtarzany wielokrotnie. Uczenie kończy się, gdy błąd sumaryczny dla tego zestawu zejdzie po-

niziej wymaganej wartości. W przypadku uczenia bez nauczyciela pożądane odpowiedzi nie są dostępne, a sieć dokonuje samoorganizacji w taki sposób, aby osiągnąć stan stabilności energetycznej. Po nauczaniu sieć udziela poprawnych odpowiedzi na wszystkie pytania spośród zestawu uczącego, ale nie tylko. Jej wielką zaletą jest to, że ma ona zdolność uogólniania, czyli udzielania dobrych odpowiedzi na pytania spoza zestawu uczącego, jeśli tylko zestaw uczący był reprezentatywny dla problemu danej klasy. Właśnie tu zawarta jest sztuczna inteligencja sieci – na podobne wymuszenie sieć reaguje najbardziej zbliżoną odpowiedzią, korzystając z własnych doświadczeń. Dobrym przykładem jest aproksymacja funkcji: sieć wyuczona na wybranym zestawie próbek potrafi następnie aproksymować przebieg funkcji w całej dziedzinie. Ogólnie sieć neuronowa dokonuje przekształcenia R^n wymiarowej przestrzeni $\{\mathbf{X}\}$, na R^m wymiarową przestrzeń $\{\mathbf{Y}\}$, przy czym postać przekształcenia formowana jest w procesie uczenia.

Istnieje wiele algorytmów uczenia sztucznych sieci neuronowych (SSN). Najbardziej rozpowszechnione są uogólnione zasady delty (ang. *Delta Rules*) oraz powszechnie stosowany do uczenia sieci wielowarstwowych algorytm wstecznej propagacji błędów (ang. *backpropagation*) [7.10, 7.14, 7.19].

W klasycznym algorytmie propagacji wstecznej stosuje się metodę największego spadku, zgodnie z którą przyrosty wag Δw_{ij} określa się według kierunku ujemnego gradientu (zmiana wartości wag odbywa się pod wpływem gradientu funkcji celu w kierunku największego spadku):

$$\Delta w_{ij} = -\eta(y_i - d_i) \frac{d f(u_i)}{d u_i} x_j \quad (7.3)$$

gdzie:

- η – współczynnik uczenia,
- $f(u_i)$ – funkcja aktywacji.

W przypadku kiedy funkcja aktywacji jest funkcją liniową, wzór (7.3) sprowadza się do następującej zależności:

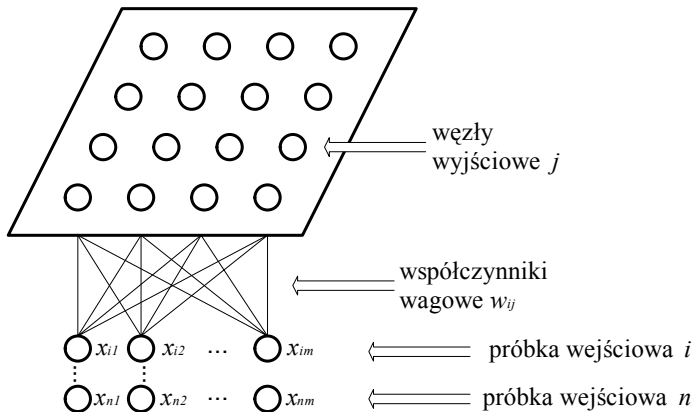
$$\Delta w_{ij} = -\eta(y_i - d_i)x_j \quad (7.4)$$

Jedną z istotnych niedogodności metody propagacji wstecznej, jako sposobu uczenia sieci neuronowej, jest to, że wymagają one „nauczyciela”, którego zadaniem jest podawanie do każdego wzorcowego wektora wejściowego, wektora oczekiwanej odpowiedzi sieci. Dlatego rozwinęły się sieci, które powinny „odkryć” bez zewnętrznej zależności uporządkowanie danych wejściowych, a następnie podać te informacje w odpowiednio zakodowanej postaci na wyjście.

Uczenie „bez nauczyciela” nazywa się również *nienadzorowanym*. Jest możliwe wówczas, kiedy mamy do czynienia z redundancją danych wejściowych [7.6, 7.10, 7.14, 7.21, 7.22]. Bez tej cechy obrazów uczących byłoby niemożliwe wyodrębnienie

z nich wzorców, czy też rozpoznawanie cech. Aby sieć mogła pracować bez zakłóceń, powinna istnieć możliwość podziału zbioru obrazów wejściowych na rozłączne klasy, według dobrze określonych cech wspólnych. Sieć powinna być zdolna do zidentyfikowania wspomnianych wspólnych cech w dowolnym prezentowanym wektorze wejściowym.


Opisany sposób uczenia nienadzorowanego możliwy jest w tzw. *sieciach samoorganizujących się*, wśród których podstawowe znaczenie mają tzw. sieci odwzorowujące Kohonena (rys. 7.3) [7.3, 7.21]. W razie braku informacji *a priori* o przynależności obrazów wejściowych do określonych klas, sieć będzie stopniowo definiowała klasy i linie podziału między nimi w miarę wykrywania wspólnych cech charakteryzujących pewne grupy danych wejściowych. Działaniem pierwotnym w stosunku do klasyfikacji, czyli ustalania przynależności danego obiektu do zdefiniowanej klasy, jest grupowanie (ang. *clustering*). Przez grupowanie rozumie się kojarzenie obiektów podobnych i rozdzielanie różnych. Sieć Kohonena klasyfikuje wektory wejściowe x_i na p kategorii wykrywanych podczas grupowania zbioru uczącego. Sieć musi sama wykrywać wszelkie istotne dla niej zależności w zbiorze danych wejściowych, aby z czasem nauczyć się rozpoznawania obrazów, ich kategorii, cech istotnych czy regularności bez pomocy nauczyciela. W tym celu sieć powinna posłużyć się określoną miarą podobieństwa zaprezentowanego jej obrazu do obrazów znanych z przeszłości. Najpopularniejszą miarą podobieństwa obrazów x i x_j jest odległość Euklidesa.



Rys. 7.3. Schemat ideowy sieci neuronowej typu Kohonena

Inną popularną miarą jest sąsiedztwo topologiczne, czyli odległość między tymi spośród neuronów ułożonych w regularne struktury geometryczne, które zostają pobudzone danym obrazem wejściowym. To drugie podejście umożliwia określanie sąsiedztwa danego neuronu w postaci zbioru neuronów powiązanych między sobą odpowiednimi relacjami topologicznymi. Sąsiedztwo różnych rozmiarów w przypadku siatki prostokątnej przedstawiono na rysunku 7.4. W mniejszym prostokącie znalaz-

zły się neurony będące sąsiadami wybranego centralnego neuronu, natomiast w większym prostokącie zawarte są neurony należące do sąsiedztwa drugiego rzędu. Analogicznie określa się sąsiedztwo w innych topologiach sieci.



Rys. 7.4. Sąsiedztwo pierwszego i drugiego rzędu w sieci samoorganizującej z topologią prostokątną

W podstawowym algorytmie sieci samoorganizującej się zarówno liczba neuronów, jak i topologia sieci określa się od początku i nie ulegają zmianie w procesie uczenia sieci. Zmniejsza się natomiast rozmiar sąsiedztwa tak, aby w końcowym etapie sąsiedztwo było zerowego rzędu i składało się jedynie z rozpatrywanego neuronu. Uczenie sieci jest procesem iteracyjnym, skojarzonym z czasem $t = 1, 2, \dots$

Algorytmy samouczenia się sieci prowadzą do sensownej adaptacji wag w trakcie procesu zwanego samoorganizacją. Sieci uczone w tym trybie reagowały nie tylko na wartości sygnałów wejściowych, lecz również na prawdopodobieństwo ich pojawienia się. Uczenie więc wymaga nadmiarowych danych wejściowych. Rzadko występujące wektory wejściowe mają mniejszy wpływ na przebieg nauki niż wektory pojawiające się często.

W początkowej fazie uczenia odpowiedzi sieci mogą być nie do przyjęcia. Sieć musi stopniowo uczyć się, które cechy sygnałów wejściowych są ważne dla jej prawidłowego działania, a które można zaniedbać. Może się to odbywać na przykład według reguły *wygrywający bierze wszystko* (ang. *winner takes all*) przyznającej prawo do korekcji wag tylko temu neuronowi (a czasami również jego najbliższemu sąsiadowi), który jest najbardziej wrażliwy na aktualny sygnał wejściowy [7.22].

Jeżeli $\mathbf{x} = \{x_1, x_2, \dots, x_m\}$ oznacza aktualnie prezentowany wektor wejściowy, to zadaniem sieci jest wybranie spośród wszystkich neuronów takiego neuronu W_c , który jest najbliższy w stosunku do wektora \mathbf{x} względem wybranej metryki, np.:

$$\|\mathbf{x} - \mathbf{w}_m\| = \min_i \{\|\mathbf{x} - \mathbf{w}_i\|\} \quad (7.5)$$

Wagi wygrywającego neuronu W_c oraz jego sąsiadów N_c są aktualizowane w taki sposób, aby upodobnić je do prezentowanego wzorca \mathbf{x} . Zbiór sąsiadów N_c jest zależ-

ny od wybranej topologii sieci i jest ograniczany w miarę postępu procesu uczenia, czyli promień wzajemnych oddziaływań S_i maleje.

W sieciach typu Kohonena uaktualnianie wag odbywa się wg reguły:

$$\Delta \mathbf{w}_i(t+1) = \alpha(S_i, t)[\mathbf{x} - \mathbf{w}_i(t)] \quad (7.6)$$

gdzie $0 < \alpha < 1$ – współczynnik uczenia malejący w miarę uczenia i zależny od promienia sąsiedztwa S_i .

Neuron zwycięzca przyjmuje wartość sygnału wyjściowego równą $y_i = 1$. Neurony należące do sąsiedztwa zwycięzcy przyjmują wartości $y_i \neq 0$, malejące wraz z odległością od zwycięzcy. W efekcie tylko neurony najbliższe zwycięzcy uaktualniają w istotny sposób swoje wagi, podążając w ten sposób za zwycięzcą. Z zależności (7.5) widać, że wektor wag i -tego neuronu przyjmuje wartość zbliżoną do odpowiednich składowych wektora \mathbf{x} , dla których i -ty neuron jest zwycięzcą. Wektory wag neuronów sąsiadujących ze zwycięzcą podążają za nim, jednak zmiana wartości ich wag jest znacznie mniejsza.

W wyniku zastosowanego trybu uczenia, poszczególne neurony sieci otrzymują wagi, które mogą być zinterpretowane na płaszczyźnie (x_1, x_2) w taki sposób jak współrzędne wektorów wejściowych \mathbf{x} . Rozmieszczenie ich na płaszczyźnie tworzy węzły, które połączone z najbliższymi sąsiadami reprezentują kształt odtwarzający rozkład danych wejściowych. Jest to rozkład odpowiadający gęstości pojawiania się danych wejściowych w danym rejonie, a nie współrzędnych odpowiednich wektorów, gdyż liczba prezentowanych wektorów wejściowych \mathbf{x} jest zwykle o kilka rzędów wielkości większa niż liczba neuronów w sieci.

Samoorganizująca się sieć odwzorowań Kohonena znalazła liczne zastosowania w praktyce. Podstawową funkcją, jaką pełni, jest odwzorowanie topologii danych wejściowych przez dużo mniejszą liczbę współrzędnych wag neuronów tworzących sieć. Stąd jej bezpośrednie zastosowanie w kompresji danych i diagnostyce.

7.3. Sieci neuronowe w diagnostyce

Konwencjonalne podejście do budowy systemów diagnostycznych (ekspertowych) wymaga utworzenia bazy wiedzy zawierającej sformułowane przez człowieka reguły w postaci „jeżeli – to”, wyrażające wiedzę z określonej dziedziny. Reguły te i dane wejściowe wykorzystywane są w procesie wnioskowania (poszukiwania diagnozy). Zadanie wydobywania wiedzy od eksperta i przełożenie jej na język formalny (ekstrakcja wiedzy) wymaga od eksperta posiadania wiedzy o ścisłych regułach (modelach matematycznych) w danej dziedzinie. Jednak ekspert ma również wiedzę intuicyjną, niejawną, trudną do sformalizowania, którą bardzo ciężko jest przetworzyć na reguły. Często jest to wręcz niemożliwe.

Wszystko to powoduje, że ekstrakcja wiedzy jest dużym problemem utrudniającym budowanie efektywnych systemów diagnostycznych. Tworzenie ich jest zagadnieniem trudnym, pracochłonnym i kosztownym. Ciągłe trwają badania i poszukiwania rozwiązań przydatnych w praktyce przemysłowej. Jedną z takich dróg poszukiwań jest sprawdzanie przydatności metod sztucznej inteligencji [7.3, 7.21, 7.22].

Szczególnie przydatne w diagnostyce są sztuczne sieci neuronowe i sieci neuronowe rozmyte. Ze względu na fakt, że sieci neuronowe nie wymagają znajomości formalnych zależności między przetwarzanymi danymi, mogą one stanowić istotną alternatywę dla systemów regulowych. W systemach tego rodzaju (tzw. systemach konekcyjnych), na węzły wejściowe sieci warstwowej podawane są informacje o wybranych symptomach i ich parametrach. Sztuczne sieci neuronowe działają jak równoległe, rozproszone systemy obliczeniowe. Mogą więc, swoją zdolnością do podejmowania decyzji i uczenia się przez doświadczenie, uzupełniać wielką moc obliczeniową komputerów programowalnych. Przy ogromnej skali powiązań neuronowych możliwe jest znaczne przyspieszenie procesu przetwarzania informacji. W wielu przypadkach jest możliwe przetwarzanie sygnałów w czasie rzeczywistym. Ponadto przy dużej liczbie powiązań międzyneuronowych sieć staje się odporna na błędy występujące w niektórych powiązaniach.

Sieci neuronowe mogą pełnić różne funkcje w zastosowaniach praktycznych. Funkcje te można sklasyfikować w kilku podstawowych grupach: aproksymacja, klasyfikacja i rozpoznawanie wzorców, predykcja, sterowanie oraz asocjacja. Sieć neuronowa może być uniwersalnym aproksymatorem funkcji nieliniowej wielu zmiennych wykorzystywanym w zadaniach modelowania, identyfikacji i przetwarzania sygnałów [7.3, 7.10, 7.13, 7.14, 7.21].

Inną formą przetwarzania neuronowego jest kojarzenie. Sieć może zapamiętywać pewien zbiór obrazów wzorcowych i jeżeli przedstawi się jej obraz podobny do któregoś z zapamiętanych, to może ona te obrazy skojarzyć (autoasocjacja lub heteroasocjacja). Jeszcze inną formą przetwarzania neuronowego jest klasyfikacja i rozpoznawanie. Jeżeli zbiór wejściowy dzieli się na kilka klas, to w odpowiedzi na obraz wejściowy z tego zbioru klasyfikator powinien podać informację o klasie, do której należy obraz.

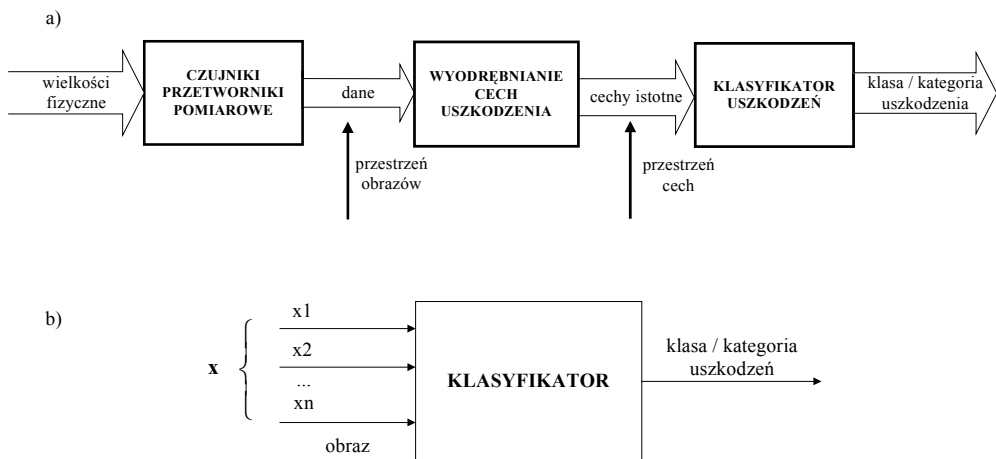
W systemach diagnostycznych podstawowe znaczenie mają sieci neuronowe realizujące funkcje klasyfikatora stanów obiektu lub funkcje rozpoznawania. Sieci neuronowe można wykorzystywać w zagadnieniach diagnostyki jako klasyfikatory stanów obiektu na podstawie zebranych danych pomiarowych. Uznając, że stan obiektu jest swego rodzaju obrazem, można problem diagnozowania traktować jako zadanie rozpoznawania obrazów lub ich klasyfikowania. Każdy obraz stanu obiektu charakteryzuje się określonym zestawem wartości sygnałów wejściowych i wyjściowych.

Przez pojęcie rozpoznawania i klasyfikacji obrazów uszkodzeń należy rozumieć identyfikację uszkodzenia i przypisanie go do odpowiedniej klasy lub kategorii. Pojęcie klasy uszkodzenia jest rozumiane jako stopień uszkodzenia. Stopień uszkodzenia

określany przez sieć neuronową może być precyzyjny, np. liczba uszkodzonych prętów wirnika lub opisowy, np. duże, średnie, małe uszkodzenie. Natomiast przez pojęcie kategoria uszkodzenia rozumie się rodzaj uszkodzenia, np. uszkodzenie wirnika, stojana lub łożyska.

Sieć neuronowa może pełnić funkcję zarówno ekstraktora cech, jak i klasyfikatora, dokonującego przypisania uszkodzenia do odpowiedniej klasy. Zwykle jednak ekstrakcja cech uszkodzenia jest realizowana w odrębnym etapie wstępnego przetwarzania sygnałów pomiarowych, w tzw. preprocesorze. Często ekstraktor realizuje kompresję danych tak, aby otrzymać mniejszy wymiar wektora cech. Wektory cech, mając mniejszą wymiarowość, zachowują się tak samo jak przed kompresją, prawdopodobieństwo poprawnej klasyfikacji i w rezultacie dalsze przetwarzanie danych staje się łatwiejsze. Spotyka się również rozwiązania bez preprocesora cech. Na wejście klasyfikatora podawany jest bezpośrednio obraz wejściowy z przetworników obrazu. Na rysunku 7.5 przedstawiono schemat ideowy systemu diagnostycznego traktowanego jako system rozpoznający i klasyfikujący w rozumieniu teorii sieci neuronowych [7.12, 7.22].

Celem działania takiego systemu jest rozpoznanie uszkodzenia i przyporządkowanie go do określonej klasy/kategorii. Sygnały wyjściowe preprocesora są sygnałami wejściowymi dla sieci neuronowej pełniącej funkcję układu rozpoznającego i jednocześnie dokonującej klasyfikacji (przypisania obrazu do odpowiedniej klasy). Liczba węzłów wejściowych sieci jest równa liczbie cech charakteryzujących uszkodzenia. Neurony wyjściowe reprezentują klasy i/lub kategorie uszkodzenia. Liczba warstw ukrytych i neuronów w warstwie podlega doborowi według metodyki przedstawionej w rozdziale 7.4.



Rys. 7.5. System diagnostyczny jako system rozpoznający i klasyfikujący:
a – schemat ogólny, b – klasyfikator

Diagnostyka za pomocą sieci neuronowej wymaga dokonania arbitralnej klasyfikacji wzorców uczących dla wybranych obszarów przestrzeni obserwacji. Każdy wzorzec jest opisany za pomocą określonych cech stanowiących wektor w przestrzeni n -wymiarowej. Klasę można zdefiniować jako zbiór punktów w tej przestrzeni, odpowiadający wybranemu stanowi obiektu (stan normalny lub uszkodzenie). Zestawy uczące klasyfikator neuronowy muszą być tak dobrane, aby po zakończeniu uczenia sieci poszczególne klasy miały dobrze rozdzielone granice. Drugim ważnym elementem jest liczba wzorców uczących. Od poprawności klasyfikacji wzorców uczących zależy poprawność separacji obszarów. Sieć neuronowa dokonuje klasyfikacji za pomocą funkcji ekstrapolacyjnych opartych o wyznaczone w procesie uczenia współczynniki wagowe.

Aby proces detekcji uszkodzenia za pomocą neuronowego detektora przebiegał prawidłowo, muszą być spełnione następujące wymagania [7.3]:

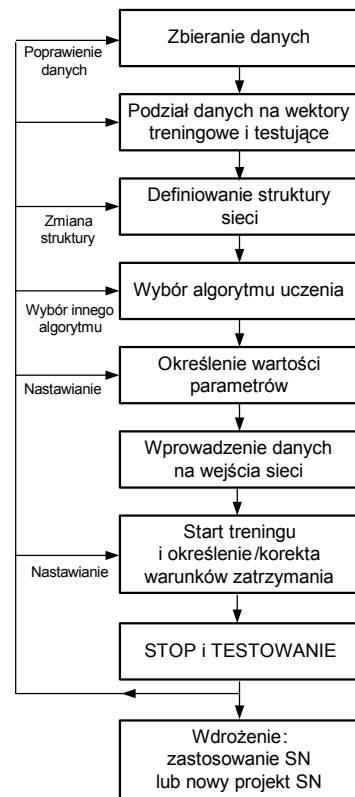
- wzorce danych wejściowych w trakcie uczenia powinny być przygotowywane dla rozłącznych klas,
- sieć powinna zostać nauczona identyfikowania uszkodzeń na podstawie częściowego lub zakłóconego wejścia,
- mechanizm uogólniania (działanie klasyfikacji) powinien zostać sprawdzony w przypadku występowania szumów i zniekształceń sygnałów wejściowych.

Kolejnym problemem występującym w budowie detektorów neuronowych uszkodzeń jest odpowiedni dobór liczby wzorców uczących. Zgodna z teorią sieci neuronowych liczba wzorców uczących zazwyczaj jest niewystarczająca w praktyce. Często też uzyskanie bardzo małego błędu w czasie uczenia nie zapewnia dobrego diagnozowania [7.14].

Istotną zaletą sieci neuronowych jest możliwość ich realizacji w technice o wielkim stopniu scalenia. Zróznicowanie elementów sieci jest niewielkie, a ich powtarzalność bardzo duża, co stwarza perspektywę realizacji równoległej SN, np. w FPGA (ang. *Field Programmable Gate Arrays*). Możliwości zastosowań sieci neuronowych w przetwarzaniu sygnałów są ciągle jeszcze nie końca zbadane i wydaje się, że będą one jeszcze przez wiele lat stanowić o postępie w technice informacji i diagnostyce.

7.4. Metodyka uczenia i testowania neuronowych detektorów uszkodzeń

Projektowanie sieci neuronowej (SN) do celów diagnostycznych składa się z kilku podstawowych etapów. Jest to ciąg czynności realizowanych cyklicznie w strukturze wielopętlowej (rys. 7.6).



Rys. 7.6. Cykl przygotowania SN do wdrożenia

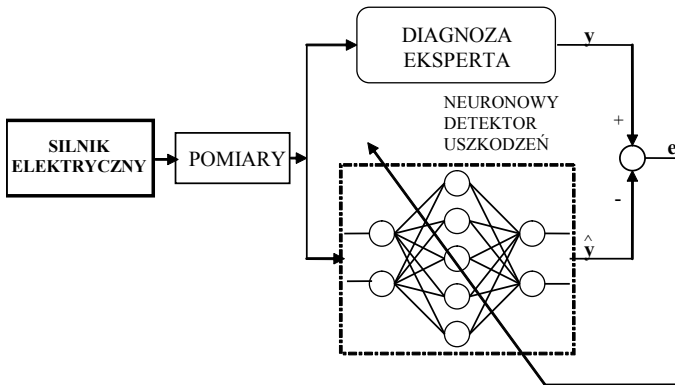
W przypadku stosowania sztucznych sieci neuronowych do budowy detektorów uszkodzeń silników kolejność podstawowych działań jest następująca:

- zdefiniowanie kategorii i/lub klas uszkodzeń;
- określenie typowych obrazów odpowiadających stanom normalnym (silnik nieuszkodzony) oraz wybranym stanom nienormalnym (silnik z określoną kategorią i klasą uszkodzenia);
- projektowanie neuronowego detektora uszkodzeń (wybór struktury sieci i algorytmu jej uczenia, uczenie sieci i testowanie sieci dla różnych kategorii i klas uszkodzeń) za pomocą komputerowych symulatorów sieci neuronowych (np. Matlab Neural Network Toolbox);
- implementacja sieci neuronowej (programowa lub sprzętowa) w komputerze lub procesorze sygnałowym i jej testowanie na obiekcie rzeczywistym.

Pierwszym krokiem jest zbieranie danych tworzących wektory wejściowe do uczenia i testowania sieci. Dane te mogą pochodzić z badań eksperymentalnych realizowanych na obiektach rzeczywistych lub z badań modelowych wykonywanych technikami symulacyjnymi w komputerach z zastosowaniem modeli matematycznych. Przed wykorzystaniem tych danych w neuronowych detektorach uszkodzeń niezbędne

jest dokonanie wstępnego przetworzenia, które przetransformuje je do postaci odpowiedniej dla wejść sieci neuronowej.

Wiedza z pomiarów i/lub symulacji stanowi, wraz z wcześniejszym doświadczeniem człowieka–eksperta, tzw. wiedzę eksperta, na podstawie której dokonywana jest przez człowieka–eksperta ocena aktualnego stanu technicznego obiektu. Znajomość tej oceny jest niezbędna do uczenia sieci neuronowej. Na rysunku 7.7 przedstawiono ideę takiego sposobu uczenia sieci. Różnica $e = y - \hat{y}$ między decyzją eksperta y a decyzją generowaną przez sieć neuronową \hat{y} służy do przestrojenia wewnętrznych parametrów (wag) sieci.




Rys. 7.7. Idea uczenia SN jako detektora uszkodzeń silnika

Uczenie sieci polega na „pokazaniu” jej odpowiednio dużej liczby obrazów – zestawów „dane wejściowe – stan obiektu”, na podstawie których nauczy się rozpoznawać i/lub klasyfikować uszkodzenia. Zebrana informacja wejściowa musi być rozdzielona na dwa rozłączne zbiory: uczący i testujący. Zbiór testujący nie powinien być używany w procedurze uczenia. Dane używane do uczenia i testowania sieci zwykle muszą być odpowiednio przygotowane, tzn. poddane różnym przekształceniom matematycznym, mającym na celu ich normalizację (skalowanie) [7.14, 7.19, 7.20]. Szczególnie dotyczy to sieci typu Kohonena.

Dla prawidłowego uczenia sieci duże znaczenie ma rozmiar zbioru uczącego. Iteracyjne algorytmy uczenia, wykorzystujące cały zbiór w każdej epoce, na ogół reagują liniowo na rozmiar zbioru uczącego. Po podwojeniu zbioru czas uczenia zwiększa się dwukrotnie. Jeżeli sieć neuronowa ma efektywnie spełniać swoje funkcje, to zbiór uczący musi być dostatecznie zupełny. Należy pamiętać, że stosowanie zbyt dużych zbiorów uczących prowadzi do nadmiernego dopasowania sieci [7.14, 7.19]. Skłonność do nadmiernego dopasowania jest proporcjonalna do wielkości sieci. Jedynym sposobem uchronienia sieci przed uczeniem się unikatowej charakterystyki zbioru uczącego, z uszczerbkiem uczenia się charakterystyki uniwersalnej, jest podanie tylu przykładów, aby nie mogła się nauczyć

wszystkich szczegółów. W [7.14] zaleca się, aby minimalna liczba próbek w zbiorze uczącym była dwa razy większa od liczby wag sieci.

Przyjmując, że błąd uczenia sieci określa jakość odtwarzania wzorców uczących przez sieć neuronową, można wyodrębnić błąd związany z odtwarzaniem przez sieć szumów pomiarowych, danych przypadkowych, zakłóceń (rys. 7.8.). Optimum, czyli najlepsza generalizacja danych występuje wtedy, kiedy oba błędy się kompensują. W celu dobrania struktury sieci neuronowej odpowiadającej optimum generalizacji danych stosuje się specjalne algorytmy modyfikujące proces uczenia [7.1, 7.14].



Rys. 7.8. Zależność błędów sieci neuronowej od złożoności jej struktury

Kolejnym krokiem jest wybór typu sieci oraz określenie jej struktury. Projektowanie architektury sieci wielowarstwowej rozpoczyna się od przyjęcia typu funkcji aktywacji w modelu neuronu. Zastosowanie nieliniowej funkcji aktywacji wprowadza nieliniowość do definicji funkcji energetycznej, wykorzystywanej w procedurze uczenia metodą wstecznej propagacji. W wyniku tego powstają możliwości utworzenia się wielu minimów lokalnych, w których może utknąć proces uczenia sieci. Wymaga to albo odpowiedniego wstępnego doboru wartości wag w taki sposób, aby uniknąć nasycania się nieliniowych funkcji aktywacji poszczególnych neuronów, albo realizuje się to przez wprowadzenie przypadkowych zmian próbek uczących w określonych cyklach. Istnieją również inne wyspecjalizowane techniki, np. tzw. wyżarzanie [7.3, 7.22] dostępne w komputerowych symulatorach sieci neuronowych.

Dobór liczby neuronów w warstwie wejściowej jest uwarunkowany wymiarem wektora wejściowego x . Podobnie jest w warstwie wyjściowej, w której liczba neuronów równa się wymiarowi wektora wyjściowego (np. rodzaje lub stopnie uszkodzeń). Problemem pozostaje dobór warstwy ukrytej i liczby neuronów w każdej warstwie. Praktycznie używa się jednej warstwy ukrytej. Nie ma również żadnych teoretycznych przesłanek, aby używać więcej niż dwóch warstw ukrytych [7.19].

Duże znaczenie ma wybór odpowiedniej liczby neuronów ukrytych. Użycie zbyt małej liczby pozbawi sieć środków potrzebnych do rozwiązania problemu. Z kolei użycie zbyt dużej liczby neuronów zwiększa istotnie czas uczenia. Ponadto nadmiar

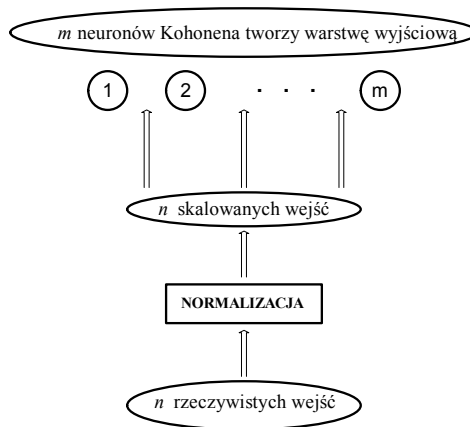
neuronów ukrytych może spowodować wystąpienie tzw. nadmiernego dopasowania. Sieć może mieć tak duże zdolności przetwarzania informacji, że będzie uczyła się nieistotnych cech zbioru uczącego, które są nieważne w populacji generalnej.

Dobór architektury sieci neuronowej optymalnej pod względem liczby neuronów i powiązań międzyneuronowych może odbywać się przez:

- redukcję sieci,
- rozszerzanie sieci.

W metodzie redukcji sieci przyjmuje się na starcie maksymalną liczbę neuronów wynikającą z twierdzenia Kołmogorowa [7.3, 7.14]. Minimalizację przeprowadza się przez modyfikację funkcji energetycznej. W metodzie rozszerzania sieci przyjmuje się strategię odwrotną. Zgrubną przesłanką wyboru liczby neuronów ukrytych dla dużej klasy problemów jest tzw. *reguła piramidy geometrycznej*, według której liczba neuronów w warstwach ukrytych tworzy kształt piramidy, przy czym liczba neuronów maleje od wejścia w kierunku wyjścia.

Po ustaleniu struktury sieci można przystąpić do trenowania sieci za pomocą odpowiednio przygotowanych wektorów danych wejściowych. Proces kształtowania architektury sieci we wszystkich przedstawionych metodach przebiega jednocześnie z uczeniem sieci (rys. 7.6). W przypadku sieci Kohonena w procesie jej projektowania występują inne problemy. Jest to w zasadzie sieć jednowarstwowa. Ponieważ wymagana jest specjalna normalizacja wejść, niektórzy nazywają ją siecią dwuwarstwową, dodając warstwę normującą wejścia. Większość badaczy uważa normalizację tylko za krok wstępnego przygotowania danych, niezasługujący na przyznanie mu specjalnej warstwy [7.14, 7.21]. Na rysunku 7.9 przedstawiono podstawową strukturę sieci Kohonena z zaznaczonym blokiem normalizacji. Wyjście każdego neuronu jest równe wejściu sieciowemu – sygnał wyjściowy neuronu równa się sumie ważonej jego sygnałów wejściowych. Nie stosuje się żadnej funkcji aktywacji.



Rys. 7.9. Sieć Kohonena z blokiem normalizacji wejść

Wirtualnie sieć Kohonena jest klasyfikatorem. Po obliczeniu wag w równaniu (7.6) w procesie uczenia prezentuje się sieci nieznaną przypadłość. Następnie zostają obliczone aktywacje wszystkich neuronów. Neuron wyjściowy o maksymalnej aktywacji jest uznany za zwycięzcę i w ten sposób wyznacza klasę, do której należy dany przypadek. Według [7.10, 7.22] sieć Kohonena jest dość słabym klasyfikatorem. Nie ma żadnej warstwy ukrytej i daje odpowiedź ściśle liniową. Dąży się do tego, aby sieć miała dużo neuronów wyjściowych, z których każdy koncentruje się na jednym wzorze.

W projektowaniu sieci Kohonena bardzo duże znaczenie ma prawidłowo zrealizowana normalizacja sygnałów wejściowych, co jest uważane za jedną z większych przeszkód w upowszechnieniu użycia tego typu sieci [7.22]. Długość wektora wejściowego musi być taka sama dla wszystkich przypadków uczących i testujących. Zwykle przyjmuje się, że długość ta jest równa 1. Pierwszym krokiem normalizacji wejść jest upewnienie się, że wszystkie zmienne są określone w dziedzinie sieci, tzn. w przedziale $[-1, +1]$. Dla każdej zmiennej określa się jej wartość maksymalną i minimalną, i wybiera przekształcenie, które odwzorowuje wartość najmniejszą na -1 , a największą na $+1$. W doborze współczynnika uczenia α najlepsze rezultaty otrzymuje się zazwyczaj przez jego stopniowe zmniejszanie w miarę postępów uczenia. Większy współczynnik przyspiesza proces uczenia, jeżeli jednak jest on zbyt duży, to mogą wystąpić problemy ze zbieżnością i wektory wag mogą dziwnie oscylować [7.22]. Proces uczenia sieci Kohonena przerywa się, gdy zmiany wektorów wag stają się nieznaczne. Wytrenowane sieci podlegają testowaniu. Jeżeli wyniki testu użytkownik uznaje za zadowalające, następuje implementacja wytrenowanej sieci jako detektora uszkodzeń.

Na podstawie obszernej literatury można sformułować praktyczne wskazówki w wykrywaniu istotnych cech z zastosowaniem sieci Kohonena. Liczba kroków uczenia musi być duża, gdyż uczenie jest tu procesem wychwytyjącym właściwości statystyczne sygnałów wejściowych. Według [7.21, 7.22] powinno być około 500 kroków na każdy neuron mapy. Zasięg sąsiedztwa może początkowo pokrywać całą sieć. Potem powinien być stopniowo redukowany aż do zera, czyli w ostatniej fazie nauki dostraja się wagi tylko pojedynczych neuronów. Warunki samoorganizacji mapy cech są następujące:

- każdy z neuronów jest pobudzany wystarczającą liczbą razy,
- korekcji podlegają tylko wagi w pobudzonym sąsiedztwie,
- korekcja jest proporcjonalna do pobudzenia neuronu.

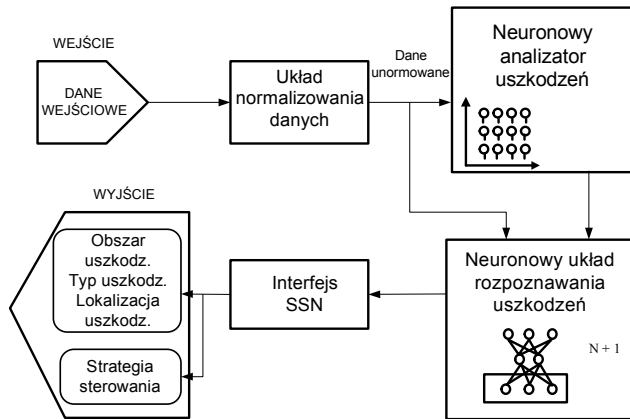
Podczas samoorganizującego uczenia mapy cech stosuje się kolejno formuły (7.5) i (7.6) dla każdego obrazu uczącego. Jeśli w rzeczywistych sytuacjach występuje jakaś naturalna kolejność pojawiania się obrazów, to należy to uwzględnić w konstrukcji ciągu uczącego.

Detektor uszkodzeń oparty na strukturze sieci Kohonena potrafi wyróżnić grupy uszkodzeń (kategorie uszkodzeń) nawet wtedy, gdy pewne cechy wzorców dla róż-

nych uszkodzeń są takie same, a węzły w mapie Kohonena są bliskie sobie. Zdarza się jednak [7.8], że sieć tworzy grupy nierozdzielone dla danego wzorca, czyli wzorce opisujące różne uszkodzenia są klasyfikowane do tych samych elementów warstwy Kohonena.

W strukturze systemu diagnostyki uszkodzeń wdrożenie struktury neuronowego detektora uszkodzeń może być zrealizowane jako:

- układ rozpoznawania uszkodzeń, którego zadaniem jest wykrycie rodzaju uszkodzenia (np. sieć samoorganizująca Kohonena),
- układ analizatora uszkodzeń, którego zadaniem jest określenie stopnia uszkodzenia (np. sieć perceptronowa).



Rys. 7.10. Idea struktury systemu diagnostyki z zastosowaniem dwóch rodzajów detektorów neuronowych

W systemie oba układy mogą działać wspólnie lub osobno, przy czym układ rozpoznawania uszkodzeń może pełnić również rolę kompresora danych w przypadku dużej liczby danych wejściowych. Na rysunku 7.10 przedstawiono strukturę takiego systemu. Struktura ta jest przedmiotem rozważań w dalszych rozdziałach, zmierzających do realizacji systemu diagnostyki silników indukcyjnych wykorzystującego metody sztucznej inteligencji.

Spośród wielu znanych struktur sieci i sposobów ich uczenia najczęściej w układach diagnostycznych stosuje się:

- perceptrony wielowarstwowe MPL ze standardowym algorytmem uczenia typu propagacji wstecznej,
- sieci radialne RBF,
- sieci realizujące regresję uogólnioną GRNN,
- sieci neuronowe rozmyte
- sieci samoorganizujące się typu Kohonena.

W następnych rozdziałach skoncentrowano się na zagadnieniach projektowania neuronowych detektorów uszkodzeń realizowanych z wykorzystaniem tego typu sieci neuronowych.

7.5. Metody logiki rozmytej w diagnostyce

W diagnostyce bardzo często wykorzystuje się przybliżone kryteria do oceny aktualnego stanu technicznego obiektu. Z takimi kryteriami można spotkać się, gdy stan obiektu określa się na podstawie oględzin i dostępu do informacji niepewnej i nieprecyzyjnej. W praktyce przemysłowej większość danych ma taki charakter, gdyż występują zakłócenia i szумы pomiarowe. Ponadto również ocena dokonywana przez eksperta obciążona jest pewną niepewnością. Dlatego zastosowanie logiki rozmytej jest naturalnym sposobem uwzględnienia tych zakłóceń i niepewności, gdyż umożliwia zapisanie relacji uszkodzenia-symptomy oraz wnioskowania. Do budowy modeli rozmytych zwykle wykorzystuje się wiedzę eksperta, na podstawie której wyznaczane są reguły działania obiektu, początkowe wartości parametrów, struktura modelu oraz dane pomiarowe (zmienne procesowe) zbierane przez systemy pomiarowe. Do największych zalet logiki rozmytej należy możliwość zapisu dowolnego algorytmu za pomocą reguł logicznych: *Jeśli – to*, opisanych heurystycznie lub lingwistycznie [7.16]. Do detekcji uszkodzeń najczęściej wykorzystywane są dwie techniki logiki rozmytej:

- modele rozmyte typu Wanga i Mendela (WM),
- rozmyte sieci neuronowe.

Modele WM są prostymi modelami rozmytymi reprezentowanymi przez zbiór reguł typu:


$$R_m: \quad \text{JEŻELI } (x_1 = A_{m1}) \text{ i } (x_2 = A_{m2}) \text{ i } \dots \text{ i } (x_n = A_{mn}), \text{ TO } (y = B_m) \quad (7.7)$$

gdzie:

- A_{11}, \dots, A_{mn} – wejściowe zbiory rozmyte dla x_n ,
- B_1, \dots, B_m – zbiory rozmyte konkluzji,
- x_1, \dots, x_n – zmienne wejściowe systemu rozmytego,
- y – zmienna wyjściowa systemu rozmytego.

Wejściami systemu rozmytego x_1, \dots, x_n są sygnały diagnostyczne lub wyekstrahowane z nich symptomy uszkodzeń informujące o stopniu uszkodzenia. W zależności od warunków pracy napędu elektrycznego, sygnałami tymi mogą być amplitudy charakterystycznych częstotliwości widma prądu silnika lub drgań mechanicznych, prędkość chwilowa silnika, częstotliwość zadana falownika, poślizg, temperatura itp. Rozmiar wektora wejściowego X może być dowolny, jednak należy pamiętać, że zbyt duża liczba sygnałów wejściowych bardzo komplikuje proces projektowania detektora

rozmytego. Na rysunku 7.11 przedstawiono schemat ideowy struktury systemu rozmytego do wykrywania uszkodzeń [7.15, 7.16].



Rys. 7.11. Struktura systemu rozmytego do wykrywania uszkodzeń

W pierwszej kolejności wykonywana jest operacja rozmywania, polegająca na obliczeniu stopnia przynależności poszczególnych wejść do zbiorów rozmytych $A_{11}, \dots, A_{m1}, A_{12}, \dots, A_{m2}, \dots, A_{1n}, \dots, A_{mn}$. Funkcje przynależności $\mu_{A_{11} \dots A_{m1}}(x_1), \mu_{A_{12} \dots A_{m2}}(x_2), \dots, \mu_{A_{1n} \dots A_{mn}}(x_n)$ muszą być dokładnie zdefiniowane dla każdego wejścia. W wyniku fuzyfikacji, wektor wejściowy \mathbf{X} mający ostre wartości zostaje przekształcony w wektor stopni przynależności, stanowiąc wejście bloku inferencji. Proces inferencji oblicza wynikową funkcję przynależności $\mu_{wyn}(y)$ wyjścia systemu, na podstawie wejściowych stopni przynależności $\mu_{A_{11} \dots A_{m1}}(x_1), \mu_{A_{12} \dots A_{m2}}(x_2), \dots, \mu_{A_{1n} \dots A_{mn}}(x_n)$. W celu przeprowadzenia procesu wnioskowania, należy zdefiniować następujące parametry:

- bazę reguł typu *JEŻELI* \rightarrow *TO*,
- mechanizm inferencji,
- funkcje przynależności wyjścia y systemu rozmytego.

Baza reguł jest podstawowym elementem definiującym sposób działania systemu rozmytego, który jest wyrażony za pomocą lingwistycznych reguł działania, wykorzystując relacje wejść i wyjść typu *JEŻELI* \rightarrow *TO*. Mechanizm inferencji jest algorytmem matematycznym realizującym relacje wyrażone za pomocą bazy reguł. Mając zdefiniowaną bazę reguł ($R_1 \dots R_m$), należy obliczyć stopień spełnienia \mathbf{h} przesłanek poszczególnych reguł (tzw. agregację przesłanek reguł). Proces ten można wyrazić następująco:

$$\mathbf{h}_m = T [\mu_{A_{m1}}(x_1), \dots, \mu_{A_{mn}}(x_n)] \quad (7.8)$$

gdzie T oznacza operator tzw. T -normy, realizującej operację iloczynu logicznego [7.9, 7.15].

Do najczęściej stosowanych operatorów T należy operator iloczynu poszczególnych stopni przynależności, typu *PROD*. Wówczas stopień spełnienia przesłanek poszczególnych reguł można obliczyć z ogólnej zależności (7.9):

$$\mathbf{h}_m = [\mu_{A_{m1}}(x_1) \times \mu_{A_{m2}}(x_2) \times \dots \times \mu_{A_{mn}}(x_n)] \quad (7.9)$$

Kolejnym etapem obliczeń jest określenie zmodyfikowanych funkcji przynależności konkluzji poszczególnych niezerowych reguł. Operacji tej dokonuje się również stosując T -normę w postaci iloczynu $PROD$ (7.10):

$$\mu_{Bm}(y) = T [h_m, \mu_{Bm}(y)] \quad (7.10)$$

Końcowym etapem jest obliczenie wynikowej funkcji przynależności dla wszystkich m -reguł na podstawie agregacji zmodyfikowanych funkcji przynależności konkluzji poszczególnych reguł, według zależności (7.11):

$$\mu_{wyn} = S [\mu_{B1}(y), \dots, \mu_{Bm}(y)] \quad (7.11)$$

gdzie S – operator tzw. S -normy [7.9, 7.15].

Zadaniem procesu defuzyfikacji (wyostrzania) jest obliczenie ostrej wartości sygnału wyjściowego na podstawie zbioru rozmytego, będącego produktem wyjściowym procesu inferencji.

W literaturze można spotkać wiele algorytmów realizujących proces wyostrzania, jednak najczęściej stosowana jest metoda tzw. singletonów, ze względu na prostą strukturę obliczeniową i łatwość realizacji technicznej. Ideą tej metody jest zastąpienie funkcji przynależności wyjścia B_j jednoelementowym zbiorem (singletonem) umiejscowionym w środku obszaru funkcji B_j [7.16]. Do obliczenia ostrego wyjścia y systemu rozmytego można wykorzystać uproszczoną metodę wnioskowania rozmytego, stosując równanie (7.12), w którym wyznaczana jest średnia ważona centroidów zbiorów rozmytych poszczególnych następników reguł B_j .

$$y = \frac{\sum_{j=1}^m y_j \mu_{Bj}}{\sum_{j=1}^m \mu_{Bj}} \quad (7.12)$$

gdzie m – liczba reguł.

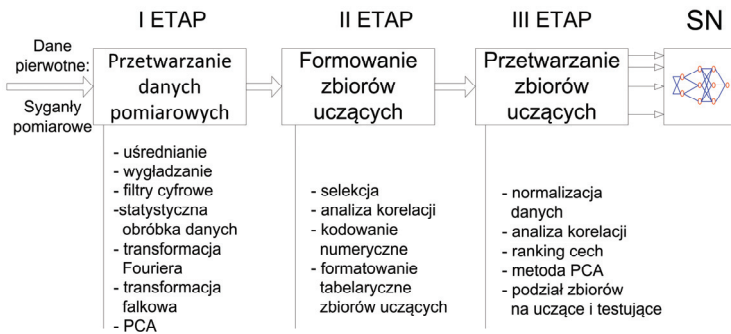
Metoda ta jest prosta w realizacji praktycznej. Ponadto umożliwia analityczne określenie zależności między wejściem a wyjściem systemu.

Wyjściowa wartość y w systemie diagnostycznym może być informacją liczbową o stopniu uszkodzenia obiektu (np. liczba zwojów zwartych stojana lub liczba przerwanych prętów wirnika). Detektor rozmyty może być również tak zaprojektowany, aby na jego wyjściu pojawiały się sygnały reprezentujące lingwistyczne formy opisu uszkodzenia, np.:

- obiekt nieuszkodzony ,
- niewielki stopień uszkodzenia,
- średni stopień uszkodzenia – stan ostrzegawczy,
- duże uszkodzenie – stan alarmowy,
- awaria – obiekt całkowicie zniszczony.

7.6. Wstępne przetwarzanie sygnałów pomiarowych dla neuronowych detektorów uszkodzeń

Bezpośrednie wykorzystanie w neuronowych detektorach uszkodzeń silników indukcyjnych informacji pomiarowej, zbieranej w czasie pracy obiektu, jest praktycznie niemożliwe, a na pewno nieefektywne. Może to być związane z niejednoznacznością reprezentacją wielkości występujących w obiekcie, rozmiarem wektora tych wielkości czy występujących zakłóceń. Dostępne na obiektach sygnały są generowane przez różne źródła, np. czujniki, przetworniki, analizatory itp. Wiąże się to z odpowiednim projektowaniem układów pomiarowych na potrzeby systemów diagnostycznych, w których zwraca się uwagę na odpowiedni stosunek sygnału do szumów i korygowanie charakterystyk statycznych i dynamicznych. Obecne układy pomiaru i analizy sygnałów projektuje się gdy analizie poddawany jest sygnał cyfrowy dostarczany bezpośrednio ze źródła sygnału lub cyfrowego systemu pomiarowego (rozdział 4.3).



Rys. 7.12. Wstępne przetwarzanie sygnałów pomiarowych na potrzeby neuronowego detektora uszkodzeń

Poprawnie zbudowany układ pomiarowy nie rozwiązuje tych problemów, które są istotne dla sieci neuronowych, a zwłaszcza dla neuronowych detektorów uszkodzeń. Niezbędne jest zastosowanie bloku wstępnego przetwarzania (tzw. preprocesora), którego zadaniem jest transformacja mierzonych sygnałów (obrazów) do takiej postaci, która będzie odpowiednia do wykorzystania na wejściu sieci neuronowej. Proces wstępnego przetwarzania danych w każdym konkretnym przypadku jest inny, można przyjąć, że składa się z kilku podstawowych etapów (rys. 7.12):

- przetwarzania sygnałów pomiarowych (danych pierwotnych),
- tworzenia zbiorów danych uczących i testujących,
- przetwarzania zbiorów danych uczących i testujących.

Ze względu na charakter informacji pomiarowej oraz poziomu jej przetworzenia, dane poddawane wstępnej obróbce mogą być różnego typu, np.: dane pierwotne nie-

przetworzone lub dane wstępnie przetworzone (np. z analizatora), dane w dziedzinie czasu lub częstotliwości, dane wielowymiarowe itp.

W pierwszym etapie, przed przystąpieniem do ekstrakcji cech uszkodzenia, należy wyeliminować wpływ zakłóceń, zjawisk ubocznych sieci zasilającej. Niekorzystne wpływy objawiają się w postaci trendów, składowych oscylacyjnych lub szybkozmiennych. Do usunięcia ze zmierzonych próbek sygnału niepożądanych składowych lub też odseparowanie z nich składowych reprezentujących interesujące cechy, służą przekształcenia typu: filtry cyfrowe, wygładzanie, uśrednianie, analiza składowych głównych PCA (rozdział 4.2). Wybór właściwego filtru i jego dostosowanie do wymagań diagnostyki ma bardzo istotne znaczenie ze względu na wprowadzane przez nie zniekształcenia. Każda decyzja o filtracji danych pomiarowych musi być uzasadniona przewagą korzyści nad zniekształceniem informacji, która dalej będzie wykorzystywana w układzie diagnostyki.

Po wstępnym przetworzeniu danych pierwotnych powinno wystąpić przetwarzanie związane z wydobywaniem cech charakteryzujących uszkodzenia (tzw. ekstrakcja cech uszkodzenia). W przeciwieństwie do wstępnego przetwarzania danych pierwotnych, ekstrakcja cech powoduje zazwyczaj znaczną zmianę rozmiaru danych.

Wstępnie przetworzone pierwotne dane pomiarowe, czyli cechy uszkodzeń, przed wprowadzeniem na wejście sieci neuronowej, zazwyczaj wymagają jeszcze właściwej selekcji i poprawnej organizacji (rysunek 7.12 – etap 2).

Jeżeli dane mają postać jakościową, a nie ilościową, to może zachodzić potrzeba ich kodowania do postaci numerycznej tak, aby były użyteczne dla sieci neuronowej. Gdy są to zmienne dwustanowe wówczas koduje się je do postaci binarnej. W przypadku większej liczby stanów, koduje się za pomocą kolejnych uporządkowanych wartości numerycznych, np. (0; 0,5; 1).

W zależności od typu sieci, zbiory obrazów uszkodzeń muszą być odpowiednio stabelaryzowane. Dla uczenia z nauczycielem zbior obrazów jest tzw. tablicą decyzyjną, w której każdemu wektorowi wejściowemu $\mathbf{x}(k) = [x_1, x_2, \dots, x_n]^T$ odpowiada zadany wektor wyjściowy $\mathbf{y}(k) = [y_1, y_2, \dots, y_m]^T$. Dane uczące są w postaci par $(\mathbf{x}(k), \mathbf{y}(k))$ dla $k = 1, 2, \dots, p$, gdzie p jest liczbą obrazów. Dla uczenia bez nauczyciela zbior obrazów zawiera wyłącznie obrazy danych wejściowych.

Niezależnie od zastosowanego sposobu uczenia, zbiór obrazów uczących powinien być reprezentatywny dla aproksymowanego przez sieć odwzorowania. W przypadku gdy sieć neuronowa pełni rolę klasyfikatora uszkodzeń, jest bardzo ważne, aby zbiór ten zawierał obrazy graniczne dla poszczególnych klas, czyli najbardziej nietypowe dla danej klasy uszkodzenia [7.19]. Takie zbiory są najczęściej używane w strojeniu wag i umożliwiają istotnie zmniejszyć rozmiary zbioru uczącego.

Innym problemem jest reprezentatywność danych i ich kompletność. Sieć neuronowa jest w stanie kojarzyć pewne zależności wyłącznie na podstawie przykładów.

Dlatego obrazy w zbiorze uczącym muszą reprezentować wszystkie klasy oraz istotne przypadki. Przy selekcji sygnałów wejściowych dla sieci neuronowej można posłużyć się analizą statystyczną. Pozwala to sprawdzić czy między wybranymi cechami (zmiennymi wejściowymi) nie istnieją korelacje. Jeżeli dwie z nich są silnie skorelowane, należy jedną pominąć. Aby ocenić stopień korelacji między zmiennymi, należy obliczyć korelację w następujący sposób:

$$r = \frac{\sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v})}{(n-1)\sigma_u\sigma_v} \quad (7.13)$$

gdzie:

- u – jedna ze zmiennych,
- v – druga zmienna,
- n – liczba punktów danych; wielkości z kreską oznaczają wartości średnie zmiennych,
- σ_u, σ_v – standardowe odchylenia badanych zmiennych:

$$\sigma_u = \sqrt{\frac{\sum_{i=1}^n (u_i - \bar{u})^2}{n-1}}, \quad \sigma_v = \sqrt{\frac{\sum_{i=1}^n (v_i - \bar{v})^2}{n-1}} \quad (7.14)$$

Jeżeli dwie zmienne są dokładnie skorelowane, współczynnik $r = 1$. Jeżeli w ogóle nie zależą od siebie, to $r = 0$. Gdy $r \geq 0,75$, należy uznać, że istnieje silna korelacja między zmiennymi.

W drugiej fazie przygotowania danych sprawdza się je pod kątem zawartości nietypowych nieprawidłowości, aby wykluczyć nieprawidłowe dane z zestawu treningowego. W tym celu należy wykreślić każdy z zestawów danych. Dane spoza zakresu wymagają rozważenia (analizy); mogą one wynikać z błędnego odczytu danych pomiarowych, z błędów zapisu lub mogą być oznaką jakiegoś istotnego zjawiska w układzie rzeczywistym. Dlatego należy je szczegółowo przeanalizować przed ich wykluczeniem z zestawu treningowego.

W większości zastosowań sieci neuronowych, dane uczące zapisywane w formie tabelarycznej poddawane są dalszej obróbce (3 etap wstępnego przetwarzania – rys. 7.12). Związane jest to przede wszystkim z różnymi skalami zmiennych numerycznych. W przypadku niektórych algorytmów uczenia sieci neuronowych, zróżnicowany zakres zmienności danych wejściowych ma wpływ na działanie stosowanych procedur numerycznych. Dlatego niezbędna jest normalizacja danych, czyli sprowadzenie do postaci bezwymiarowej o ujednoczonym zakresie zmienności. Metoda wstecznej propagacji błędu preferuje dane zawarte w zakresie $\{0, 1\}$. Aby dokonać normalizacji danych, należy rozważyć typowy zakres dla każdego wejścia w zestawie treningo-

wym. Niekoniecznie muszą to być wartości maksymalne i minimalne, gdyż później, w aplikacji, może wystąpić wartość spoza tego zakresu, chociaż nie powinno się to zdarzać często, jeżeli dane treningowe stanowią dobrą reprezentację rzeczywistego procesu. Określenie typowego zakresu danych musi nastąpić przed zaprojektowaniem struktury sieci neuronowej. Liczba danych wymagana do treningu sieci metodą wstecznej propagacji błędu stanowi również bardzo istotny czynnik. Jeżeli problem jest skomplikowany, większa liczba zestawów danych jest wymagana w celu właściwego jego odwzorowania za pomocą sieci neuronowej.

W tabeli 7.1 przedstawiono podstawowe metody normalizacji danych. Najczęściej stosowana jest metoda skalowania względem wartości średniej.

Tabela 7.1. Podstawowe metody normalizacji danych

Metoda normalizacji	Wzór przeliczeniowy	Uwagi
Względem wartości maksymalnej	$x_{\text{norm}} = \frac{x}{x_{\text{max}}}$	
Względem wartości średniej	$x_{\text{norm}} = \frac{x}{x_{\text{śr}}}$	$x_{\text{śr}} = \frac{1}{n} \sum_{i=1}^n x_i$
Względem odchylenia od wartości średniej	$x_{\text{norm}} = \frac{x - x_{\text{śr}}}{x_{\text{śr}}}$	Przedział zmienności (-1, 1) $x_{\text{norm śr}} = 0$
Względem odchylenia od wartości minimalnej	$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}}$	Przedział zmienności (0, 1) $x_{\text{norm śr}} = 0,5$

Znormalizowany wektor wyekstrahowanych cech uszkodzenia nie gwarantuje jeszcze najlepszego rozwiązania neuronowego detektora uszkodzenia. Problem tkwi w tym, że w trakcie selekcji danych pierwotnych oraz ekstrakcji cech (1 i 2 etap wstępnego przetwarzania) zwykle nie wiadomo, które z nich mogą być najbardziej użyteczne. Z zagadnieniem tym związany jest problem wymiarowości wektora uczącego oraz współzależności między cechami. Sieci neuronowej należy dostarczyć dostateczną liczbę obrazów uczących, aby mogła wypełnić nimi przestrzeń sygnałów wejściowych. Szacunkowo przyjmuje się, że dla przestrzeni zawierającej N cech, zbiór uczący powinien zawierać około 2^N elementów, co oznacza, że zwiększenie liczby cech na wejściu sieci pociąga za sobą konieczność dostarczenia większej liczby próbek, aby zbiór uczący był bardziej reprezentatywny. Realizacja tego wymagania jest dość trudna w przypadkach, gdy zbiór uczący powstaje na bazie danych zbieranych z eksperymentu rzeczywistego, a nie symulacyjnego. Nie wszystkie rodzaje i stopnie uszkodzenia można bezproblemowo „wygenerować” na obiekcie rzeczywistym.

Sieci neuronowe mają jednak zdolność eliminowania zbędnych cech przez zerowanie wag, lecz wymaga to tzw. selekcji w układzie zamkniętym, tzn. sprzężenia procesu selekcji z procesem uczenia i testowania sieci neuronowej. Otóż w procesie treningu, po przejściu pewnej liczby epok (cykli treningowych), obserwacja współczynników wago-

wych dostarcza pewnych informacji. Każdy z sygnałów wejściowych, który nie ma istotnego wpływu na właściwe odwzorowanie relacji wejście – wyjście, charakteryzuje się bardzo małymi wartościami współczynników wagowych w porównaniu z innymi wejściami. Nie należy od razu eliminować tych sygnałów wejściowych; doświadczenie wskazuje, że należy w dalszym ciągu prowadzić proces uczenia i dopiero, jeśli wartości tych „małych” współczynników wagowych nie ulegną większym zmianom, należy wyeliminować odpowiadające im sygnały wejściowe sieci neuronowej.

Ostatnim krokiem we wstępnym przetwarzaniu danych jest podział zbioru cech na zbiór uczący, wykorzystywany przez algorytm uczenia, oraz zbiór testujący, który służy do weryfikacji sieci neuronowej. W praktyce brak jest analitycznych metod, które dostarczałyby kryteriów podziału zbioru obrazów na część uczącą i testującą [7.3, 7.6, 7.22]. Zbiór uczący powinien być bardziej liczny niż zbiór testowy.

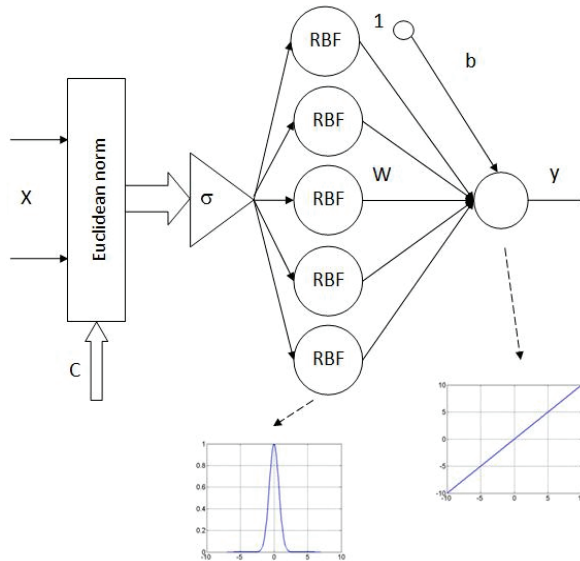
7.7. Sieci neuronowe radialne RBF

Wielowarstwowe sieci neuronowe, określane w literaturze również jako perceptrony wielowarstwowe (*Multi Layer Perceptron*), realizują funkcję aproksymacji globalnej. O odwzorowaniu każdego elementu wektora wejściowego decyduje w tym przypadku jednocześnie wiele neuronów. Natomiast w przypadku zastosowania sieci RBF za realizację odwzorowania każdego klastera przestrzeni odpowiada poszczególny neuron warstwy ukrytej sieci. Podane podejście odpowiada aproksymacji lokalnej. Odwzorowanie całego zbioru danych uzyskuje się przez operację superpozycji sygnałów wyjściowych poszczególnych neuronów ukrytych. Jest ona realizowana za pomocą liniowego neuronu wyjściowego. Sieci neuronowe radialne (ang. *Radial Basis Function*) stanowią specjalną grupę sieci neuronowych o charakterystycznej topologii oraz budowie poszczególnych neuronów w warstwie ukrytej. Sieci RBF mają strukturę typu *feedforward*, zatem istnieje jeden ustalony kierunek przepływu danych między poszczególnymi warstwami sieci neuronowej. Na rysunku 7.13 przedstawiono sieć składającą się z trzech warstw. Pierwszą z nich jest warstwa wejściowa, w której formowany jest wektor wejściowy neuronów kolejnej warstwy. Następną, ukrytą warstwę tworzą neurony o radialnej funkcji aktywacji. Warstwa wyjściowa składa się z neuronów liniowych, których liczba jest uzależniona od liczby sygnałów wyjściowych sieci.

W topologii sieci neuronowej RBF należy wyodrębnić kolejne elementy związane z poszczególnymi etapami przetwarzania danych [7.1, 7.3]:

- warstwa wejściowa, w której obliczane są odległości między elementami wektora wejściowego a centrami neuronów radialnych (najczęściej norma Euklidesa),
- skalowanie za pomocą współczynnika σ ,
- warstwa ukryta realizująca obliczenia wartości funkcji radialnych na podstawie argumentów z wcześniejszych obliczeń (neurony ukryte nie mają połączeń z sygnałami zewnętrznymi oraz sprzężeniami wewnętrznymi sieci), warstwa wyj-

ściowa, zawierająca neuron liniowy (wartości uzyskane na wyjściu neuronów radialnych są mnożone przez współczynniki wagowe, a następnie sumowane).



Rys. 7.13. Topologia sieci radialnej RBF

Jako funkcja aktywacji neuronów w warstwie ukrytej najczęściej jest stosowana funkcja Gaussa, którą można przedstawić za pomocą wzoru:

$$h_j = h(v_j) = \exp(-v_j \sigma) \quad (7.15)$$

gdzie:

σ – parametr określający szerokość funkcji radialnej,

v_j – odległość między wektorem wejściowym oraz centrum neuronu.

Najczęściej odległość ta jest wyrażona przez normę Euklidesową wyznaczaną następująco:

$$v_j(\mathbf{X}) = \|\mathbf{X} - \mathbf{C}_j\| = \sqrt{\sum_{i=1}^n (x_i - c_{ji})^2}, \quad i = 1, 2, 3, \dots, n \quad (7.16)$$

gdzie:

$\mathbf{X} = [x_1, x_2, x_3, \dots, x_n]^T$ – wektor wejściowy,

\mathbf{C}_j – wektor odpowiadający centrum danego neuronu.

Analizując równania (7.16), można zauważyć, że wartość wyjściowa danego neuronu radialnego wzrasta ze zbliżaniem się kolejnych próbek wejściowych do centrum funkcji radialnej. Wartości wyjściowe sieci oblicza się jako sumę sygnałów wyjścio-

wych kolejnych neuronów radialnych przemnożonych przez odpowiednie współczynniki wagowe

$$y_k = \sum_{j=1}^n w_{jk} h_j + b_k \quad (7.17)$$

gdzie:

- y_k – wyjście k -tego neuronu wyjściowego,
- w_{jk} – współczynnik wagowy między wyjściem j -tego neuronu warstwy ukrytej a k -tym neuronem wyjściowym,
- b_k – bias k -tego neuronu wyjściowego.

Zadanie uczenia sieci neuronowych jest równoznaczne z minimalizacją funkcji celu, która dla opisywanych sieci została zdefiniowana jako błąd średniokwadratowy (*Mean Squared Error*) między wartością estymowaną a rzeczywistą. W przypadku jednej pary uczącej przyjmuje się następującą postać:

$$E = \frac{1}{2} \sum_{k=1}^M (y_k - d_k)^2 \quad (7.18)$$

natomiast dla p -elementowego ciągu uczącego:

$$E = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k(j) - d_k(j))^2 \quad (7.19)$$

gdzie:

- p – liczba zadanych wzorców uczących,
- d_k – wartości zadane,
- y_k – aktualne wartości wyjściowe neuronu,
- M – wymiar wektora d_k .

Proces uczenia radialnej sieci neuronowej znacznie różni się od treningu sieci MLP. Jest to związane z odmienną budową obu typów sieci neuronowych. Ogólna procedura trenowania sieci RBF składa się z trzech etapów obejmujących kolejno wyznaczenie: centrów neuronów ukrytych, parametrów odpowiadających szerokości funkcji radialnych poszczególnych neuronów ukrytych, współczynników wagowych między warstwą ukrytą a wyjściową. Zastosowany algorytm treningu sieci umożliwił tworzenie struktury sieci przez dołączanie w każdej iteracji kolejnego neuronu radialnego. Po przeprowadzeniu symulacji sieci, w miejscu wektora wejściowego o największym błędzie, wprowadzany jest dodatkowy neuron. Następnie wyznaczone są wartości wag między warstwą ukrytą a wyjściową, za pomocą algorytmów optymalizacyjnych stosowanych w klasycznych sieciach MLP. Koniec procesu uczenia sieci następuje po osiągnięciu założonego poziomu błędu dopasowania sieci do danych uczących lub określonej wcześniej maksymalnej liczby neuronów. Specyficzna budowa oraz sposób przetwarzania sygnałów umożliwia odtwarzanie za pomocą sieci RBF dowolnej nieliniowej funkcji za

pomocą jednej warstwy ukrytej. Jednak jest to związane z koniecznością zastosowania większej liczby neuronów niż w przypadku sieci MLP [7.1].

7.8. Sieci neuronowe typu GRNN

Coraz częściej oprócz klasycznej sieci MLP poszukuje się innych typów sieci neuronowych o prostszych strukturach lub lepszych właściwościach generalizujących. Do takich rozwiązań można zaliczyć sieć typu GRNN (ang. *General Regression Neural Network*). Sieć tego typu jest równoległą implementacją statystycznych reguł w strukturze sztucznych sieci neuronowych [7.17].

W statystyce zagadnienia związane z poszukiwaniem zależności między danymi sprowadzają się zwykle do rozwiązań typu regresyjnych. Dla danych ze zbioru elementów $\{(x_i, y_i)\}$ model regresyjny można zapisać następująco:

$$y_i = f(\beta, x_i) + \varepsilon_i, \quad i = 1, \dots, n \quad (7.20)$$

gdzie:

- ε_i – błąd obserwacji (z rozkładu normalnego ze średnią zero oraz stałą wariancją),
- f – funkcja regresji,
- β – współczynnik regresji,
- n – liczba elementów zbioru, $i = 1, 2, \dots, n$.

W pracy [7.17] przedstawiono możliwość realizacji założeń regresji w postaci równoległej struktury sieci neuronowej. Poszczególne jądra regresji stanowią funkcje aktywacji, w analizowanym przypadku przyjęto zależności Gaussa. Analiza danych odbywa się w odniesieniu do punktów przestrzeni x , które odpowiadają centrom poszczególnych funkcji aktywacji kolejnych neuronów. Położenie kolejnych elementów zbioru wejściowego w odniesieniu do centrów poszczególnych neuronów jest wyznaczana za pomocą zależności:

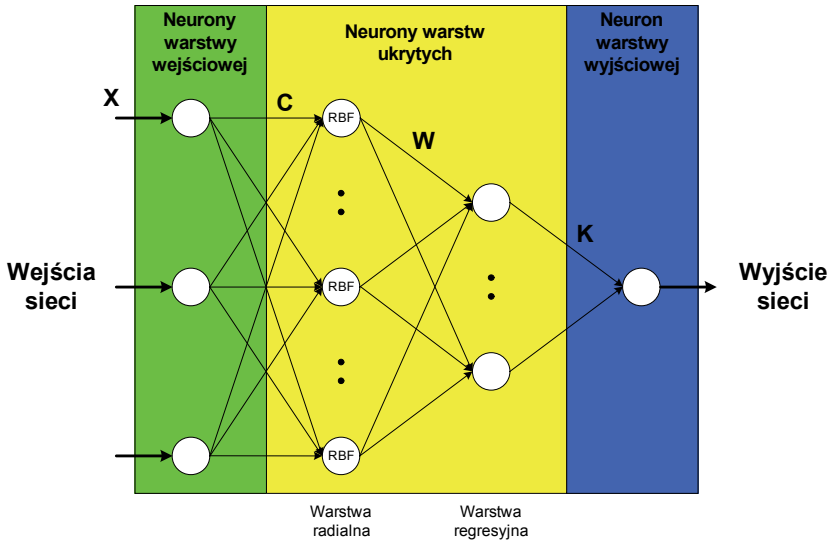
$$D_i^2 = (X - X^i)^T (X - X^i) \quad (7.21)$$

Przyjmując podane założenia funkcja regresyjna jest opisana w tym przypadku wzorem:

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (7.22)$$

gdzie σ – współczynnik determinujący szerokość funkcji Gaussa.

Sieci regresyjne mają budowę typu *feedforward*, w związku z tym istnieje w nich jeden ustalony kierunek przepływu danych między poszczególnymi warstwami sieci neuronowej (rys. 7.14). Struktura sieci zawiera połączone ze sobą neurony, ułożone w warstwy: wejściowe oraz wyjściowe oraz ukryte. Liczba poszczególnych warstw jest zależna od wymiarów przetwarzanych w procesie treningu macierzy oraz założonej liczby wejść i wyjść struktury sieci neuronowej.



Rys. 7.14. Schemat ideowy struktury sieci typu GRNN

Analizowana sieć neuronowa składa się z czterech warstw. Poniżej opisano algorytm przedstawiający programową implementację opisanych zależności wraz z przyjętym sposobem wyznaczania poszczególnych parametrów modelu. Wstępny etap przetwarzania polega na formowaniu wektora wejściowego dla warstwy ukrytej. Na tym etapie przetwarzania neuronowego wyznaczana jest odległość Euklidesowa między wektorem wartości wejściowych oraz centrów funkcji radialnych:

$$v_j(\mathbf{X}) = \|\mathbf{X} - \mathbf{C}_j\| = \sqrt{\sum_{k=1}^n (x_k - c_k)^2}, \quad k = 1, 2, 3, \dots, n \quad (7.23)$$

gdzie:

$\mathbf{X} = [x_1, x_2, x_3, \dots, x_n]^T$ – wektor wejściowy,

\mathbf{C}_j – wektor odpowiadający centrum danego neuronu,

$k = 1, 2, 3, \dots, n$.

W dalszych obliczeniach uzyskane wartości z (7.23) są skalowane przez wymnożenie ich przez wartość biasu (takiego samego dla wszystkich neuronów radialnych):

$$\mathbf{L}_{in} = \mathbf{v}\mathbf{b} \quad (7.24)$$

Przyjęty poziom biasu jest stały dla wszystkich neuronów. Jego wartość wyznaczono za pomocą zależności:

$$b = \left(\frac{\sqrt{-\log(0,5)}}{\eta} \right) \quad (7.25)$$

gdzie η – parametr skalujący.

Rezultaty przedstawionego przetwarzania stanowią wejścia funkcji aktywacji opisanej wzorem:

$$\mathbf{L}_h = \exp(-\mathbf{L}_{in}^2) \quad (7.26)$$

Otrzymane wyniki formują wektor wyjściowy warstwy ukrytej \mathbf{L}_h . Warstwa sumacyjna realizuje sumowanie ważone, realizowane na podstawie \mathbf{L}_h oraz macierzy wag:

$$\mathbf{L}_{sum} = \mathbf{W}\mathbf{L}_h \quad (7.27)$$

Następnie uzyskany sygnał przetwarzany jest w warstwie decyzyjnej, gdzie wykonywane są następujące obliczenia:

$$\mathbf{Y} = \frac{\mathbf{L}_{sum}}{\sum_q \mathbf{L}_h} \quad (7.28)$$

gdzie q – liczba neuronów warstwy ukrytej.

W strukturze sieci neuronowej GRNN w procesie treningu wyznaczane są położenia centrów neuronów wejściowych \mathbf{C} oraz wartości wag \mathbf{W} warstwy sumacyjnej. Do zadania można zastosować następującą metodę wyznaczania parametrów sieci neuronowej:

- wartości centrów neuronów radialnych uzyskiwane przez przepisanie wartości wejściowych danych uczących,
- wagi przyjmowane jako wartości wyjściowe ze zbioru danych wykorzystywanych do treningu.

Na uwagę zasługuje bardzo krótki czas trwania całego procesu. Jest to tzw. jednokrokowa metoda uczenia (ang. *one-pass training method*), w przeciwieństwie do algorytmów treningu klasycznych sieci neuronowych MLP, najczęściej opartych na wyznaczaniu pochodnych funkcji celu względem wag. Ponadto nie pojawia się tutaj problem związany z losowymi wartościami początkowymi wag, co oznacza pełną powtarzalność uzyskiwanych wyników. Kolejną zaletą zastosowania sieci GRNN i tej metody uczenia jest brak konieczności podejmowania decyzji o strukturze samej sieci, co jest ważne dla prawidłowego wykonania zadania. Do optymalizacji topologii sieci neuronowej można stosować specjalne algorytmy, jednak są one skomplikowane

i wydłużają proces uczenia. W przypadku perceptronowych sieci wielowarstwowych MLP często niezbędna jest konieczność wstępnego przetwarzania danych według skalowania liniowego (rozdział 7.6). Operacja ta jest wprowadzana w celu dostosowania danych wejściowych do zakresu funkcji aktywacji. W sieciach GRNN obliczana jest odległość euklidesowa między danymi wejściowymi a centrami funkcji radialnych. Centra są równe wejściowym danym uczącym, więc podczas porównania są podobne. W procesie projektowania oraz uczenia sieci GRNN dobierany jest tylko parametr σ . W obliczeniach wewnątrz sieci parametr ten wpływa na kalibrację danych wprowadzanych do węzłów radialnych, dlatego że działa jako czynnik kształtowania funkcji radialnych.

Sieci neuronowe realizujące regresję uogólnioną (GRNN) dzięki dobrej zdolności aproksymacji i generalizacji zestawów danych pomiarowych zostały wykorzystane do detekcji uszkodzeń elektrycznych i mechanicznych omówionych w dalszych rozdziałach pracy.


7.9. Sieci neuronowo-rozmyte

Do największych zalet sztucznych sieci neuronowych można zaliczyć możliwość ich uczenia i adaptacji. Sieci neuronowe wymagają szczegółowej wiedzy o procesie i znajomości dokładnego modelu matematycznego obiektu. Sieć neuronowa jest w stanie nauczyć się odwzorowania praktycznie każdej nieliniowości na podstawie sygnałów wejściowych oraz wzorcowych. Jak przedstawiono w rozdziale (7.2), sieci neuronowe składają się z wielkiej liczby prostych elementów przetwarzających (neuronów) połączonych wzajemnie, co w efekcie daje ogromną moc obliczeniową przetwarzania równoległego. Sposób projektowania takich układów jest oparty w zasadzie na intuicji niż na konkretnych zależnościach matematycznych, gdyż brak jest algorytmu umożliwiającego ustalenie liczby warstw i neuronów w poszczególnych warstwach dla konkretnego zastosowania. Niewątpliwie jednak, po nauczaniu, sieci neuronowe sprawdzają się w zadaniach rozpoznawania wzorców, aproksymacji, optymalizacji, kwantyzacji wektorowej czy też klasyfikacji. Z drugiej strony, wiedza, która została przez sieć neuronową nabyta, jest w tej sieci rozproszona, więc nieprzydatna dla obserwatora. Wady tej pozbawione są systemy z logiką rozmytą, w których jednak zależności między sygnałami wejściowymi a wyjściowymi muszą być znane już na etapie projektowania i muszą pochodzić od eksperta, bez możliwości ich uczenia. Wiedza ekspercka służy do określenia struktury oraz początkowych wartości parametrów modelu. Model nie stanowi czarnej skrzynki w odróżnieniu od sytuacji jaka jest przy stosowaniu klasycznych sieci neuronowych. Jest on zbiorem reguł, które ekspert może interpretować i weryfikować.

Nie jest jednak wymagana wiedza szczegółowa, opisująca w sposób matematyczny zależność funkcyjną między wejściem a wyjściem systemu. W odróżnieniu od

układów analitycznych, logika rozmyta posługuje się wiedzą jakościową, a nie ilościową i odpowiednie decyzje są podejmowane przez układ oparty na bazie reguł, zapisanych w postaci implikacji IF-THEN. Najprostszym podejściem do projektowania takich układów jest wyznaczenie reguł wejścia-wyjścia oraz funkcji przynależności na podstawie wiedzy eksperta. W każdej chwili modyfikacja projektu jest możliwa w sposób intuicyjny, gdyż struktura systemu rozmytego jest jawna. Wadą tych układów jest brak możliwości uczenia i adaptacji.

Synteza obu metod sztucznej inteligencji, czyli połączenie zdolności uczenia i mocy obliczeniowej sieci neuronowych ze sposobem działania na wzór rozumowania ludzkiego, czyli układu z logiką rozmytą wydaje się idealnym rozwiązaniem. W ten sposób powstały konstrukcje wykorzystujące ideę rozumowania rozmytego wraz ze zdolnością uczenia sieci neuronowych w postaci tzw. sieci neuronowych rozmytych (ang. *fuzzy-neural networks*) [7.15, 7.16].



Rys. 7.15. Schemat blokowy sieci neuronowej rozmytej

Analizując system rozmyty pod kątem budowy strukturalnej, można zauważyć, że stanowi on system przetwarzania informacji w jednym kierunku, od wejścia do wyjścia, jego poszczególne procesy można wyodrębnić jako warstwy. Budowa taka jest

bardzo podobna do budowy jednokierunkowych wielowarstwowych sieci neuronowych, które mają zdolność uczenia, wykorzystując np. algorytm wstecznej propagacji błędów. W związku z tym, system rozmyty można przedstawić w postaci sieci neuronowej, dzięki czemu uzyskuje się możliwość wykorzystania różnych metod optymalizacji (uczenia), charakterystycznych dla sieci neuronowych. Wynikowa sieć neuronowa rozmyta stanowi nadal system rozmyty, w którym odwzorowanie opisane jest lingwistycznymi regułami działania. Schemat ideowy sieci neuronowej rozmytej [7.15] przedstawiono na rysunku 7.15.

Przedstawiona sieć neuronowa rozmyta ma 4 warstwy charakterystyczne dla systemu rozmytego.

Warstwa 1 – wejściowa. Wyjście i -tego neuronu w warstwie wejściowej można zapisać jako:

$$O_i^1 = x_i \quad (7.29)$$

gdzie x_i – i -te wejście sieci, dla $i = 1, 2, \dots, n$.

Warstwa 2 – fuzyfikacji. Neurony w tej warstwie reprezentują odpowiednie funkcje przynależności i realizują odwzorowanie:

$$O_j^2 = \mu_{A_j}(x_i) \quad (7.30)$$

Funkcje przynależności A_j mogą być stosowane jako funkcje przynależności klasy t (funkcje trójkątne) lub gaussowskie [7.16] (7.31):

$$\mu_{A_j}(x_i, a, b) = \exp \left[- \left(\frac{x_i - a}{b} \right)^2 \right] \quad (7.31)$$

Parametry a i b mogą podlegać procesowi optymalizacji w trakcie uczenia struktury rozmytej sieci. Daje to możliwość zmiany położenia i kształtu zbiorów rozmytych.

Warstwa 3 – reguł. Konfiguracja połączeń tej warstwy odpowiada bazie reguł, a elementy mnożące blokowi wnioskowania. Każdy neuron w tej warstwie realizuje funkcję iloczynu wyjściowych stopni przynależności μ_{A_j} obliczonych w warstwie 2 i opisany jest zależnością (7.32):

$$O_r^3 = \prod_j O_j^2 \quad (7.32)$$

dla $r = 1, 2, \dots, R$, gdzie R oznacza liczbę neuronów w 3 warstwie.

Wielkość O_r^3 oznacza poziom spełnienia przesłanek r -tej reguły dla danych wartości sygnałów wejściowych sieci x_i . Zastosowanie iloczynu do obliczenia spełnienia

przesłanek reguł jest korzystne ze względu na łatwe obliczenie pochodnej $\partial O_r^3 / \partial O_j^2$, która musi być obliczona za pomocą algorytmu wstecznej propagacji błędu w procesie optymalizacji struktury sieci.

Warstwa 4 – wyjściowa. Zadaniem tej warstwy jest realizacja procesu defuzyfikacji metodą singletonów. Warstwa zawiera jeden neuron z liniową funkcją aktywacji realizujący funkcję sumatora sygnałów wejściowych, według zależności:

$$O_o^4 = \sum_{r=1}^R w_r O_{Nr}^3 \quad (7.33)$$

gdzie:

$$O_{Nr}^3 = \frac{O_r^3}{\sum_{r=1}^R O_r^3} \quad (7.34)$$

Parametr w_r określa wartość wagi połączenia między r -tą regułą a warstwą wyjściową O_o . Nawiązując od klasycznego systemu rozmytego, współczynnik wagowy w_r określa położenie wyjściowej funkcji przynależności w postaci singletona dla danej reguły r , O_r^3 zaś stanowi „ostre” wyjście systemu rozmytego.

Struktura przedstawiona na rysunku 7.15 wykazuje duże podobieństwo do sieci neuronowych. W odróżnieniu do klasycznych sieci neuronowych, każda z warstw wraz z umieszczonymi w niej elementami, konfiguracja połączeń, jak również wszystkie parametry i wagi mają fizyczną interpretację. Jest to bardzo ważna zaleta, gdyż wiedza nie jest rozproszona i może być przez obserwatora w łatwy sposób z takiej sieci wyodrębniona. W przedstawionej strukturze sieci neuronowej rozmytej parametrami podlegającymi optymalizacji w procesie uczenia mogą być współczynniki wagowe w_r oraz parametry zastosowanych wejściowych funkcji przynależności. Ponieważ jest to struktura jednokierunkowa o propagacji w przód (tzw. *feedforward*), najkorzystniej do jej uczenia wykorzystać powszechnie znany algorytm wstecznej propagacji błędu, który jest szczegółowo opisany w licznych pozycjach literaturowych [7.14, 7.16, 7.18].

7.10. Podsumowanie

Na temat projektowania struktur sieci neuronowych ukazało się bardzo dużo opracowań naukowych, również w języku polskim, z których najważniejsze zawarto w wykazie literatury. W niniejszym rozdziale przedstawiono podstawowe informacje dotyczące metod projektowania sieci neuronowych ukierunkowanych na zastosowania

diagnostyczne. Omówiono praktyczne sposoby przygotowywania danych uczących i testujących oraz sposoby syntezy struktur sieci pod kątem zastosowania w detektorach wykrywających uszkodzenia w napędzie elektrycznym. Przedstawiono podstawowe zalety i wady sieci najczęściej stosowanych w diagnostyce.

Przedstawiona metodyka projektowania sieci neuronowych została wykorzystana w przykładach detektorów neuronowych omówionych w następnych rozdziałach monografii.

Literatura


- [7.1] Bishop C.M., *Neural Networks for Pattern Recognition*, Oxford University Press, UK, 1996.
- [7.2] Chow M., *Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection*, World Scientific, 1993.
- [7.3] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (red.), *Biocybernetyka i inżynieria biomedyczna 2000, Tom 6: Sieci neuronowe*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
- [7.4] Ewert P., *Diagnostyka mechanicznych uszkodzeń napędów z silnikami indukcyjnymi przy wykorzystaniu sieci neuronowych*, Praca doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i pomiarów Elektrycznych 2012.
- [7.5] Filippetti F., Franceschini G., Tassoni C., Vas P., *Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques*, IEEE Trans. on Industrial Electr., Vol. 47, No. 5, 2000, 994–1004.
- [7.6] Hertz J., Krogh A., Palmer R.G., *Wstęp do obliczeń neuronowych*, WNT, Warszawa 1995.
- [7.7] Isermann R., *Supervision, fault detection and fault-diagnosis methods. An introduction*, Control Engineering Practice, Vol. 5, No. 5, 1997, 639–652.
- [7.8] Koivo H.N., *Artificial neural networks in fault diagnosis and control*, Control Engineering Practice, Vol. 2, No. 1, 1994, 89–101.
- [7.9] Kościelny J.M., *Diagnostyka zautomatyzowanych procesów przemysłowych*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2001.
- [7.10] Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [7.11] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W. (red.), *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002.
- [7.12] Kowalski C.T., Orłowska-Kowalska T., *Neural Networks Application for Induction Motor Faults diagnosis*, Trans. of IMACS – Mathematics and Computers in Simulation, Vol. 63, No. 3–5, 2003, 435–448.
- [7.13] Kowalski C.T., *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wroclawskiej 57, Wrocław 2005.
- [7.14] Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa 1996.
- [7.15] Pawlak M., *Zastosowanie metod sztucznej inteligencji do wykrywania uszkodzeń wirnika silnika indukcyjnego*, Praca doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych 2005.
- [7.16] Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa 1997.

-
- [7.17] Specht A.F., *A General Regression Neural Network*, IEEE Transactions on Neural Networks, Vol. 2, Issue 6, 1991, 568–576.
- [7.18] Sułowicz M., *Diagnostyka silników indukcyjnych metodami sztucznej inteligencji*, Rozprawa doktorska, Instytut Elektrotechniki w Warszawie, Samodzielna Pracownia Diagnostyki Układów Elektromechanicznych w Krakowie, 2005.
- [7.19] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1995.
- [7.20] Tadeusiewicz R., *Zasady selekcji i organizacji danych uczących w sieciach neuronowych*, Mater. II Kraj. Konfer. Metody i Systemy Komputerowe w Badaniach Naukowych i Projektowaniu Inżynierskim, Kraków 1999, 43–54.
- [7.21] Vas P., *Artificial-Intelligence-Based Electrical Machines and Drives*, Oxford University Press, 1999.
- [7.22] Żurada J., Barski M., Jędruch W., *Sztuczne sieci neuronowe*, Wydawnictwo Naukowe PWN, Warszawa 1996.

8. Wykrywanie uszkodzeń wirników klatkowych silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości

8.1. Charakterystyka zjawisk w silniku indukcyjnym z uszkodzonym wirnikiem klatkowym

Uszkodzenia klatek wirników oraz pierścieni zwierających powodują, że wirnik staje się asymetryczny. Strumień magnetyczny Ψ_s wzbudzony przez uzwojenie stojana w niesymetrycznym wirniku, wytwarza pole wirujące o dwóch składowych, mających względem wirnika prędkość $\omega_2 = \pm s \omega_s$ (rys. 8.1).



Rys. 8.1. Strumienie Ψ_r' i Ψ_r'' wzbudzone w wirniku niesymetrycznym

Składowa zgodna wiruje względem stojana z prędkością synchroniczną

$$\omega_2' = \omega_m + \omega_2 = \omega_s(1-s) + s\omega_s = \omega_s \quad (8.1a)$$

Składowa przeciwbieżna wiruje względem stojana z prędkością

$$\omega_2'' = \omega_m + \omega_2 = \omega_s(1-s) - s\omega_s = (1-2s)\omega_s \quad (8.1b)$$

Składowa przeciwbieżna pola jest źródłem składowej prądu stojana o częstotliwości $(1-2s)f_s$, wytwarzającej hamujący moment elektromagnetyczny. Moment ten,

dopiero przy odpowiednio dużym stopniu uszkodzenia wirnika ma istotny wpływ na charakterystykę momentu użytkowego. W stojanie płynie prąd wywołany napięciem sieci zasilającej oraz napięciem indukowanym przez pole przeciwbieżne. Występuje pulsacja prądu fazowego stojana. Jednak w początkowej fazie awarii jest ona słabo widoczna i w związku z tym nie może być sygnałem diagnostycznym.

Na rysunku 8.2 przedstawiono mechanizm i następstwo powstawania kolejnych składowych harmoniczných, po raz pierwszy podany w [8.5].

Uzwojenie stojana	f_s	$(1-2s)f_s$	$(1+2s)f_s$	$(1-4s)f_s$
Uzwojenie wirnika z asymetrią	$\pm sf_s$			$\pm 3sf_s$
Prędkość obrotowa	$2sf_s$			
	Częstotliwość prądu wirnika	Częstotliwość oscylacji prędkości	Częstotliwość prądu wirnika	

Rys. 8.2. Ilustracja mechanizmu generowania częstotliwości w prądzie stojana i wirnika

Jeżeli wirnik jest niesymetryczny (uszkodzony), to prąd wirnika wytwarza dwa przeciwnie wirujące pola o częstotliwościach $\pm sf_s$. Pole współbieżne oddziałuje z polem stojana ($+sf_s \rightarrow f_s$), pole przeciwbieżne indukuje w stojanie siłę elektromotoryczną o częstotliwości $(1-2s)f_s$. Na rysunku 8.2 symbolizuje to zapis $-sf_s \rightarrow (1-2s)f_s$. Powstający pod wpływem tego pola prąd i_1^s współdziała z prądem wirnika o częstotliwości $-sf_s$ (rys. 8.2: $(1-2s)f_s \rightarrow -sf_s$). Prąd i_1^s opisuje zależność:

$$i_1^s = I_1^s \cos[(1-2s)\omega_s t - \alpha_I] \quad (8.2)$$

Współdziałanie tego prądu z podstawowym strumieniem magnetycznym

$$\psi_s = \Psi_s \cos(\omega_s t - \alpha_\psi) \quad (8.3)$$

wytwarza oscylacje momentu elektromagnetycznego o częstotliwości $2sf_s$

$$\Delta M_e(t) = 3p_b \Psi_s I_1^s \sin[2s\omega_s t - (\alpha_\psi - \alpha_I)] \quad (8.4)$$

Oscylacje momentu powodują zmiany prędkości kątowej $\Delta\omega_m(t)$ wokół średniej prędkości ω_m , którą można określić z zależności:


$$J \frac{d(\Delta\omega_m)}{dt} = \Delta M_e(t) \quad (8.5)$$

Po przekształceniach, po uwzględnieniu (8.3) i (8.4), otrzymuje się:

$$\Delta\omega_m(t) = \frac{1}{J} \int \Delta M_e(t) dt = -\frac{3p_b \Psi_s I_1^s}{J 2s\omega_s} \sin[2s\omega_s t - (\alpha\Psi - \alpha_I)] \quad (8.6)$$

Z zależności (8.6) wynika, że moment bezwładności J ma istotny wpływ na zmianę prędkości, a tym samym na amplitudę składowych harmonicznych prądu stojana [8.17, 8.20]. Im mniejszy moment bezwładności, tym większe są oscylacje prędkości silnika.

Efektom oscylacji prędkości jest indukowanie się w stojanie dwóch napięć e_1 i e_2 o prawie równych amplitudach i częstotliwościach $(1 \pm 2s)f_s$ [8.5]. Napięcie e_1 o częstotliwości $(1 - 2s)f_s$ powoduje przepływ prądu i_{1d}^s , który jest odpowiedzią na pierwotne wymuszenie i_1^s (na rysunku 8.2 symbolizuje to zapis $2sf_s \rightarrow (1 - 2s)f_s$). Napięcie e_2 o częstotliwości $(1 + 2s)f_s$ wymusza prąd stojana i_{2d}^s (na rysunku 8.2 symbolizuje to zapis $2sf_s \rightarrow (1 + 2s)f_s$). Efektem końcowym jest pole magnetyczne wirujące względem wirnika z prędkością wynikającą z częstotliwości $3sf_s$ (rys. 8.2). Można więc powiedzieć, że w wyniku asymetrii wirnika jego prąd jest źródłem dwóch pól o częstotliwościach $\pm 3sf_s$. Sekwencja zjawisk powtarza się dalej. Na każdą zmianę strumienia, o różnych częstotliwościach, silnik indukcyjny reaguje, próbując te efekty wytłumić. W konsekwencji powstają kolejne składowe $(1 \pm 2ks)f_s$ coraz mocniej tłumione. W praktyce rozważania zwykle ogranicza się tylko do składowych $(1 \pm 2s)f_s$.



Rys. 8.3. Schemat ilustrujący mechanizm powstawania oscylacji momentu

Na rysunku 8.3 przedstawiono ilustrację zjawisk zachodzących w uszkodzonym wirniku. Składowa prądu stojana i_1^s o częstotliwości $(1 - 2s)f_s$, powstająca w wyniku asymetrii wirnika, powoduje oscylacje momentu elektromagnetycznego $\Delta M_{e\Sigma}$ o czę-

stotliwości $2sf_s$, które z kolei są źródłem oscylacji $\Delta\omega_m$ prędkości kątowej silnika (na wielkość tych oscylacji ma wpływ moment bezwładności J).

Odpowiedzią układu na oscylacje prędkości są dwie składowe prądy: i_{1d}^s o częstotliwości $(1 - 2s)f_s$ oraz i_{2d}^s o częstotliwości $(1 + 2s)f_s$. Prądy te mają w przybliżeniu równe amplitudy i wywołują dodatkowe oscylacje momentu ΔM_{e1} i ΔM_{e2} :

$$\Delta M_{e1} = 3p_b \Psi_s I_{1d}^s \sin \left[2s\omega_s t - (\alpha_\psi - \alpha_I) + \frac{\pi}{2} + \varphi \right] \quad (8.7)$$

$$\Delta M_{e2} = 3p_b \Psi_s I_{2d}^s \sin \left[2s\omega_s t - (\alpha_\psi - \alpha_I) - \frac{\pi}{2} - \varphi \right] \quad (8.8)$$

Wypadkowe oscylacje momentu $\Delta M_{e\Sigma}$:

$$\Delta M_{e\Sigma} = \Delta M_e + \Delta M_{e1} + \Delta M_{e2} \quad (8.9)$$

Po założeniu $I_{1d}^s \cong I_2^s$ oraz po uproszczeniach trygonometrycznych otrzymuje się:

$$\Delta M_{e\Sigma} \cong 3p_b \Psi_s (I_1^s - I_{1d}^s) \cong 3p_b \Psi_s (I_1^s - I_{2d}^s) \quad (8.10)$$

Z zależności (8.10) wynika, że wypadkowe oscylacje momentu są skalarną różnicą między efektem asymetrii (składowa I_1^s) i reakcją na oscylacje prędkości (składowa I_{1d}^s lub I_{2d}^s). Wypadkowy prąd o częstotliwości $(1 - 2s)f_s$ jest więc różnicą między prądem i_1^s i jego reakcją i_{1d}^s .

Mechanizm przedstawiony na rysunku 8.3 można rozszerzyć o działanie kolejnych sił elektromotorycznych o częstotliwościach $2sf_s$ indukowanych w wirniku przez składowe $(1 + 2s)f_s$. Jednak dalsze oddziaływania są już znacznie słabsze i w praktyce mogą być pominięte.

8.2. Wykrywanie uszkodzeń wirnika na podstawie analizy widmowej prądu stojana


Jak zostało to szczegółowo przedstawione w punkcie 8.1, uszkodzeniom wirnika towarzyszą w widmie prądu stojana składowe o częstotliwościach:

$$f_p = (1 \pm 2ks)f_s \quad (8.11)$$


gdzie: $k = 1, 2, 3, \dots$

W dalszej części monografii, częstotliwości, zwane często poślizgowymi, oznaczone odpowiednio: $f_{p1} = (1 - 2s)f_s$ – „lewa” częstotliwość poślizgowa, $f_{p2} = (1 + 2s)f_s$ – „prawa” częstotliwość poślizgowa, $f'_{p1} = (1 - 4s)f_s$, $f'_{p2} = (1 + 4s)f_s$ itd. (rys. 8.4).

Analiza widmowa prądu stojana jest podstawą metody diagnostyki eksploatacyjnej wirników silników indukcyjnych. W literaturze często określa się ją skrótem MCSA (ang. *Motor Current Signature Analysis*). Podstawy metody omówiono m.in. w [8.1, 8.2, 8.6–8.8, 8.23, 8.24, 8.25]. Na rysunku 8.4 przedstawiono ideę rozkładu charakterystycznych częstotliwości zgodnie z zależnością (8.11).



Rys. 8.4. Ilustracja rozkładu częstotliwości poślizgowych w widmie prądu stojana spowodowanych uszkodzeniem wirnika wg (8.11) dla $k = 1, 2$



Rys. 8.5. Ilustracja rozkładu harmonicznych poślizgowych w widmie prądu stojana spowodowanych uszkodzeniem wirnika wg (8.12) dla $k/p = 1, 5, 7, 11$

Do określenia częstotliwości charakteryzujących składowe prądu stojana można również posłużyć się zależnością podaną w [8.8], uwzględniającą harmoniczne przeszerenne pola:

$$f_b = f_s \left[\left(\frac{k}{p_b} \right) (1-s) \pm s \right] \quad (8.12)$$

gdzie $k/p_b = 1, 5, 7, 11$ przy normalnym układzie uzwojeń.

Na rysunku 8.5 przedstawiono ideę rozkładu charakterystycznych składowych częstotliwości wg zależności (8.12).

W tabeli 8.1 przedstawiono przykładowe harmoniczne obliczone z zależności (8.11) dla $k = 1, 2, 3$ i poślizgu $s = 6,5\%$ (silnik SSh 90L-4), a w tabeli 8.2 zestawiono częstotliwości obliczone wg (8.12) dla silnika o poślizgu $s = 6,5\%$ dla kolejnych wartości k/p .

Tabela 8.1. Wartości częstotliwości charakteryzujących uszkodzony wirnik obliczone wg (8.11) dla $s = 6,5\%$

k	f_p [Hz]	
	-	+
1	43,5	56,5
2	37,0	63,0
3	30,5	69,5


Tabela 8.2. Wartości częstotliwości charakteryzujących uszkodzony wirnik obliczone wg (8.12) dla $s = 6,5\%$

k/p	f_b [Hz]	
	-	+
1	43,5	50,0
5	230,5	237,1
7	324,1	330,5


Na rysunkach 8.6–8.9 przedstawiono widma prądu stojana silnika z nieuszkodzonym wirnikiem oraz z wirnikiem z uszkodzonymi (przerwanymi 5 prętów), na których widoczne są charakterystyczne częstotliwości poślizgowe wymienione w tabelach 8.1 i 8.2. Z porównania częstotliwości obliczonych z zależności (8.11) i (8.12) wynika, że dla $k = 1$ i $k/p = 1$, częstotliwości pokrywają się ($f_{p1} = f_{b1}$). Potwierdza to, że pod względem diagnostyki wirnika klatkowego jest to podstawowa częstotliwość charakteryzująca w widmie prądu stojana asymetrię wirnika.

Jednocześnie z wystąpieniem w widmie prądu stojana częstotliwości „poślizgowych” i ich kolejnych krotności wokół f_s (rys. 8.4 i 8.7), w silniku z uszkodzoną klatką występują częstotliwości poślizgowe w pobliżu $5f_s$ i $7f_s$ (tabela 8.2 i rys. 8.8 i 8.9). Fakt ten ma duże znaczenie praktyczne, gdyż w przypadku obciążeń silnika mniejszych niż połowa obciążenia znamionowego ($s < 0,5 s_N$), ocenę klatki wirnika


można realizować na podstawie widma prądu stojana w otoczeniu 5. i 7. harmonicznej.




Rys. 8.6. Widmo prądu stojana w otoczeniu częstotliwości $f_s = 50$ Hz
– „zdrowy” wirnik (silnik SSH 90L-4)



Rys. 8.7. Widmo prądu stojana w otoczeniu częstotliwości $f_s = 50$ Hz
– uszkodzony wirnik (silnik SSH 90L-4)



Rys. 8.8. Widmo prądu stojana w otoczeniu częstotliwości $f_s = 250, 350$ Hz
– „zdrowy” wirnik (silnik SSH 90L-4)



Rys. 8.9. Widmo prądu stojana w otoczeniu częstotliwości $f_s = 250, 350$ Hz
– uszkodzony wirnik (silnik SH 90L-4)

Otoczenie podstawowej harmonicznej jest najbardziej znaczące, ale dla obciążeń $s < 0,5 s_N$ częstotliwości poślizgowe wokół f_s mogą być słabo wyodrębnione. Natomiast częstotliwości charakterystyczne, oprócz $5 f_s$ i $7 f_s$, są stosunkowo wyraźnie wyodrębnione. Na rysunku 8.9 przedstawiono przykład widma prądu w obszarze 5 i 7 harmonicznej sieciowej dla uszkodzonego wirnika.

Według [8.8, 8.26, 8.27] przydatność przedstawionej procedury i posiłkowanie się obszarami wokół 5. i 7. harmonicznej umożliwia skuteczne diagnozowanie klatki wirnika silników dużej mocy już od obciążeń $m_o > 0,2 m_N$. Należy pamiętać, że prowadzenie badań przy zbyt małym i dodatkowo zmiennym obciążeniu, może spowodować pokrywanie się częstotliwości poślizgowych z częstotliwościami od oscylacji obciążenia, co w efekcie może spowodować mylną diagnozę. Procedura diagnostyczna sprowadza się więc do sprawdzenia czy w widmie prądu stojana oprócz składowej podstawowej występują częstotliwości „poślizgowe” $f_s(1 \pm 2s)$ na poziomie właściwym dla uszkodzenia obwodu elektrycznego klatki z uwzględnieniem wpływu obciążenia. Jeżeli obciążenie silnika jest powyżej połowy znamionowego ($s > 0,5 s_N$), to jak wynika z badań eksperymentalnych dla silników o dobrym stanie technicznym klatki, różnice w poziomach składowych f_s i $f_s(1 \pm 2s)$ są rzędu 50 dB i więcej (zależnie od jakości technologii). Jeżeli różnice w poziomach tych składowych są poniżej 35 dB, to silnik należy bezwzględnie wyłączyć.

Tabela 8.3. Klasyfikacja poziomów uszkodzeń wirników klatkowych dla silników dużej mocy

Poziom uszkodzenia	$\Delta = I^s - I_{p1}^s$ (dB)	I^s / I_{p1}^s	I^s / I_{p1}^s [%]	Ocena stanu wirnika	Zalecane działania
1	>60	>1000	<0,10	Doskonały	Żadne
2	54–60	501–1000	0,10–0,20	Dobry	Żadne
3	48–54	251–501	0,20–0,40	Średni	Obserwacja trendu
4	42–48	126–251	0,40–0,79	Uszkodzenie pręta wirnika może powodować problemy związane ze wzrostem rezystancji połączeń	Zwiększyć częstotliwość przeglądu
5	36–42	63–126	0,79–1,58	Jeden lub dwa pręty wirnika uszkodzone lub pęknięte	Wykonać test drganiowy w celu potwierdzenia źródła uszkodzenia
6	30–36	32–63	1,58–3,16	Wielokrotnie uszkodzone lub pęknięte pręty wirnika	Naprawa (możliwie jak najszybciej)
7	<30	<32	>3,16	Wielokrotnie uszkodzone lub pęknięte pręty wirnika i połączenia czołowe	Naprawa lub wymiana (możliwie jak najszybciej)

W tabeli 8.3 zamieszczono klasyfikację poziomów uszkodzeń wirników klatkowych silników dużej mocy. W tabeli zastosowano następujące oznaczenia: I^s – amplituda składowej podstawowej prądu stojana, I_{p1}^s – amplituda składowej poślizgowej prądu stojana.

W przypadku występowania uszkodzeń prętów w różnych miejscach wirnika, na podstawie analizy widmowej można, otrzymać zafałszowaną informację odnośnie do poziomu amplitudy I_1^s . Występuje to zwłaszcza, gdy uszkodzenie w prętach przesuniętych względem siebie o $\pi/2$ [8.1, 8.2, 8.22, 8.27]. Z badań eksperymentalnych wynika, że zarówno skos żłobkowy, jak i niez izolowane pręty wirnika prowadzą do redukcji amplitudy harmonicznycy poślizgowycy [8.7]. Oprócz tego, wśród wirników dużej mocy istnieją charakterystyczne konstrukcje wirników, które wykazują częstotliwość poślizgową w widmie prądu fazowego nawet w przypadku nieuszkodzonego nowego wirnika. Efekt ten jest bardzo widoczny w konstrukcjach wirników, w których liczba ramion stanowi wielokrotność biegunów magnetycznych [8.3].

Na widma prądu stojana ma wpływ nie tylko moment obciążenia, ale również jego charakter. Jeżeli moment obciążenia zmienia się wraz z położeniem wirnika, to widmo prądu stojana zawiera częstotliwości, które mogą się pokrywać z częstotliwościami będącymi symptomami uszkodzeń. Oscylacje momentu obciążenia o krotności częstotliwości obrotowej wirnika f_r wytwarzają w widmie prądu stojana następujące częstotliwości:

$$f_{\text{obc}} = f_s \pm k f_r = f_s \left[1 \pm m \frac{1-s}{p_b} \right] \quad (8.13)$$

gdzie $m/p_b = 1, 5, 7, \dots$

Częstotliwości mogą w niektórych przypadkach pokrywać się w widmie prądu stojana z charakterystycznymi częstotliwościami uszkodzeniowymi, określonymi według zależności (8.11) i (8.12). Może to być powodem błędnej interpretacji widma, a tym samym błędnej diagnozy silnika. Z przypadkami zmiennych obciążeń można się często spotkać w napędach przemysłowych (napędy kompresorów tłokowych, młynów węglowych lub wapiennych).

Należy podkreślić, że klasyczna metoda analizy widmowej prądu stojana nie rozwiązuje w pełni problemu klasyfikacji uszkodzeń i oszacowywania stopnia uszkodzenia na podstawie amplitudy określonych harmonicznycy. Jest wrażliwa na zakłócenia pochodzące od zmian momentu obciążenia i w wielu przypadkach sprawia kłopot z wyizolowaniem charakterystycznycy częstotliwości.

W silnikach indukcyjnych małej i średniej mocy symptomy uszkodzeń wirników są mniej widoczne w widmie prądów fazowych. Ponadto efekty uszkodzeń wirnika są słabo rozróżnialne w silnikach mających wirniki z niez izolowaną klatką lub ze skośną klatką. Zależności między amplitudą częstotliwości charakterystycznycy a stopniem uszkodzenia wirnika są nieliniowe, dlatego też znajomość bezwzględnych wartości tych amplitud jest zazwyczaj niewystarczająca do prawidłowej oceny wielkości uszkodzenia. Jeżeli diagnostyka uszkodzeń wirników jest realizowana w zmiennych warunkach obciążenia silnika, to do poprawnej diagnozy niezbędne jest wprowadzenie dodatkowego sygnału zawierającego informację o warunkach obciążenia silnika, np.

w postaci poślizgu, momentu obciążenia czy też średniego prądu fazowego. Problem jeszcze bardziej się komplikuje w przypadku zasilania silnika z przemiennika częstotliwości, gdyż dochodzi dodatkowa zmienna – aktualna częstotliwość napięcia zasilania. Ponadto, impulsowy charakter pracy przekształtnika powoduje, że widmo prądu zawiera wyższe harmoniczne, co skutecznie utrudnia, a często wręcz uniemożliwia „wyłowienie” użytecznych informacji diagnostycznych, świadczących o uszkodzeniu wirnika [8.24]. Z wyników badań przedstawionych w pracach [8.18, 8.22] wynika, że mimo wymienionych trudności możliwa jest skuteczna diagnostyka wirników silników małej i średniej mocy pracujących w przekształtnikowych układach napędowych w szerokim zakresie zmian częstotliwości.

8.3. Wykrywanie uszkodzeń wirnika na podstawie analizy widmowej modułu wektora prądu stojana

Jak wspomniano w rozdziale 3, w diagnostyce silników indukcyjnych przydatna jest również metoda analizy widma modułu wektora przestrzennego prądu stojana **EPVA**. Moduł wektora przestrzennego prądu (3.7), w przypadku symetrii wirnika, ma wartość stałą. Natomiast w przypadku wystąpienia uszkodzenia, w składowych $i_{s\alpha}$ i $i_{s\beta}$ pojawiają się charakterystyczne częstotliwości, zgodnie z wyrażeniami (8.14a) i (8.14b):

$$i_{s\alpha} = \sqrt{\frac{3}{2}} \{ I_m^s \cos(\omega_s t - \alpha) + I_{p1}^s \cos[(1-2s)\omega_s t - \beta_1] + I_{p2}^s \cos[(1+2s)\omega_s t - \beta_2] \} \quad (8.14a)$$

$$i_{s\beta} = \sqrt{\frac{3}{2}} \{ I_m^s \sin(\omega_s t - \alpha) + I_{p1}^s \sin[(1-2s)\omega_s t - \beta_1] + I_{p2}^s \sin[(1+2s)\omega_s t - \beta_2] \} \quad (8.14b)$$


Po podstawieniu wyrażenia (8.14) do (3.7) otrzymuje się:

$$|\mathbf{i}_s|^2 = \frac{3}{2} ((I_m^s)^2 + (I_{p1}^s)^2 + (I_{p2}^s)^2) + 3I_m^s I_{p1}^s \cos(2s\omega_s t - \alpha + \beta_1) + 3I_m^s I_{p2}^s \cos(2s\omega_s t + \alpha - \beta_1) + 3I_{p1}^s I_{p2}^s \cos(4s\omega_s t + \beta_1 + \beta_2) \quad (8.15)$$


gdzie $I_m^s, I_{p1}^s, I_{p2}^s$ – odpowiednio amplitudy składowej podstawowej i harmonicznnych o częstotliwościach f_{p1} i f_{p2} .

Z zależności (8.15) wynika, że w widmie modułu wektora przestrzennego prądu wystąpi składowa stała, generowana przez składową podstawową prądu stojana oraz

dwa składniki o częstotliwościach $2 sf_s$ i $4 sf_s$. Widmo modu wektora prądu stojana jest „czyste” wokół składowej podstawowej 50 Hz, natomiast symptomy uszkodzenia wirnika są widoczne w pobliżu częstotliwości $2 sf_s$ i $4 sf_s$ (rys. 8.12 i 8.13). Wystąpienie uszkodzenia prętów wirnika powoduje istotny wzrost amplitudy charakterystycznych częstotliwości $2 sf_s$ i $4 sf_s$. [8.1, 8.4, 8.13, 8.17, 8.24].




Rys. 8.10. Hodograf prądu stojana silnika z nieuszkodzonym wirnikiem




Rys. 8.11. Hodograf prądu stojana silnika z uszkodzonym wirnikiem

Na rysunkach 8.10 i 8.11 przedstawiono hodografy modu wektora prądu stojana silnika SSh 90L-4 z nieuszkodzonym i uszkodzonym wirnikiem. Hodograf prądu silnika z uszkodzonym wirnikiem przypomina pierścień, który wywołany jest przez składową $2 sf_s$ w sygnale wektora przestrzennego prądu, pojawiającej się w wyniku

uszkodzenia wirnika. Na rysunkach 8.12 i 8.13 przedstawiono widmo modułu wektora przestrzennego prądu stojana odpowiednio z wirnikiem nieuszkodzonym i wirnikiem z uszkodzonymi pięcioma prętami.



Rys. 8.12. Widmo modułu wektora przestrzennego prądu stojana silnika nieuszkodzonego

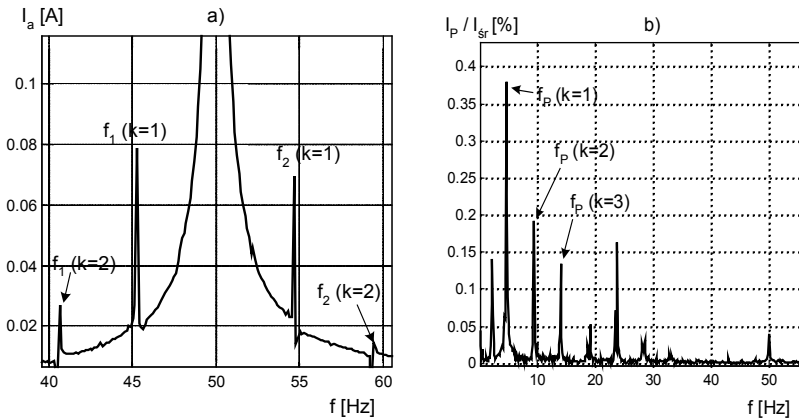


Rys. 8.13. Widmo modułu wektora przestrzennego prądu stojana silnika z uszkodzonym wirnikiem

Amplituda charakterystycznych składowych częstotliwościowych zależy nieliniowo od momentu obciążenia silnika. Badania wykazały, że zależą one również od temperatury silnika – rosną ze wzrostem temperatury silnika, gdyż rośnie wówczas wy-

padkowa rezystancja wirnika, powodując zmniejszenie sztywności charakterystyki mechanicznej silnika i w efekcie zwiększenie wartości poślizgu [8.24].

Diagnostyka wirnika, oparta na metodzie analizy modułu wektora przestrzennego prądu stojana, ma takie same pozytywne cechy co konwencjonalna metoda analizy prądu stojana (MCSA) i jednocześnie eliminuje niektóre ograniczenia i niedogodności widoczne w klasycznym podejściu. Przede wszystkim uwalnia od dodatkowych oddziaływań zmiennego momentu obciążenia na amplitudę harmonicznych poślizgowych $(1 - 2s)f_s$ i $(1 + 2s)f_s$, zafałszowujących autentyczny stopień uszkodzenia. Natomiast w module wektora prądu bardzo łatwo dają się wyodrębnić charakterystyczne składowe $2sf_s$ i $4sf_s$, oddalone wyraźnie od harmonicznej podstawowej. Mają one amplitudy wyraźnie większe od podstawowej, zredukowanej przez transformację Parka. Na rysunku 8.14 przedstawiono przykładowe obliczone widma prądu fazowego i widma modułu wektora przestrzennego prądu dla silnika z uszkodzonym wirnikiem.



Rys. 8.14. Widmo prądu fazowego silnika (a) oraz modułu wektora przestrzennego (b) dla silnika z uszkodzonymi 4 prętami wirnika

Należy podkreślić, że metoda umożliwia wykrycie również innych uszkodzeń typu elektrycznego (np. asymetria zasilania) lub typu mechanicznego (np. niewyosiowanie napędu, niecentryczne osadzenie wirnika). W przypadku asymetrii zasilania lub asymetrii uzwojenia stojana w widmie modułu wektora przestrzennego prądu pojawia się składowa o częstotliwości $f_{usz} = 2f_s$. Natomiast w przypadku niewłaściwego sprzęgnięcia silnika z maszyną roboczą w widmie modułu wektora przestrzennego prądu pojawia się składowa o częstotliwości $f_{usz} = kf_r$ [8.17, 8.20, 8.24].

Reasumując, można stwierdzić, że zastosowanie analizy widmowej modułu wektora przestrzennego prądu stojana ułatwia ocenę diagnostyczną stanu silnika indukcyjnego, ale wiąże się to z większymi nakładami obliczeniowymi.

8.4. Neuronowe detektory uszkodzeń wirnika

8.4.1. Charakterystyka badań

Głównym celem diagnostyki wirników silników indukcyjnych jest wykrycie wstępnej fazy rozwoju uszkodzenia tak, aby nie dopuścić do zaistnienia poważnej awarii. Urządzenia monitorujące stan techniczny wirników powinny odpowiednio wcześniej sygnalizować wystąpienie uszkodzenia i przede wszystkim określić jego stopień. Zależności między amplitudą charakterystycznych składowych spektralnych widma prądowego silnika a stopniem uszkodzenia wirnika są nieliniowe, co powoduje duże trudności w prawidłowej interpretacji wyników analizy częstotliwościowej [8.20, 8.24].


W związku z tym, precyzyjne wyznaczenie stopnia uszkodzenia wirnika z wykorzystaniem klasycznych metod analitycznych jest trudne (szczególnie dla maszyn średniej i małej mocy), gdyż nie ma bezpośredniego powiązania między wielkością uszkodzenia a wyrazistością rozważanych symptomów uszkodzenia. Dlatego też, w takich przypadkach bardzo cennym narzędziem są metody sztucznej inteligencji, zwłaszcza metody korzystające z sieci neuronowych, które mają zdolności uczenia się i uogólniania.

Na podstawie omówionej analizy prądu stojana zaprojektowano i przebadano różnego typu detektory neuronowe, zwłaszcza detektory uszkodzeń wirnika silnika indukcyjnego zasilanego z falownika PWM. Zadaniem neurodetektorów jest rozpoznanie stopnia uszkodzenia wirnika silnika pracującego w szerokim zakresie zmian prędkości obrotowej i momentu obciążenia, na podstawie sygnałów pomiarowych prądu stojana. Na podstawie badań eksperymentalnych silnika rzeczywistego z uszkodzonym wirnikiem sporządzono zestawy sygnałów wejściowych dla detektorów, zawierające charakterystyczne symptomy, odpowiadające różnym wariantom uszkodzenia wirnika. W przypadku neurodetektorów zestawy testujące nie zawierały sygnałów wejściowych stosowanych w procesie uczenia sieci neuronowych.

W badaniach eksperymentalnych zastosowano silnik indukcyjny SSh 90L-4 o mocy 1,5 kW (dane w załączniku 1) wyposażony w zestaw 10 wirników, w których spreparowano różny stopień uszkodzenia. Poszczególne przypadki uszkodzenia wykonano za pomocą przewiercenia wybranych prętów, rozłożonych obok siebie (tzw. uszkodzenie symetryczne) lub wzdłuż jednej osi (tzw. uszkodzenie niesymetryczne). Szczególna uwaga została skupiona na wariancie niesymetrycznego uszkodzenia sąsiednich prętów, gdyż jest ono najczęstszym przypadkiem wśród wszystkich uszkodzeń wirników, ze względu na postępujący charakter rozwoju stopnia uszkodzenia. Badany silnik miał 26 prętów odlewanej klatki, wykonanej z aluminium. Wirnik z największym stopniem uszkodzenia miał 8 przewierconych sąsiednich prętów, co stanowiło prawie 1/3 ogółu wszystkich prętów klatki. Poszczególne otwory powstałe

w wyniku wiercenia zostały wypełnione klejem wykonanym na bazie żywicy epoksydowej, w celu częściowego uzupełnienia ubytku masy na obwodzie wirnika, redukując stopień jego niewyważenia (rys. 8.15).

Modelowanie fizyczne uszkodzeń wirników silników indukcyjnych klatkowych jest metodą inwazyjną, która prowadzi do nieodwracalnego zniszczenia wirnika. Stosowanie tej metody w zakresie silników wielkiej mocy jest praktycznie nieopłacalne ze względu na bardzo duże straty związane z wymianą zniszczonych wirników. Na podstawie teoretycznych znajomości zjawisk fizycznych zachodzących w uszkodzonej maszynie, można przypuszczać, że symptomy uszkodzeń wirników występujących w maszynach małej mocy mogą mieć charakter podobny jak w silnikach dużej mocy. Należy jednak podkreślić, że niezbędne jest gromadzenie danych pomiarowych w czasie eksploatacji maszyn dużej mocy, gdyż tylko one mogą dostarczyć wiarygodnych informacji pomiarowych do uczenia detektorów neuronowych. Efektywność metody fizycznego modelowania uszkodzeń wirnika zależy od jakości wykonania przerw w prętach klatki.



Rys. 8.15. Fotografia wirnika z 7. przewierconymi prętami

W badaniach eksperymentalnych wykorzystano zestaw wirników, do obróbki których zastosowano najprostszą metodę, polegającą na przewierceniu prętów klatki wiertłem o odpowiednio dobranej średnicy. Skutkiem ubocznym zastosowanej metody obróbki mechanicznej jest zniszczenie fragmentu pakietu żelaza, usytuowanego w bezpośrednim sąsiedztwie przewierconego pręta. Prowadzi to do powstania błędów pomiarowych w trakcie realizacji badań, które są spowodowane przepływem prądu o nieznannej wartości przez zniszczony fragment pakietu blach. Pojawienie się prądów międzyprętowych w uszkodzonym wirniku powoduje zafałszowanie informacji uzyskanej w analizie widmowej. W związku z tym, charakterystyczne składowe częstotliwościowe pojawiające się w widmie prądu uszkodzonego silnika mogą mieć nieco zafałszowaną wartość amplitudy w stosunku do wartości generowanych przez rze-

czywiste, „czyste” uszkodzenie wirnika. Niemniej jednak, w praktyce „idealne” przerwy w prętach klatki raczej nie występują.

Badania eksperymentalne rzeczywistego silnika z zestawem uszkodzonych wirników zostały przeprowadzone na stanowisku laboratoryjnym, które umożliwiało zmianę momentu obciążenia silnika w zakresie $0-1,3 M_N$ oraz regulację prędkości obrotowej. Badania wykonano w strukturze sterowania skalarnego. Schemat struktury stanowiska przedstawiono w załączniku 2.

Badania eksperymentalne silnika polegały na pomiarze sygnałów prądu w 3 fazach uzwojenia stojana, dla poszczególnych wariantów uszkodzenia wirnika, dla różnych wartości momentu obciążenia. Następnie zarejestrowane sygnały zostały poddane przekształceniom analizy widmowej, w wyniku których obliczono amplitudę charakterystycznych składowych częstotliwościowych, odpowiadające poszczególnym przypadkom uszkodzenia wirnika.

8.4.2. Perceptronowy detektor uszkodzeń wirników klatkowych

Na podstawie badań eksperymentalnych silnika z zestawem wymiennych wirników, w których zamodelowano różny stopień uszkodzenia został opracowany obszerny zestaw cech diagnostycznych, uzyskanych w wyniku analizy sygnałów prądu stojana. Cechy te zostały wykorzystane jako wzorce diagnostyczne dla neuronowych detektorów uszkodzeń wirnika SI i zostały podzielone na zestawy uczące i testujące sygnałów wejściowych sieci neuronowych [8.15, 8.16, 8.18, 8.24].

Do realizacji algorytmów detektorów uszkodzeń wirnika wykorzystano sieci neuronowe jednokierunkowe, wielowarstwowe, o różnych topologiach. Warstwa wejściowa sieci składała się z różnej liczby wejść, w zależności od stopnia złożoności rozwiązywanego problemu. W sieciach występowała jedna lub dwie warstwy ukryte, o różnej liczbie neuronów. Liczba neuronów w poszczególnych warstwach sieci była dobierana eksperymentalnie. Uczenie rozpoczynano od sieci o prostej topologii, a następnie zwiększano liczbę neuronów w celu znalezienia najkorzystniejszej struktury sieci. W neuronach warstwy wejściowej oraz warstw ukrytych zastosowano nieliniowe funkcje aktywacji typu tangens hiperboliczny, natomiast warstwa wyjściowa zawierała zawsze liniową funkcję aktywacji. Zadaniem sieci neuronowej jest udzielenie odpowiedzi w postaci liczby uszkodzonych prętów klatki badanego silnika. Założono, że detektor powinien pracować poprawnie w szerokim zakresie zmian momentu obciążenia ($0,5 \div 1,0 m_N$) oraz w zakresie zmian częstotliwości wyjściowej przemiennika częstotliwości z przedziału $30 \div 50$ Hz. Dane pomiarowe były rejestrowane dla 3 wartości częstotliwości zadanej falownika: 30, 40 i 50 Hz. Przemiennik częstotliwości pracował w klasycznym, otwartym układzie sterowania, przy stałym stosunku napięcia do częstotliwości ($U/f = \text{const}$).

Przebadano kilkadziesiąt typów sieci neuronowych, różniących się między sobą liczbą warstw ukrytych, liczbą neuronów w poszczególnych warstwach oraz wielkością wektora wejściowego. Wszystkie sieci neuronowe były uczone zestawem wzorców diagnostycznych, które sporządzono na podstawie badań eksperymentalnych silnika z różnymi przypadkami uszkodzenia wirnika.

Opracowany zestaw cech diagnostycznych składa się z następujących symptomów uszkodzeń [8.9, 8.16, 8.18, 8.24]:

- f – częstotliwość napięcia zasilającego,
- I_{\max} – amplituda składowej zerowej modułu wektora przestrzennego prądu stojana,
- I_{sl_1} – amplituda lewej częstotliwości poślizgowej prądu stojana, wyrażona w procentach 1. harmonicznej prądu stojana,
- I_{sp_1} – amplituda prawej częstotliwości poślizgowej prądu stojana, wyrażona w procentach 1. harmonicznej prądu stojana,
- I_{sl_5} – amplituda lewej częstotliwości poślizgowej wokół 5. harmonicznej prądu stojana, wyrażona w procentach 5. harmonicznej prądu stojana,
- I_{sp_5} – amplituda prawej częstotliwości poślizgowej wokół 5. harmonicznej prądu stojana, wyrażona w procentach 5. harmonicznej prądu stojana,
- I_{sl_7} – amplituda lewej częstotliwości poślizgowej wokół 7. harmonicznej prądu stojana, wyrażona w procentach 7. harmonicznej prądu stojana,
- I_{sp_7} – amplituda prawej składowej poślizgowej wokół 7. harmonicznej prądu stojana, wyrażona w procentach 7. harmonicznej prądu stojana,
- slp_1 – suma amplitud składowych sl_1 i sp_1 ,
- slp_5 – suma amplitud składowych sl_5 i sp_5 ,
- slp_7 – suma amplitud składowych sl_7 i sp_7 ,
- p_1, p_2 – amplitudy częstotliwości uszkodzeniowych wyznaczone na podstawie modułu wektora przestrzennego prądu, wyrażone w procentach składowej I_{\max} ,
- p_{12} – suma amplitud składowych p_1 i p_2 .

Ze względu na liczbę i rodzaj sygnałów wejściowych dla sieci neuronowych utworzono 5 zestawów wejściowych, zawierających następujące sygnały:

- Zestaw 1: $f, I_{\max}, I_{sl_1}, I_{sl_2}, p_1$;
- Zestaw 2: $f, I_{\max}, I_{sl_1}, I_{sl_2}, slp_1, p_1, p_2$;
- Zestaw 3: $f, I_{\max}, I_{sl_1}, I_{sl_2}, I_{sl_5}, I_{sp_5}, I_{sl_7}, I_{sp_7}$;
- Zestaw 4: $f, I_{\max}, I_{sl_1}, I_{sl_2}, I_{sl_5}, I_{sp_5}, I_{sl_7}, I_{sp_7}, p_1, p_2$;
- Zestaw 5: $f, I_{\max}, I_{sl_1}, I_{sl_2}, slp_1, I_{sl_5}, I_{sp_5}, slp_5, I_{sl_7}, I_{sp_7}, slp_7, p_1, p_2, p_{12}$;

W celu znalezienia optymalnej struktury sieci neuronowej, realizującej funkcje niezawodnego detektora uszkodzeń wirnika silnika indukcyjnego, przebadano kilkadziesiąt różnych topologii sieci neuronowych, różniących się między sobą liczbą wejść, liczbą warstw ukrytych oraz liczbą neuronów w poszczególnych warstwach.

Ogólnie sieci neuronowe podzielono na 2 grupy, do których należały sieci z jedną warstwą ukrytą oraz sieci z dwiema warstwami ukrytymi.

Zestaw wejściowych wzorców diagnostycznych stanowiła obszerna baza danych, zawierająca 900 rekordów, z których każdy zawierał 14 wyszczególnionych powyżej cech diagnostycznych. Poszczególne rekordy bazy opracowano na podstawie wyników badań laboratoryjnych, które były przeprowadzone w trzech etapach, w efekcie czego uzyskano trzy serie pomiarowe. W związku z tym ogólny zestaw 900 rekordów podzielono na 3 serie danych, na podstawie których sporządzono 3 warianty par zestawów uczących i testujących:

- wariant 1:
 - zestaw uczący: seria 1 + seria 2
 - zestaw testujący: seria 3
- wariant 2:
 - zestaw uczący: seria 1 + seria 3
 - zestaw testujący: seria 2
- wariant 3:
 - zestaw uczący: seria 2 + seria 3,
 - zestaw testujący: seria 1.

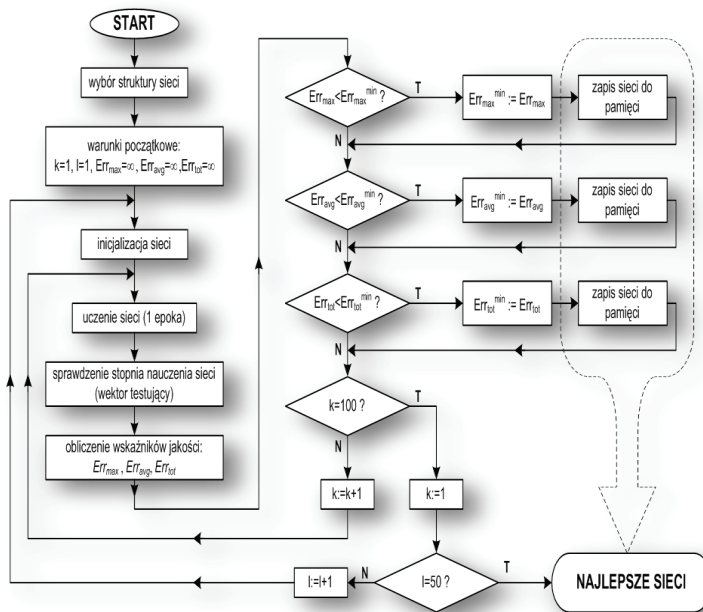
Zestawy uczące dla poszczególnych wariantów zawierały 600 wektorów wejściowych, natomiast zestawy testujące miały 300 wektorów.

W większości przypadków do trenowania sieci neuronowych stosuje się algorytm spadku gradientowego, w których funkcją celu jest minimalizacja błędu średniokwadratowego, obliczanego jako różnica między aktualną wartością wyjściową sieci a wartością pożądaną. Jeżeli proces uczenia trwa odpowiednio długo, takie podejście powoduje, że sieć neuronowa bardzo dobrze rozpoznaje dane należące do zestawu uczącego, natomiast może mieć problemy w przetwarzaniu danych spoza tego obszaru (dane testujące). Następstwem tego jest częściowa bądź całkowita utrata zdolności generalizacji przez sieć neuronową, co powoduje, że sieć staje się nieprzydatna. Zagadnienie to jest szczególnie istotne w diagnostyce silników elektrycznych, gdzie sygnały wejściowe do sieci neuronowej doprowadzone są bezpośrednio z systemów pomiarowych i przetwarzających, w związku z czym odznaczają się stosunkowo dużym szumem oraz dużą wariancją wartości.

Jedną z metod poprawy zdolności generalizacji sieci neuronowych jest metoda polegająca na odpowiednio wczesnym zatrzymaniu procesu uczenia (ang. *early stopping*), co pozwala uniknąć efektu przeuczenia. Niestety optymalny moment zatrzymania procesu uczenia sieci jest trudny do określenia, gdyż zależy on od wielu czynników, między innymi od struktury sieci, liczby i rodzaju danych wejściowych itp. Jeżeli jednak dysponuje się odpowiednio dużym zestawem danych wejściowych sieci, można oprócz zestawu uczącego i testującego wydzielić dodatkowy podzbiór danych – tzw. zestaw walidacyjny, który umożliwi ciągłą kontrolę „stanu nauczania” sieci neuronowej i odpowiednio wczesne przerwanie dalszego procesu uczenia.

W przypadku gdy zestaw danych wejściowych jest stosunkowo mały, można stosować metodę podobną do poprzedniej, która polega na systematycznej kontroli stanu wytrenowania sieci za pomocą zestawu testującego i wyznaczenia momentu, w którym odpowiednio zdefiniowana funkcja celu jest najlepiej spełniona. Wszystkie sieci neuronowe były trenowane z wykorzystaniem właśnie tej metody. Zadaniem każdej sieci neuronowej było określenie stopnia uszkodzenia wirnika przez podanie liczby uszkodzonych prętów. Założono przy tym 3 różne funkcje celu, które polegały na minimalizacji trzech zdefiniowanych wskaźników jakości sieci i pozwoliły na znalezienie najlepiej wytrenowanych sieci.

Na rysunku 8.16 przedstawiono algorytm trenowania sieci wykorzystujący opisaną metodykę oraz zdefiniowane wskaźniki [8.18, 8.22, 8.24].



Rys. 8.16. Algorytm uczenia neuronowych detektorów uszkodzeń wirnika silnika indukcyjnego

Pierwszym wskaźnikiem jakości był **maksymalny błąd odpowiedzi** sieci na poszczególne dane zestawu testującego – Err_{\max} , wyznaczony według następującej zależności:

$$Err_{\max} = \max_{k=1}^N (|Y(k) - Y'(k)|) \quad (8.16)$$

gdzie:

N – całkowita liczba próbek zestawu testującego,

$Y'(k)$ – odpowiedź sieci na k -tą próbkę zestawu testującego,

$Y(k)$ – wartość oczekiwana (liczba faktycznie uszkodzonych prętów).

Drugim wskaźnikiem jakości był **średni błąd odpowiedzi** sieci na wszystkie dane zestawu testującego – Err_{avg} :

$$Err_{avg} = \frac{1}{N} \sum_{k=1}^N |Y(k) - Y'(k)| \quad (8.17)$$

Trzecim wskaźnikiem jakości był **całkowity błąd odpowiedzi** sieci na dane zestawu testującego – Err_{tot} , obliczany jako iloczyn poprzednich wskaźników, według następującej zależności:

$$Err_{tot} = Err_{max} \cdot Err_{avg} \quad (8.18)$$

Na początku zakłada się, że maksymalna liczba epok (iteracji) dla każdej sieci wynosi 100. Każda z przebadanych struktur sieci zostaje poddawana procesowi uczenia 50 razy, za każdym razem, dokonując losowej inicjalizacji wartości współczynników wagowych sieci. Po każdej epoce następuje obliczenie trzech wskaźników jakości wytrenowania sieci (Err_{max} , Err_{avg} i Err_{tot}).

Jeżeli wartość któregoś z tych wskaźników jest mniejsza od minimalnej zapamiętanej wartości, aktualna sieć zostaje uznana za najlepszą i jest zapisywana do pamięci tymczasowej. Jeżeli w kolejnej iteracji uzyska się mniejsze wskaźniki jakości, to poprzednio zapisane sieci zostają zastąpione nowymi. W ten sposób możliwe jest wyłonienie najlepiej wytrenowanych sieci o zadanej topologii, spełniających założone kryteria jakości.

Na podstawie przedstawionego algorytmu wytrenowano 180 różnych neurodetektorów uszkodzeń wirnika, różniących się między sobą strukturą sieci neuronowej oraz wielkością wektora wejściowego, które były uczone na podstawie 3 wariantów zestawów ucząco-testujących. W tabeli 8.4 przedstawiono wyniki uczenia sieci na podstawie wariantu 2 (dane uczące: seria 1 + seria 3, dane testujące: seria 2), w którym uzyskano najlepsze wyniki w trenowaniu sieci neuronowych. W tabeli przedstawiono wskaźniki jakości stopnia wytrenowania każdej z sieci (Err_{max} , Err_{avg} i Err_{tot}) – najlepsze wyniki zostały wyróżnione. Na rysunkach 8.17–8.19 przedstawiono odpowiedzi wybranych sieci neuronowych (wyróżnionych w tabeli 8.4) na zestawy testujące.


Tabela 8.4. Wyniki uczenia sieci neuronowych z 1 warstwą ukrytą dla wariantu 2 (dane uczące: seria 1 + seria 3, dane testujące: seria 2)

Lp.	Topologia sieci	Err_{max}	Err_{avg}	Err_{tot}
1	2	3	4	5
1	5-5-1	2,95	0,78	2,50
2	5-10-1	2,38	0,64	1,73
3	5-15-1	2,10	0,58	1,21
4	5-20-1	2,35	0,50	1,33


1	2	3	4	5
5	5-25-1	2,17	0,47	1,30
6	5-30-1	1,90	0,45	0,88
7	7-5-1	2,55	0,68	2,01
8	7-10-1	2,47	0,53	1,53
9	7-15-1	2,12	0,45	1,01
10	7-20-1	2,30	0,42	1,05
11	7-25-1	1,81	0,44	0,93
12	7-30-1	2,26	0,40	1,11
13	8-5-1	2,88	0,70	2,74
14	8-10-1	2,86	0,59	2,13
15	8-15-1	2,81	0,57	1,72
16	8-20-1	2,57	0,60	1,72
17	8-25-1	2,75	0,56	1,63
18	8-30-1	2,86	0,52	1,65
19	10-5-1	2,30	0,54	1,49
20	10-10-1	2,14	0,47	1,18
21	10-15-1	2,20	0,42	1,03
22	10-20-1	2,07	0,40	0,97
23	10-25-1	1,95	0,37	0,83
24	10-30-1	2,04	0,39	0,85
25	14-5-1	2,43	0,58	1,53
26	14-10-1	2,05	0,46	1,08
27	14-15-1	2,13	0,37	0,92
28	14-20-1	1,99	0,35	1,12
29	14-25-1	2,37	0,41	1,10
30	14-30-1	2,30	0,44	1,07

Na wykresach zaznaczono odpowiedź sieci symbolem gwiazdki, natomiast stopień uszkodzenia wirnika (faktyczną liczbę uszkodzonych prętów klatki) w postaci kropki. Badania wykazały, że w projektowaniu neurodetektorów typu MLP największe znaczenie ma odpowiedni dobór zestawów ucząco-testujących danych wejściowych oraz odpowiednio przeprowadzony proces uczenia sieci neuronowych.


Okazało się, że struktura sieci neuronowej ma zdecydowanie mniejsze znaczenie, możliwe bowiem jest uzyskanie zadowalających wyników zarówno w stosowaniu prostych sieci neuronowych z jedną warstwą ukrytą, jak i struktur bardziej złożonych, zawierających dwie warstwy ukryte, z dużą liczbą neuronów. Zastosowany algorytm trenowania sieci neuronowych oparty na wczesnym zatrzymaniu procesu uczenia sieci, skutecznie zapobiega niekorzystnemu zjawisku „przetrenowania sieci” i utracie zdolności generalizacji przez sieć. Zdefiniowane trzy wskaźniki (8.16)–(8.18) umożliwiały wstępną ocenę neurodetektorów i stanowiły wygodne kryterium w analizie porównawczej ich właściwości.



Rys. 8.17. Odpowiedź neurodetektora 5-30-1 na zestaw testujący, uczonego na podstawie wariantu 2 zestawu danych



Rys. 8.18. Odpowiedź neurodetektora 14-20-1 na zestaw testujący, uczonego na podstawie wariantu 2 zestawu danych



Rys. 8.19. Odpowiedź neurodetektora 14–15–10–1 na zestaw testujący, uczonego na podstawie wariantu 2 zestawu danych

Do ostatecznej oceny działania detektorów neuronowych niezbędne jest sprawdzenie ich skuteczności pod kątem trafności udzielanych odpowiedzi diagnostycznych w różnych warunkach pracy badanego silnika (różny stopień uszkodzenia wirnika, różne wartości momentu obciążenia silnika, zmienna częstotliwość źródła napięcia zasilającego itp.). Odpowiedzi wybranych neurodetektorów na zestawy testujące, przedstawione w postaci graficznej na rysunkach 8.17–8.19, wykazały bardzo dobrą ich skuteczność. We wszystkich przypadkach detektory prawidłowo odróżniały przypadek silnika uszkodzonego od nieuszkodzonego, co ma największe znaczenie w praktyce eksploatacyjnej. Średni błąd wskazania stopnia uszkodzenia wirnika był na zadowalającym poziomie (zwykle poniżej 2 prętów).

Z przeprowadzonych badań wybranych detektorów uszkodzeń wirnika opartych na sieci neuronowej typu MLP wynika, że najlepsze wyniki uzyskano dla sieci neuronowych mających rozbudowany zestaw sygnałów wejściowych (zestaw 4–10 sygnałów, zestaw 5–14 sygnałów). Najlepsze wyniki uzyskano w trenowaniu sieci neuronowych na podstawie danych wejściowych opracowanych według wariantu 2 (dane uczące: seria 1 + seria 3, dane testujące: seria 2), natomiast najgorsze wyniki uzyskano dla neurodetektorów z 8 wejściami (zestaw danych wejściowych nr 3). Wynikało to z faktu, że zestaw sygnałów wejściowych nie zawierał cech diagnostycznych pochodzących z analizy częstotliwościowej modułu wektora przestrzennego (p_1 , p_2 , p_{12}). Liczba warstw ukrytych sieci neuronowych, jak również liczba neuronów w tych war-

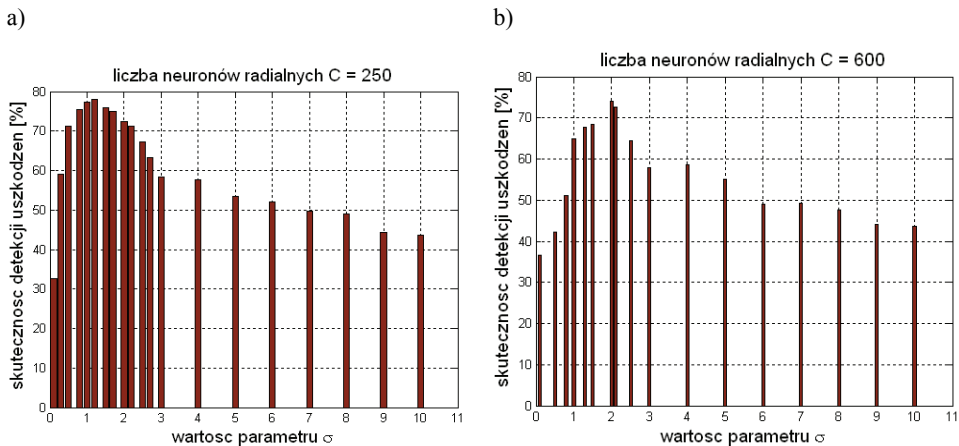
stwach mają zdecydowanie mniejszy wpływ na właściwości neurodetektorów niż liczba sygnałów w wektorze wejściowym.

8.4.3. Detektor uszkodzeń wirników klatkowych oparty na sieci radialnej

Idea przetwarzania danych w sieciach radialnych jest odmienna w stosunku do klasycznych, perceptronowych struktur sieci MLP (*Multi Layer Perceptron*) (rozdział 7.7). W przypadku zastosowania sieci radialnych RBF (*Radial Basis Function*), za realizację odwzorowania każdego klastra przestrzeni odpowiada poszczególny neuron warstwy ukrytej sieci. Dalej przedstawiono przykład zastosowania sieci radialnej do budowy detektora uszkodzeń wirnika z zastosowaniem dwóch metod rozmieszczania centrów neuronów radialnych:

- przez bezpośrednie przypisanie poszczególnych elementów ze zbioru treningowego jako centrum poszczególnych klastrów,
- za pomocą algorytmu K -średnich.


Do projektowania detektora wykorzystano te same wyniki analizy FFT prądu stojana oraz modułu wektora przestrzennego prądu stojana, które zostały wykorzystane w detektorze MLP (rozdział 8.4.2). Poniżej przedstawiono wyniki otrzymane dla sieci uczonej zestawem danych nr 2 [8.9, 8.11].



Rys. 8.20. Zależność skuteczności detekcji uszkodzeń od wartości parametru σ dla sieci RBF: (a) metoda K -średnich, (b) bezpośrednie dopasowanie do zbioru danych wejściowych

W badaniach wykonane zostały testy dla sieci RBF, w których dobór centrów funkcji radialnych przeprowadzono za pomocą opisanych wcześniej obu metod podziału danych uczących (rozdział 7.7). Należy zauważyć, że bezpośrednie przypisanie

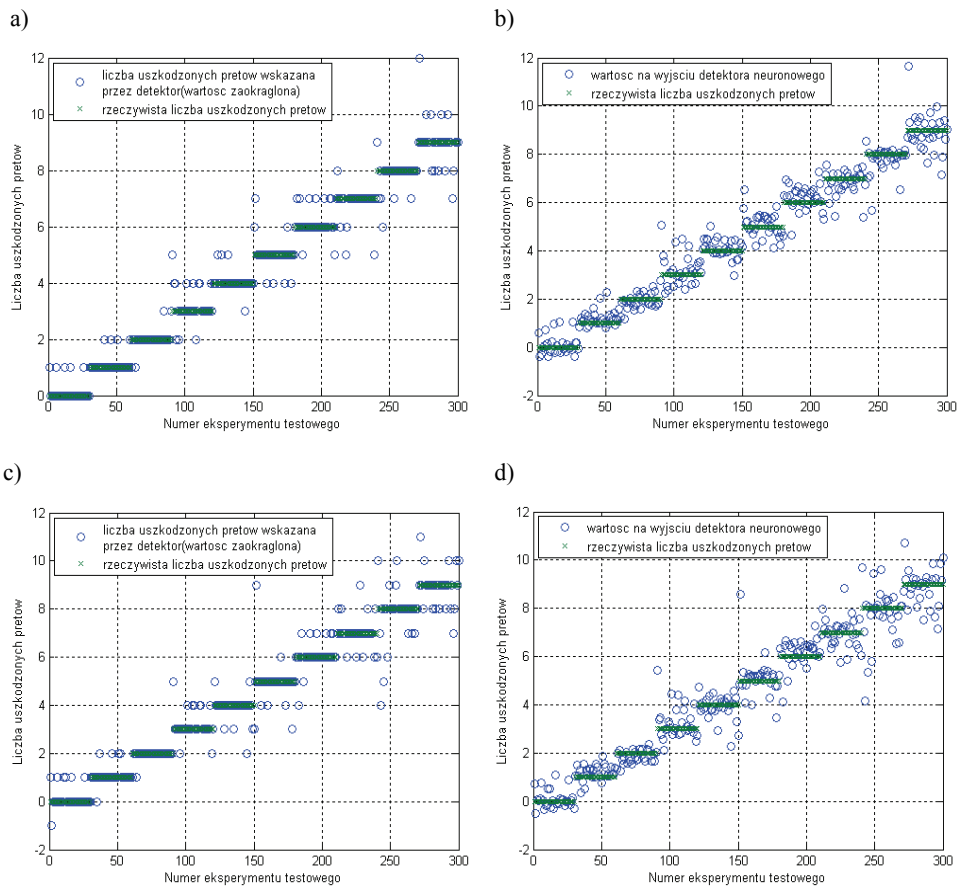
danych z treningu jako centrów poszczególnych neuronów radialnych eliminuje konieczność doboru liczby neuronów ukrytych. Metoda ta jest prosta i nie wymaga dużych nakładów obliczeniowych, jednak sieć jest bardzo złożona. Duża liczba neuronów w warstwie radialnej powoduje zwiększenie rozmiaru macierzy przetwarzanych w sieci neuronowej danych, co jest znacznym utrudnieniem w próbach implementacji sprzętowej takiej sieci. Zastosowanie algorytmu K -średnich wymaga założenia *a priori* liczby neuronów ukrytych, jednak umożliwia uzyskanie bardzo dobrych wyników z jednoczesnym ograniczeniem złożoności sieci. Na rysunku 8.20 przedstawiono zależność skuteczności detekcji uszkodzeń dla różnych wartości parametru σ i liczby neuronów radialnych z zastosowaniem obu metod.



Rys. 8.21. Wpływ liczby neuronów ukrytych sieci RBF (metoda K -średnich) na skuteczność detekcji uszkodzeń wirnika

Uzyskano dużą dokładność detekcji uszkodzeń dla danych pomiarowych otrzymanych przy zmianach momentu obciążenia oraz przy zasilaniu silnika z przemiennika częstotliwości. Na dokładność detekcji uszkodzeń przez sieć radialną istotny wpływ ma współczynnik σ (kształtuje szerokość funkcji radialnej). Wartość tego parametru wpływa na wartość biasu, a zatem na skalowanie danych wejściowych kolejnych neuronów. Jeśli wartość parametru σ jest zmniejszana, to zwiększa się szerokość funkcji aktywacji neuronu. W takim przypadku zmniejsza się dokładność przetwarzania danych przez sieć. Wraz ze wzrostem współczynnika σ funkcja obejmuje mniejszy obszar, zwiększa się dokładność generalizacji danych, wrażliwość na zmiany sygnałów wejściowych. Jednak konsekwencją zwiększania wartości σ może być w praktycznych rozwiązaniach generowanie zakłóceń przez sieć, przenoszenie na wyjście szumów pomiarowych. W związku z zawężaniem przestrzeni obejmowanej przez funkcje radialne, wymagana jest większa liczba neuronów do poprawnej reprezentacji danego zbioru danych przez sieć neuronową. Podczas pracy w zakresie największej zmienno-

ści funkcji radialnej uzyskiwana jest największa efektywność działania detektorów. W przypadku detektora, w którym dobierano rozmieszczenie neuronów za pomocą metody K -średnich zbadano wpływ liczby neuronów ukrytych na dokładność wykrywania uszkodzeń wirnika (rys. 8.21). Badania wykonano dla stałej wartości współczynnika $\sigma = 1, 2$. Liczba neuronów ukrytych ma istotny wpływ na dokładność detekcji uszkodzeń. Dla badanego silnika najlepsze rezultaty uzyskano w przypadku sieci z 250 neuronami ukrytymi. Dla mniejszej liczby neuronów ukrytych sieć nie jest w stanie poprawnie dopasować się do danych uczących, natomiast w razie nadmiarowej liczby neuronów radialnych maleją zdolności generalizacyjne sieci.



Rys. 8.22. Wpływ metody rozmieszczania centrów neuronów radialnych na dokładność detekcji uszkodzeń wirnika silnika indukcyjnego: (a, b) – metoda K -średnich, (c, d) – metoda bezpośredniego dopasowania do zbioru danych wejściowych (a, c – wyniki zaokrąglone, b, d – wyniki dokładne)

Sposób przetwarzania danych w sieciach RBF umożliwia odtwarzanie dowolnej nieliniowej funkcji za pomocą jednej warstwy ukrytej, jednak jest to związane z koniecznością zastosowania większej liczby neuronów niż w przypadku sieci MLP. Na rysunku 8.22 przedstawiono wykresy przedstawiające działanie detektorów RBF dla poszczególnych serii danych pomiarowych wykorzystanych w procesie testowania, dla obu analizowanych metod rozmieszczania centrów neuronów radialnych.

Detektory zaprojektowane z wykorzystaniem metody K -średnich umożliwiły uzyskanie większej dokładności detekcji (78%) w porównaniu z sieciami RBF opartymi na uproszczonej metodzie doboru centrów funkcji radialnych (74%). W przypadku najlepszych detektorów (rys. 8.22 a,b) nie występują błędne diagnozy polegające na wskazaniu, że wirnik jest sprawny, w przypadku gdy w rzeczywistości występuje uszkodzenie prętów klatki. Dla rozbudowanej bazy danych pomiarowych, obejmującej zmiany momentu obciążenia oraz częstotliwości zasilania silnika, występują nieznaczne i nieliczne błędy w określaniu konkretnej liczby uszkodzonych prętów klatki silnika.


Detektory uszkodzeń wirnika silnika indukcyjnego, zrealizowane za pomocą sieci RBF, są alternatywą dla klasycznych sieci MLP. Zastosowanie sieci RBF znacznie upraszcza dobór struktury detektorów, proces treningu sieci jest znacznie prostszy niż w sieciach MLP, wymaga mniej mocy obliczeniowej oraz trwa znacznie krócej. Uzyskane wyniki badań prezentują duże możliwości zastosowania sieci radialnych w klasyfikacji danych.

8.4.4. Detektor uszkodzeń wirników klatkowych oparty na sieci neuronowo-rozmytej


Rolę detektorów uszkodzeń wirnika silnika klatkowego zasilanego z przemiennika częstotliwości mogą również spełniać sieci neuronowo-rozmyte [8.10, 8.16, 8.23]. Zaprezentowany detektor projektowano i testowano z wykorzystaniem tych samych danych pomiarowych, które zastosowano w detektorach MLP i RBF (rozdział 8.4.2 i 8.4.3). Podobnie jak w poprzednich typach detektorów, na wejście sieci neuronowo-rozmytej podawane są symptomy uszkodzeń, natomiast na wyjściu uzyskiwana jest informacja o wystąpieniu defektu oraz liczbie uszkodzonych prętów wirnika silnika indukcyjnego.

Na rysunku 8.23 przedstawiono porównanie jakości detekcji uszkodzeń wirnika w zależności od przyjętego zestawu danych wejściowych podawanych na detektor (zestaw nr 1 do zestaw nr 4 – jak w rozdziale 8.4.3). Na rysunkach 8.23a,c,e przedstawiono odpowiedzi sieci zaokrąglonych, zgodnie z zasadami matematyki, natomiast 8.23b, d, f – odpowiedzi rzeczywiste sieci.


a)




b)




c)




d)

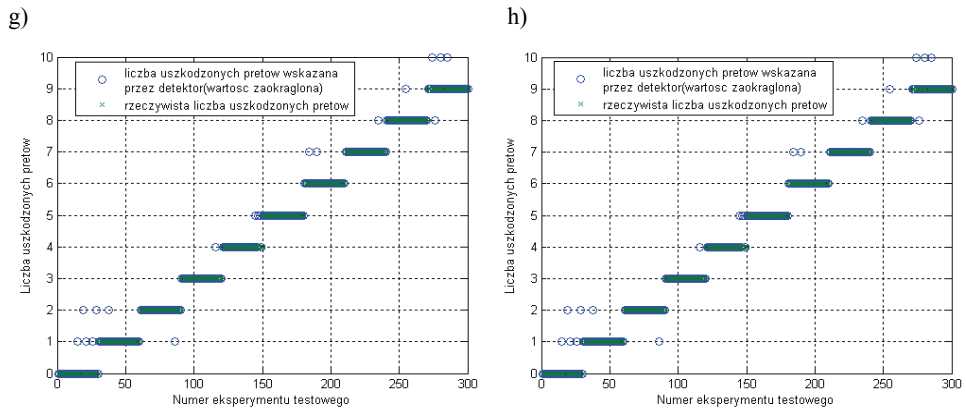


e)



f)





Rys. 8.23. Wyniki testowania neuronowo-rozmytego detektora uszkodzeń wirnika silnika indukcyjnego dla różnych postaci wektora wejściowego (zestaw 1 – a, b, zestaw 2 – c, d, zestaw 3 – e, f, zestaw 4 – g, h)

Należy zauważyć, że wraz z rozbudową wektora wejściowego detektora wzrasta skuteczność wykrywania uszkodzeń, jednak znacząco zwiększa się jednocześnie czas trwania etapu uczenia. Przyczyną takiego stanu jest wzrost rozmiarów struktury modelu neuronowo-rozmytego, dobieranej za pomocą automatycznej metody *subtractive clustering*.

W przypadku najbardziej rozbudowanego zestawu danych wejściowych (zestaw 5 – rozdział 8.4.2) czas treningu wydłużył się na tyle znacząco, że zrezygnowano z realizacji detektora z tak sformowanym wektorem sygnałów wejściowych. W tabeli 8.5 przedstawiono ilościowe zestawienie błędów działania sieci (zdefiniowanych w punkcie 8.4.2) oraz podano procentową skuteczność działania sieci w zależności od złożoności wektora wejściowego.

Tabela 8.5. Zestawienie parametrów opisujących skuteczność detekcji uszkodzeń wirnika silnika indukcyjnego dla różnych postaci wektora wejściowego


	Err_{max}	Err_{avg}	Err_{tot}	Skuteczność[%]
Zestaw 1	5,16	0,43	2,20	73,67
Zestaw 2	4,47	0,25	1,12	83,67
Zestaw 3	3,05	0,22	0,66	90,33
Zestaw 4	1,84	0,16	0,29	93,33

Zastosowanie tego typu modelu w detekcji asymetrii wirnika maszyny jest bardzo korzystne i wynika to z właściwości struktur neuronowo-rozmytych, które w procesie treningu uczą się relacji między danymi wejściowymi, aby w następnym etapie prawidłowo klasyfikować dane (nie brane pod uwagę w zbiorze uczącym) związane

z symptomami uszkodzeń. Uzyskano bardzo dobre wyniki klasyfikacji uszkodzeń przy zmianach momentu obciążenia oraz zasilania falownikowego [8.10, 8.23].

8.4.5. Detektor uszkodzeń wirników klatkowych oparty na sieci MLP trenowanej danymi z analizy falkowej

Jedne z pierwszych zastosowań sieci neuronowej typu MLP trenowanej danymi z analizy falkowej w zastosowaniu do projektowania detektorów uszkodzeń wirników klatkowych przedstawiono w [8.14, 8.19–8.21]. Na rysunku 8.24 przedstawiono ogólny schemat systemu diagnostycznego opartego na analizie falkowej i sieci neuronowej.




Rys. 8.24. Schemat ideowy systemu diagnostycznego wykorzystującego analizę falkową


W bloku pierwszym następuje pomiar sygnału diagnostycznego (np. prądu stojana), który w kolejnym bloku jest przetwarzany za pomocą falkowej dekompozycji sygnału WPD (ang. *Wavlet Packet Decomposition*), omówionej w rozdziale 4, oraz obliczane są wartości energii przenoszonej przez każdy węzeł drzewa dekompozycji. W bloku trzecim następuje wybór odpowiednich węzłów zdekomponowanego sygnału, przenoszących informację o szukanym uszkodzeniu (wykazujących określoną tendencję zmian energii – wzrost lub zmniejszanie się). Energia przenoszona przez wybrane pasma jest następnie podawana na blok wnioskowania. Zawiera on system klasyfikujący stopień uszkodzenia, na podstawie wektora wejściowego. System ten może być oparty na metodach sztucznej inteligencji – sieci neuronowej lub neuronowo-rozmytej. Wyjściem bloku wnioskowania jest liczba określająca stopień uszkodzenia wirnika.

Dalej przedstawiono dwa przykłady zastosowania analizy falkowej do projektowania neuronowych detektorów uszkodzeń wirnika.

W pierwszym przykładzie do projektowania detektora uszkodzeń wirnika wykorzystano przebiegi rozruchowe (rozruch bezpośredni) silnika indukcyjnego. Na rysunku 8.25 i 8.26 przedstawiono przebieg prądu stojana w trzech fazach, dla przypadku rozruchu silnika z nieuszkodzonym oraz uszkodzonym (8 prętów pękniętych) wirnikiem.



Rys. 8.25. Przebieg prądu fazowego stojana podczas rozruchu silnika z nieuszkodzonym wirnikiem



Rys. 8.26. Przebieg prądu fazowego stojana podczas rozruchu silnika z uszkodzonym wirnikiem (8 pretów pękniętych)

Wyraźnie można zauważyć zależność między stopniem uszkodzenia wirnika a czasem trwania rozruchu. Wraz ze wzrostem liczby uszkodzonych pretów, czas roz-


ruchu ulega wydłużeniu. Wykorzystując programy *Wavelet Decomposition* i *Wavelet Packet Decomposition* (WDP) ze środowiska MATLAB, przeprowadzono dekompozycję zarejestrowanego sygnału prądu stojana do poziomu piątego. Częstotliwość próbkowania mierzonego sygnału wynosiła $f_p = 10$ kHz. Szerokość pasma częstotliwości węzła można obliczyć z zależności:

$$B = \frac{1}{2} \frac{f_p}{2^n} \quad (8.19)$$


gdzie:

- B – szerokość pasma częstotliwości [Hz],
- f_p – częstotliwość próbkowania sygnału [Hz],
- n – przyjęty poziom dekompozycji.


Dekompozycję przeprowadzono dla falki Daubechies rzędu 5 (db5). Zgodnie z wzorem (4.27) obliczono wartość energii każdego węzła. Wyniki obliczeń przedstawiono w tabeli 8.6. Natomiast na rysunku 8.27 pokazano pełne drzewo dekompozycji pakietowej do poziomu piątego oraz na rys. 8.28 – drzewo zwykłej dekompozycji falkowej (również do piątego poziomu). W tabeli 8.6 zaznaczono węzły wytypowane do uczenia sieci neuronowej – mają one wyraźne trendy rosnące lub malejące w zależności od poziomu uszkodzenia wirnika (rys. 8.29 i 8.30). Dodatkowo, dla lepszego zobrazowania trendów, na rys. 8.31 przedstawiono przykładowy przebieg składowej sygnału prądu stojana na piątym poziomie dekompozycji w węzłach (5.0) i (5.1) dla wirnika nieuszkodzonego i uszkodzonego.



Rys. 8.27. Pełne drzewo dekompozycji pakietowej do poziomu piątego




Rys. 8.28. Pełne drzewo zwykłej dekompozycji falkowej do poziomu piątego



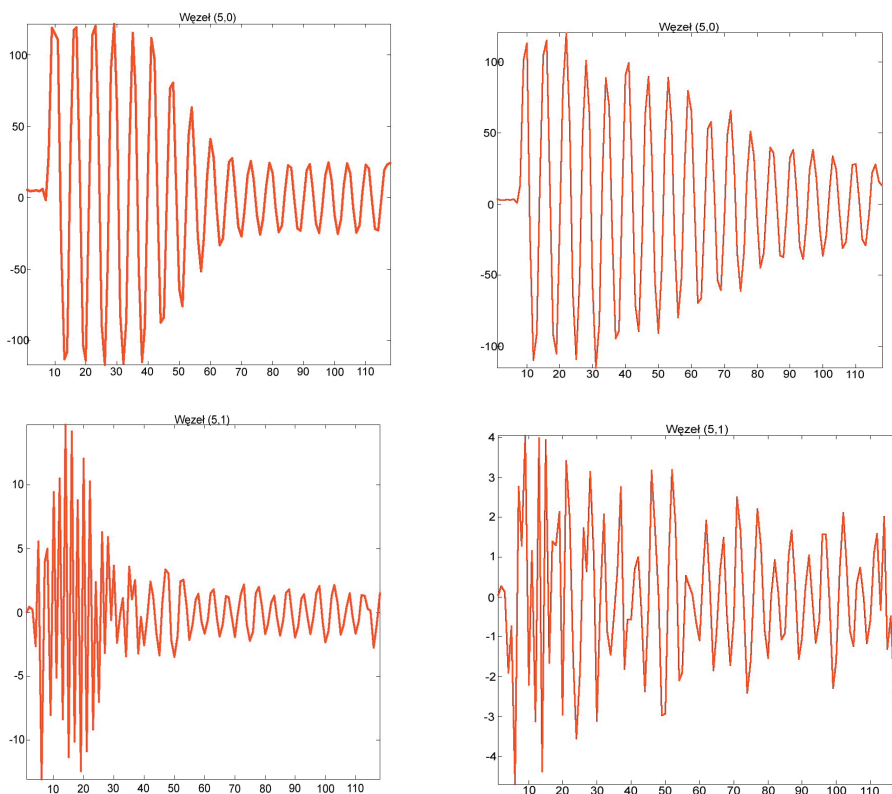
Rys. 8.29. Zależność wartości energii w węźle (5,0) od stopnia uszkodzenia wirnika

Tabela 8.6. Wartości energii węzłów na piątym poziomie drzewa dekompozycji pod obciążeniem znamionowym

Liczba uszkodzonych prętów	Numer kolejnego węzła piątego poziomu dekompozycji							
	0	1	2	3	4	5	6	7
0	9,92E+01	6,71E-01	6,69E-03	5,56E-02	2,13E-04	6,97E-04	2,62E-03	1,34E-03
1	9,93E+01	6,36E-01	8,43E-03	4,74E-02	8,54E-05	3,59E-04	2,91E-03	1,61E-03
2	9,94E+01	5,28E-01	4,92E-03	4,57E-02	1,26E-04	4,95E-04	2,61E-03	1,11E-03
3	9,95E+01	4,66E-01	6,45E-03	3,09E-02	1,12E-04	2,25E-04	2,49E-03	8,70E-04
4	9,96E+01	3,62E-01	3,64E-03	5,87E-02	6,83E-05	3,02E-04	1,52E-03	1,19E-03
5	9,96E+01	3,21E-01	6,23E-03	4,45E-02	7,52E-05	3,09E-04	1,98E-03	9,98E-04
6	9,97E+01	2,56E-01	5,78E-03	3,14E-02	6,36E-05	2,86E-04	2,15E-03	8,09E-04
7	9,98E+01	1,81E-01	4,46E-03	4,80E-02	5,87E-05	3,79E-04	1,99E-03	1,14E-03
8	9,98E+01	1,29E-01	2,72E-03	3,48E-02	3,77E-05	1,56E-04	1,11E-03	3,93E-04
	8	9	10	11	12	13	14	15
0	7,28E-06	5,96E-06	4,43E-05	1,88E-05	8,75E-05	7,40E-05	3,70E-05	5,07E-05
1	6,09E-06	7,76E-06	5,71E-05	1,26E-05	1,43E-04	1,24E-04	3,19E-05	6,70E-05
2	4,90E-06	5,14E-06	5,04E-05	1,56E-05	9,57E-05	6,26E-05	3,23E-05	4,80E-05
3	8,22E-06	1,18E-05	5,99E-05	1,67E-05	8,39E-05	6,84E-05	4,51E-05	6,12E-05
4	5,04E-06	7,54E-06	2,86E-05	1,18E-05	5,19E-05	3,57E-05	3,82E-05	5,25E-05
5	5,95E-06	5,64E-06	4,42E-05	1,18E-05	7,58E-05	5,65E-05	3,78E-05	4,86E-05
6	6,01E-06	7,08E-06	4,85E-05	1,07E-05	7,67E-05	5,12E-05	4,91E-05	5,33E-05
7	3,32E-06	4,21E-06	3,60E-05	7,97E-06	5,00E-05	4,60E-05	2,55E-05	2,68E-05
8	3,03E-06	3,62E-06	1,81E-05	3,78E-06	3,43E-05	1,02E-05	2,05E-05	3,14E-05
	16	17	18	19	20	21	22	23
0	9,07E-07	8,29E-07	1,05E-06	1,14E-06	1,66E-06	2,21E-06	1,01E-06	1,10E-06
1	9,62E-07	6,64E-07	8,99E-07	1,14E-06	3,72E-06	4,08E-06	1,75E-06	1,26E-06
2	9,25E-07	8,91E-07	1,22E-06	8,16E-07	2,64E-06	1,55E-06	1,19E-06	1,40E-06
3	2,18E-06	1,51E-06	2,67E-06	3,34E-06	4,48E-06	5,12E-06	3,96E-06	3,62E-06
4	5,34E-07	5,67E-07	4,80E-07	5,61E-07	1,30E-06	1,83E-06	8,81E-07	8,33E-07
5	5,58E-07	6,02E-07	5,80E-07	3,91E-07	1,66E-06	9,19E-07	6,39E-07	1,18E-06
6	1,42E-06	1,18E-06	3,27E-06	1,66E-06	2,07E-06	2,71E-06	2,52E-06	3,02E-06
7	4,54E-07	4,29E-07	7,83E-07	3,86E-07	1,34E-06	1,56E-06	3,98E-07	6,98E-07
8	2,16E-07	1,60E-07	1,51E-07	2,69E-07	3,98E-07	3,53E-07	2,83E-07	2,54E-07
	24	25	26	27	28	29	30	31
0	7,18E-06	6,51E-06	4,45E-06	5,29E-06	3,14E-06	2,96E-06	8,63E-06	5,28E-06
1	7,75E-06	8,16E-06	4,22E-06	4,52E-06	1,00E-06	2,14E-06	5,17E-06	3,50E-06
2	6,12E-06	7,50E-06	3,58E-06	4,44E-06	2,89E-06	2,40E-06	6,66E-06	5,50E-06
3	7,25E-06	1,02E-05	9,99E-06	6,21E-06	2,91E-06	3,32E-06	6,99E-06	6,15E-06
4	4,22E-06	2,55E-06	2,59E-06	2,52E-06	1,09E-06	1,01E-06	2,33E-06	1,41E-06
5	2,14E-06	2,19E-06	2,35E-06	1,94E-06	5,40E-07	8,13E-07	9,26E-07	8,37E-07
6	6,13E-06	7,10E-06	7,11E-06	5,50E-06	2,29E-06	5,01E-06	5,16E-06	3,41E-06
7	2,14E-06	2,12E-06	1,36E-06	2,07E-06	6,65E-07	9,25E-07	2,19E-06	8,73E-07
8	8,10E-07	8,03E-07	7,19E-07	6,06E-07	4,88E-07	5,10E-07	4,43E-07	4,58E-07




Rys. 8.30. Zależność wartości energii w węźle (5.1) od stopnia uszkodzenia wirnika




Rys. 8.31. Przebieg składowej prądu stojana dla piątego poziomu dekompozycji dla: wirnika nieuszkodzonego – lewa kolumna, z 8 uszkodzonymi prętami – prawa kolumna

Przykład wyników tradycyjnej wielorozdzielczej dekompozycji falkowej dla silnika ze „zdrwym” i uszkodzonym wirnikiem przedstawiono na rys. 8.32 i 8.33. Na

rysunkach przedstawiono sygnał pierwotny, sygnał aproksymaty a_5 oraz sygnały detali $d_1 \div d_5$. Nie będą one dalej wykorzystywane.



Rys. 8.32. Dekompozycja do 5 poziomu dla wirnika nieuszkodzonego



Rys. 8.33. Dekompozycja do 5 poziomu dla wirnika uszkodzonego (8 prętów)

Do zaprojektowania neuronowego detektora uszkodzeń wirnika wykorzystano wyniki dekompozycji pakietowej, zamieszczone tabeli 8.6 dla zaznaczonych węzłów (5.0) i (5.1). W tabeli 8.7 zestawiono parametry wektorów uczących i testujących z pomiaru prądu stojana.

Tabela 8.7. Charakterystyka wektorów uczących neurodetektora

	Liczba badanych wirników	Liczba serii pomiarowych	Całkowita liczba pomiarów	Długość wektora uczącego	Długość wektora testującego
Pomiar prądu stojana	9	40	360	315	45

Do rozwiązania problemu wykrywania stopnia uszkodzenia wirnika zaprojektowano sieć typu MLP o następujących parametrach:

- liczba warstw – 2 lub 3,
- liczba neuronów w warstwie ukrytej od 2 do 35,
- funkcje aktywacji neuronów w warstwie ukrytej – tangens hiperboliczny,
- funkcje aktywacji neuronów w warstwie wyjściowej – liniowa,
- parametry uczenia – maksymalnie 2000 epok.


Do trenowania neurodetektora wykorzystano opracowany algorytm. Jego podstawą jest cykliczne douczanie sieci, z jednoczesnym sprawdzaniem stopnia poprawności jej odpowiedzi na wektor testujący. Na kolejne etapy algorytmu składało się kilka kroków:

- wstępny dobór struktury sieci,
- skrócony trening (10 epok),
- sprawdzenie stopnia poprawności odpowiedzi sieci na wektor testujący – obliczanie liczby pomyłek,
- zapisanie wytrenowanej sieci o liczbie spełniającej początkowe założenia,
- dalsze trenowanie i testowanie aż do osiągnięcia warunków końcowych,
- modyfikacja parametrów sieci, kontynuacja pracy algorytmu.

Cykl douczania sieci był powtarzany 200 razy, więc całkowita liczba epok wynosiła 2000. Na jakość wytrenowania sieci mają również wpływ odpowiednio zainicjowane wartości wag poszczególnych neuronów. Najczęściej odbywa się to losowo. Dlatego algorytm uczenia był powtarzany 50 razy, za każdym razem z innymi losowo dobranymi wartościami początkowymi wag. Efekt końcowy prowadził do wybrania najlepiej „wytrenowanej” sieci, która daje najlepszą odpowiedź na wektor testujący. Sieci neuronowe trenowano i testowano oddzielnymi zestawami danych pochodzących z tej samej grupy. Ostatecznie po kilkukrotnej liczbie powtórzeń algorytmu znaleziono optymalne, pod względem skuteczności, struktury sieci neuronowych, których zestawienie przedstawiono w tabeli 8.8.


Tabela 8.8. Zastawienie struktur detektorów neuronowych i stopnia ich skuteczności

Rodzaj uszkodzenia	Struktura SN	Liczba epok treningu	Liczba pomyłek	Skuteczność [%]
Pręty wirnika (obciążenie znamionowe)	2–13–1	190	3	91
Pręty wirnika (50% obciążenia znamionowego – SN trenowana dla obciążenia znamionowego)	2–13–1	190	5	86
Pręty wirnika (50% obciążenia znamionowego – SN trenowana dla 50% obciążenia)	2–8–1	20	5	86



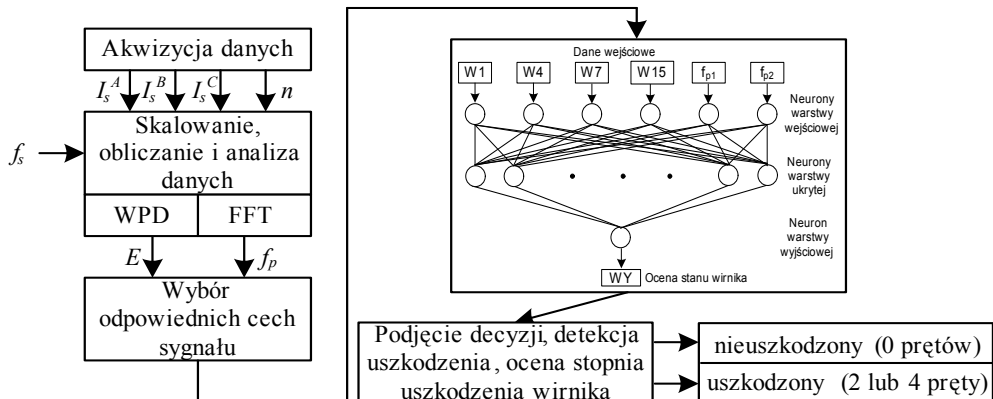
Rys. 8.34. Wyniki testowania neuronowego detektora uszkodzeń wirnika (2–13–1) pod obciążeniem znamionowym

Przedstawione struktury detektorów neuronowych zostały uznane za optymalne. Badania innych, bardziej złożonych struktur z dwiema warstwami ukrytymi, mimo znacznego skomplikowania struktury, nie poprawiły skuteczności SN. Na rysunku 8.34 przedstawiono przykładowe wyniki testowania detektora neuronowego pod obciążeniem znamionowym (skuteczność 91%), a na rys. 8.35 wyniki testowania tego samego detektora przy obciążeniu 50% wartości znamionowej (skuteczność 86%).



Rys. 8.35. Wyniki testowania neuronowego detektora uszkodzeń wirnika (2–13–1) pod obciążeniem 50% m_N

W celu zbudowania detektora uszkodzeń wirnika klatkowego silnika zasilanego z przemiennika częstotliwości napięciem o regulowanej częstotliwości w przedziale 10–50 Hz, wykorzystano dane pochodzące z pełnej dekompozycji sygnału prądu stojana w trzech fazach w stanie ustalonym oraz dodatkowo informację z widma FFT o częstotliwościach poślizgowych. Na rysunku 8.36 przedstawiono strukturę neuronowego detektora uszkodzeń wirnika.



Rys. 8.36. Struktura ideowa neuronowego detektora uszkodzeń wirnika klatkowego

System realizował programowo pakietową dekompozycję sygnałów prądu stojana do piątego poziomu, wykorzystując falę podstawową db5, a następnie poszukiwał takich węzłów, w których występowała tendencja zmian energii (wzrost lub zmniejszanie się) wraz ze zmianą stopnia uszkodzenia wirnika dla różnych częstotliwości zasilania. Badania zrealizowano dla częstotliwości napięcia zasilającego 10, 30 i 50 Hz i trzech przypadków stanu wirnika: nieuszkodzony oraz odpowiednio 2 i 4 pręty wirnika uszkodzone. W tabeli 8.9 przedstawiono przykładowo wartości energii na piątym poziomie dekompozycji dla częstotliwości zasilania $f_s = 50$ Hz.

Tabela 8.9. Wartości energii węzłów na piątym poziomie WPD dla $f_s = 50$ Hz

		Węzeł 1	Węzeł 2	Węzeł 3	Węzeł 4	Węzeł 5	Węzeł 6	Węzeł 7	Węzeł 8
Liczba uszkodzonych prętów	0	7 571 166	205,85	1 359,22	422,03	234,28	999,80	4 498,46	583,07
	2	8 611 519	207,52	1 360,34	397,91	240,43	950,30	4 369,36	532,11
	4	8 714 878	187,63	1 328,98	376,04	211,47	946,76	4 334,02	545,90
		Węzeł 9	Węzeł 10	Węzeł 11	Węzeł 12	Węzeł 13	Węzeł 14	Węzeł 15	Węzeł 16
	0	333,40	2 547,62	379,66	2 553,93	350,35	3 027,00	524,72	442,54
	2	313,86	2 554,84	356,40	2 356,60	335,17	2 854,71	490,39	422,63
	4	305,47	2 427,30	356,75	2 276,14	307,95	2 874,47	473,17	433,28
		Węzeł 17	Węzeł 18	Węzeł 19	Węzeł 20	Węzeł 21	Węzeł 22	Węzeł 23	Węzeł 24
	0	55,98	149,39	386,96	91,37	753,98	324,22	358,66	165,36
	2	57,01	143,65	385,18	96,33	725,68	290,28	356,47	174,57
	4	58,77	140,29	392,14	96,30	711,35	288,54	346,80	175,14
		Węzeł 25	Węzeł 26	Węzeł 27	Węzeł 28	Węzeł 29	Węzeł 30	Węzeł 31	Węzeł 32
0	373,67	1 262,17	412,17	2 161,95	1 181,39	404,49	278,00	357,99	
2	359,45	1 288,36	387,51	2 003,15	1 115,25	357,11	271,06	362,99	
4	347,18	1 207,34	422,19	1 943,31	1 092,30	349,71	270,80	348,89	

Węzły W1, W4, W7 i W15 spełniają przyjęte kryterium wyboru dla trzech wartości częstotliwości zasilania $f_s = 50$ Hz, $f_s = 30$ Hz i $f_s = 10$ Hz. Dane obliczone dla trzech prądów fazowych, trzech częstotliwości zasilania oraz trzech stanów wirnika zostały podzielone odpowiednio na części wykorzystane do trenowania i testowania sieci.

Do rozwiązania problemu automatycznej detekcji uszkodzeń prętów wirnika wykorzystano sieć neuronową o strukturze 6-x-1 (gdzie $x = 1 \div 35$). Przyjęto funkcje aktywacji dla warstw: ukrytej – tangens hiperboliczny oraz wyjściowej – funkcja liniowa. W celu znalezienia optymalnej struktury sieć neuronowa poddana została cyklicznemu douczaniu oraz sprawdzaniu odpowiedzi na wektor testujący.

Zastosowano taki sam algorytm optymalizacji struktury SN jak w poprzednim przykładzie. Przyjęto dwa warianty wartości oczekiwanych na wyjściu:

- wariant A: 0 – wirnik bez uszkodzenia, 1 – wirnik uszkodzony;
- wariant B: 0 dla nieuszkodzonych prętów, 2 dla dwóch uszkodzonych prętów oraz 4 dla czterech uszkodzonych prętów.

W tabeli 8.10 i 8.11 przedstawiono skuteczność działania detektora neuronowego, dla sieci o strukturze 6–18–1 dla wariantu A i B. Ocenę skuteczności D obliczono jako procentowy stosunek prawidłowych odpowiedzi N_{db} dla różnych stanów wirnika (nieuszkodzony, uszkodzony lub 0, 2, 4 uszkodzone pręty) do wszystkich testów N_{max} .

Tabela 8.10. Ocena skuteczności neuronowego detektora – wariant A

Wykrycie uszkodzenia	Liczba testów N_{max}	Wynik diagnozy N_{db}/N_{max}	Skuteczność D [%]
0	18	18/18	100
1	36	24/36	66,7
Σ	54	42/54	77,7

Tabela 8.11. Ocena skuteczności neuronowego detektora uszkodzeń – wariant B

Stopień uszkodzenia	Liczba testów N_{max}	Wynik diagnozy N_{db}/N_{max}	Skuteczność D [%]
0	18	18/18	100
2	18	12/18	66,7
4	18	9/18	50
Σ	54	39/54	75,5

Z podanych badań wynika, że pomimo zastosowania analizy falkowej i złożonego sposobu ekstrakcji symptomów uszkodzeń, nie uzyskano istotnie lepszych wyników, w stosunku do wcześniej omawianych rozwiązań detektorów uszkodzeń. Otrzymano średnią skuteczność wykrywania uszkodzenia w całym przedziale regulacji częstotliwości na poziomie 75%. Wraz ze zmniejszaniem się obciążenia i częstotliwości zasilania wykrywalność uszkodzenia oraz stopnia uszkodzenia istotnie maleje.

8.5. Podsumowanie

Przedstawione w niniejszym rozdziale wyniki badań laboratoryjnych dotyczyły silników małej mocy. Podobne jakościowo symptomy uszkodzeń wirników występują w silnikach dużej mocy. Dlatego też można mieć nadzieję, że wyniki badań eksperymentalnych silników małej mocy mogą być wykorzystane do budowy systemów diagnostycznych przeznaczonych do współpracy z silnikami o znacznie większej mocy.

Zasilanie silnika z przemiennika częstotliwości utrudnia wyodrębnianie charakterystycznych symptomów uszkodzeń wirnika, szczególnie przy małych częstotliwościach zasilania oraz zmiennym momencie obciążenia.

Niemniej jednak ciągle prowadzone są badania nad udoskonaleniem metod cyfrowego przetwarzania sygnału prądu i wprowadzania nowych technik przetwarzania

opartych na sztucznej inteligencji. Przedstawione przykłady zastosowań neurodetektorów i transformacji falkowej potwierdzają słuszność przyjętego podejścia i celowość jego dalszego rozwoju.

Literatura

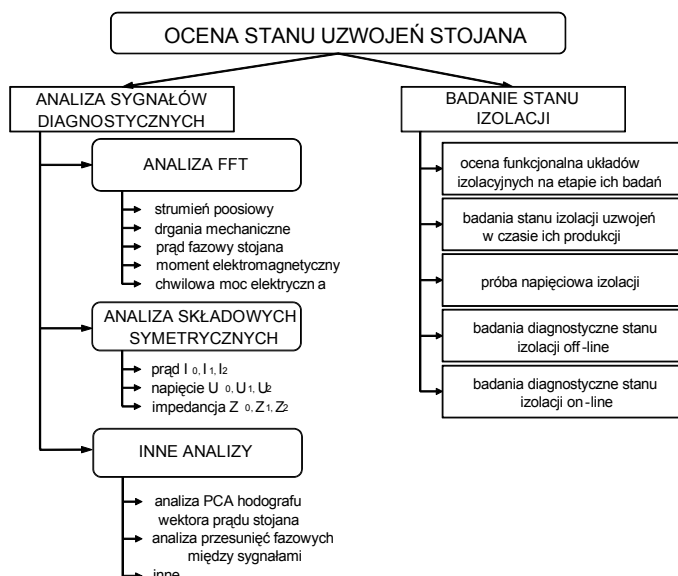
- [8.1] Benbouzid M., *A Review of Induction Motors Signature Analysis as a Medium for Faults Detection*, IEEE Trans. on Ind. Electronics, Vol. 47, No.5, 2000, 984–993.
- [8.2] Benbouzid M., Kliman G.B., *What Stator Current Processing-Based Technique to Use for Induction Motor Rotor Faults Diagnosis*, IEEE Trans. on Energy Conversion, Vol. 18, No. 2, June 2003, 238–244.
- [8.3] Bellini A., Filippetti F., Franceschini G., Tassoni C., Passaglia R., Saottini M., Giovannini M., Rossi A., *On-field Experience With Online Diagnosis of Large Induction Motors Cage Failures Using MCSA*, IEEE Trans. on Ind. Applications, Vol. 38, No. 4, 2002, 1045–1052.
- [8.4] Cruz S.M., Cardoso A.J.M., *Rotor cage fault diagnosis in three-phase induction motors by the synchronous reference frame current Park's Vector approach*, International Conference on Electrical Machines ICEM'2000, Espoo, Finland, 2000, 776–780.
- [8.5] Filippetti F., Franceschini G., Tassoni C., Vas P., *AI Techniques in Induction Machines Diagnosis Including the Speed Ripple Effect*, IEEE Trans. on Ind. Appl., Vol. 34, No. 1, 1998, 98–107.
- [8.6] Hickiewicz J., Neyman P., Szymaniec S., Wach P., *Metodyka badań uszkodzeń klatek wirników silników indukcyjnych*, Zeszyty Naukowe Politechniki Łódzkiej, Elektryka, z. 74, nr 432, 1983, 247–253.
- [8.7] Kliman G.B. et al., *Noninvasive detection of broken rotor bars in operating induction motors*, IEEE Trans. on Energy Conversion, Vol. 3, No. 4, 1988, 873–879.
- [8.8] Kliman G.B., Stein J., *Methods of motor current signature analysis*, Electric Machines and Power Systems, No. 20, 1992, 463–474.
- [8.9] Kamiński M., Kowalski C.T., Orłowska-Kowalska T., *Zastosowanie radialnych sieci neuronowych w detekcji uszkodzeń wirnika silnika indukcyjnego*, Maszyny Elektryczne. Zeszyty Problematyczne, nr 84, 2009, 71–76.
- [8.10] Kamiński M., Kowalski C.T., Orłowska-Kowalska T., *Neuronowo-rozmyte detektory uszkodzeń wirnika silnika klatkowego*, Napęd i Sterowanie, nr 10, 2009, 17–21.
- [8.11] Kamiński M., Kowalski C.T., Orłowska-Kowalska T., *Application of Radial Basis Neural Networks for the Rotor Fault Detection of the Induction Motor*, Eurocon 2011, Lisbon, Portugal, on CD.
- [8.12] Kowalski C.T., Kamiński M., *Rotor fault detection of converter-fed induction motor using General Regression Neural Networks*, Przegląd Elektrotechniczny, Vol. 88, No. 12a, 2012, 71–77.
- [8.13] Kowalski C.T., Pawlak M., *Park's Vector Approach in the Induction Motor On-Line Monitoring and Diagnosis*, Conf. Proc. of EDPE'2003, High Tatras, Slovakia, 2003, on CD.
- [8.14] Kowalski C.T., *Zastosowanie analizy falkowej do budowy neuronowych detektorów uszkodzeń silnika indukcyjnego*, Proc. of 41st Intern. Symp. on Electrical Machines SME'2003, Opole 2003.
- [8.15] Kowalski C.T., Pawlak M., *Application of AI methods for rotor faults detection of the induction motor*, Conf. Proc. of EPE'2003, France, Toulouse 2003.
- [8.16] Kowalski C.T., Pawlak M., *Application of artificial intelligence methods for rotor faults detection of the induction motor*, Acta Electrotechnica et Informatica, Vol. 4, No. 1, 2004, 39–42.
- [8.17] Kowalski C.T., Pawlak M., *Zastosowanie metody analizy wektora przestrzennego prądów stojana do wykrywania uszkodzeń w silnikach indukcyjnych*, Przegląd Elektrotechniczny, nr 7/8, 2004, 771–777.

- [8.18] Kowalski C.T., Pawlak M., *Zastosowanie neuronowego detektora do monitorowania i diagnostyki wirników klatkowych silników indukcyjnych*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME KOMEL, nr 69, 2004.
- [8.19] Kowalski C.T., Szabat K., *Zastosowanie analizy falkowej do wykrywania uszkodzeń w układach napędowych z silnikami indukcyjnymi*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME KOMEL, nr 69, 2004.
- [8.20] Kowalski C.T., *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej nr 57, seria: Monografie, nr 18, Wrocław 2005.
- [8.21] Kowalski C.T., *Zastosowanie analizy falkowej w diagnostyce silników indukcyjnych*, Przegląd Elektrotechniczny, vol. 82, nr 18, 2006, 21–26.
- [8.22] Pawlak M., Kowalski C.T., *Zastosowanie analizy częstotliwościowej prądu do wykrywania uszkodzeń wirników silników indukcyjnych zasilanych z przemiennika częstotliwości*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME KOMEL, nr 77, 2005.
- [8.23] Pawlak M., *Neuronowo-rozmyty detektor uszkodzeń wirnika silnika klatkowego*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych PWr., Zagadnienia maszyn, napędów i pomiarów elektrycznych, seria: Studia i Materiały nr 58, 2005, 316–327.
- [8.24] Pawlak M., *Zastosowanie metod sztucznej inteligencji do wykrywania uszkodzeń wirnika silnika indukcyjnego*, Rozprawa doktorska, Politechnika Wroclawska, 2005.
- [8.25] Sobolewski A., *Zastosowanie klasyfikatorów neuronowych w diagnostyce uszkodzeń wirnika silnika indukcyjnego*, Rozprawa doktorska, Politechnika Białostocka, 2008.
- [8.26] Szymaniec S., *Diagnostyka eksploatacyjna klatek silników indukcyjnych*, Mater. XXX Sympozjum Maszyn Elektrycznych SME'94, Kazimierz, 1994, 478–485.
- [8.27] Szymaniec S., *Badania, eksploatacja i diagnostyka zespołów maszynowych z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 333, Opole 2013.

9. Wykrywanie zwarć zwojowych w stojanie silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości

9.1. Metody wykrywania uszkodzeń w stojanie

Monitorowanie stanu uzwojeń stojana silników indukcyjnych jest obecnie realizowane przez okresowe sprawdzanie jakości izolacji oraz kontrolę symetrii uzwojeń i pomiar ich temperatury. Nie są stosowane metody monitorowania na bieżąco (on-line). Czujniki do ciągłego monitorowania pracy silników indukcyjnych są zwykle instalowane tylko na bardzo ważnych napędach. Czułość czujników jest ograniczona i zwykle nie wykrywają one uszkodzeń w początkowej fazie.



Rys. 9.1. Podział metod monitorowania stanu uzwojeń stojana silnika indukcyjnego

Wykrywanie zwarć zwojowych jest uzasadnione tylko wówczas, gdy będzie realizowane w możliwie wczesnej fazie (ang. *incipient fault*). Obecnie stosowane techniki monitorowania uszkodzeń silników indukcyjnych skoncentrowane są głównie na analizie widmowej drgań mechanicznych oraz prądu stojana [9.9, 9.22, 9.23]. Procedury diagnostyczne, korzystające z takiej analizy, umożliwiają w ograniczonym zakresie wykrywanie symptomów zwarć zwojowych w uzwojeniach stojana. Dlatego poszukuje się bardziej zaawansowanych metod i technik opartych na cyfrowym przetwarzaniu sygnałów oraz sztucznej inteligencji, m.in. sieci neuronowe.


Na rysunku 9.1 przedstawiono ogólny podział metod stosowanych do monitorowania stanu uzwojeń stojana. Przedmiotem rozważań w niniejszej pracy będą tylko metody oparte na analizie sygnałów diagnostycznych. Grupa metod obejmująca badanie stanu izolacji uzwojeń stojana została doskonale opisana w literaturze krajowej [9.24, 9.25].

Mimo wielu rozwiązań prezentowanych w publikacjach naukowych, obszar badań związanych z monitorowaniem uszkodzeń uzwojeń stojana nadal stanowi otwarty problem, ponieważ wiele metod wykazuje dużą wrażliwość na zmienne obciążenia, niedoskonałości produkcji maszyn, warunki otoczenia (środowiska), w jakich pracują, a ponadto na niesymetrii w napięciach zasilających oraz odkształcenie napięcia i prądu stojana związane z zasilaniem silników z przekształtników PWM. Podane aspekty mogłyby w pewnych warunkach eksploatacyjnych spowodować niepewne działanie systemu monitorującego stan maszyny.

Dalej omówiono wybrane metody wczesnego wykrywania zwarć zwojowych. W pierwszej kolejności omówiono metody oparte na analizie widmowej podstawowych sygnałów diagnostycznych, tzn.: prądu fazowego stojana, modułu wektora przestrzennego prądu stojana, strumienia poosiowego, mocy chwilowej, momentu elektromagnetycznego i drgań mechanicznych. Następnie zostaną scharakteryzowane metody oparte na analizie przesunięcia fazowego między napięciem i prądem fazowym stojana oraz przesunięcia kąтового między prądem fazowym we współrzędnych ABC . W trzeciej grupie metod wykorzystano analizę składowych głównych, a w nich określenie na podstawie wektora przestrzennego prądu stojana wartości oraz wektorów głównych. Czwarta grupa metod dotyczy analizy składowych symetrycznych, a zwłaszcza określenia zmian amplitudy składowej kolejności przeciwnej prądu fazowego oraz impedancji.

Wszystkie wyszczególnione metody przetestowano przy zasilaniu silnika indukcyjnego STg 80x-4c z przekształtnika częstotliwości PWM w zakresie zmian częstotliwości $f_s = 10 \div 50$ Hz, pracującego w układzie sterowania skalarnego ($U/f = \text{const}$). Badania wykonano dla zmian momentu obciążenia w zakresie $m_o = 0 \div m_N$. W silniku indukcyjnym istniała możliwość fizycznego modelowania zwarć zwojowych stojana w każdej z faz silnika. Badania eksperymentalne przeprowadzono tylko do 10 zwarć zwojów w jednej fazie, co stanowi około 3% zwojów w uzwojeniu jednej fazy badanego silnika. Prąd zwarciovowy w zwojach zwartych nie był ograniczany dodatko-

wą rezystancją, tym samym rezystancja punktu zwarcia była niemal zerowa. Wprowadzenie końców odpowiednich grup zwojów w każdej z faz uzwojenia stojana (1, 2, 5, 10, 22, 33 zwoje w jednej cewce uzwojenia) umożliwiło fizyczne modelowanie zwarcć zwojowych stojana, niezależnie w każdej z trzech faz silnika (rys. 9.2). Prąd w poszczególnych fazach silnika indukcyjnego mierzono za pomocą wielozakresowych przetworników LA 25-NP firmy LEM, natomiast napięcie międzyfazowe przetwornikami LV 100-400 tej samej firmy. Do pomiaru drgań silnika zastosowano trójosiowy akcelerometr piezoelektryczny Delta Tron typu 4506 firmy Bruel&Kjaer. Pomiar strumienia poosiowego uzyskano pośrednio przez pomiar napięcia indukowanego w zewnętrznej cewce pomiarowej umieszczonej na wale silnika.



Rys. 9.2. Tabliczka zaciskowa silnika indukcyjnego

Sygnaly wyjściowe z przetworników pomiarowych były wprowadzane do układu akwizycji danych, który stanowiła 8-kanalowa karta pomiarowa DAQ typu NI PXI – 4472 firmy *National Instruments*, umieszczona w komputerze przemysłowym typu NI PXI 8186 tej samej firmy. Środowisko programowe stanowiło oprogramowanie LabVIEW dostarczone przez *National Instruments*. Wykonana aplikacja laboratoryjna w postaci wirtualnego przyrządu pomiarowo-diagnostycznego w całości została napisana w języku graficznym G [9.12, 9.16, 9.35].

9.2. Symptomy zwarcć zwojowych w stojanie silnika indukcyjnego zasilanego z przemiennika częstotliwości

9.2.1. Symptomy zwarcć zwojowych w prądzie stojana

W prądzie stojana odzwierciedlone są wszystkie asymetrie występujące w uzwojeniach silnika oraz uszkodzenia typu mechanicznego. Jednakże zwarcia zwojowe w początkowej fazie rozwoju uszkodzenia powodują małe zmiany ilościowe wartości

chwilowej i skutecznej prądów fazowych (rys. 9.3) [9.11, 9.28, 9.35]. Zauważalne zmiany w przebiegach czasowych prądu widoczne są dopiero przy zwarciu 10 zwojów w jednej fazie. Zastosowanie analizy widmowej prądu stojana MCSA (ang. *Motor Current Signature Analysis*) w celu wyodrębnienia częstotliwości charakterystycznych dla zwarć zwojowych, w przypadku napędów przekształtnikowych jest dodatkowo utrudnione ze względu na odkształcenie sygnałów prądów oraz zmienne warunki pracy (regulowana częstotliwość i amplituda napięcia zasilającego). Za symptomy uszkodzeń uzwojeń stojana można przyjąć istotny wzrost amplitud częstotliwości $3f_s$ oraz charakterystycznych częstotliwości w przedziale niskich i średnich częstotliwości obliczanych według zależności sformułowanych w [9.9, 9.22]:

$$f_{sh1} = f_s \left(k \left(\frac{1-s}{p_b} \right) \pm m \right) \quad (9.1)$$

$$f_{sh2} = f_s \left(k N_r \left(\frac{1-s}{p_b} \right) \pm m \right) \quad (9.2)$$


gdzie:

s – poślizg,

p_b – liczba par biegunów,


$k = 1, 2, 3, \dots, m = 1, 3, 5, \dots,$

N_r – liczba zębów wirnika (dla silnika STg 80x-4c $N_r = 22$)



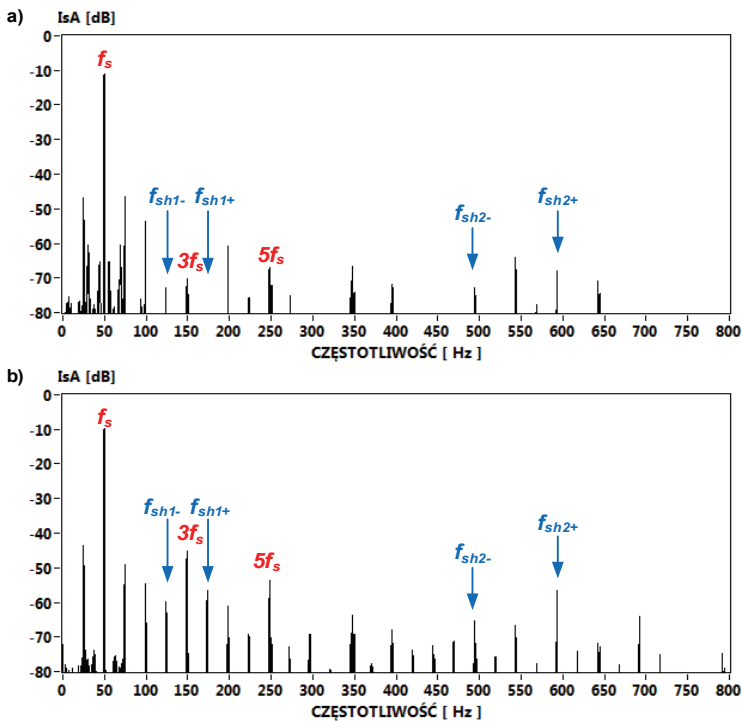
Rys. 9.3. Przebieg czasowy prądu fazowego stojana dla silnika nieobciążonego w przypadku braku uszkodzenia oraz 1, 5 i 10 zwartych zwojów w fazie C

Na rysunku 9.4 przedstawiono zamiany wartości skutecznej prądu w poszczególnych fazach w zależności od liczby zwartych zwojów, dla różnych wartości momentu obciążenia. Największe zmiany widoczne są w fazie C, w której modelowane są zwarcia zwojowe. Zwarcie 10 zwojów powoduje zmianę wartości skutecznej prądu w fazie C o około 15%, podczas gdy w obwodzie zwarciovym płynie prąd przekraczający dziesięciokrotną wartość prądu znamionowego silnika. Dodatkowo zmiany te są silnie zależne od obciążenia silnika. Wraz ze wzrostem obciążenia wzrasta wartość skuteczna prądu fazowego, natomiast zmniejsza się wpływ asymetrii spowodowanej zwarcie. Oprócz zmian amplitudy prądu fazowego, zmianie ulegają również wartości przesunięć fazowych między prądem a napięciem w każdej z faz.



Rys. 9.4. Zależność wartości skutecznej prądu fazowego stojana od liczby zwartych zwojów w fazie C dla różnych obciążeń silnika przy częstotliwości zasilania $f_s = 50$ Hz

Na rysunku 9.5a przedstawiono widmo prądu stojana w fazie A dla silnika nieobciążonego zasilanego częstotliwością $f_s = 50$ Hz, w przypadku braku uszkodzenia oraz 10 zwartych zwojów (rys. 9.5b). Widoczny jest wzrost nieparzystych krotności częstotliwości sieciowej oraz wzrost częstotliwości wynikających z (9.1) dla $k = 1$ i $m = 3$ oraz z (9.2) dla $k = 1$ i $m = 1$. Niestety harmoniczne te występują także podczas normalnej pracy silnika nieuszkodzonego i pokrywają się z częstotliwościami pochodzącymi od zmian momentu obciążenia, czy też ekscentryczności silnika. Dlatego też należy uznać, że klasyczna metoda analizy widmowej prądu fazowego stojana nie rozwiązuje w pełni problemu oszacowania stopnia uszkodzenia uzwojenia stojana na podstawie wartości amplitud charakterystycznych częstotliwości.



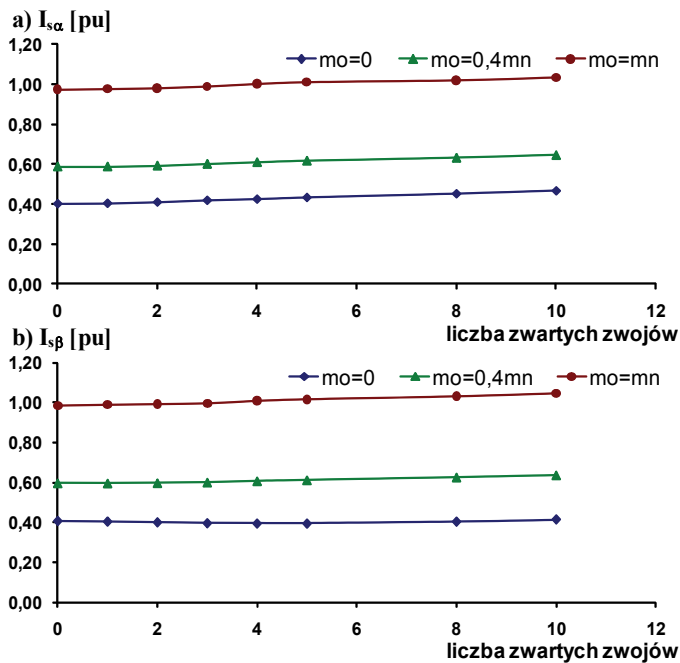
Rys. 9.5. Widmo prądu stojana silnika nieobciążonego przy częstotliwości $f_s = 50$ Hz oraz
a) braku uszkodzenia, b) 10 zwartych zwojów w fazie A

9.2.2. Symptomy zwarcie zwojowych w wektorze przestrzennym prądu stojana

Definicję składowych wektora przestrzennego prądu stojana oraz jego modułu przedstawiono w rozdziale 3. Zmiany wartości chwilowych obliczonego prądu we

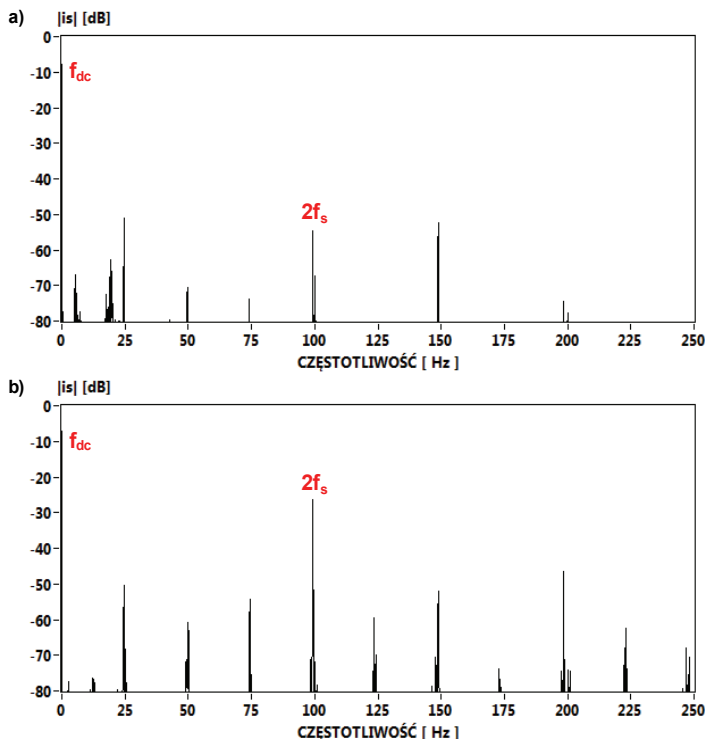
współrzędnych prostokątnych α - β ((3.5) i (3.6)) wskutek zwarcia zwojowego, podobnie jak w przypadków prądu fazowego w układzie współrzędnych ABC , widoczne są dopiero podczas zwarcia 10 zwojów.

Na rysunku 9.6 przedstawiono zmiany wartości maksymalnej prądu w osiach α - β w zależności od liczby zwartych zwojów dla różnej wartości momentu obciążenia. Zwarcie 10 zwojów w jednej fazie powoduje wzrost amplitudy obu prądów $i_{s\alpha}$ i $i_{s\beta}$, z tym, że wzrost amplitudy prądu w osi α jest większy (o około 10%). Dodatkowo zmiany te są zależne od obciążenia silnika. Wraz ze wzrostem obciążenia wzrasta amplituda prądów $i_{s\alpha}$ i $i_{s\beta}$, natomiast zmniejsza się oddziaływanie asymetrii spowodowanej zwarcie.



Rys. 9.6. Zależność amplitudy prądu stojana w osiach α - β od liczby zwartych zwojów dla różnych wartości obciążenia silnika przy częstotliwości zasilania $f_s = 50$ Hz

Diagnostyka oparta na metodzie analizy widmowej modułu wektora przestrzennego prądu stojana $EPVA$ ma te same cechy pozytywne co konwencjonalna metoda widmowa prądu stojana i jednocześnie eliminuje niektóre ograniczenia i niedogodności widoczne w klasycznym podejściu. W przypadku wystąpienia zwarcia w uzwojeniach stojana, w sygnale $|i_s|$ pojawiają się dodatkowe harmoniczne. Jest to podwójna harmoniczna podstawowej częstotliwości napięcia zasilającego $2f_s$ [9.12, 9.29].



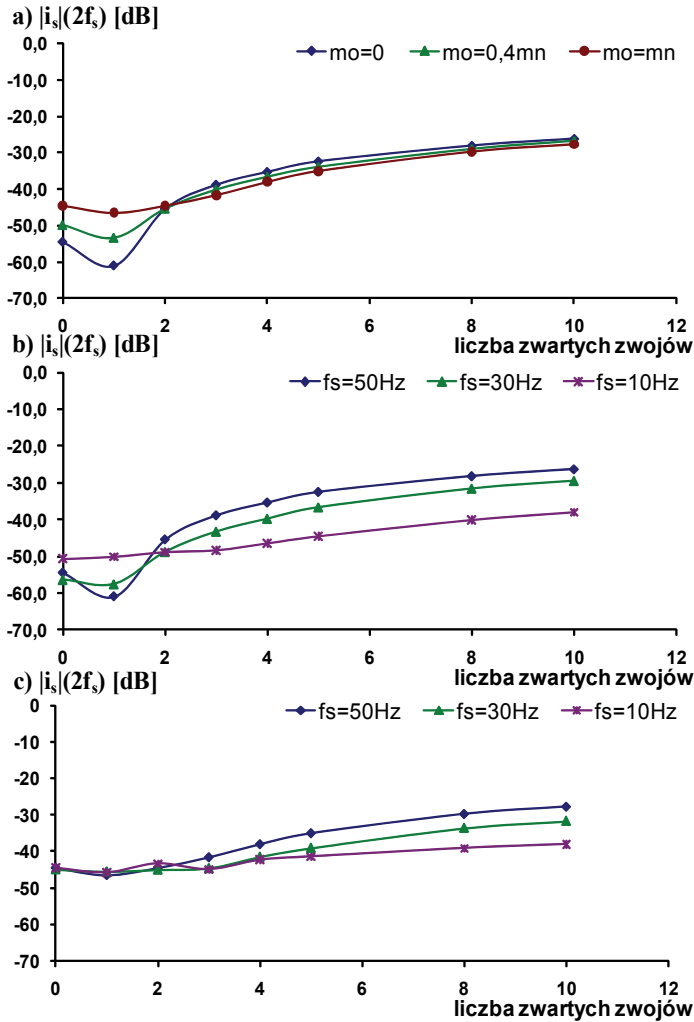
Rys. 9.7. Widmo modułu wektora przestrzennego prądu stojana $|i_s|$ dla częstotliwości zasilania $f_s = 50$ Hz oraz $m_o = 0$: a) silnik nieuszkodzony, b) 10 zwojów zwartych

Na rysunku 9.7a przedstawiono widmo modułu wektora przestrzennego prądu stojana dla silnika nieuszkodzonego przy zasilaniu napięciem o częstotliwości 50 Hz. Widmo częstotliwościowe zawiera oprócz składowej podstawowej f_{dc} , składową sieciową f_s , składową podwójną sieciową $2f_s$ oraz harmoniczną rotacyjną f_r . Na rysunku 9.7b przedstawiono widmo dla przypadku 10 zwojów zwartych w jednej fazie. Wynika z niego, że harmoniczna podwójna sieciowa zwiększa swoją amplitudę wraz ze wzrostem stopnia uszkodzenia.

Na rysunku 9.8 przedstawiono jak kształtuje się amplituda częstotliwości $2f_s$ w module wektora przestrzennego prądu stojana w zależności od liczby zwartych zwojów dla różnych wartości momentu obciążenia (rys. 9.8a) oraz częstotliwości napięcia zasilania (rys. 9.8b i c).

Wraz ze wzrostem stopnia uszkodzenia uzwojenia stojana w jednej fazie wzrasta amplituda charakterystycznej częstotliwości. Dla silnika nieobciążonego ze zwartymi 10 zwojami wzrost amplitudy harmonicznego $2f_s$ jest na poziomie 30 dB przy $f_s = 50$ Hz. Dodatkowo moment obciążenia nieznacznie wpływa na zmianę amplitudy $2f_s$, co ma istotne znaczenie ze względu na monitorowanie stanu uzwojenia silnika induk-


cyjnego. Zmniejszanie częstotliwości zasilania f_s w zakresie od 50÷10 Hz powoduje zmniejszenie intensywności wzrostu amplitudy $2f_s$.



Rys. 9.8. Zależność amplitudy harmonicznej $2f_s$ modułu wektora przestrzennego prądu stojana od liczby zwartych zwojów: a) różne wartości momentu obciążenia silnika przy $f_s = 50$ Hz, b), c) różne częstotliwości zasilania silnika przy $m_o = 0$, $m_o = m_n$, odpowiednio

Stopień uszkodzenia uzwojeń stojana można również oceniać na podstawie zmiany hodografu wektora przestrzennego prądu stojana w nieruchomym układzie współrzędnych α - β . Na rysunku 9.9 przedstawiono teoretyczne zmiany hodografu otrzymane z modelowania matematycznego zwarc zwojowych w różnych fazach stojana. W sy-

metrycznym silniku hodograf prądu stojana ma kształt okręgu. W przypadku uszkodzenia uzwojenia powstaje deformacja hodografu, który wraz ze zwiększaniem stopnia uszkodzenia przekształca się w elipsę. Dodatkowo zwarcia zwojowe powodują zmianę orientacji osi głównych hodografu, w zależności od fazy silnika w jakiej wystąpiło zwarcie. W przypadku uszkodzenia uzwojenia stojana pojawia się deformacja hodografu wektora przestrzennego prądu stojana, która w miarę zwiększania się stopnia uszkodzenia powoduje przekształcenie się okręgu w elipsę. Dodatkowo zwarcia zwojowe powodują zmianę orientacji osi głównych hodografu prądu, w zależności od fazy silnika w jakiej wystąpiło zwarcie.




Rys. 9.9. Hodograf wektora przestrzennego prądu stojana w osiach α - β dla silnika:
 0 – nieuszkodzonego, 1 – z uszkodzeniem uzwojenia w fazie A,
 2 – z uszkodzeniem uzwojenia w fazie B, 3 – z uszkodzeniem uzwojenia w fazie C

W przypadku realizacji rzeczywistego zwarcia kilku zwojów w dowolnej fazie występuje nieznaczne odkształcenie hodografu i stosunkowo trudno zauważyć jest różnice w porównaniu do silnika nieuszkodzonego (rys. 9.10).

Zauważalne zniekształcenie hodografu jest widoczne dopiero podczas zwarcia około 10 zwojów w jednej fazie. Dodatkowo intensywność tych zmian zależy od obciążenia silnika. Dlatego bezpośrednie zastosowanie hodografu wektora przestrzennego prądu stojana do oceny stanu uzwojeń stojana nie znalazło praktycznego zastosowania. Takie możliwości daje dopiero ilościowa analiza zmian hodografu za pomocą statystycznej metody analizy danych PCA. Zostanie to omówione w następnym rozdziale.

W przypadku zasilania silnika z przemiennika częstotliwości zapewniona jest większa symetria napięć zasilających niż w przypadku zasilania z sieci. Można zauważyć, że dla silnika nieuszkodzonego początkowa amplituda częstotliwości $2f_s$ jest

na poziomie około -50 dB (rys. 9.7). W chwili wystąpienia uszkodzenia widoczny jest wzrost amplitudy harmonicznej $2f_s$.



Rys. 9.10. Hodograf prądu stojana w osiach α - β przy zwarciu zwojowym w fazie C dla silnika:
a) zasilanie z PCz, b) zasilanie z sieci

Zarówno częstotliwość napięcia zasilania f_s , jak i moment obciążenia silnika mają ograniczony wpływ na zmiany amplitudy harmonicznej $2f_s$ po zaistnieniu zwarcia. W czasie zasilania silnika z przemiennika częstotliwości możliwe jest wykrycie uszkodzenia uzwojenia stojana podczas zwarcia 2–3 zwojów (około 1% całego uzwojenia).

9.2.3. Zastosowanie hodografu wektora przestrzennego prądu stojana do wykrywania zwarć zwojowych w stojanie

Jak podano w rozdziale 9.2.2, w przypadku uszkodzenia uzwojenia stojana pojawia się deformacja hodografu, która w miarę zwiększania się stopnia uszkodzenia powoduje przekształcenie się okręgu w elipsę. Dodatkowo zwarcia zwojowe powodują zmianę orientacji osi głównych hodografu prądu, w zależności od fazy silnika, w której wystąpiło zwarcie. Aby możliwe było wykorzystanie informacji o odkształceniu hodografu do oceny stopnia uszkodzenia stojana, niezbędne jest wprowadzenie ilościowej miary odkształcenia. Do ilościowej analizy zmian hodografu wektora prądu stojana, wywołanej zwarciami zwojowymi, można zastosować statystyczną metodą analizy danych, zwaną analizą składowych głównych PCA (ang. *Principal Component Analysis*), omówioną w rozdziale 4.2. Szczegółową analizę wykorzystania PCA do oceny stopnia uszkodzenia stojana przedstawiono w [9.19, 9.20, 9.29, 9.33–9.35].

Obliczenie składowych głównych oparte jest na wartościach własnych (ang. *eigenvalue*) i wektorach własnych (ang. *eigenvector*), tzw. macierzy kowariancji pierwotnego zbioru danych \mathbf{S} , jaką tutaj tworzą prądy osiowe stojana w nieruchomym układzie współrzędnych α - β :

$$\mathbf{S} = \begin{bmatrix} i_{s\alpha}(t_0) & i_{s\alpha}(t_0 + dt) & \dots & i_{s\alpha}(t_0 + (n-1)dt) \\ i_{s\beta}(t_0) & i_{s\beta}(t_0 + dt) & \dots & i_{s\beta}(t_0 + (n-1)dt) \end{bmatrix} \quad (9.3)$$

gdzie:

- t_0 – wartość początkowa czasu pomiaru, $t_0 = 0$ s,
- dt – krok pomiarowy,
- n – całkowita liczba zmierzonych próbek.

Macierz kowariancji wyjściowego zbioru danych \mathbf{S} można również zapisać jako iloczyn macierzy wektorów własnych $\mathbf{\Gamma}$ oraz macierzy wartości własnych $\mathbf{\Lambda}$:

$$\mathbf{S} = \mathbf{\Gamma} \mathbf{\Lambda} \mathbf{\Gamma}^T \quad (9.4)$$

gdzie:

$$\mathbf{\Gamma} = \begin{bmatrix} \gamma_1^1 & \gamma_2^1 \\ \gamma_1^2 & \gamma_2^2 \end{bmatrix} \text{ – macierz wektorów własnych,}$$

$$\mathbf{\Lambda} = \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} \text{ – macierz wartości własnych}$$


oraz:

- γ – składowe cząstkowe macierzy wektorów własnych $\mathbf{\Gamma}$ (indeks górny określa numer wektora, natomiast dolny – odpowiednią jego składową), np. γ_1^1 oznacza pierwszą składową pierwszego wektora głównego,
- λ – składowe cząstkowe macierzy wartości własnych $\mathbf{\Lambda}$.

Utworzona macierz kowariancji \mathbf{S} jest miarą stopnia liniowej zależności między prądem stojana w osiach α - β lub, interpretując inaczej, miarą rozproszenia danych w przestrzeni R^2 (w tym przypadku – hodografie wektora przestrzennego prądu). Wyznaczona na podstawie (9.4) macierz kowariancji \mathbf{S} odpowiada iloczynowi macierzy wektorów własnych $\mathbf{\Gamma}$ oraz diagonalnej macierzy wartości własnych $\mathbf{\Lambda}$. Wyznaczone wektory własne macierzy $\mathbf{\Gamma}$ określają kierunki nowych osi głównych hodografu prądu, natomiast wartości własne określają zmienność prądu stojana w osiach α - β przedstawionych we współrzędnych składowych głównych [9.20, 9.21, 9.35].

Jak zauważono wcześniej, w przypadku silnika symetrycznego nieuszkodzonego, hodograf prądu stojana w osiach α - β ma kształt okręgu (rys. 9.9, krzywa 0). Wówczas wyznaczone nowe osie główne z dwóch wektorów własnych macierzy kowariancji γ^1, γ^2 pokrywają się z pierwotnymi osiami hodografu, a dwie wartości własne

macierzy kowariancji pozostają niezienne i są sobie równe $\lambda_1 = \lambda_2 = \text{const}$. W przypadku uszkodzenia uzwojenia stojana, spowodowanego zwarciem zwojowymi następuje odkształcenie hodografu prądu, który przyjmuje kształt elipsy (rys. 9.9, krzywa 1, 2, 3). Wówczas poszukiwane wektory własne wyznaczają nowe osie główne hodografu prądów w kierunku postępujących zmian, a wyznaczone wartości główne nie są sobie równe $\lambda_1 \neq \lambda_2$ i wyznaczają intensywność tych zmian w nowych osiach układu współrzędnych. Ustalenie zmian wartości głównych umożliwia ocenienie stopnia uszkodzenia uzwojenia stojana, natomiast określenie nowych osi współrzędnych, na podstawie wyznaczonych wektorów głównych dostarcza informację o miejscu jego wystąpienia.



Rys. 9.11. Zależność indeksu λ_{PCA} od liczby zwartych zwojów: a) dla różnych wartości momentu obciążenia silnika przy $f_s = 50$ Hz, b), c) dla różnych częstotliwości zasilania silnika gdy $m_o = 0$, $m_o = m_n$, odpowiednio

Do monitorowania kierunku odkształcenia hodografu wektora prądu można wprowadzić dwie nowe składowe kierunkowe wektorów głównych, jako:

$$\gamma^1 = [\lambda_1 \gamma_1^1 \quad \lambda_2 \gamma_2^1] \quad (9.5)$$

$$\gamma^2 = [\lambda_1 \gamma_1^2 \quad \lambda_2 \gamma_2^2] \quad (9.6)$$

W celu określenia zmienności wartości głównych λ_1, λ_2 został wprowadzony indeks intensywności zmian [9.33–9.35]:

$$\lambda_{\text{PCA}} = \frac{\lambda_1 - \lambda_2}{\lambda_1} \quad (9.7)$$

gdzie λ_{PCA} – indeks intensywności zmian dwóch wartości głównych λ_1, λ_2 .

Na rysunku 9.11 przedstawiono zależność zmian indeksu intensywności dwóch wartości głównych λ_{PCA} od liczby zwartych zwojów. Dla silnika nieuszkodzonego wartość λ_{PCA} jest bliska zeru. Wraz ze wzrostem stopnia uszkodzenia uzwojenia stojana, indeks zwiększa swoją wartość. Jednak intensywność jego zmian maleje wraz ze zwiększaniem obciążenia i zmniejszaniem częstotliwości zasilania silnika.

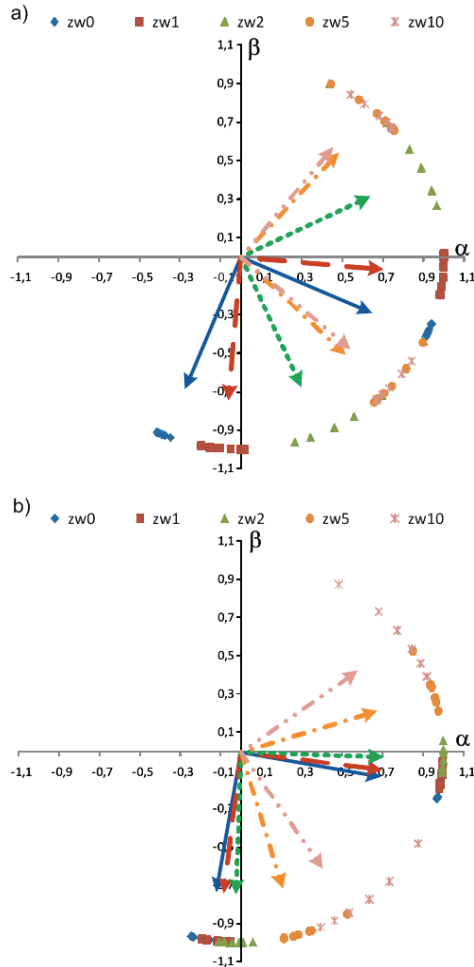
Na rysunku 9.12 pokazano zmiany wektorów własnych macierzy Γ dla różnego stopnia uszkodzenia uzwojenia stojana o częstotliwości zasilania $f_s = 50$ Hz (rys. 9.12a) oraz $f_s = 10$ Hz (rys. 9.12b). Dwa wektory własne γ^1, γ^2 , dla każdego z przypadków uszkodzenia uzwojenia tworzą nowe osie głównych współrzędnych, które przesuwają się w stronę powstającej asymetrii silnika. Powstające zmiany osi współrzędnych zgodnie wskazują na zwarcie w fazie C silnika. Moment obciążenia ma niewielki wpływ na wyznaczenie nowych współrzędnych przy małej liczbie zwartych zwojów, natomiast przy dużym stopniu uszkodzenia wpływ jest większy, ale nadal możliwe jest określenie, w której fazie wystąpiło uszkodzenie. W razie braku uszkodzenia silnika widoczna jest niewielka wewnętrzna asymetria stojana niezależna od modelowanych zwarc zwojowych. W przypadku zasilania $f_s = 50$ Hz przy zamodelowanym i zwartym zwoju, powstające uszkodzenie uzwojenia stojana przeciwdziała wewnętrznej asymetrii silnika, powodując symetryzację maszyny oraz możliwą błędną interpretację uszkodzenia. Przy zwarcu większej liczby zwojów, widoczna asymetria spowodowana jest już modelowanym uszkodzeniem. Dodatkowo zmniejszanie częstotliwości zasilania f_s powoduje, że zakres wyznaczania zmian nowych współrzędnych jest mniejszy, a tym samym wpływ asymetrii wewnętrznej silnika jest większy, powodując symetryzację maszyny dopiero przy zwartych 3 zwojach.

Z podanych rozważań wynikają następujące uwagi dotyczące korzyści z zastosowania metody PCA do ilościowej oceny hodografu wektora przestrzennego prądu stojana w wykrywaniu uszkodzeń stojana:

- nieskomplikowany i szybki proces obliczania składowych głównych jest alternatywą dla metod diagnostycznych wykorzystujących analizę widmową prądu

fazowego stojana, gdyż dostarczają one więcej wiarygodnej informacji o stanie uzwojeń stojana,

- wartości główne λ_1, λ_2 umożliwiają ocenę stanu uzwojenia stojana,
- wektory kierunkowe γ^1, γ^2 umożliwiają określenie fazy uzwojenia, w której wystąpiło uszkodzenie,
- niestety nawet niewielka asymetria napięcia zasilania silnika ma duży wpływ na zmiany wartości indeksu λ_{PCA} , oraz na położenie początkowe wektorów kierunkowych γ^1, γ^2 , w warunkach wystąpienia niesymetrii zasilania może to spowodować błędną identyfikację uszkodzenia w początkowej fazie.



Rys. 9.12. Zmiany położenia wektorów własnych macierzy Γ dla różnego stopnia uszkodzenia stojana przy częstotliwości zasilania: a) $f_s = 50$ Hz, b) $f_s = 10$ Hz

W sytuacjach gdy będą występowały częste zmiany obciążenia i częstotliwości napięcia zasilania, może się okazać niezbędne zastosowanie dodatkowych sygnałów diagnostycznych lub wykorzystanie specjalnej techniki opartej na sztucznej inteligencji, co zostanie przedstawione w dalszych rozdziałach.

9.2.4. Wykrywanie zwarcí zwojowych na podstawie analizy przesunięcia kąowego między prądami fazowymi oraz prądem i napięciem stojana

Zwarcia zwojowe powodują zmianę wartości przesunięć fazowych między prądem i napięciem stojana oraz między prądami fazowymi. W pracach [9.5, 912, 914, 9.15, 9.17] wykazano możliwość zastosowania analizy przesunięcia kąowego do wykrywania i lokalizacji zwarcí zwojowych. W przypadku pomiaru wyłącznie prądów fazowych stojana, możliwe jest wyznaczenie przesunięć kąowych między prądami w poszczególnych fazach. Dla silnika symetrycznego i nieuszkodzonego przesunięcie kąowe między prądami fazowymi jest równe 120° . W celu oceny zwarcí zwojowych można zdefiniować wielkość określającą stopień uszkodzenia uzwojenia stojana silnika indukcyjnego, oznaczoną w następujący sposób:

$$\begin{aligned}\varepsilon_i^{AB} &= 120^\circ - \phi_i^{AB} \\ \varepsilon_i^{BC} &= 120^\circ - \phi_i^{BC} \\ \varepsilon_i^{CA} &= 120^\circ - \phi_i^{CA}\end{aligned}\tag{9.8}$$

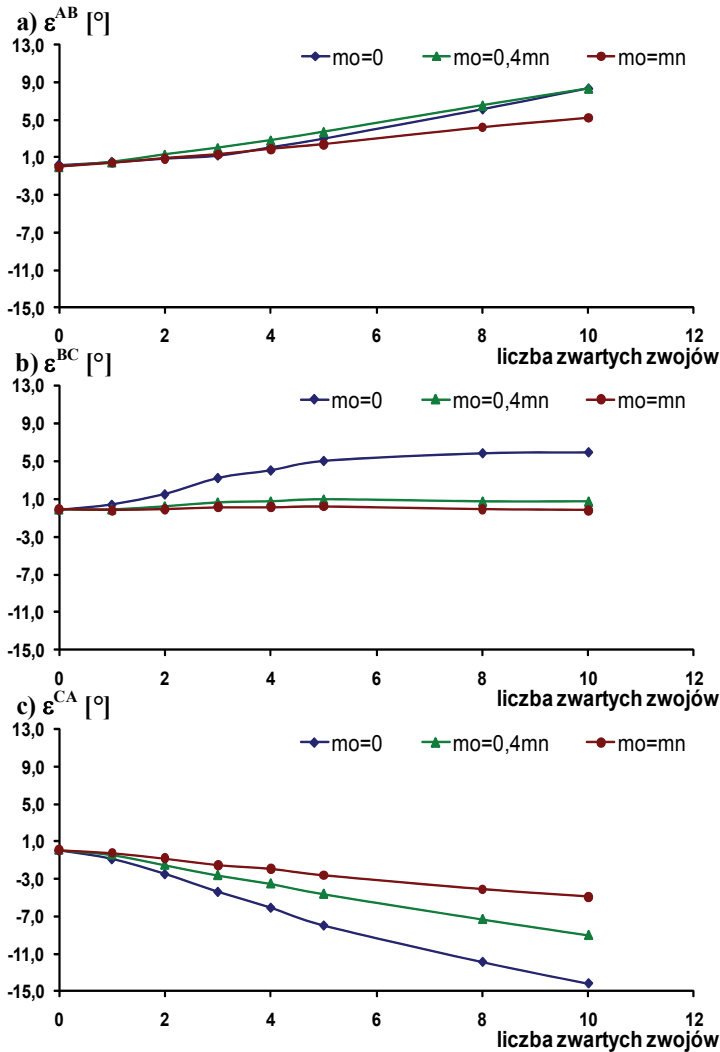
gdzie:

$i = 0, 1, 2, 3, 4, 5, 8, 10$ – liczba zwojów zwartych,

$\varepsilon^{AB}, \varepsilon^{BC}, \varepsilon^{CA}$ – zmiana przesunięcia kąowego między poszczególnymi prądami fazowymi,


$\phi^{AB}, \phi^{BC}, \phi^{CA}$ – przesunięcie kąowe między poszczególnymi prądami fazowymi.

Zmiany przesunięć kąowych między poszczególnymi fazami przedstawiono na rysunku 9.13. Wraz ze zwiększaniem się stopnia uszkodzenia uzwojenia stojana zmienia się przesunięcie kąowe między odpowiednimi fazami. Podczas zwarcia w fazie C największa zmiana przesunięcia widoczna jest między fazami CA. Wraz ze wzrostem stopnia uszkodzenia zmniejsza się przesunięcie kąowe między fazami C i A nawet o 15° dla 10 zwartych zwojów (rys. 9.13c), natomiast w pozostałych przypadkach zakres zmian jest dużo mniejszy (rys. 9.13a i b).



Rys. 9.13. Zależność zmiany przesunięcia kąowego między poszczególnymi fazami prądu stojana od liczby zwartych zwojów w fazie C dla różnych wartości obciążenia silnika przy $f_s = 50$ Hz

Charakter tych zmian umożliwia, oprócz badania stopnia uszkodzenia uzwojenia stojana, również dokładne określenie jego lokalizacji. Jednak intensywność zmian maleje wraz ze wzrostem obciążenia silnika oraz przy zmniejszaniu częstotliwości zasilania. Na rysunku 9.14 przedstawiono zależność przesunięcia kąowego między fazami C i A od liczby zwartych zwojów w fazie C dla różnych wartości częstotliwości zasilania silnika, w zakresie $f_s = 10$ –50 Hz, przy zmianie momentu obciążenia.



Rys. 9.14. Zależność zmiany przesunięcia kąowego między fazami C i A prądu stojana od liczby zwartych zwojów dla różnych wartości częstotliwości zasilania silnika pod obciążeniem: a) $m_o = 0$, b) $m_o = m_N$

Podczas zasilania silnika z sieci należy liczyć się z zakłóceniem oceny wskaźnika ε wskutek możliwości wystąpienia asymetrii napięcia zasilania w każdej z faz silnika. W takiej sytuacji początkowa wartość wskaźnika zmian przesunięcia kąowego ε między poszczególnymi prądami fazowymi jest różna od zera. Natomiast przy zasilaniu silnika z przemiennika częstotliwości zapewniona jest symetria napięcia zasilania w każdej z faz silnika i początkowa wartość wskaźnika zmian przesunięcia kąowego ε między poszczególnymi prądami fazowymi jest wówczas równa zero. Podstawowym mankamentem w wykrywaniu zwarcia za pomocą wskaźnika ε jest silna jego zależność od wartości momentu obciążenia napędu (rys. 9.13). Również mała częstotliwość napięcia zasilania (mała prędkość obrotowa) zmniejsza zakres zmian wskaźnika ε (rys. 9.14). Jednak z prac [9.15, 9.28, 9.35] wynika, że możliwe jest wykrycie uszkodzenia uzwojenia stojana w jego początkowej fazie, przy zwarcu 2–3 zwojów (około 1% całego uzwojenia).

W przeprowadzonych badaniach zauważono, że oprócz zmian amplitudy prądów oraz przesunięć fazowych między nimi, zmianie ulegają również wartości przesunięć fazowych między prądem a napięciem ϕ w każdej z faz. Wartość kąta przesunięcia fazowego między napięciem a prądem w fazie silnika silnie zależy od wartości obciążenia maszyny, dlatego do celów diagnostyki zdefiniowano nową wielkość, określającą

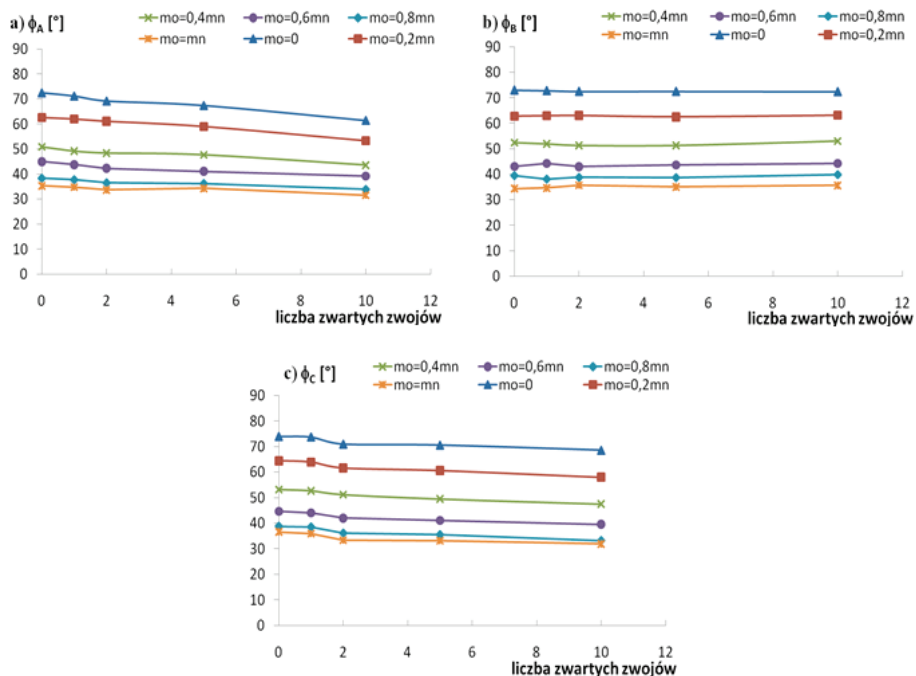
cą stopień uszkodzenia uzwojenia stojana silnika indukcyjnego, obliczoną w następujący sposób:

$$\xi_k = \phi_0 - \phi_k, \quad (9.9)$$

gdzie:

- ξ_k – wskaźnik progresji uszkodzenia uzwojenia stojana w [°],
- ϕ_k – kąt przesunięcia fazowego między prądem a napięciem stojana w jednej fazie silnika dla $k = 0, 1, 2, 5, 10$ zwartych zwojów,
- ϕ_0 – kąt przesunięcia fazowego między prądem a napięciem stojana w jednej fazie silnika dla silnika nieuszkodzonego.

Na rysunku 9.15a przedstawiono zmiany kąta przesunięcia fazowego między napięciem a prądem w fazie A, na rys. 9.15b w fazie B oraz na rys. 9.15c w fazie C, w zależności od stopnia uszkodzenia uzwojenia stojana silnika, dla różnych wartości momentu obciążenia silnika.



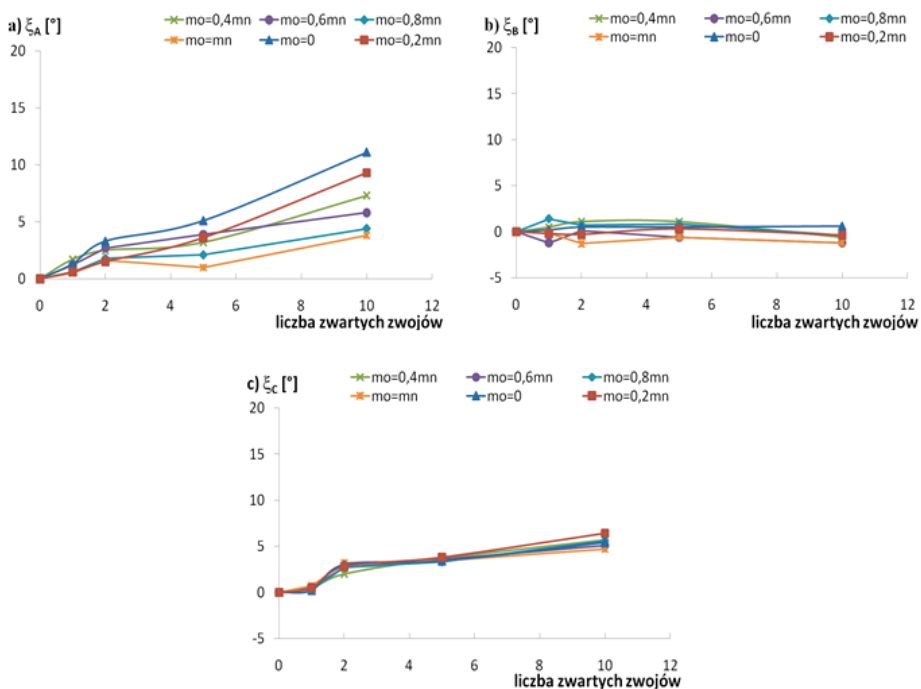
Rys. 9.15. Zmiana kąta przesunięcia fazowego w fazach stojana silnika indukcyjnego w zależności od stopnia uszkodzenia uzwojenia stojana oraz zmian momentu obciążenia

Zwarcie zwojowe w uzwojeniu fazy A stojana silnika indukcyjnego powoduje zmniejszenie wartości kąta przesunięcia fazowego w fazie A, zarówno dla silnika

nieobciążonego, jak i silnika obciążonego. Natomiast w fazie B wartość kąta przesunięcia fazowego utrzymuje się praktycznie na tym samym poziomie niezależnie od obciążenia, natomiast w fazie C maleje w zależności od obciążenia maszyny. Wyniki eksperymentalne są zbieżne z wynikami badań symulacyjnych.

Zmiany wskaźnika progresji uszkodzenia uzwojenia stojana silnika indukcyjnego przedstawiono na rys. 9.16, odpowiednio dla trzech faz. Największy wzrost wartości wskaźnika progresji ξ_k występuje w fazie, w której wystąpiło uszkodzenie (rys. 9.16a).

Analiza zmian wskaźnika ξ_k pozwala w jednoznaczny sposób określić stopień uszkodzenia fazy stojana oraz lokalizację występującego uszkodzenia. Nieskomplikowany i szybki proces obliczania kątów przesunięć fazowych może być pewną alternatywą dla stosowanych obecnie metod diagnostycznych wykorzystujących analizę częstotliwościową sygnałów diagnostycznych



Rys. 9.16. Zmiany wskaźnika progresji uszkodzenia uzwojenia stojana ξ_k

9.2.5. Symptomy zwarc zwojowych w strumieniu poosiowym

Asymetria uzwojeń stojana powoduje zmianę rozkładu harmoniczných przestrzenných indukcyjności w szczelinie i w konsekwencji w strumieniu stojana pojawiają się cha-

rakterystyczne częstotliwości czasowe, których amplituda zmienia się w zależności od stopnia uszkodzenia stojana. Na podstawie prac [9.2, 9.7, 9.10] można stwierdzić, że uszkodzenia uzwojeń stojana powodują duże zmiany w widmie strumienia poosiowego, w którym pojawiają się charakterystyczne częstotliwości:

$$f_{sp} = kf_s \pm n \frac{1-s}{p_b} f_s = kf_s \pm nf_r \quad (9.10)$$

gdzie:

k – rząd harmonicznej czasowej źródła zasilania,

$n = 1, 2, 3, \dots, 2p_b - 1; n \neq 2p_b m; m = 1, 2, \dots,$

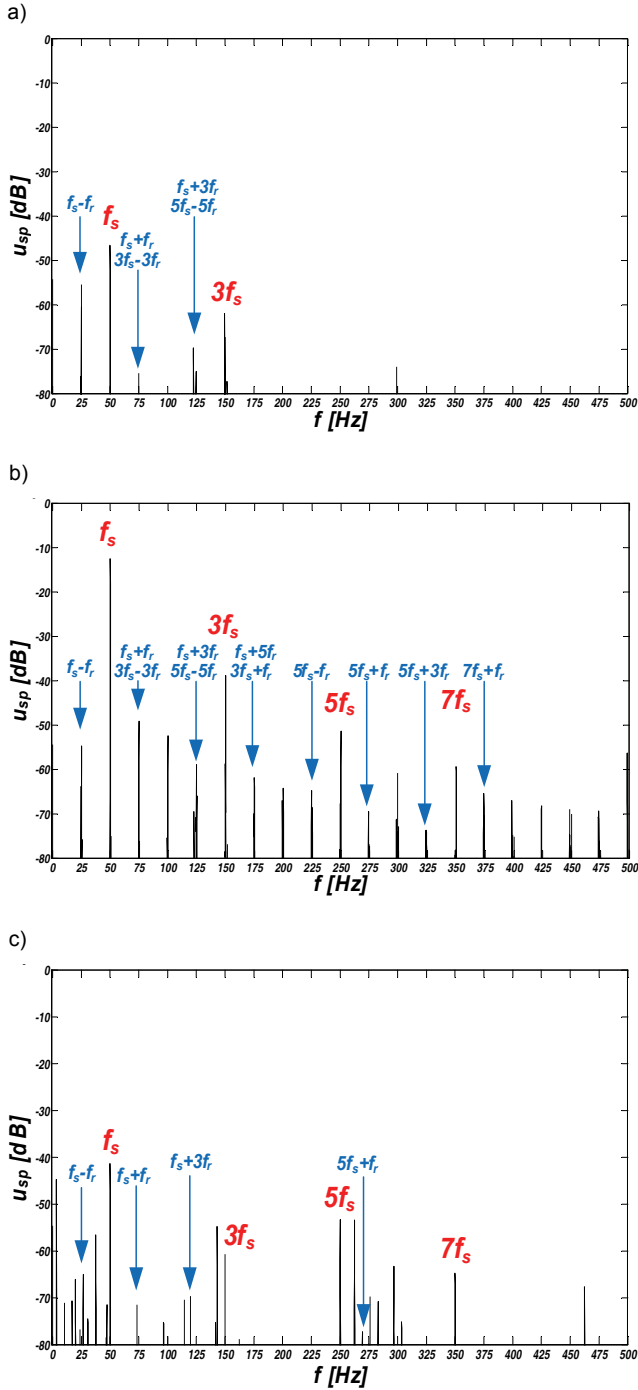
f_r – częstotliwość obrotowa wirnika w [Hz].


W tabeli 9.1 zestawiono częstotliwości obliczone według zależności (9.10). Pogrubioną czcionką oznaczono te składowe, które w praktyce eksperymentalnej mają największe znaczenie i wykazują zwykle największe zmiany amplitudy.

Tabela 9.1. Częstotliwości charakterystyczne dla zwarc zwojowych w strumieniu poosiowym wg (9.10)

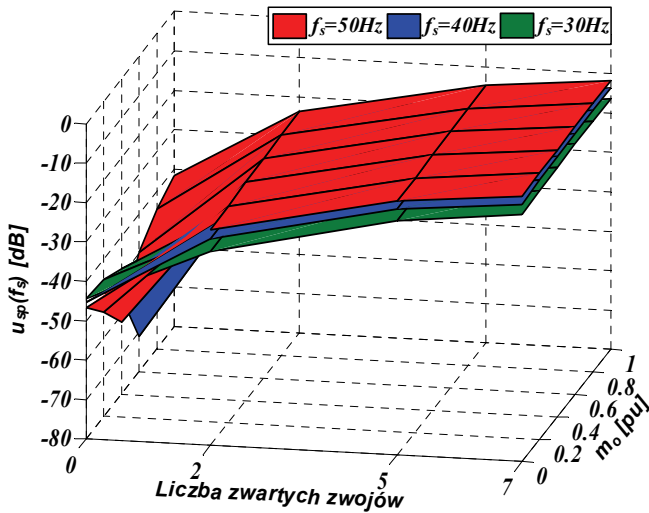
$n \backslash k$	1		3		5	
	-	+	-	+	-	+
1	$f_s - f_r$	$f_s + f_r$	$3f_s - f_r$	$3f_s + f_r$	$5f_s - f_r$	$5f_s + f_r$
2	$f_s - 2f_r$	$f_s + 2f_r$	$3f_s - 2f_r$	$3f_s + 2f_r$	$5f_s - 2f_r$	$5f_s + 2f_r$
3	$f_s - 3f_r$	$f_s + 3f_r$	$3f_s - 3f_r$	$3f_s + 3f_r$	$5f_s - 3f_r$	$5f_s + 3f_r$
5	$f_s - 5f_r$	$f_s + 5f_r$	$3f_s - 5f_r$	$3f_s + 5f_r$	$5f_s - 5f_r$	$5f_s + 5f_r$

Pomiar strumienia poosiowego jest realizowany w praktyce metodą pośrednią (rys. 3.4b) za pomocą dodatkowej cewki pomiarowej. Monitorowanie stanu uzwojenia stojana można więc realizować albo na podstawie zmian wartości skutecznej napięcia u_{sp} indukowanego się w cewce pomiarowej przez strumień poosiowy, albo przez analizę widmową tego napięcia. Na rysunku 9.17 przedstawiono widma napięcia u_{sp} dla silnika zasilanego z przemiennika częstotliwości i obciążonego znamionowo nieuszkodzonego i ze zwartymi 7 zwojami w stojanie [9.35]. Zwarcia zwojowe powodują istotny wzrost amplitudy harmonicznej sieciowej (około 30 dB) i jej nieparzystych krotności oraz charakterystycznych częstotliwości z tabeli 9.1. Zmiany częstotliwości napięcia zasilania f_s oraz momentu obciążenia m_o mają stosunkowo ograniczony wpływ na wartość amplitudy harmonicznej sieciowej (rys. 9.18) [9.35].





Rys. 9.17. Widmo napięcia indukowanego w cewce pomiarowej przez strumień poosiowy silnika zasilanego z przetwornika częstotliwości $f_s = 50$ Hz dla: a) silnika nieuszkodzonego i nieobciążonego, b) nieobciążonego ze zwartymi 7 zwojami w fazie A silnika, c) obciążonego znamionowo i nieuszkodzonego, d) obciążonego znamionowo i ze zwartymi 7 zwojami w fazie A silnika



Rys. 9.18. Zależność amplitudy harmonicznej f_s napięcia u_{sp} indukowanego w cewce przez strumień poosiowy od obciążenia silnika oraz liczby zwartych zwojów w fazie C, przy zasilaniu z PCz


Jak wynika z przedstawionych badań, wykrywanie zwarców zwojowych w stojanie przez ocenę amplitudy charakterystycznych częstotliwości w widmie strumienia poosiowego, jest możliwe praktycznie począwszy od kilku zwojów zwartych. Głównym mankamentem metody jest jej inwazyjność w stosunku do konstrukcji silnika oraz

podobne oddziaływanie uszkodzeń powstających w wirniku. Dlatego może ona mieć w praktyce eksploatacyjnej charakter pomocniczy.


9.2.6. Symptomy zwarcć zwojowych w sygnałach mocy chwilowej i momentu elektromagnetycznego

W przypadku zasilania silnika z sieci, moc chwilową można obliczyć jako sumę iloczynów wartości chwilowych prądu i napięcia. W sytuacji zasilania silnika napięciami odkształconymi z przekształtnika częstotliwości, do obliczania mocy chwilowej czynnej i biernej (ang. *instantaneous active and reactive power*) można zastosować pojęcia wprowadzone przez Akagię [9.1, 9.4].


Sygnały chwilowej mocy czynnej $p(t)$ oraz chwilowej mocy biernej $q(t)$ zostały wprowadzone w celu uogólnienia klasycznego pojęcia mocy elektrycznej w niesinusoidalnych systemach trójfazowych (rozdział 3.4). Mogą one być również przydatne w monitorowaniu stanu stojana silnika indukcyjnego, gdyż w przypadku wystąpienia zwarcia w uzwojeniach stojana, w sygnałach mocy pojawiają się dodatkowe charakterystyczne częstotliwości. W szczególności jest to podwójna harmoniczna podstawowej częstotliwości napięcia zasilającego $2f_s$. Widma chwilowej mocy czynnej p silnika nieuszkodzonego i ze zwarciami zwojowymi, przedstawione na rysunku 9.19, zawierają oprócz składowej podstawowej f_{dc} , składową sieciową f_s i podwójną sieciową $2f_s$ oraz częstotliwość rotacyjną f_r . Na rysunku 9.20 przedstawiono jak kształtuje się amplituda składowej $2f_s$ w zależności od liczby zwartych zwojów o różnych częstotliwościach napięcia zasilania. Praktycznie na podstawie jej zmian możliwa jest identyfikacja zwarcia już od kilku zwojów [9.11].




Rys. 9.19. Widmo chwilowej mocy czynnej p dla częstotliwości zasilania $f_s = 10$ Hz:
a) silnik nieuszkodzony, b) 10 zwojów zwartych



Rys. 9.20. Zależność amplitudy harmonicznej $2f_s$ w sygnale mocy chwilowej czynnej od liczby zwartych zwojów dla różnych częstotliwości zasilania




Rys. 9.21. Widmo chwilowej mocy biernej q dla częstotliwości zasilania $f_s = 10$ Hz: a) silnik nieuszkodzony, b) 10 zwojów zwartych



Rys. 9.22. Zależność amplitudy harmonicznej $2f_s$, sygnału mocy chwilowej biernej od liczby zwartych zwojów dla różnych częstotliwości zasilania


Podobnie wygląda sytuacja w przypadku sygnału mocy chwilowej biernej q przy zasilaniu silnika z przemiennika PWM. W widmie widoczne są: składowa podstawowa f_{dc} , składowa sieciowa f_s oraz jej wielokrotności oraz częstotliwość rotacyjna f_r . Zwarcie zwojów w jednej z faz (rys. 9.21) powoduje wyraźny wzrost amplitudy harmonicznej o częstotliwości $2f_s$. Amplitudy składowej podwójnej sieciowej dla różnej liczby zwartych zwojów silnika indukcyjnego zasilanego napięciem o różnej częstotliwości przedstawiono na rysunku 9.22. Podobnie jak w przypadku sygnału mocy chwilowej czynnej, zmiany amplitudy częstotliwości $2f_s$ i $4f_s$ w sygnale mocy chwilowej biernej są dobrymi symptomami do wykrywania zwarc zwojowych.

Równie dobrymi właściwościami diagnostycznymi charakteryzuje się sygnał momentu elektromagnetycznego. Jednak w tym przypadku bardzo kłopotliwy jest bezpośredni jego pomiar. Obecnie w związku rozwojem technik estymacyjnych coraz częściej moment jest na bieżąco estymowany (odtworzany) na podstawie modelu matematycznego silnika indukcyjnego (rozdział 3.3 oraz 6).



Rys. 9.23. Widmo estymowanego momentu elektromagnetycznego m_e dla częstotliwości zasilania $f_s = 10$ Hz: a) silnik nieuszkodzony, b) 10 zwojów zwartych

Na rysunku 9.23 przedstawiono widma estymowanego momentu elektromagnetycznego dla przypadku zasilania silnika z przemiennika PWM napięciem o częstotliwości 10 Hz. Zwarcie zwojowe powoduje wyraźny wzrost amplitudy harmonicznych $2f_s$ i $4f_s$. W przypadku uszkodzenia stojana przy zasilaniu napięciem o częstotliwości 50 Hz amplituda harmonicznej $2f_s$ zwiększa około 30 dB. Wpływ częstotliwości zasilania na amplitudę harmonicznej $2f_s$ przedstawiono na rysunku 9.24.



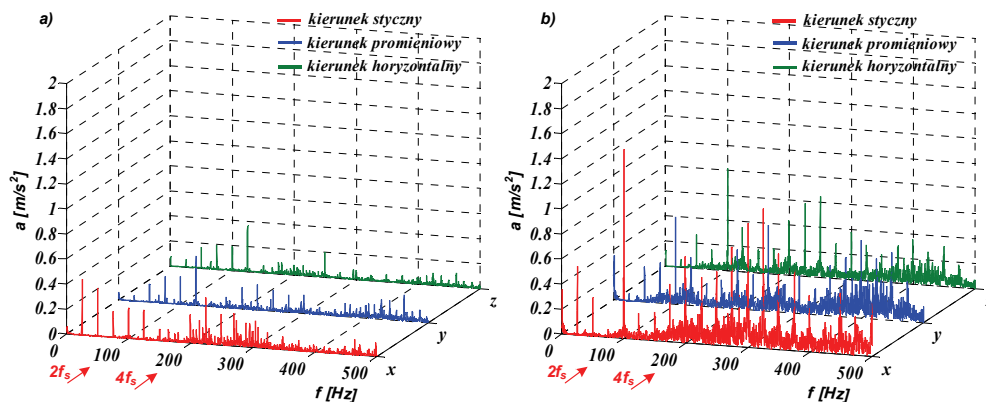
Rys. 9.24. Zależność amplitudy harmonicznej $2f_s$ sygnału estymowanego momentu elektromagnetycznego od liczby zwartych zwojów dla różnych częstotliwości zasilania

Jak wykazały szczegółowe badania przedstawione w [9.11, 9.12, 9.28, 9.35], analiza widmowa sygnałów mocy chwilowej i estymowanego momentu elektromagnetycznego umożliwia wykrywanie zwarc zwojowych w stanie już w początkowej fazie rozwoju (od 2–3 zwojów zwartych) przy zasilaniu z sieci i przemiennika częstotliwości. Zastosowanie przekształtnika częstotliwościowego powoduje odkształcenie napięcia i prądu zasilającego, ale powstające dodatkowe harmoniczne nie zakłócają procesu diagnozy uszkodzenia uzwojenia stojana. Nawet przy obniżonej częstotliwości zasilania silnika możliwe jest wyodrębnienie częstotliwości odpowiedzialnych za uszkodzenie stojana.

9.2.7. Symptomy zwarc zwojowych w drganiach mechanicznych

Duża wartość prądu płynącego w zwartych zwojach stojana wywołuje odkształcenie pola magnetycznego w szczelinie, co pociąga za sobą pojawienie się sił przemiennych działających na stojan i wirnik. Ich wynikiem jest wzrost hałasu i drgań maszyny. Tak więc możliwe jest wykrywanie zwarc zwojowych przez pomiar globalnej wartości skutecznej przyspieszenia drgań a_{RMS} lub/i prędkości drgań v_{RMS} silnika, jak również na podstawie oceny w widmie drgań wartości amplitudy podwójnej częstotliwości napięcia zasilania $2f_s$, bądź jej parzystych wielokrotności. Jak wykazały badania w [9.24, 9.25, 9.35] najkorzystniej jest mierzyć składową styczną drgań, gdyż jej wzrost po wystąpieniu zwarcia jest największy.

Na rysunku 9.25 przedstawiono przykład widma przyspieszenia drgań silnika zasilanego z przemiennika częstotliwości [9.35]. Drgania zostały zmierzone czujnikiem trójosiowym na nieobciążonym silniku nieuszkodzonym i ze zwartymi 7 zwojami, o częstotliwości 50 Hz napięcia zasilającego. Uszkodzenie stojana powoduje wzrost amplitudy częstotliwości $2f_s$ oraz jej parzystych wielokrotności.



Rys. 9.25. Widmo przyspieszenia drgań mechanicznych w osiach x , y , z silnika nieobciążonego, zasilanego z przemiennika częstotliwości $f_s = 50$ Hz dla: a) silnika nieuszkodzonego, b) przy zwarciu 7 zwojów w fazie A silnika

W napędach przekształtnikowych ze względu na charakter zasilania sygnał drganiowy jest bardzo zakłócony, co powoduje dodatkowe utrudnienia w wyodrębnianiu symptomów uszkodzeń stojana i poprawnym określeniu poziomu amplitudy charakterystycznej częstotliwości. Poprawna interpretacja symptomów jest możliwa dopiero przy większym stopniu uszkodzenia (od 7–10 zwojów zwartych).

9.3. Zastosowanie składowych symetrycznych do wykrywania zwarć zwojowych w silniku zasilanym z przemiennika częstotliwości

Wykorzystanie składowych symetrycznych w monitorowaniu i diagnostyce silników indukcyjnych zaproponowano w [9.23, 9.27], a następnie rozwinięte przez [9.2, 9.5, 9.6, 9.13, 9.21]. Opiera się ono na badaniu zmienności modułu impedancji kolejności przeciwnej lub amplitudy składowej kolejności przeciwnej prądu stojana.

Silnik indukcyjny podłączony do niesymetrycznego źródła zasilania można analizować metodą składowych symetrycznych. Metoda ta jest stosowana po założeniu obecności tylko podstawowej harmonicznej w napięciu zasilania. Informacje zawarte w składowych symetrycznych mogą być również wykorzystywane, gdy asymetria ma charakter wewnętrzny i wiąże się z uszkodzeniem silnika.

Procedura zaproponowana przez [9.23, 9.27] jest bardzo prosta i polega na pomiarze wartości chwilowych prądu i napięcia, a następnie obliczaniu impedancji kolejności przeciwnej, która wykazuje duże zmiany przy zwarciach stojana. Choć teoretyczne podstawy procedury są proste, to proces obliczeniowy jest bardzo złożony

i obliczone wartości impedancji mają duży rozrzut. Do obliczania amplitud składowych symetrycznych i kątów fazowych między zmiennymi niezbędne jest stosowanie złożonych algorytmów obliczeniowych [9.18]). Zwykle algorytmy te ograniczają się do obliczania składowych podstawowych prądu i napięcia, i wiele ważnych informacji diagnostycznych zawartych w harmonicznym ulega odfiltrowaniu. Obecnie, ze względu na rozwój szybkich procesorów sygnałowych i malejącą ich cenę, coraz częściej proponuje się nowe procedury wykorzystujące składowe symetryczne i przekształcenia DFT i FFT [9.7, 9.13, 9.31]. Również coraz częściej uwzględnia się w prądzie i napięciu całe spektrum harmonicznym [9.7, 9.32, 9.35].

Brak równowagi w trójfazowych systemach może być oceniany również po przetransformowaniu trójfazowych napięć i prądów silnika do układu współrzędnych składowych symetrycznych. Jedną z metod wykorzystania składowych symetrycznych w monitorowaniu i diagnostyce silników indukcyjnych opiera się na badaniu zmienności amplitudy składowej kolejności przeciwnej prądu stojana. Ogólna zależność przekształcenia prądów fazowych i_{sA} , i_{sB} , i_{sC} i napięć u_{sA} , u_{sB} , u_{sC} z układu współrzędnych ABC na składowe symetryczne 012 ma postać:

$$\begin{bmatrix} U_1 \\ U_2 \\ U_0 \end{bmatrix} = \begin{bmatrix} 1 & a & a^2 \\ 1 & a^2 & a \\ 1 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} U_{sA} \\ U_{sB} \\ U_{sC} \end{bmatrix}, \quad \begin{bmatrix} I_1 \\ I_2 \\ I_0 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} 1 & a & a^2 \\ 1 & a^2 & a \\ 1 & 1 & 1 \end{bmatrix} \cdot \begin{bmatrix} I_{sA} \\ I_{sB} \\ I_{sC} \end{bmatrix} \quad (9.11)$$

gdzie:

- I_{sA}, I_{sB}, I_{sC} – ustalony prąd fazowy stojana w fazach A, B, C odpowiednio,
- U_{sA}, U_{sB}, U_{sC} – ustalone napięcie fazowe stojana w fazach A, B, C odpowiednio,
- I_0, I_1, I_2 – odpowiednio składowa zerowa, zgodna i przeciwna prądu stojana,
- U_0, U_1, U_2 – odpowiednio składowa zerowa, zgodna i przeciwna napięcia stojana,
- a – zespolony operator obrotu o kąt $2\pi/3$.

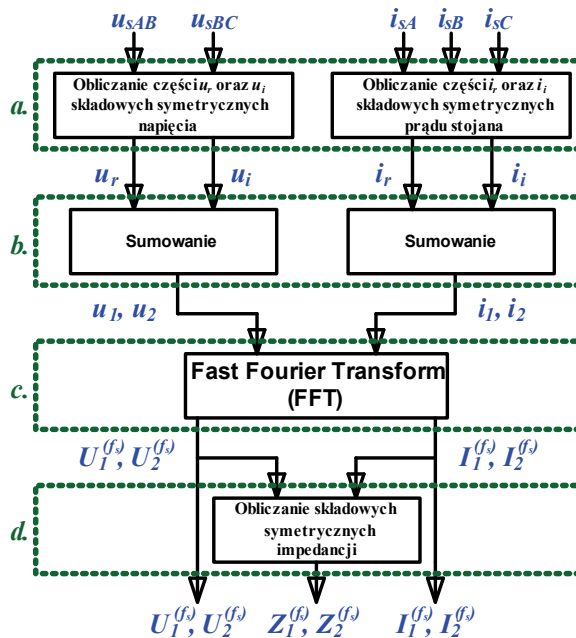
Zależności (9.11) dotyczą sinusoidalnych sygnałów napięć i prądów fazowych w stanie ustalonym. Zasilanie silników z przekształtników PWM wprowadza dodatkowo szereg harmonicznym powodujących odkształcenia napięcia i prądu. Dlatego, aby można było zastosować klasyczną metodę obliczania składowych symetrycznych, konieczne jest odfiltrowanie harmonicznym zakłócających lub wyodrębnienie składowej podstawowej częstotliwości napięcia zasilania. Do wyodrębnienia podstawowej częstotliwości, w sytuacji zasilania odkształconego z falownika PWM, można zastosować procedurę obliczania tzw. chwilowych wartości składowych symetrycznych (ang. *instantaneous symmetrical components*) [9.8]. Schemat procedury przedstawiono na rysunku 9.26 [9.13, 9.32, 9.35]. Zastosowano w niej ideę metody chwilowych wartości składowych symetrycznych istotnie przyspieszającą wykonywanie obliczeń składowych symetrycznych. Metoda opiera się na zastąpieniu zespolonego operatora obrotu a operatorem S_{90} przesunięcia fazowego o kąt 90° w dziedzinie czasu [9.8, 9.35]:

$$\begin{bmatrix} u_1 \\ u_2 \\ u_0 \end{bmatrix} = \begin{bmatrix} u_{sA} - \frac{1}{2}(u_{sB} + u_{sC}) + \frac{\sqrt{3}}{2} S_{90}(u_{sB} - u_{sC}) \\ u_{sA} - \frac{1}{2}(u_{sB} + u_{sC}) - \frac{\sqrt{3}}{2} S_{90}(u_{sB} - u_{sC}) \\ u_{sA} + u_{sB} + u_{sC} \end{bmatrix} \quad (9.12)$$

$$\begin{bmatrix} i_1 \\ i_2 \\ i_0 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} i_{sA} - \frac{1}{2}(i_{sB} + i_{sC}) + \frac{\sqrt{3}}{2} S_{90}(i_{sB} - i_{sC}) \\ i_{sA} - \frac{1}{2}(i_{sB} + i_{sC}) - \frac{\sqrt{3}}{2} S_{90}(i_{sB} - i_{sC}) \\ i_{sA} + i_{sB} + i_{sC} \end{bmatrix} \quad (9.13)$$

gdzie:

- S_{90} – operator przesunięcia fazowego o kąt 90° w dziedzinie czasu,
- u_{sA}, u_{sB}, u_{sC} – chwilowe wartości napięcia fazowego stojana w fazach A, B, C,
- u_1, u_2 – chwilowe wartości składowej zgodnej i przeciwnej napięcia stojana,
- i_{sA}, i_{sB}, i_{sC} – chwilowe wartości prądu fazowego stojana w fazach A, B, C,
- i_1, i_2 – chwilowe wartości składowej zgodnej i przeciwnej prądu stojana.



Rys. 9.26. Procedura obliczania składowych symetrycznych napięcia, prądu oraz impedancji

Chwilowe wartości składowych symetrycznych obliczone z zależności (9.12) i (9.13) można traktować jako wartości chwilowe całego sygnału lub rozpatrywać je dla poszczególnych częstotliwości, np. dla podstawowej częstotliwości zasilania f_s . Uwzględniając, że w silniku indukcyjnym klatkowym składowa zerowa prądu i napięcia nie występuje, można wielkości u_1, u_2 i i_1, i_2 przedstawić jako sumy części rzeczywistej i urojonej:

$$\begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = \begin{bmatrix} u_r + S_{90} u_i \\ u_r - S_{90} u_i \end{bmatrix} \quad (9.14)$$

$$\begin{bmatrix} i_1 \\ i_2 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} i_r + S_{90} i_i \\ i_r - S_{90} i_i \end{bmatrix} \quad (9.15)$$

gdzie:

$$\begin{aligned} u_r &= u_{sA} - \frac{1}{2}(u_{sB} + u_{sC}) \\ u_i &= \frac{\sqrt{3}}{2}(u_{sB} - u_{sC}) \end{aligned} \quad (9.16)$$

$$\begin{aligned} i_r &= i_{sA} - \frac{1}{2}(i_{sB} + i_{sC}) \\ i_i &= \frac{\sqrt{3}}{2}(i_{sB} - i_{sC}) \end{aligned} \quad (9.17)$$

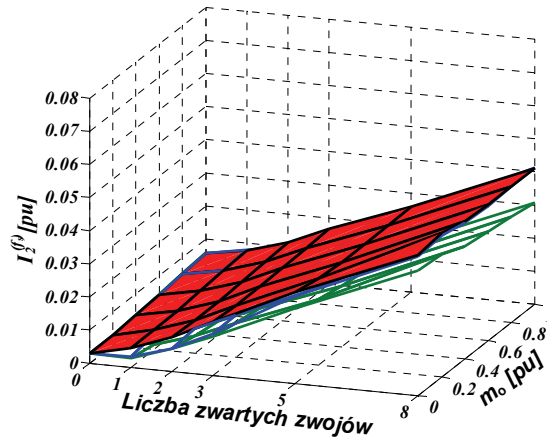
W następnym kroku algorytmu jest realizowana analiza FFT obliczonych wartości chwilowych składowych symetrycznych, a następnie na podstawie widma, wyznaczana podstawowa częstotliwość napięcia zasilania [9.7, 9.23, 9.35]. Dla obliczonej harmonicznej podstawowej wyznacza się składowe kolejności zgodnej i przeciwnej oraz składowe zgodna i przeciwna impedancji:

$$\begin{bmatrix} U_1^{(f_s)} \\ U_2^{(f_s)} \end{bmatrix} = \begin{bmatrix} Z_1^{(f_s)} & 0 \\ 0 & Z_2^{(f_s)} \end{bmatrix} \begin{bmatrix} I_1^{(f_s)} \\ I_2^{(f_s)} \end{bmatrix} \quad (9.18)$$

gdzie:

- $U_1^{(f_s)}, U_2^{(f_s)}$ – składowa zgodna i przeciwna napięcia stojana dla podstawowej częstotliwości napięcia zasilania f_s ,
- $I_1^{(f_s)}, I_2^{(f_s)}$ – składowa zgodna i przeciwna prądu stojana dla podstawowej częstotliwości napięcia zasilania f_s ,
- $Z_1^{(f_s)}, Z_2^{(f_s)}$ – składowa zgodna i przeciwna impedancji dla podstawowej częstotliwości napięcia zasilania f_s .

Z analizy teoretycznej i badań symulacyjnych wynika, że wartość skuteczna składowej zgodnej prądu stojana praktycznie nie zmienia swojej wartości przy asymetrii uzwojeń i podobnie jak prąd fazowy zależy od obciążenia. Natomiast wartość skuteczna prądu kolejności przeciwnej istotnie zmienia się po wystąpieniu zwarcia zwojowego i tylko w ograniczonym zakresie zależy od momentu obciążenia [9.28, 9.32]. Na rysunku 9.27 przedstawiono przykładowo dla badanego silnika zależność amplitudy składowej kolejności przeciwnej prądu stojana $I_2^{(f_s)}$ od stopnia uszkodzenia stojana (liczby zwartych zwojów – zwarcie w fazie A) dla różnych wartości momentu obciążenia, przy zasilaniu z przemiennika częstotliwości. Widoczna jest duża zależność składowej $I_2^{(f_s)}$ od liczby zwartych zwojów w fazie stojana oraz mały wpływ zmian momentu obciążenia. Występuje również pewna niewielka wartość początkowa składowej dla silnika nieuszkodzonego. Świadczy to o istnieniu pewnej niesymetrii konstrukcyjnej silnika. Wpływ zmiany częstotliwości napięcia zasilania na amplitudę $I_2^{(f_s)}$ przedstawiono na rysunku 9.28 [9.35].




Rys. 9.27. Zmiany składowej kolejności przeciwnej prądu stojana $I_2^{(f_s)}$ w zależności od liczby zwojów zwartych oraz zmian momentu obciążenia przy zasilaniu z przemiennika częstotliwości $f_s = 50$ Hz

Zmiany kolejności przeciwnej stojana $I_2^{(f_s)}$ można uznać za bardzo dobry symptom wystąpienia zwarcia zwojowego i z powodzeniem stosować do wykrywania początkowej fazy powstawania uszkodzenia przy różnych częstotliwościach zasilania. W przypadku zasilania z przemiennika częstotliwości możliwe jest wykrycie już zwarcia 1–2 zwojów [9.32, 9.35].

Zastosowanie składowej kolejności przeciwnej impedancji $Z_2^{(f_s)}$ do monitorowania stanu uzwojenia stojana ma ograniczony zakres zastosowania, zwłaszcza w zasilaniu z sieci i występowaniu nawet ograniczonej niesymetrii konstrukcyjnej silnika.

Niewielkie zmiany składowej kolejności przeciwnej napięcia zasilania powodują duże zmiany składowej $Z_2^{(f_s)}$, co znacznie utrudnia wykrycie początkowej fazy uszkodzenia. Dodatkowo przy małych częstotliwościach napięcia zasilania istotnie zmniejsza się zakres zmian składowej $Z_2^{(f_s)}$.



Rys. 9.28. Zmiany składowej kolejności przeciwnej prądu stojana $I_2^{(f_s)}$ w zależności od liczby zwojów zwartych w fazie A oraz zmian częstotliwości napięcia zasilania (obciążenie znamionowe)

Amplituda składowej przeciwnej prądu stojana $Z_2^{(f_s)}$ wykazuje bardzo dobre właściwości jako symptom wystąpienia uszkodzenia w stojanie, szczególnie w zasilaniu z przekształtników PWM, które zapewniają dużą symetrię napięć zasilających. W przypadku zasilania z sieci pojawienie się asymetrii zasilania może znacząco wpływać na zmiany amplitudy składowej $Z_2^{(f_s)}$ i powodować błędną identyfikację uszkodzenia w początkowej fazie.

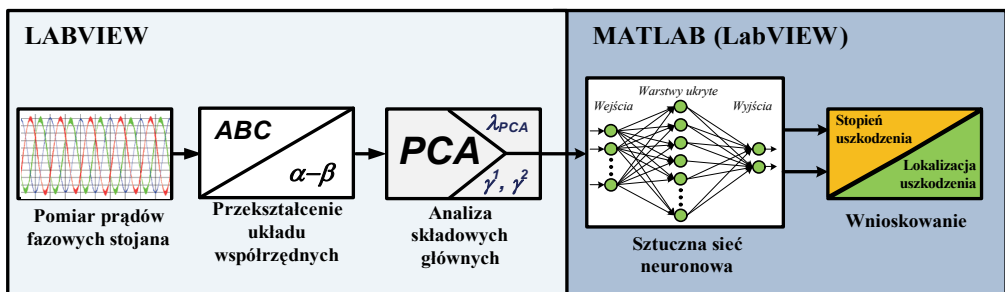
9.4. Neuronowe detektory uszkodzeń uzwojenia stojana

9.4.1. Neuronowy detektor uszkodzeń stojana oparty na danych z analizy PCA wektora przestrzennego prądu stojana

Klasyfikacja i ocena symptomów uszkodzeń może być znacznie utrudniona w przypadku niejednoznacznych zmian sygnałów diagnostycznych i dużych zbiorów

danych zbieranych cyklicznie. W takich przypadkach korzystnym rozwiązaniem zadania klasyfikacji i oceny symptomów uszkodzeń jest zastosowanie sztucznych sieci neuronowych. Dodatkowo zastosowanie sieci neuronowych w odniesieniu do identyfikacji uszkodzeń uzwojeń stojana stwarza nowe możliwości, ponieważ zbędna staje się konieczność posiadania dokładnej wiedzy w zakresie mechanizmów powstawania uszkodzenia. Przedstawiono analizę możliwości wykorzystania środowiska programistycznego LabVIEW do realizacji wirtualnego neuronowego detektora zastosowanego do wykrywania i lokalizacji zwarć zwojowych silnika indukcyjnego we wczesnym stadium ich powstawania. Do wykrywania i oceny stopnia uszkodzenia uzwojenia stojana wykorzystano metodę opartą na analizie składowych głównych wektora przestrzennego prądu stojana oraz obliczonych na jej podstawie wskaźników uszkodzenia uzwojenia stojana (patrz rozdział 9.2.3). Praktyczną użyteczność metody sprawdzono w badaniach eksperymentalnych na silniku małej mocy o różnej częstotliwości napięcia zasilania i różnych momentach obciążenia [9.33, 9.35]. Stopień uszkodzenia uzwojenia stojana modelowano fizycznie na obiekcie rzeczywistym, przez zmianę liczby zwieranych zwojów, natomiast miejsce uszkodzenia przez modelowanie zwarć kolejno w każdej z faz uzwojenia stojana.

Na rysunku 9.29 przedstawiono etapy przetwarzania informacji diagnostycznej z wykorzystaniem metody opartej na analizie PCA, począwszy od pomiaru trzech prądów fazowych, a następnie przekształceniu układu współrzędnych ABC do układu stacjonarnego $\alpha-\beta$ na podstawie zależności (3.5). Kolejnym etapem jest wyznaczenie składowych macierzy wektorów głównych Γ i wartości głównych Λ , wykorzystując dostępne w środowisku LabVIEW bloki funkcyjne (TSA_Principal_Component_Analysis.vi). Następnie obliczane są dwa wektory główne: γ^1 i γ^2 (9.5), (9.6) oraz indeks zmian wartości głównych λ_{PCA} (9.7). Ostatnim etapem jest wnioskowanie o stanie uzwojenia stojana, a w przypadku wykrycia uszkodzenia ocena jego stopnia oraz lokalizacji. Do tego celu zastosowano sieć neuronową typu MLP.



Rys. 9.29. Neuronowy detektor zwarć zwojowych oparty na analizie PCA wektora prądu stojana

W warstwie wyjściowej zastosowano neurony o liniowej funkcji aktywacji, na których wyjściu pojawiała się wartość określająca stopień uszkodzenia uzwojenia silnika oraz fazę silnika, w której wystąpiło uszkodzenie. W pozostałych neuronach zastosowano

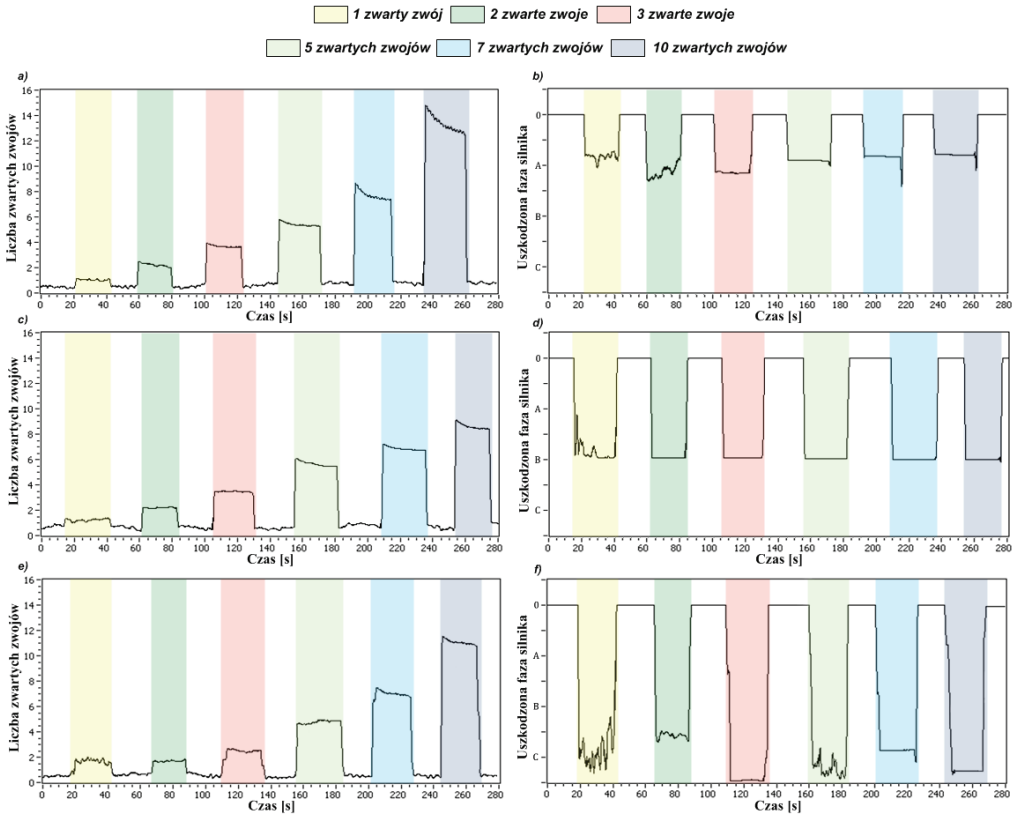
wano funkcję aktywacji typu tangens hiperboliczny. W procesie treningu sieci neuronowej zastosowano algorytm Levenberga-Marquardta. Sieci neuronowe projektowano za pomocą pakietu Matlab Neural Network Toolbox.

Zbiór danych wejściowych sieci neuronowej stanowiły: współczynnik stopnia uszkodzenia uzwojenia stojana λ_{PCA} , składowe wektora głównego γ^1 oraz dodatkowo częstotliwości napięcia zasilania. Na wyjściu sieci zastosowano 2 neurony, na których oczekiwano odpowiedzi w postaci stopnia uszkodzenia uzwojenia stojana (liczby zwartych zwojów w jednej fazie silnika) oraz lokalizacji uszkodzenia (fazy silnika, w której wystąpiło uszkodzenie). Wektor uczący i testujący został sporządzony na bazie symptomów uszkodzenia uzwojenia stojana, wygenerowanych na podstawie badań eksperymentalnych. Przebadano sieci o różnych topologiach, zmieniając kolejno liczbę neuronów w warstwie ukrytej (5÷25). Każda struktura sieci była testowana 10 razy. Do oceny poprawności działania sieci przyjęto skuteczność, obliczoną jako procentowa poprawność odpowiedzi sieci na sygnał wejściowy. Dodatkowo założono, że maksymalna różnica między spodziewaną a faktyczną odpowiedzią sieci nie może być większa niż 2 zwarte zwoje.

Tabela 9. 2. Wyniki testowania wytrenowanej sieci neuronowej

Numer powtórzeń Struktura sieci	Skuteczność detektora %										Średnia skuteczność %
	1	2	3	4	5	6	7	8	9	10	
4-5-2	63,0	59,7	61,1	55,6	59,7	59,3	54,2	63,0	51,4	74,1	55,1
4-6-2	80,6	55,6	61,6	50,5	50,5	53,7	59,7	60,6	64,4	70,4	55,8
4-7-2	56,9	64,4	54,2	69,4	64,4	55,1	59,3	66,2	52,8	68,1	56,1
4-8-2	50,9	68,1	63,0	55,1	65,3	54,2	55,1	59,7	55,6	63,4	54,4
4-9-2	54,2	48,6	62,0	62,5	69,9	64,4	63,0	60,2	62,0	73,6	57,2
4-10-2	50,9	59,7	62,5	75,9	55,6	55,6	54,6	74,5	64,8	67,1	62,1
4-11-2	73,1	67,6	66,2	67,6	51,4	52,3	51,4	63,4	59,3	72,7	62,5
4-12-2	67,1	69,4	65,7	64,4	72,7	72,2	64,8	71,8	63,0	68,5	68,0
4-13-2	74,5	62,0	69,4	65,7	80,1	66,2	75,0	60,2	78,2	56,5	68,8
4-14-2	73,6	87,0	83,8	78,2	78,2	69,9	75,0	78,2	75,5	68,5	76,8
4-15-2	79,6	75,5	85,2	77,8	74,1	83,3	65,3	80,6	81,5	81,9	78,5
4-16-2	78,7	89,4	78,7	77,8	80,1	80,6	83,3	76,4	81,9	77,3	80,4
4-17-2	84,3	80,6	82,4	75,5	84,7	79,2	82,9	86,6	77,3	80,6	81,4
4-18-2	81,0	79,6	88,4	76,4	88,4	76,4	75,9	83,3	77,8	80,1	80,7
4-19-2	88,0	84,3	85,6	74,1	84,3	84,7	82,4	75,5	81,5	81,9	82,2
4-20-2	87,5	88,4	83,3	86,1	91,7	74,5	88,4	87,5	84,3	91,7	86,3
4-21-2	73,1	87,0	86,6	88,4	81,0	89,4	88,9	75,9	88,4	81,0	84,0
4-22-2	78,2	83,3	83,3	91,2	80,6	87,5	86,1	87,0	78,2	82,4	83,8
4-23-2	84,3	92,1	90,3	92,6	82,9	80,1	84,7	95,4	85,2	88,9	87,6
4-24-2	85,2	87,5	84,7	88,9	88,9	86,1	84,3	90,3	86,6	91,2	87,4
4-25-2	81,5	83,3	93,5	84,7	84,7	89,8	81,9	83,8	81,0	82,4	84,7

W tabeli 9.2 przedstawiono wyniki testowania sieci neuronowej. Najlepsze odpowiedzi sieci na sygnał wejściowy wyróżniono. Spośród przedstawionych topologii sieci, najlepszą okazała się sieć o strukturze {4–23–2} (4 wejścia, 23 neurony ukryte, 2 neurony wyjściowe), która uzyskała średnią skuteczność z 10 powtórzeń na poziomie 87,6%.




Rys. 9.30. Odpowiedzi neuronowego detektora uszkodzeń uzwojeń stojana {4–23–2} pracującego on-line: stopień i lokalizacja uszkodzenia w fazie A (a, b), w fazie B (c, d), w fazie C (e, f)

Sprawdzony w testach symulacyjnych neuronowy detektor uszkodzeń o strukturze {4–23–2} zaimplementowano do pracy on-line na obiekcie rzeczywistym. Jako realizacja programowa stanowi on uzupełnienie wirtualnego przyrządu pomiarowo-diagnostycznego o element wnioskowania stanu uzwojeń stojana. Cały system zrealizowano programowo w środowisku LabVIEW i podłączono do pracy on-line na rzeczywistym napędzie przekształtnikowym. Wyniki odpowiedzi neuronowego detektora (stopień uszkodzenia i lokalizacja), działającego on-line, w fizycznym modelowaniu zwarć zwojowych kolejno w trzech fazach silnika, przedstawiono na rysunku 9.30.

Możliwe jest wykrycie bezpośrednio 1 zwartego zwoju w jednej fazie silnika oraz bezbłędne określenie fazy silnika, w której wystąpiło uszkodzenie. Pomyłki w odpowiedzi detektora (maksymalnie 2 zwoje) widoczne są jedynie w zwarcu większej liczby zwojów (7 i więcej).

Na rysunku 9.31 przedstawiono wpływ obciążenia silnika na wykrywalność uszkodzenia uzwojenia stojana modelowanego fizycznie w fazie A silnika. Wzrost momentu obciążenia silnika ($m_0 = 0 \div m_N$) ma niewielki wpływ na wykrywalność zwarców zwojowych. Powoduje zwiększenie oscylacji odpowiedzi detektora przy ocenie stopnia uszkodzenia uzwojenia stojana. Możliwe jest wykrycie 1 zwartego zwoju przy pełnym obciążeniu silnika oraz bezbłędne wskazanie fazy silnika, w której wystąpiło uszkodzenie.




Rys. 9.31. Odpowiedzi neuronowego detektora uszkodzeń uzwojeń stojana pracującego on-line przy zwarcjach zwojowych w fazie A silnika i różnym obciążeniu maszyny:

a) określanie stopnia uszkodzenia, b) lokalizacja uszkodzenia

Na rysunku 9.32 przedstawiono wpływ częstotliwości napięcia zasilania na wykrywalność zwarców zwojowych w stanie w fazie A silnika. Zmiana f_s w przedziale od 50 Hz do 20 Hz ma niewielki wpływ na wykrywalność liczby zwojów zwartych (rys. 32a), zwłaszcza dla małych wartości częstotliwości napięcia zasilania. Powoduje

powstanie niewielkich oscylacji odpowiedzi detektora. Jednak możliwe jest wykrycie nawet 1 zwoju zwartego w każdej z faz silnika oraz bezbłędne wskazanie lokalizacji uszkodzenia (rys. 9.32b).

Przedstawiony system diagnostyczny realizuje pomiar, ekstrakcję symptomów uszkodzeń z wykorzystaniem metody składowych głównych PCA oraz detekcję i lokalizację zwarców zwojowych za pomocą sieci neuronowych na bardzo wczesnym etapie powstania uszkodzenia.



Rys. 9.32. Odpowiedzi neuronowego detektora uszkodzeń uzwojeń stojana pracującego on-line przy zwiarcach zwojowych w fazie A silnika i różnych częstotliwościach napięcia zasilania:


a) stopień uszkodzenia, b) lokalizacja uszkodzenia

9.4.2. Neuronowy detektor uszkodzeń stojana oparty na danych z analizy składowych symetrycznych


Do realizacji neuronowego detektora zwarców zwojowych wykorzystano wielkości otrzymane z analizy składowych symetrycznych napięć i prądu stojana (rozdział 9.3), dla różnego stopnia uszkodzenia stojana. Wielkościami wejściowymi sieci neuronowej są amplitudy składowych kolejności zgodnej i przeciwnej prądu stojana I_1 , I_2 , składowa kolejności zgodnej napięcia zasilania U_1 oraz impedancja kolejności prze-

ciwnej Z_2 . Na wyjściu sieci oczekiwano odpowiedzi w postaci stopnia uszkodzenia uzwojenia stojana (liczby zwartych zwojów w jednej fazie silnika).

Podobnie jak w poprzednim przypadku (rozdział 9.4.1), przebadano sieci o różnych topologiach zmieniając kolejno od 5 do 25 liczbę neuronów w warstwie ukrytej. Badania symulacyjne wykonano w środowisku MATLAB. Każda struktura sieci była testowana 10 razy. Do realizacji neuronowego detektora uszkodzeń stojana na podstawie badań eksperymentalnych sporządzono obszerny zestaw danych pomiarowych. Spośród przebadanych topologii sieci najlepszą z nich okazała się sieć o strukturze $\{4-12-1\}$, która uzyskała średnią poprawność odpowiedzi z 10 powtórzeń na poziomie 89,8% [9.17, 9.31, 9.32, 9.35]. Otrzymano strukturę o małej liczbie neuronów w warstwie ukrytej, co ma duże znaczenie w realizacji technicznej detektora. Struktura ta została zrealizowana programowo w środowisku programistycznym LabVIEW i podłączona do systemu pomiarowo-diagnostycznego jako struktura wnioskowania diagnostycznego. Strukturę neuronowego detektora zwarców wykorzystującego składowe symetryczne przedstawiono na rysunku 9.33.




Rys. 9.33. Neuronowy detektor zwarców zwojowych oparty na składowych symetrycznych



Rys. 9.34. Odpowiedzi neuronowego detektora uszkodzeń uzwojeń stojana $\{4-12-1\}$ pracującego on-line przy zwarcach zwojowych w fazie A silnika o różnym obciążeniu

Na rysunkach 9.34 i 9.35 przedstawiono działanie neuronowego detektora podczas pracy on-line w napędzie przekształtnikowym. Zwarcie uzwojeń w fazie A było realizowane fizycznie na rzeczywistym silniku, bez ograniczania prądu płynącego w zwojach zwartych. Detektor wykrywał uszkodzenia już od 1 zwoju zwartego niezależnie od wartości obciążenia. Również zmiana częstotliwości zasilania w przedziale 20–50 Hz w niewielkim stopniu wpływała na wykrywalność liczby zwojów zwartych (rys. 9.35).



Rys. 9.35. Odpowiedzi neuronowego detektora uszkodzeń uzwojeń stojana {4–12–1} pracującego on-line przy zwarcjach zwojowych fazy A, o różnych częstotliwości napięcia zasilania

9.5. Zastosowanie analizy falkowej do wykrywania zwarc zwojowych


Coraz częściej stosowaną i wciąż rozwijaną w diagnostyce uszkodzeń silników indukcyjnych jest analiza falkowa. Jak przedstawiono w rozdziale 4.4.3, analiza falkowa umożliwia skuteczniejsze wydobycie osobliwych krótkoczasowych cech analizowanych sygnałów [9.10, 9.36, 9.37].

Dyskretna wielorozdzielcza transformata falkowa powoduje rozdzielenie sygnału na składowe, zwane aproksymatami a_k i detalami $d_{j,k}$, przez filtrację odpowiednio filtrem dolnoprzepustowym i górnoprzepustowym oraz operację próbkowania sygnału przez wybieranie tylko próbek parzystych (ang. *downsampling*). Współczynniki $d_{j,k}$ zawierają informację o wysokich częstotliwościach oraz tworzą zbiór tzw. detali. Natomiast współczynniki a_k zawierają informację dolnoprzepustową wraz ze składową stałą, czyli stanowią tzw. aproksymację sygnału. Pełna informacja o sygnale wejściowym (oryginalnym) jest zachowana w zbiorze złożonym z połączenia w całym

rozkładzie wszystkich detali i aproksymacji najniższego poziomu rozdzielczości. Przedstawiono przykład połączenia korzystnych właściwości metody analizy modułu wektora przestrzennego prądu stojana z analizą falkową w detektorze do wykrywania zwarc zwojowych, pracującym w trybie on-line. Detektor został zrealizowany w środowisku programowym LabVIEW [9.36].

Na rysunku 9.36 przedstawiono etapy przetwarzania informacji diagnostycznej, które realizuje detektor za pomocą metody opartej na analizie falkowej sygnału modułu wektora przestrzennego prądu stojana.

Pierwszym etapem jest pomiar trzech prądów fazowych stojana i przetworzenie ich do wektora przestrzennego prądu stojana oraz obliczenie jego modułu.



Rys. 9.36. Etapy przetwarzania informacji diagnostycznej za pomocą analizy falkowej $|i_s|$

Kolejnym etapem jest wykonanie transformaty falkowej sygnału $|i_s|$. Transformatę falkową zrealizowano, wykorzystując dostępne w środowisku LabVIEW bloki funkcyjne (*WA Get Coefficients of Discrete Wavelet Transform.vi*) umożliwiające m.in. wybór rodzaju falki do dekompozycji (wybrano falkę Haar) oraz wybór poziomu dekompozycji [9.10, 9.36, 9.37]. Przed wykonaniem transformaty falkowej sygnał został przepróbkowany do poziomu 1024 kS/s, w celu ujednoczenia rozdzielczości mierzonych sygnałów. Proces dekompozycji sygnału powtórzono do trzeciego poziomu, w celu uzyskania możliwości badania zjawisk w zakresie częstotliwości od 64 do 128 Hz. W tym zakresie znajduje się częstotliwość charakterystyczna dla uszkodzenia stojana ($2 f_s$). Następnym etapem jest ekstrakcja symptomów uszkodzenia, którą zrealizowano w środowisku LabVIEW po wprowadzeniu odpowiedniego bloku funkcyjnego i obliczeniu współczynnika zmian energii sygnału $|i_s|^E$ dla wybranego poziomu dekompozycji według zależności:


$$|i_s|_i^E = \frac{\sum_{k=1}^{t/dt} (A_i(kdt))^2}{t} \quad (9.18)$$

gdzie:


- i – indeks określający stopień dekompozycji sygnału (D1, D2, D3 lub A3),
- A – amplituda sygnału $|i_s|$ na wybranym poziomie dekompozycji,

t – czas rejestracji sygnału,
 dt – rozdzielczość sygnału.

Ze względu na wzrost amplitudy harmonicznej $2f_s$ w chwili wystąpienia zwarcia zwojowego, skupiono się na monitorowaniu współczynnika zmian energii w detalu trzeciej dekompozycji sygnału $|i_s|_{D3}^E$. Ostatnim etapem jest wnioskowanie o stanie uzwojenia stojana, a w przypadku wykrycia uszkodzenia ewentualna ocena jego stopnia.




Rys. 9.37. Zmiana detalu trzeciego poziomu dekompozycji sygnału modułu wektora przestrzennego prądu stojana $|i_s|_{D3}$ silnika nieobciążonego: a) silnik nieuszkodzony, b) zwarcie 5 zwojów, c) zwarcie 10 zwojów



Rys. 9.38. Detal trzeciego poziomu dekompozycji sygnału modułu wektora przestrzennego prądu stojana $|i_s|_{D3}^2$ silnika nieobciążonego: a) silnik nieuszkodzony, b) zwarcie 5 zwojów, c) zwarcie 10 zwojów

Na rysunku 9.37 przedstawiono detal modułu wektora przestrzennego prądu stojana przy dekompozycji sygnału do trzeciego poziomu silnika nieobciążonego w przypadku silnika nieuszkodzonego, ze zwartymi 5 i 10 zwojami w fazie A. Można zaobserwować, że wraz ze wzrostem stopnia uszkodzenia uzwojenia stojana wrasta amplituda detalu $|i_s|_{D3}$ do trzeciego poziomu dekompozycji. Podniesienie do kwadratu sygnału $|i_s|_{D3}$ umożliwia uwydatnienie zmian amplitudy wywołanej uszkodzeniem (rys. 9.38).

W celu monitorowania zmian amplitudy sygnału $|i_s|_{D3}^2$ wprowadzono współczynniki zmian energii $|i_s|_{D3}^E$ sygnału opisany zależnością (9.18). Na rysunku 9.39 przedstawiono zmiany współczynnika $|i_s|_{D3}^E$ w zależności od stopnia uszkodzenia uzwojenia stojana i różnych wartości obciążenia silnika. Widoczny jest wyraźny wzrost wartości zaproponowanego współczynnika już podczas zwarcia 1 zwoju.




Rys. 9.39. Zależność zmian współczynnika $|i_s|_{D3}^E$ modułu wektora przestrzennego prądu stojana $|i_s|$ od obciążenia silnika oraz liczby zwartych zwojów

W celu oceny przydatności przedstawionego sposobu oceny zwarców zwojowych podczas pracy on-line, sprawdzono czy czas trwania pomiarów sygnału (liczba próbek) ma wpływ na zmiany wartości $|i_s|_{D3}^E$. Jak wynika z pomiarów zamieszczonych w tabeli 9.3 wpływ czasu rejestracji sygnału jest bardzo ograniczony. Możliwe jest zaobserwowanie zmian wartości $|i_s|_{D3}^E$, co oznacza, że podczas rejestracji sygnału już od 0,05 sekundy uzyskuje się nową informację o stanie uzwojeń.

Tabela 9.3. Zmiany wartości $|i_s|_{D3}^E$ w zależności od liczby zwartych zwojów i czasu rejestracji danych pomiarowych silnika nieobciążonego i obciążonego znamionowo

Liczba zwartych zwojów	Czas rejestracji danych						
	$t = 5$ s	$t = 2$ s	$t = 1$ s	$t = 0,5$ s	$t = 0,2$ s	$t = 0,1$ s	$t = 0,05$ s
	$m_o = 0$						
zw. 0	0,035	0,037	0,037	0,039	0,044	0,057	0,056
zw. 1	0,045	0,043	0,043	0,052	0,056	0,068	0,075
zw. 2	0,149	0,149	0,152	0,159	0,181	0,216	0,219
zw. 5	0,573	0,573	0,567	0,563	0,584	0,656	0,708
zw. 10	1,871	1,884	1,886	1,896	1,921	2,046	2,066
	$m_o = m_n$						
zw. 0	0,024	0,023	0,023	0,023	0,024	0,020	0,020
zw. 1	0,031	0,032	0,033	0,032	0,029	0,025	0,021
zw. 2	0,079	0,081	0,076	0,076	0,077	0,083	0,070
zw. 5	0,443	0,448	0,456	0,451	0,479	0,513	0,530
zw. 10	1,594	1,598	1,598	1,581	1,644	1,727	1,760



Rys. 9.40. Wyniki działania on-line detektora zwarc zwojowych przy skokowym zwiększeniu stopnia uszkodzenia uzwojenia stojana: a) silnik nieobciążony, b) silnik obciążony znamionowo

Na rysunku 9.40 przedstawiono wyniki działania on-line aplikacji pomiarowo-diagnostycznej realizującej wyżej przedstawione algorytmy przetwarzania i analizy prądu fazowego stojana dla czasu rejestracji sygnału $t = 0,2$ s. Można na ich podstawie stwierdzić, że zmiany wartości współczynnika $|i_s|_{D3}^E$ umożliwiają monitorowanie stanu uzwojenia stojana silnika indukcyjnego on-line. W przypadku omawianym w przykładzie, dekompozycja do trzeciego poziomu oraz wprowadzenie współczynnika zmian energii $|i_s|_{D3}^E$ dla detalu znacznie zwiększyło dokładność oceny stanu uzwojenia w porównaniu do korzystania tylko z informacji z widma modułu wektora przestrzennego prądu stojana.

9.6. Podsumowanie

Z przeprowadzonego przeglądu metod wykrywania uszkodzeń w stanie silnika indukcyjnego zasilanego z przemiennika częstotliwości wynika, że klasyczna analiza widmowa omówionych sygnałów diagnostycznych jest dobrym sposobem do wykrycia i oceny liczby zwartych zwojów w silniku indukcyjnym, przy zapewnieniu odpowiednio dużej dokładności i rozdzielczości aparatury pomiarowo-przetwarzającej. Zastosowanie przekształtnika częstotliwości powoduje odkształcenie napięcia i prądu zasilającego, ale powstające dodatkowe częstotliwości nie zakłócają procesu oceny uszkodzenia stojana. Nawet w razie zmniejszonej częstotliwości zasilania silnika możliwe jest wyodrębnienie i ocena amplitudy częstotliwości charakterystycznych dla uszkodzenia stojana. Niestety, nawet niewielka asymetria napięcia zasilania silnika ma wpływ na zmianę amplitudy $2f_s$, na zmianę amplitudy składowych symetrycznych $I_2^{(f_s)}$, $Z_2^{(f_s)}$ oraz na zmiany λ_{PCA} i położenie początkowe wektorów kierunkowych γ^1 , γ^2 . W takich przypadkach możliwa jest błędna identyfikacja uszkodzenia w początkowej fazie. Problem ten w małym stopniu dotyczy napędu przekształtnikowego, gdzie falowniki dostarczają symetryczne napięcie zasilające.

Metody wykrywania zwarcí stojanowych, oparte na pomiarze i ocenie przesunięć fazowych, są bardzo wygodne i łatwe w realizacji. Podobnie jak metody oparte na analizie PCA hodografu wektora prądu umożliwiają również określenie fazy, w której wystąpiło uszkodzenie. Zalety tej nie mają pozostałe metody.

W przypadku występowania częstych zmian obciążenia i częstotliwości napięcia zasilania może się okazać niezbędne zastosowanie dodatkowych sygnałów diagnostycznych lub wykorzystanie specjalnych technik opartych na sztucznej inteligencji lub zastosowaniu analizy czasowo-częstotliwościowej.

Wszystkie omówione metody, niezależnie od sposobu zasilania, umożliwiają wykrywanie zwarcia zwojowego w bardzo wczesnym stadium rozwoju (2–3 zwoje zwarte). Ponadto, dostarczają wiarygodnych symptomów zwarcia zwojowego, umoż-

liwiającego projektowanie neuronowych detektorów uszkodzeń uzwojeń stojana. Szczególnie do tego celu nadają się metody analizy składowych głównych hodografu wektora przestrzennego prądu stojana i metoda analizy składowych symetrycznych.

Przedstawione dwa rozwiązania neuronowego detektora zwarcia zwojowego wykazywały podczas pracy on-line na obiekcie rzeczywistym bardzo dobrą skuteczność wykrywania zwarcia zwojowego w początkowej fazie powstawania uszkodzenia (1–2 zwoje zwarte).

Literatura

- [9.1] Akagi H., Kanazawa Y., Nabae A., *Instantaneous Reactive Power Compensators Comprising Switching Devices without Energy Storage Components*, IEEE Trans. on Industrial Applications, Vol. IA-20, 1984, 625–630.
- [9.2] Assaf T., Henao H., Capolino G.A., *Simplified axial flux spectrum method to detect incipient stator inter-turn short-circuits in induction machine*, IEEE International Symposium on Industrial Electronics, Vol. 2, 2004, 815–819.
- [9.3] Bouzid M.B.K., Champenois G., Bellaaj N.M., Signac L., Jelassi K., *An Effective Neural Approach for the Automatic Location of Stator Interturn Faults in Induction Motor*, IEEE Transactions on Industrial Electronics, Vol. 55, No. 12, 2008, 4277–4289.
- [9.4] Ferrero A., Superti-Furga G., *A New Approach to the Definition of Power Components in Three-Phase Systems Under Nonsinusoidal Conditions*, IEEE Trans. on Instrumentation and Measurement, Vol. 40, No. 3, 1991, 568–577.
- [9.5] Filippetti F., Franceschini G., Tassoni C., Meo S., Ometto A., *1989–1998: State of Art of Model based Diagnostic Procedures for Induction Machines Stator Inter-Turn Short Circuits*, Proc. of IEEE Inter. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'99, Gijon, Spain, 1999, 19–31.
- [9.6] Filippetti F., Franceschini G., Tassoni C., Meo S., Ometto A., *A Simplified model of Induction Motor With Stator Shorted Turns Oriented To Diagnostics*, Proc. Inter. Confer. on Electrical Machines ICEM'96, Vigo, Spain, 1996, CD.
- [9.7] Henao H., Assaf T., Capolino G.A., *The discrete Fourier transform for computation of symmetrical components harmonics*, Power Tech Conference Proceedings, Vol. 4, 2003.
- [9.8] Iravani M.R., Karimi-Ghartemani M., *Online estimation of steady state and instantaneous symmetrical components*. IEE Proc. Gen., Trans. and Distr., Vol. 150, No. 5, 2003, 616–622.
- [9.9] Jung J.H., Lee J.J., Kwon B.H., *Online Diagnosis Of Induction Motors Using MCSA*, IEEE Transactions on Industrial Electronics, Vol. 53, No. 6, 2006, 1842–1852.
- [9.10] Kowalski C.T., *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Nr 57, seria Monografie nr 18, Oficyna Wydawnicza PWr., 2005.
- [9.11] Kowalski C.T., Wolkiewicz M., *Analiza możliwości zastosowania sygnałów mocy chwilowej i momentu elektromagnetycznego do diagnostyki silników indukcyjnych*, Prace Naukowe Inst. Maszyn, Napędów i Pomiarów Elektr. PWr, Studia i Materiały, nr 27, Zeszyt 60, 2007, 248–259.
- [9.12] Kowalski C.T., Wolkiewicz M., Ewert P., *Analiza zwarć zwojowych stojana silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości*, Przegląd Elektrotechniczny, R. 84, nr 12, 2008, 64–67.

- [9.13] Kowalski C.T., Wolkiewicz M., *Stator faults diagnosis of the converter-fed induction motor using symmetrical components and neural network*, 13th European Conference on Power Electronics and Applications, EPE '09, Barcelona 2009.
- [9.14] Kowalski C.T., Wierzbicki R., Wolkiewicz M., *Analiza wpływu uszkodzenia uzwojenia stojana silnika indukcyjnego na kąt przesunięcia fazowego pomiędzy prądem i napięciem*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, 2009, nr 29, 252–265.
- [9.15] Kowalski C.T., Orłowska-Kowalska T., Wierzbicki R., Wolkiewicz M., *Analysis of inter-turn fault symptoms for the converter-fed induction motor based on the phase-shift calculation*, 36th Annual Conf. of the IEEE Industrial Electronics Society, 2010, 760–765.
- [9.16] Kowalski C.T., Wierzbicki R., Wolkiewicz M., *Modelowanie zwarć zwojowych silnika indukcyjnego zasilanego z przemiennika częstotliwości*, Przegląd Elektrotechniczny, R. 86, nr 4, 2010, 220–224.
- [9.17] Kowalski C.T., Wolkiewicz M., Orłowska-Kowalska T., *Experimental verification of the inter-turn fault symptoms modeling for the converter-fed induction motor*, 10th Int. Conf. on Modeling and Simulation of Electric Machines, Converters and System, ELECTRIMACS 2011, Paris, France, 2011, CD.
- [9.18] Lobos T., *Fast estimation of symmetrical components in real time*, IEE Proceedings C, Vol. 139, No. 1, 1992, 27–30.
- [9.19] Martins J.F., Pires V.F., Pires A.J., *PCA-Based On-Line Diagnosis of Induction Motor Stator Fault Feed by PWM Inverter*, IEEE ISIE 2006, Canada, 2401–2405.
- [9.20] Martins J.F., Pires V.F., Pires A.J., *Unsupervised Neural-Network-Based Algorithm for an On-Line Diagnosis of Three-Phase Induction Motor Stator Fault*, IEEE Transactions on Industrial Electronics, Vol. 54, No. 1, 2007, 259–264.
- [9.21] Melero M.G., Capolino G.A., Cabanas M.F., *The ability of on-line tests to detect interturn short-circuits in squirrel cage motors*, Int. Conf. Electrical Machines ICM'2000, Espoo, Finland, 2000, 771–775.
- [9.22] Stavrou A., Sedding H., Penman J., *Current monitoring for detecting inter-turn short circuits in induction motors*, IEEE Transactions on Energy Conversion, Vol. 16, No. 1, 2001, 32–37.
- [9.23] Sotille J., Kohler J.L., *An On-Line Method to Detect Incipient Failure of Turn Insulation in Random-Wound Motors*, IEEE Trans. on Energy Conversion, Vol. 8, No. 4, 1993, 762–768.
- [9.24] Szymaniec S., *Diagnostyka stanu izolacji uzwojeń i stanu łożysk silników indukcyjnych klatkowych w warunkach przemysłowej eksploatacji*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie, z. 193, Opole 2013.
- [9.25] Szymaniec S., *Badania, eksploatacja i diagnostyka zespołów maszynowych z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Opolskiej, Studia i Monografie z. 333, Opole 2013.
- [9.26] Tallam R.M., Lee S.B., et al., *A Survey of Methods of Stator-Related Faults in Induction Machines*, IEEE Trans. Ind. Applications, Vol. 43, No. 4, 2007, 920–933.
- [9.27] Williamson S., Mirzoian K., *Analysis of cage induction motors with stator winding faults*, IEEE Trans. on Power Apparatus and Systems, Vol. 104, No. 7, 1985, 1838–1842.
- [9.28] Wolkiewicz M., Kowalski C.T., *Nieinwazyjne metody wczesnego wykrywania zwarć zwojowych w silniku indukcyjnym zasilanym z przemiennika częstotliwości*, Cz. I. *Maszyny Elektryczne, Zeszyty Problemowe*, nr 87, 2010, 145–150.
- [9.29] Wolkiewicz M., Kowalski C.T., *Nieinwazyjne metody wczesnego wykrywania zwarć zwojowych w silniku indukcyjnym zasilanym z przemiennika częstotliwości*, Cz. II. *Maszyny Elektryczne, Zeszyty Problemowe*, Nr 87, 2010, 151–156.
- [9.30] Wolkiewicz M., Kowalski C.T., *Detekcja i lokalizacja zwarć zwojowych silnika indukcyjnego zasilanego z przekształtnika częstotliwości*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, nr 30, 2010, 312–320.

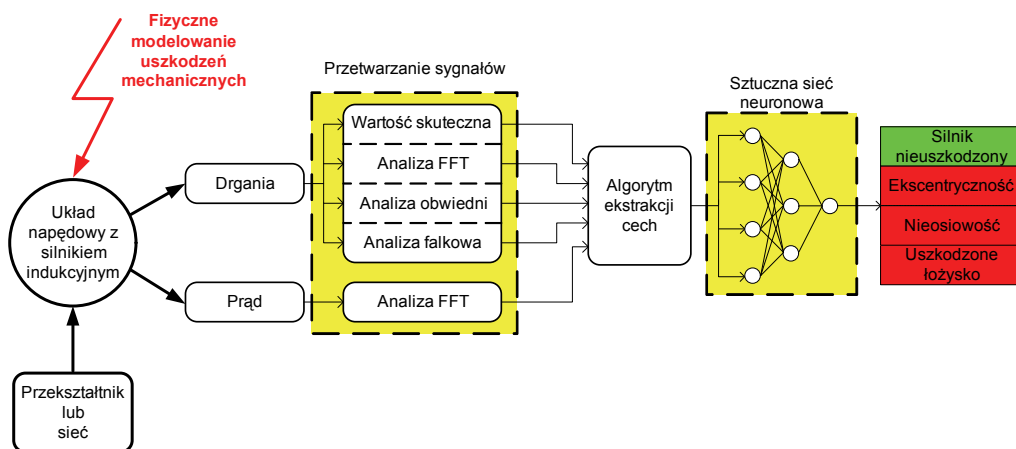
- [9.31] Wolkiewicz M., Kowalski C.T., Kamiński M., *Wykrywanie zwarć zwojowych silnika indukcyjnego z wykorzystaniem składowych symetrycznych oraz sieci neuronowych*, X Krajowa Konferencja Naukowa Sterowanie w Energoelektronice i Napędzie Elektrycznym, SENE 2011, 1–6.
- [9.32] Wolkiewicz M., Kowalski C.T., Kamiński M., *Wykrywanie zwarć zwojowych silnika indukcyjnego z wykorzystaniem składowych symetrycznych oraz sieci neuronowych*, Przegląd Elektrotechniczny, R. 88, nr 4b, 2012, 276–281.
- [9.33] Wolkiewicz M., Kowalski C.T., *Neuronowy detektor zwarć zwojowych stojana silnika indukcyjnego wykorzystujący analizę PCA wektora prądu*, Przegląd Elektrotechniczny, R. 88, nr 4b, 2012, 288–293.
- [9.34] Wolkiewicz M., Kowalski C.T., *Wykrywanie i lokalizacja zwarć zwojowych silnika indukcyjnego przy wykorzystaniu analizy składowych głównych hodografu wektora przestrzennego prądu stojana*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, nr 31, 2012, 324–331.
- [9.35] Wolkiewicz M., *Monitorowanie stanu uzwojeń stojana silnika indukcyjnego*, Praca doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2012.
- [9.36] Wolkiewicz M., Kowalski C.T., *Zastosowanie dyskretnej analizy falkowej do wykrywania zwarć zwojowych w silniku indukcyjnym*, Maszyny Elektryczne. Zeszyty Problemowe, nr 100, 2013, 191–196.
- [9.37] Zając M., *Metody falkowe w monitoringu i diagnostyce układów elektromechanicznych*, Monografia nr 371, Seria Inżynieria Elektryczna i Komputerowa, Politechnika Krakowska, Kraków 2009.

10. Wykrywanie uszkodzeń mechanicznych napędu z silnikiem indukcyjnym

10.1. Wprowadzenie

W niniejszym rozdziale scharakteryzowano wybrane uszkodzenia typu mechanicznego, najczęściej występujące w napędach elektrycznych z silnikami indukcyjnymi: uszkodzenia łożysk tocznych, niewyosiowanie napędu, ekscentryczność (mimośrodowość) silnika. Charakterystykę uszkodzeń przedstawiona, podobnie jak w poprzednich rozdziałach, przede wszystkim pod kątem określenia optymalnych sposobów uzyskiwania informacji diagnostycznej do projektowania neuronowych detektorów uszkodzeń. Przedstawiono przykłady realizacji neuronowych detektorów uszkodzeń.

Eksploatacyjne metody wykrywania uszkodzeń typu mechanicznego w silnikach indukcyjnych są oparte w zasadzie na nieinwazyjnym pomiarze i analizie częstotliwościowej dwóch sygnałów: drgań mechanicznych i prądu stojana (rys. 10.1).



Rys. 10.1. Procedura diagnostyczna wykrywania wybranych uszkodzeń mechanicznych [10.12]

Sygnał drganiowy dostarcza wielu informacji związanych ze stanem technicznym maszyn i jest obecnie podstawowym sygnałem w systemach do ciągłego monitorowania i diagnostyki napędów dużej mocy z silnikami indukcyjnymi. Analiza widmowa sygnału drganiowego umożliwia identyfikację rodzaju uszkodzenia. Trafność diagnozy opartej na analizie widmowej drgań mechanicznych zależy w bardzo dużym stopniu od wiedzy i doświadczenia eksperta oraz w pewnym stopniu od jakości i możliwości przetwarzania sygnałów w dostępnych systemach pomiarowych. Często systemy diagnostyczne wykorzystują techniki wspomagające, ułatwiające wykrywanie obecności okresowych składników sygnału drganiowego w obszarze o podwyższonym poziomie drgań [10.1, 10.27, 10.39, 10.40].

W prądzie stojana silnika indukcyjnego również są odzwierciedlone wszystkie podstawowe uszkodzenia, w tym mechaniczne, co w połączeniu z łatwością realizacji pomiaru decyduje o atrakcyjności metod monitorowania i diagnostyki on-line opartych na analizie widmowej prądu. W analizie widmowej prądu stojana do wykrywania uszkodzeń typu mechanicznego najlepiej rozpoznana i wdrożoną jest diagnostyka ekscentryczności wirnika [10.2–10.4, 10.16–10.19, 10.25, 10.28, 10.32, 10.35, 10.36, 10.41]. Również w zakresie wykrywania uszkodzeń łożysk analiza widmowa prądu jest coraz chętniej stosowana jako źródło cennych dodatkowych informacji diagnostycznych mających wpływ na trafność diagnozy silnika [10.33, 10.38, 10.42].

W ostatnich latach nastąpił gwałtowny wzrost zainteresowania zastosowaniem innych metod przetwarzania sygnałów do monitorowania i diagnostyki uszkodzeń mechanicznych maszyn elektrycznych. Wynika to z niedoskonałości metod klasycznych opartych na przekształceniu FFT. Dotyczy to zwłaszcza zastosowania analizy falkowej, która jest doskonałą metodą do wykrywania uszkodzeń osobliwych i krótkoczasowych, pojawiających się np. w łożyskach tocznych.

Główna uwaga została skupiona na problematyce uszkodzeń łożysk tocznych. Są to najbardziej odpowiedzialne i jednocześnie zawodne elementy maszyn. Umożliwiają przeniesienie sił z części obrotowych maszyny do części nieruchomych i odwrotnie oraz zmniejszają opory ruchu między tymi częściami. Z zasady działania są generatorem drgań. Na skutek nieprawidłowego doboru, złej konserwacji, intensywnej eksploatacji łożyska ulegają przedwczesnemu zużyciu, a w konsekwencji uszkodzeniu. Obecnie jest to główna przyczyna awarii w napędach z silnikami indukcyjnymi. Koszty wymiany łożyska są niewielkie w porównaniu do kosztów remontowanego silnika.

Ekscentryczność maszyn (mimośrodowość) jest to stan nierównej szczeliny powietrznej, która występuje między stojanem i wirnikiem. Detekcja i ocena ekscentryczności jest bardzo ważnym, ale i kłopotliwym elementem monitorowania stanu technicznego silników indukcyjnych. Wynika to z faktu, że tolerancje szczeliny powietrznej między stojanem a wirnikiem są bardzo małe. Niewielkie przekroczenie granic tolerancji może spowodować poważne uszkodzenie maszyny (tarcie stojana o wirnik, a w konsekwencji uszkodzenie stojana lub wirnika). Zbyt duży poziom eks-

centryczności może również pogłębić stan awaryjny maszyny wywołany niekorzystnymi zjawiskami, takimi jak: niesymetria zasilania, uszkodzenie obwodów wirnika lub stojana, praca z nadmiernym obciążeniem itp. Występowanie ekscentryczności często nie wyklucza maszyny z dalszej pracy, jednak w takim przypadku jej poziom powinien być kontrolowany, ponieważ zwykle ma ona tendencję do pogłębiania się, co w konsekwencji prowadzi do uszkodzenia maszyny.

Według niektórych autorów, aż 80% wszystkich uszkodzeń typu mechanicznego prowadzi w efekcie do powstania ekscentryczności. Do głównych źródeł ekscentryczności można zaliczyć: niecentryczne osadzenie wirnika, luzy na łożyskach, ugięcie wału, niewyważenie wirnika, rezonans mechaniczny dla krytycznej prędkości obrotowej, zużycie łożysk, niewyosowanie.

Niewspółosiowość jest trudna do wykrycia podczas pracy układu. Obecnie nie spotyka się żadnych analizatorów oraz czujników, których można użyć do pomiaru sił, działających na łożyska, wały oraz sprzęgła, wywoływanych przez rozosiowane układy napędowe. Jedynym sposobem wykrycia niewspółosiowości jest obserwacja i pomiar niektórych wtórnych efektów tych sił. Są to między innymi: zwiększony poziom drgań w kierunkach promieniowym i osiowym, niesymetryczna szczelina powietrzna, pulsacyjny moment obrotowy, wysoka temperatura obudowy przy łożyskach lub w ich pobliżu oraz wysoka temperatura oleju, nadmierne wycieki oleju na uszczelkach łożysk, poluzowane śruby mocujące do fundamentu, poluzowane lub uszkodzone śruby sprzęgła, wzrost temperatury sprzęgieł sprężystych, nadmierna ilość smaru w osłonie sprzęgła.

W trakcie eksploatacji niewspółosiowość można wykryć przez analizę drgań mechanicznych i prądu stojana, które umożliwiają identyfikację i ocenę charakterystycznych częstotliwości pojawiających się przy niewspółosiowości. Obecnie nowe możliwości diagnostyczne dają również badania termowizyjne umożliwiające monitorowanie wyosowania przez obserwację temperatury sprzęgieł, osłon łożyskowych itp.

Badania eksperymentalne wykonano na silniku indukcyjnym typu SH 90L-4, zasilanym z sieci lub falownika PWM, o parametrach przedstawionych w załączniku 1. W załączniku 2 przedstawiono schemat stanowiska laboratoryjnego. Silnik i prądnicę umieszczono na stanowisku z możliwością regulacji położenia maszyn w trzech osiach, co było szczególnie przydatne podczas badania wpływu nieosiowości układu napędowego. W silniku były montowane łożyska kulkowe typu 6205 2Z, ze sztucznie modelowanymi uszkodzeniami kulki (punktowe uszkodzenie jednej kulki), bieżni wewnętrznej (przecięcie bieżni wewnętrznej oraz uszkodzenie powierzchniowe bieżni na długości 2 cm) i zewnętrznej (przecięcie bieżni zewnętrznej oraz uszkodzenie powierzchniowe bieżni na długości 2 cm).

Pomiar drgań zrealizowano miniaturowym jednoosiowym akcelerometrem piezoelektryczny *DeltaTron typ 4397* oraz trójosiowym *DeltaTron typ 4506*. Niewspółosiowość regulowano w osi poziomej x (poziome przesunięcie równoległe) oraz w osi

pionowej y (pionowe przesunięcie równoległe). Pomiar parametrów niewyosiowania realizowano przyrządem laserowym OPTALIGN typu ALI12.200 firmy PRÜF-TECHNIK. Badania zrealizowano z wykorzystaniem komputera przemysłowego NI PXI 8106 wyposażonego w kartę przemysłową NI PXI 4472 oraz kartę pomiarową NI USB 9234. Akwizycję sygnałów diagnostycznych oraz analizę danych pomiarowych dokonano za pomocą przyrządów i analizatorów wirtualnych zrealizowanych w środowisku LabView.

10.2. Wykrywanie uszkodzenia łożyska tocznego

10.2.1. Metody klasyczne oparte na analizie widmowej drgań i prądu

Diagnostyka stanu łożyska tocznego w maszynach elektrycznych jest jednym z najważniejszych zagadnień technicznych i ekonomicznych w eksploatacji napędu elektrycznego. Cały czas prowadzi się intensywne badania nad udoskonaleniem znanych i poszukiwaniem nowych metod wykrywania i oceny uszkodzenia łożyska tocznego. Zagadnieniami diagnostyki łożysk tocznych zajmują się czołowe firmy diagnostyczne, takie jak: Bruel&Kjaer, Schenck, IRD, SPM, TEC, SKF, Bently Nevada oraz liczne ośrodki naukowo-badawcze.

Obecnie w praktyce badawczej i przemysłowej w kraju i zagranicą stosuje się następujące metody diagnozowania łożysk:


1. Metody oparte na pomiarze ogólnego poziomu drgań (według norm PN i ISO).
2. Metody oparte na analizie częstotliwościowej sygnału drgań.
3. Metody oparte na analizie częstotliwościowej sygnału prądu stojana
4. Metody oparte na specjalnych analizach, między innymi:
 - metoda analizy obwiedni (*Envelop Method*) firmy Bruel&Kjaer,
 - metoda SPM (*Shock Pulse Method*) firmy SPM,
 - metoda SE (*Spike Energy*) firmy IRD,
 - metoda BCU (*Bearing Condition Unit*) firmy Schenck,
 - metoda SEE (*Spectral Emited Energy*) firmy SKF,
 - metoda REBAM (*Rolling Element Bearing Active Monitor*) firmy Bently Nevada.

Obecnie bardzo intensywnie rozwijane są metody oparte na analizie częstotliwościowo-czasowej: analizie falkowej, analizie STFT oraz transformacie wyższych rzędów [10.15, 10.34, 10.38, 10.44, 10.45]. Metody te wydają się być szczególnie przydatne do wczesnego wykrywania uszkodzeń oraz zastosowania w detektorach opartych na sztucznej inteligencji ze względu na konieczność przetwarzania dużej liczby danych.

Przyczyny uszkodzeń oraz metody wykrywania uszkodzenia łożysk tocznych są bardzo dobrze i dokładnie opisane w literaturze, m.in. [10.38, 10.39]. Uszkodzenia łożysk tocznych mogą mieć charakter lokalny (punktowy) lub rozproszony. Uszkodzenia lokalne dotyczą jednopunktowych uszkodzeń, takich jak np. mały otwór, wgłębienie lub brakujący kawałek w odpowiednim elemencie łożyska. Można je podzielić ze względu na uszkodzony element:

- uszkodzenie koszyka,
- uszkodzenie elementu tocznego,
- uszkodzenie bieżni zewnętrznej,
- uszkodzenie bieżni wewnętrznej.

Uszkodzenia punktowe wywołują efekty w postaci drgań w obszarze małych częstotliwości. Do uszkodzeń rozproszonych można zaliczyć: nierówność, wżery korozyjne, chropowatość lub deformacje na całej powierzchni łożyska. Spowodowane są przez zanieczyszczenie lub utratę oleju (smaru). Trudno je scharakteryzować konkretną częstotliwością, dlatego ich wykrycie polega na obserwacji zmian widma drgań i prądu w szerokim pasmie częstotliwości. Uszkodzenia rozproszone wpływają również na zmianę wartości skutecznej drgań maszyny. We wczesnych stanach degradacji łożyska powstają drgania w wyższym pasmie częstotliwości. W miarę powstawania mikrouszkodzeń pasmo drgań się zawęża. Podczas dalszej eksploatacji łożyska następują ubytki masowe w łożysku powodujące dalsze zmniejszenia średniej częstotliwości drgań.



Rys. 10.2. Zestawienie wartości skutecznej przyspieszenia i prędkości drgań silnika nieobciążonego z różnymi typami uszkodzeń elementów łożyska tocznego

Metody analizy oparte na ocenie wartości skutecznej drgań omówiono w rozdziale 3.6. Na rysunku 10.2 przedstawiono zestawienie wartości skutecznej przyspieszenia drgań i prędkości silnika pracującego na biegu jałowym z uszkodzonymi elementami konstrukcyjnymi łożyska tocznego. Wartość skuteczną prędkości drgań podano dla całego zmierzonego zakresu częstotliwości (do 6400 Hz) oraz w pasmie 10÷1000 Hz (zalecenie normy PN-ISO 10816-1:1998). Z rysunku 10.2 wynika, że podczas pracy silnika z uszkodzonymi łożyskami wartość skuteczna przyspieszenia drgań zwiększa się nawet kilkunastokrotnie w porównaniu do silnika z nieuszkodzonymi łożyskami [10.6, 10.12]. Dużo mniejsze zmiany są widoczne w przypadku skutecznej prędkości drgań (zarówno w całym zmierzonym pasmie częstotliwości oraz w pasmie 10÷1000 Hz). Analiza wartości skutecznej zgodnie z normą PN-ISO 10816-1:1998 wykazała, że tylko w przypadku uszkodzonej bieżni wewnętrznej łożyska stan badanego silnika był zadowalający. W pozostałych przypadkach stan techniczny badanej maszyny był dobry.

Według [10.38, 10.39] 2,5-krotny wzrost wartości skutecznej prędkości drgań odpowiada zmianie stanu maszyny o jedną klasę jakości, natomiast co najmniej 10-krotny wzrost odpowiada zmianie klasyfikacji maszyny ze stanu dobrego na niedopuszczalny. W przypadku uszkodzonej bieżni zewnętrznej skuteczna prędkość V_{RMS} (10÷1000 Hz) wzrosła ok. 4-krotnie (z 0,0747 mm/s do 0,2295 mm/s), co świadczy o zmianie klasyfikacji maszyny na stan zadowalający. W przypadku uszkodzonej bieżni wewnętrznej wzrosła aż ok. 11-krotnie (z 0,0747 mm/s do 0,8255 mm/s), co świadczy już o niedopuszczalnym stanie technicznym maszyny. Dla uszkodzonego elementu tocznego zmiana ta jest ponad 9-krotna. Analiza oparta na pomiarze ogólnego poziomu drgań umożliwia ocenę stanu technicznego maszyny. Jednakże kontrolowanie jedynie wartości skutecznej drgań zgodnie z wytycznymi normy może być niewystarczające. Dlatego niezbędne jest również branie pod uwagę różnic między wartością skuteczną silnika z nieuszkodzonymi łożyskami i aktualnymi wynikami badań. Analiza oparta na pomiarze ogólnego poziomu drgań nie pozwala określić, który element konstrukcyjny łożyska został uszkodzony. Dlatego wartość skuteczna przyspieszenia oraz prędkość drgań nie są dobrymi cechami do projektowania detektorów neuronowych uszkodzeń elementów łożysk.

Wykrywanie uszkodzeń konstrukcyjnych łożysk tocznych oparte na widmie drgań mechanicznych jest najczęściej, po analizie opartej na normie, stosowaną metodą diagnostyczną. W klasycznym widmie drgań wyodrębnienie symptomów związanych z uszkodzeniem poszczególnych elementów konstrukcyjnych łożyska jest często utrudnione ze względu na szum i niską amplitudę charakterystycznych częstotliwości. Ocena stanu elementów konstrukcyjnych łożysk, dokonywana na podstawie widma drgań, opiera się na założeniu, że punktowe uszkodzenia powierzchni elementu łożyska generują drgania o charakterystycznych częstotliwościach w obszarze małych częstotliwości oraz drgania szerokopasmowe. Charakterystyczne częstotliwości uszkodzeniowe wyznacza się na podstawie znajomości parametrów konstrukcyjnych łożyska według zależności:

$$f_{lk} = \frac{1}{2} f_r \left(1 - \frac{d \cos \vartheta}{D} \right) \quad (10.1)$$


$$f_{bz} = \frac{N_k}{2} f_r \left(1 - \frac{d \cos \vartheta}{D} \right) \quad (10.2)$$

$$f_{bw} = \frac{N_k}{2} f_r \left(1 + \frac{d \cos \vartheta}{D} \right) \quad (10.3)$$

$$f_k = \frac{D}{2 \cdot d} f_r \left(1 - \left(\frac{d \cos \vartheta}{D} \right)^2 \right) \quad (10.4)$$

gdzie:

- $f_r = n/60$ – częstotliwość obrotowa, n – prędkość obrotowa [obr/min],
- f_{lk} – częstotliwość związana z uszkodzeniem i luzami koszyka,
- f_{bz} – częstotliwość związana z uszkodzeniem bieżni zewnętrznej,
- f_{bw} – częstotliwość związana z uszkodzeniem bieżni wewnętrznej,
- f_k – częstotliwość związana z uszkodzeniem elementu tocznego,
- d – średnica elementu tocznego,
- D – średnica podziałowa łożyska,
- ϑ – kąt pracy łożyska (0° dla łożyska kulkowego zwykłego),
- N_k – liczba elementów tocznych łożyska.



Rys. 10.3. Przekrój łożyska kulkowego: a) zwykłego ($\vartheta = 0^\circ$), b) skośnego ($0^\circ < \vartheta < 45^\circ$);
 d – średnica elementu tocznego, D – średnica podziałowa łożyska

Wymiary łożysk, niezbędne do wyznaczenia częstotliwości charakteryzujących uszkodzenia poszczególnych elementów łożyska, przedstawiono na rysunku 10.3. Obliczenie częstotliwości powinno być pierwszym etapem diagnozowania węzłów łożyskowych. Znając częstotliwości odpowiadające lokalnym defektom elementów badanego łożyska, można realizować pomiar i analizę widmową drgań w punkcie, gdzie łożysko jest najintensywniej obciążone. Do wyodrębnienia charakterystycznych częstotliwości najkorzystniej jest, zdaniem wielu autorów [10.6, 10.39, 10.42], zastosować analizę obwiedni, która umożliwia wczesne rozpoznanie uszkodzenia łożysk. Analiza obwiedni polega na tym, że sygnał drganiowy po wstępnym odfiltrowaniu zakresu częstotliwości obejmującego częstotliwość rezonansową węzła łożyskowego, podlega demodulacji, a następnie wyznaczane jest widmo powstałej obwiedni sygnału. W tak otrzymanym widmie obwiedni można dokładnie wyodrębnić charakterystyczne częstotliwości będących efektem niskoczęstotliwościowych modulacji wynikających z ewentualnych uszkodzeń elementów łożyska.


Zastosowanie analizy częstotliwościowej w połączeniu z analizą obwiedniową umożliwia precyzyjnie oddzielić informacje o uszkodzonym łożysku tocznym od zakłóceń zewnętrznych. Zalety tej metody to:

- ograniczenie wpływu zakłóceń zewnętrznych,
- możliwość precyzyjnego śledzenia rozwoju uszkodzenia łożyska,
- możliwość prowadzenia uniwersalnych pomiarów diagnostycznych.

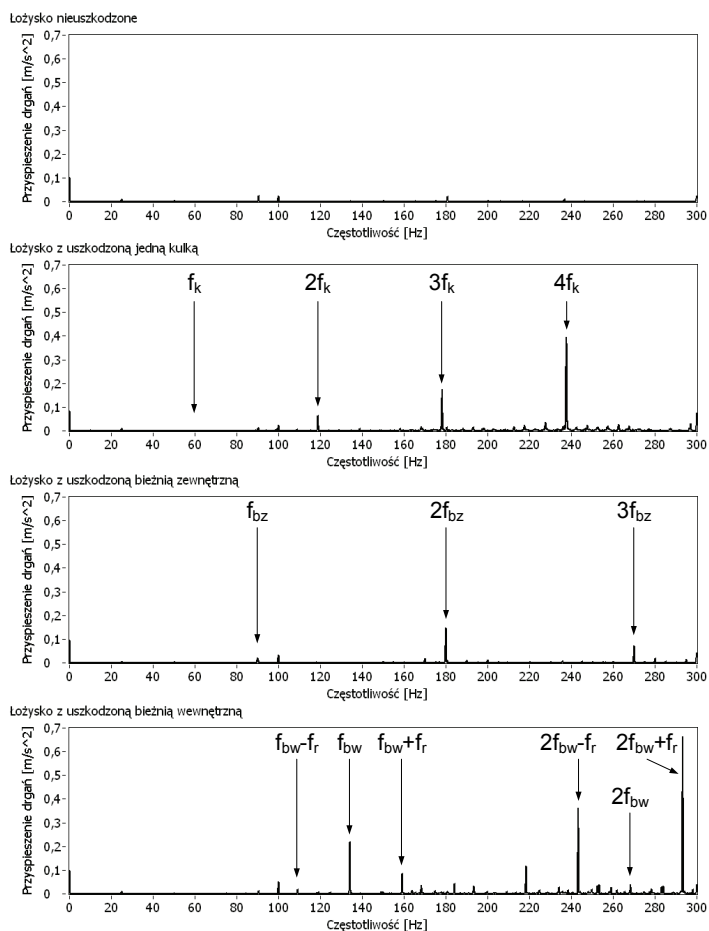
Natomiast wady to:

- konieczna znajomość obszarów rezonansowych i indywidualizacja kryteriów stanu,
- konieczna dokładna znajomość konstrukcji łożyska i rzeczywistej prędkości obrotowej,
- trudności z identyfikacją modulacji w przypadku zaawansowanego stanu uszkodzenia.

Na rysunku 10.4 przedstawiono teoretyczne widmo obwiedni drgań mechanicznych silnika z zaznaczonymi charakterystycznymi częstotliwościami świadczącymi o uszkodzeniu łożyska tocznego. Natomiast na rysunku 10.5 przedstawiono eksperymentalne wyniki analizy sygnału przyspieszenia drgań dla silnika pracującego bez obciążenia z łożyskami z uszkodzonymi elementami konstrukcyjnymi. Na rysunku zaznaczono częstotliwości dla uszkodzeń poszczególnych elementów, obliczone wg wzorów (10.1)–(10.4). Amplitudy podstawowych częstotliwości uszkodzeniowych mają zwykle zdecydowanie mniejsze wartości w porównaniu do ich krotności. W przypadku silnika pracującego z uszkodzoną bieżnią wewnętrzną pojawiają się również częstotliwości uszkodzeniowe przesunięte o częstotliwość rotacyjną f_r [10.6, 10.12]. Z przedstawionego przykładu wynika, że na podstawie widma przyspieszenia drgań można jednoznacznie stwierdzić, który element łożyska jest uszkodzony.

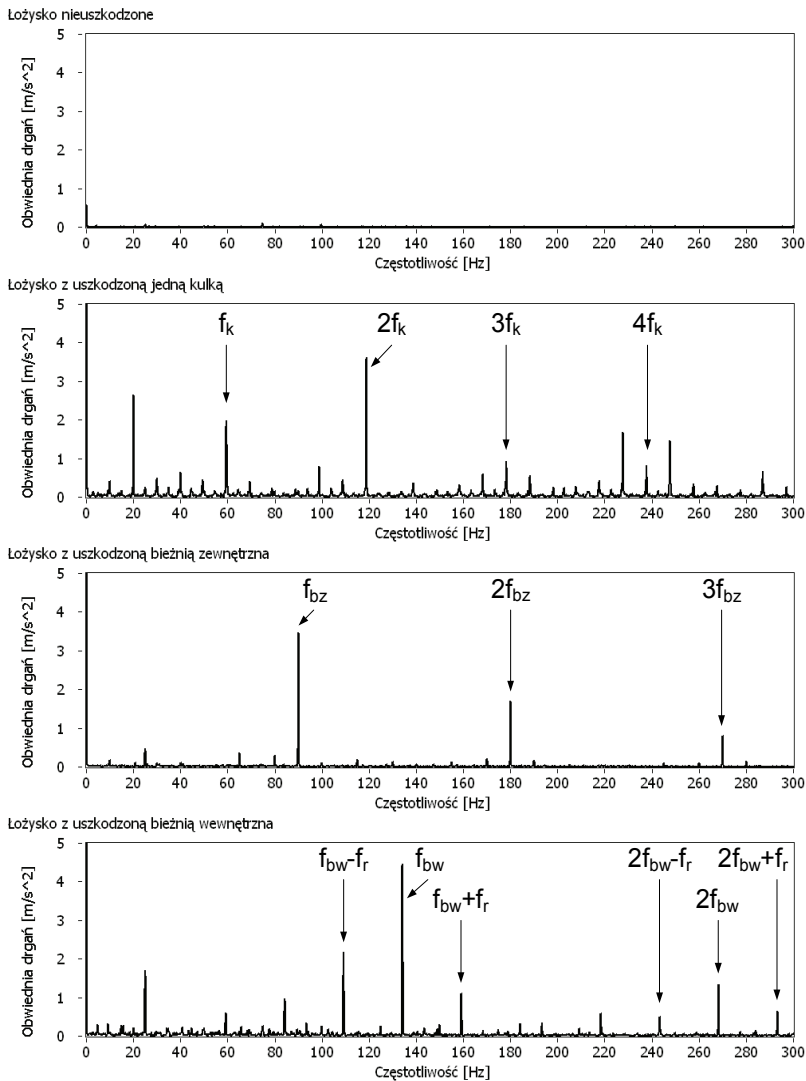


Rys. 10.4. Przykładowe teoretyczne widmo obwiedni drgań mechanicznych silnika z uszkodzonym łożyskiem tocznym



Rys. 10.5. Widma przyspieszenia drgań silnika pracującego bez obciążenia z różnymi typami uszkodzeń łożysk tocznych

Informacje uzyskane z analizy przyspieszenia drgań mogą więc posłużyć do wytrenowania sieci neuronowych. Do trenowania i testowania mogą być wykorzystane amplitudy wybranych charakterystycznych częstotliwości uszkodzeniowych. O wiele łatwiejsze jest jednak wyodrębnienie charakterystycznych częstotliwości na podstawie widma obwiedni sygnału przyspieszenia drgań. Na rysunku 10.6 przedstawione wyniki analizy obwiedni dla tych samych przypadków, które pokazano na rysunku 10.5 [10.6].



Rys. 10.6. Widma obwiedni przyspieszenia drgań silnika pracującego bez obciążenia z różnymi typami uszkodzeń łożyska tocznego

Przedstawione przykłady potwierdzają pogląd wielu autorów, że analiza widmowa obwiedni przyspieszenia drgań jest bardzo dobrą metodą detekcji uszkodzeń konstrukcyjnych łożysk tocznych. Pozyskiwanie charakterystycznych częstotliwości z widma obwiedni jest znacznie łatwiejsze i dokładniejsze niż z widma klasycznego. Informacje uzyskane na jej podstawie mogą być z lepszym skutkiem wykorzystane do uczenia sieci neuronowych.

Uszkodzenia elementów konstrukcyjnych łożyska, wywołujące drgania, powodują z kolei zmianę szczeliny powietrznej między wirnikiem i stojanem. W efekcie powstają dodatkowe harmoniczne pola, które modułują prąd fazowy silnika. Można więc oczekiwać, że symptomy uszkodzeń, w postaci charakterystycznych częstotliwości, będą widoczne w widmie prądu fazowego silnika:

$$f_u = |f_s + k \cdot f_l| \quad (10.5)$$

gdzie:


$$k = 1, 2, 3, \dots,$$

f_u – częstotliwość związana z uszkodzeniem konkretnego elementu łożyska,

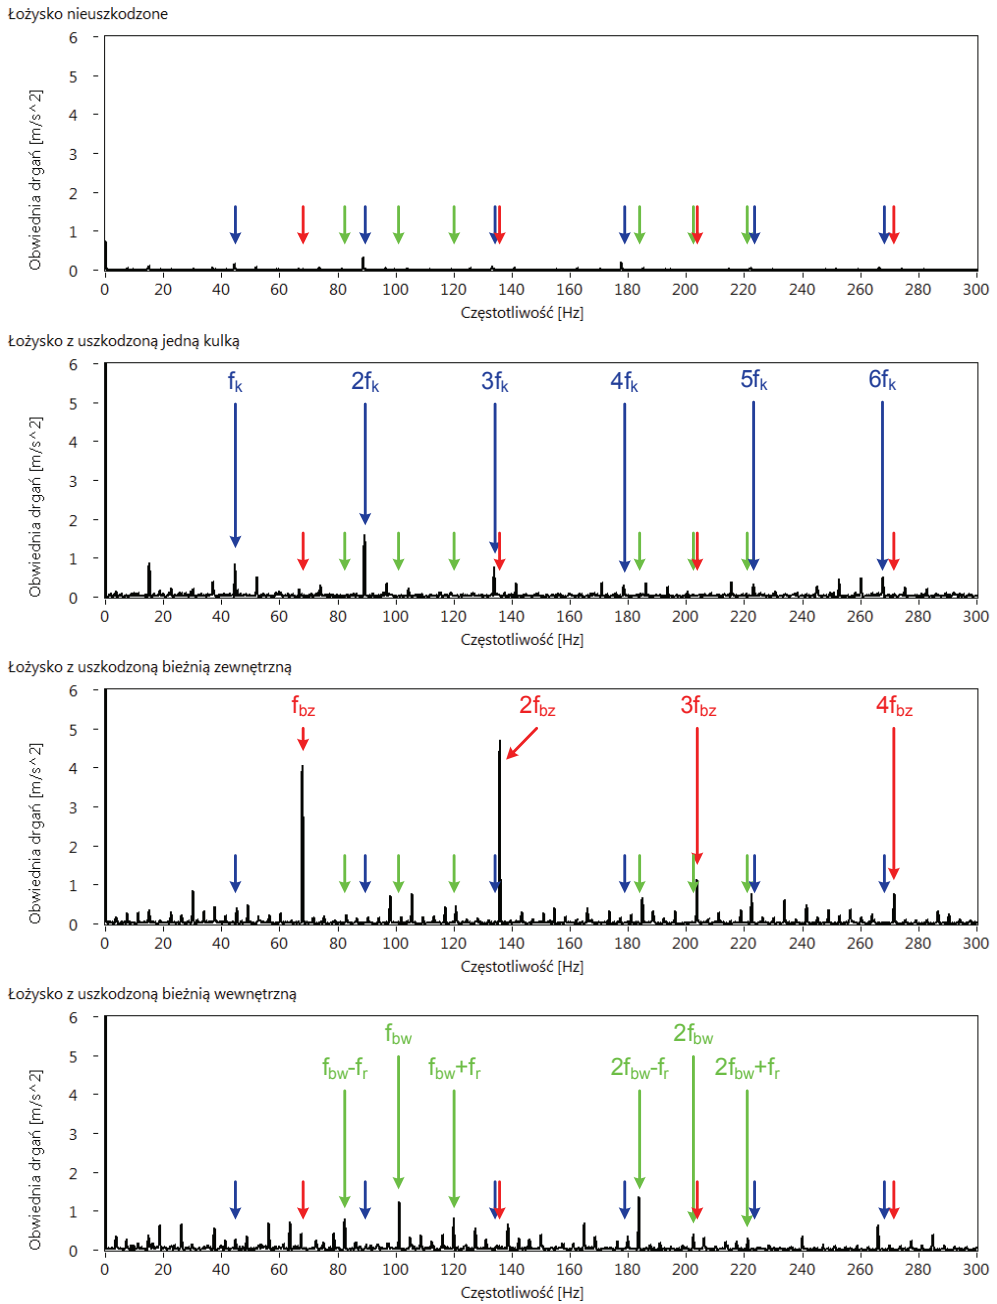
f_s – częstotliwość napięcia zasilającego,

f_l – częstotliwości charakterystyczne dla uszkodzenia elementu łożyska ($f_k, f_{bz}, f_{bw}, f_{lk}$) obliczone według zależności (10.1)–(10.4).

Na rysunku 10.7 przedstawiono widmo prądu stojana obliczone dla takich samych przypadków uszkodzeń jak powyżej. Pomimo dużej rozdzielczości widma oraz dużej dokładności pomiaru prądu fazowego stojana charakterystyczne częstotliwości osiągają w widmie bardzo małe amplitudy (dziesiąte części mA).



Rys. 10.7. Widmo prądu stojana silnika pracującego bez obciążenia z różnymi typami uszkodzeń łożyska tocznego



Rys. 10.8. Widmo obwiedni przyspieszenia drgań obciążonego silnika zasilanego napięciem o częstotliwości 40 Hz, z różnymi typami uszkodzeń łożysk tocznych

Próba diagnozowania łożysk za pomocą analizy FFT prądu stojana napotyka problemy pomiarowe wynikające z faktu, że składowe prądu silnika przekazujące informacje diagnostyczne są zbyt małe w porównaniu z dominującą składową sieciową. Aby ich uniknąć, niezbędne jest stosowanie filtrów środkowozaporowych do tłumienia składowej sieciowej oraz dużej klasy przetworników prądu [10.38, 10.39].

Jak wykazały badania w [10.11, 10.12, 10.26], zasilanie silnika indukcyjnego z przemiennika częstotliwości o regulowanej częstotliwości nie przekreśla możliwości zastosowania klasycznej analizy widmowej drgań oraz obwiedni przyspieszenia drgań do wykrywania uszkodzeń elementów konstrukcyjnych łożysk. Jednakże bardziej skuteczne jest zastosowanie analizy obwiedni, gdyż w znacznym stopniu ułatwione jest rozpoznanie rodzaju uszkodzonego elementu. Na rysunku 10.8 przedstawiono przykłady widma obwiedni dla silnika zasilanego napięciem o częstotliwości 40 Hz dla wszystkich rozpatrywanych przypadków uszkodzeń łożysk [10.12]. Informacje uzyskane z analizy obwiedni przyspieszenia drgań są w dalszej części monografii wykorzystane do projektowania neuronowego detektora.

Przedstawione przykłady widma sygnałów drganiowych wykazały, że można z nich uzyskać zdecydowanie więcej informacji diagnostycznej, w porównaniu do widma prądu stojana, przydatnej do wykrywania uszkodzeń elementów konstrukcyjnych łożysk tocznych. W przypadku zasilania z przekształtnika zdecydowanie korzystniej jest stosować analizę obwiedni drgań. Zakłócenia zewnętrzne, niestacjonarność mierzonych sygnałów oraz złożone interakcje różnych uszkodzeń powodują, że diagnozowanie na podstawie analizy widmowej wymaga dużego doświadczenia. Dlatego konieczne jest poszukiwanie nowych metod, które dostarczą bardziej obiektywnych informacji do klasyfikacji uszkodzeń. Zobiektywizowanie procesu diagnozowania, jak pokazane dalej, umożliwiają metody oparte na sztucznej inteligencji, a przede wszystkim na sztucznej sieci neuronowej.

10.2.2. Metody wykrywania uszkodzenia łożyska tocznego oparte na analizie falkowej

Jak to przedstawiono w rozdziale 4, transformata falkowa umożliwia skuteczniejsze wydobycie osobliwych krótkoczasowych cech analizowanych sygnałów. Niestacjonarny charakter sygnałów powoduje, że monitorowanie oparte na klasycznym przekształceniu FFT staje się w wielu przypadkach niewystarczające. Można wyróżnić kilka charakterystycznych sposobów wykorzystania transformaty falkowej w zagadnieniach monitorowania i diagnostyki maszyn.

Jednym z możliwych sposobów jest korzystanie ze współczynników falkowych do oceny stanu technicznego urządzenia [10.23, 10.24]. Można zastosować różne miary tych współczynników w poszczególnych pasmach częstotliwości sygnału. Może to być zarówno wartość średnia, odchylenie średniokwadratowe, jak i energia własna

współczynników falkowych. Jednak ten sposób ma pewne wady. Brak jest precyzyjnych wskazówek, jakie pasma należy analizować i zwykle dobiera się je eksperymentalnie. Kolejne utrudnienie polega na braku obiektywnego sposobu selekcji współczynników. Najczęściej uwzględnia się wszystkie współczynniki albo takie, które przekraczają pewną wartość progową.

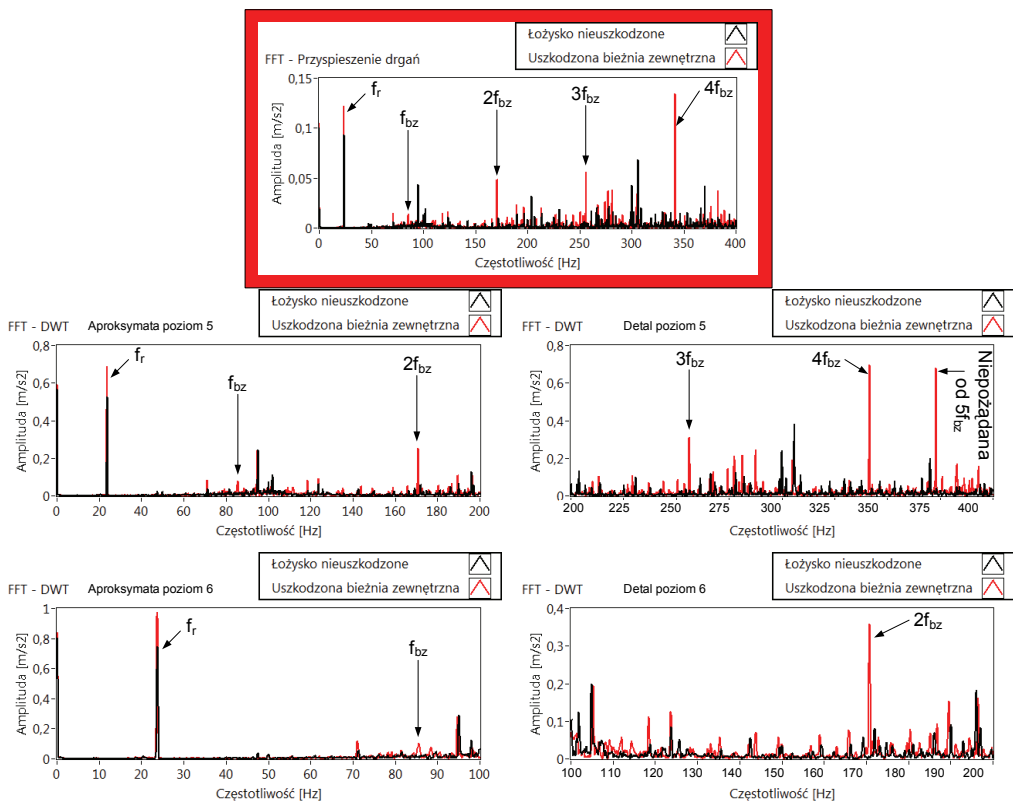
W odniesieniu do diagnostyki łożysk najczęściej proponuje się zastosowanie metody dekompozycji sygnału na poszczególne pasma częstotliwościowe i następnie analizowanie współczynników we wszystkich węzłach. Kierując się wartością średnią lub odchyleniem średniokwadratowym, można wybrać najbardziej interesujące pasmo częstotliwości sygnału diagnostycznego i następnie poddać go klasycznej analizie FFT. Zastosowanie transformaty falkowej ułatwia więc wskazanie pasma częstotliwości, w którym występują sygnały świadczące o uszkodzonych elementach łożysk. Można również zastosować podejście w pełni wykorzystujące analizę falkową i jako wskaźnik uszkodzenia przyjąć wzrost współczynników wysokiego pasma częstotliwości występujący wraz z postępującym uszkodzeniem [10.44, 10.45].

Innym podejściem opartym na transformacji falkowej i stosowanym do wykrywania uszkodzeń jest detekcja tzw. punktów szczególnych. W przypadku maszyn znajdujących się w ruchu, anomalie w sygnałach (np. piki), wskazujące na uszkodzenia, powtarzają się regularnie z częstotliwością zależną od prędkości obrotowej maszyny. Jednak ich amplituda jest zwykle dość mała, często porównywalna z amplitudą szumów występujących w układzie. Z użyciem transformaty falkowej możliwe jest wydobycie informacji o lokalnych anomaliach wskazujących na postępujące uszkodzenia. W pracy [10.37] przedstawiono zastosowanie analizy falkowej do wykrywania punktów szczególnych w sygnale drganiowym łożysk. Autorzy z powodzeniem rozpoznają różne rodzaje uszkodzeń łożysk. Zaproponowana metoda jest odporna na zmienne warunki pracy łożyska, takie jak obciążenie, prędkość itp.

Dalej przedstawiono przykład zastosowania transformaty falkowej do wykrywania uszkodzeń łożysk tocznych [10.12, 10.14, 10.15, 10.22]. Analizie falkowej poddano sygnał przyspieszenia drgań zmierzony na silniku indukcyjnym Sh90L-4. Drgania mierzono przez 10 s z częstotliwością 12 kS/s. Umożliwiło to analizę sygnału w pasmie 0–6400 Hz. Wybór poziomu dekompozycji podyktowany był chęcią wyodrębnienia charakterystycznych częstotliwości uszkodzeniowych łożyska. W przypadku dyskretnego przekształcenia falkowego DWT, analizę wykonano na 5 i 6 poziomie dekompozycji. Uzyskana szerokość pasma aproksymaty i detalu na 6 poziomie dekompozycji wynosiła 100 Hz, natomiast na 5 poziomie 200 Hz. Umożliwiło to pokazanie częstotliwości uszkodzeniowych w pasmie do 400 Hz [10.12, 10.15].

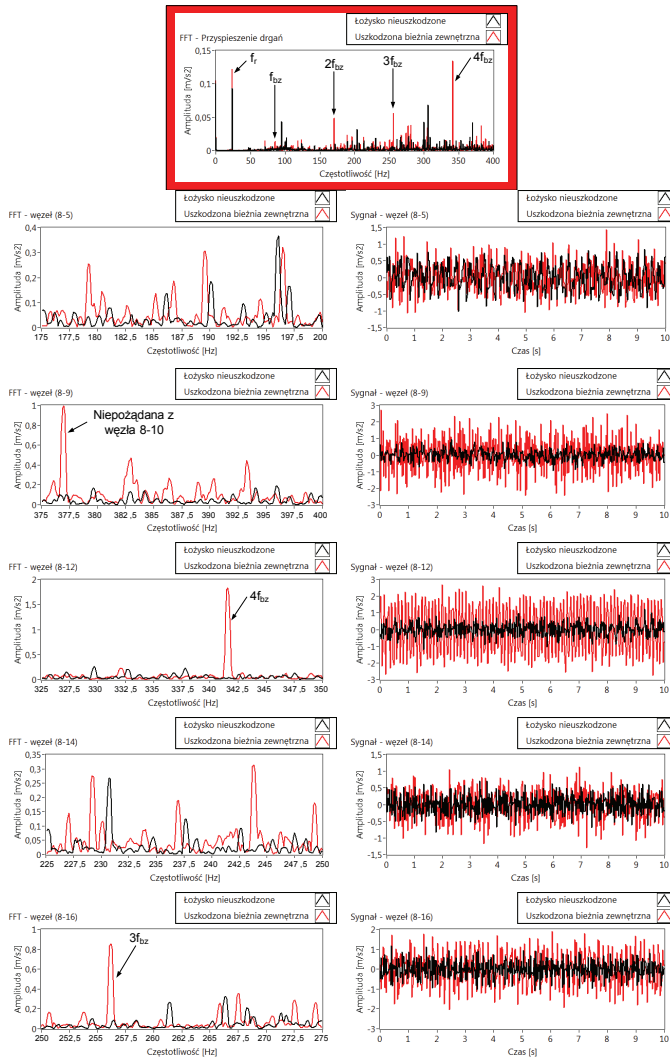
Na rysunku 10.9 przedstawiono przykładowy wynik uzyskany z dyskretnego przekształcenia falkowego przyspieszenia drgań silnika pracującego pod obciążeniem znamionowym z uszkodzeniem bieżni zewnętrznej łożyska. Zestawiono widma FFT aproksymaty oraz detalu z 5 oraz 6 poziomu dekompozycji. Dodatkowo, dla porównania, w ramce przedstawiono analizę FFT przyspieszenia drgań silnika z dobrym

oraz uszkodzonym łożyskiem. Strzałkami zaznaczono charakterystyczne częstotliwości uszkodzeniowe. Porównując widmo z przekształcenia falkowego z widmem przyspieszenia drgań, można zauważyć, że charakterystyczne częstotliwości uszkodzeniowe mają dużo większą amplitudę w przekształceniu falkowym. W przypadku silnika pracującego z łożyskiem z uszkodzoną bieżnią zewnętrzną, można zauważyć, że dodatkowo, oprócz składowych podstawowych kf_{bz} , widoczna jest również niepożądana częstotliwość od składowej $5f_{bz}$. Pojawianie się w analizie falkowej niepożądanych częstotliwości wynika z nakładania się na siebie pasm zastosowanych filtrów [10.44, 10.46]. Zastosowane cyfrowe filtry nie są idealne, w związku z czym mają pewne nachylenie charakterystyki w pasmie zaporowym, zależne od rzędu filtru. Niepożądane częstotliwości pojawiają się w momencie, gdy częstotliwość o bardzo dużej amplitudzie występuje w pobliżu granicy sąsiedniego przedziału częstotliwości (aprosymaty lub detalu).



Rys. 10.9. Przykładowe widmo FFT przyspieszenia drgań (ramka) i dyskretnego przekształcenia falkowego z 5. i 6. poziomu dekompozycji dla łożyska nieuszkodzonego oraz z uszkodzoną bieżnią zewnętrzną

W przypadku pełnego przekształcenia falkowego analizę zrealizowano do 8 poziomu dekompozycji. Ponieważ przyspieszenie drgań zostało zmierzone w pasmie 0–6400 Hz, to na 8. poziomie uzyskano pasmo 25 Hz. Tak wąskie pasmo istotnie ułatwia wyodrębnienie charakterystycznych częstotliwości uszkodzeniowych [10.12, 10.15].



Rys. 10.10. Widma FFT przyspieszenia drgań (ramka) i pełnego dyskretnego przekształcenia falkowego oraz przebiegi czasowe w wybranych węzłach z 8. poziomu dla łożyska nieuszkodzonego i z uszkodzoną bieżnią zewnętrzną

Szczegółowa analiza sygnałów w węzłach z 8. poziomu pozwoliła wybrać te, w których najlepiej były odzwierciedlone efekty uszkodzonej bieżni zewnętrznej łożyska

(rys. 10.10). Podobnie jak dla dyskretnego przekształcenia falkowego w ramce przedstawiono klasyczną analizę FFT przyspieszenia drgań oraz strzałkami zaznaczono charakterystyczne częstotliwości uszkodzeniowe. Dodatkowo umieszczono przebiegi czasowe sygnałów w wybranych węzłach. Pozwoliło to pokazać wpływ uszkodzenia łożyska na przebieg przyspieszenia drgań w danym węźle. W przypadku pełnego przekształcenia falkowego, amplitudy charakterystycznych częstotliwości są również kilkakrotnie większe od tych uzyskanych w klasycznej analizie FFT przyspieszenia drgań. W wybranych węzłach możliwe jest odnalezienie charakterystycznych częstotliwości uszkodzeniowych, świadczących o uszkodzeniu elementu konstrukcyjnego łożyska. Podobnie jak w przypadku DWT występują niepożądane częstotliwości z sąsiednich węzłów.

Wartość skuteczna sygnałów w wybranych do analizy węzłach, zmienia swoją wartość w tak dużym stopniu, że można ją przyjąć za charakterystyczną dla uszkodzenia cechę i wykorzystać do trenowania i testowania sieci neuronowych [10.12].

Na podstawie przedstawionego przykładu można stwierdzić, że informacja uzyskiwana z analizy falkowej może być bezpośrednio wykorzystywana do monitorowania charakterystycznych częstotliwości w aproksymatach i detalach lub pośrednio przez energie lub wartości skuteczne w wybranych węzłach dekompozycji.

10.3. Wykrywanie nieosiowości napędu z silnikiem indukcyjnym


Na prawidłową i długotrwałą pracę napędu elektrycznego bardzo duży wpływ ma jego prawidłowe wyosiowanie. Ponad 50% przedwczesnych uszkodzeń maszyn jest spowodowane złym wyosiowaniem napędu [10.39]. Awaryjne spowodowane brakiem współosiowości wałów powodują, oprócz nieplanowanych przestojów i związanych z tym strat produkcyjnych, znaczny wzrost zużycia energii oraz przedwczesne uszkodzenia łożysk oraz uszczelek, wyciek oleju z oprawy łożysk, przytarcie wałów o uszczelnienia, pęknięcie wału i awaryjne sprzęgła, wzrost mimośrodowości wirników. Niewspółosiowość elementów maszyn może wynikać z niewłaściwego ustawienia maszyny, błędów konstrukcyjnych, nieprawidłowej obróbki mechanicznej elementów, odkształceń cieplnych, pęknięć, osiadania fundamentów itp. Pojawia się także w trakcie eksploatacji, podczas której maszyna ulega zużyciu, fundamenty osiadają, deformują się lub poluzowują elementy napędu. Wyróżnia się trzy podstawowe rodzaje nieosiowości: przesunięcie poprzeczne (równoległe), kątowe oraz połączenia obu tych odchyleń (kątowo-równoległe bądź mieszane). Niewspółosiowość równoległa to odległość między środkami obrotu wałów, mierzona najczęściej w środku sprzęgła. Niewspółosiowość kątowa wynika z nachylenia jednego wału, zwykle maszyny ruchomej, w stosunku do wału drugiej maszyny, najczęściej stacjonarnej. Przesunięcie kątowe występuje wówczas, gdy osie wału napędzającego i napędzanego się przecinają.

Monitorowanie nieosiowości polega na ocenie amplitud charakterystycznych częstotliwości w widmie drgań lub prądu stojana. W tabeli 10.1 zestawiono charakterystyczne częstotliwości świadczące o niewyosiowaniu napędu, występujące w widmie prądu stojana oraz drgań mechanicznych. Widmo drgań charakteryzuje się wzrostem wartości amplitud składowych o częstotliwościach równych pierwszej i drugiej wielokrotności częstotliwości obrotowej wirnika. Według [10.1, 10.39], jeżeli amplituda $2f_r$ w kierunku osiowym przekracza 75% amplitudy $1f_r$ w kierunku promieniowym, to taki stan grozi awarią napędu.


Tabela 10.1. Zestawienie częstotliwości charakterystycznych dla nieosiowości

Rodzaj uszkodzenia	Charakterystyczna częstotliwość w widmie prądu stojana	Charakterystyczna częstotliwość w widmie drgań	Uwagi
Nieosiowość równoległa lub kątowa	$f_s \pm kf_r$	głównie: $1f_r$ i $2f_r$ czasami: $3f_r$ i $4f_r$	Maksymalne drgania w kierunku osiowym Czasami wszystkie harmoniczne f_r
f_s – częstotliwość napięcia zasilającego f_r – częstotliwość obrotowa silnika			


a)




b)



c)



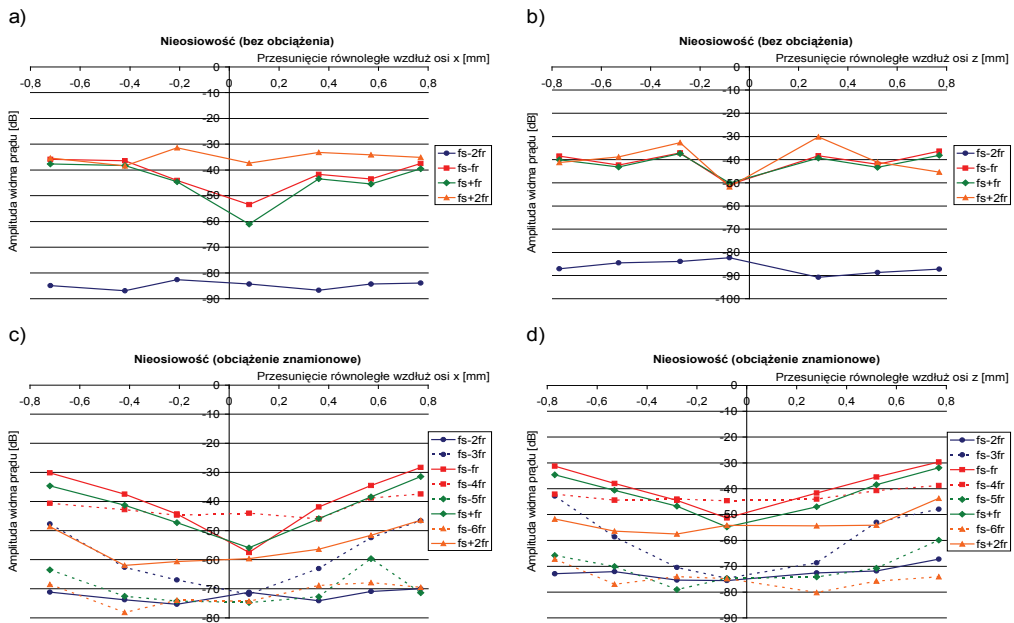
d)



Rys. 10.11. Widmo prądu stojana i drgań mechanicznych:
a), c) układ wyosiowany ; b), d) poziome przesunięcie równoległe o 0,77 mm

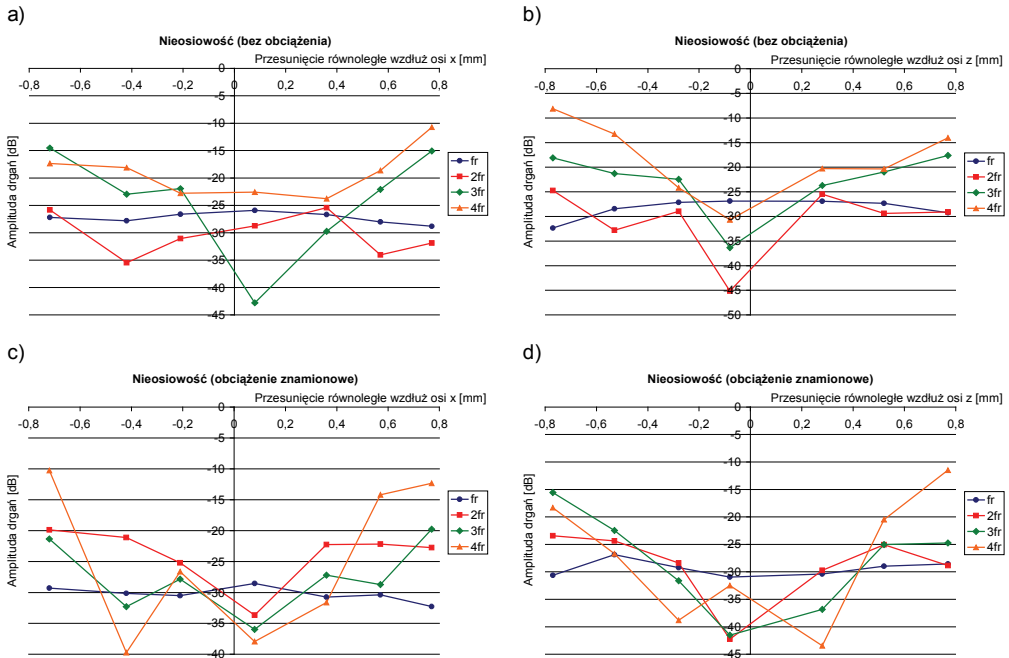
Na rysunku 10.11 przedstawiono przykładowe widmo prądu stojana i drgań mechanicznych dla układu prawidłowo wyosiowanego oraz z poziomym przesunięciem równoległym równym 0,77 mm. Porównując widmo prądu stojana układu wyosiowanego (rys. 10.11a) z widmem z poziomym przesunięciem równoległym (rys. 10.11b), można zauważyć wyraźny wzrost składowych $f_s - 3f_r$, $f_s - f_r$, $f_s + f_r$ oraz $f_s + 2f_r$. W przypadku widma drgań mechanicznych (rys. 10.11c i d) obserwuje się wzrost harmonicznymi o częstotliwościach $2f_r$, $3f_r$ oraz $4f_r$ [10,5, 10,26].

Na rysunkach 10.12 i 10.13 przedstawiono zbiorcze zestawienia ilustrujące zmianę amplitudy charakterystycznych częstotliwości w widmie prądu stojana oraz drgań mechanicznych w zależności od wartości niewyosiowania. Dla silnika pracującego bez obciążenia (rys. 10.12a i b) najlepiej zmianę tę obrazują składowe $f_s - f_r$ i $f_s + f_r$. Włączenie obciążenia powoduje zmianę prędkości obrotowej silnika, a co za tym zmianę składowej f_r – stąd większa liczba analizowanych harmonicznymi $f_s \pm kf_r$ (rys. 10.12c i d). W przypadku pracy pod obciążeniem, największe zmiany charakterystycznych składowych można zaobserwować dla $k = -3, -1$ oraz $+1$. Na podstawie oceny amplitudy tych częstotliwości w widmie prądu możliwe jest wykrycie zarówno poziomego, jak i pionowego przesunięcia równoległego.



Rys. 10.12. Zależność amplitudy harmonicznymi $f_s \pm kf_r$ w widmie prądu stojana od wielkości niewyosiowania: poziome (a) i pionowe (b) przesunięcie równoległe (bieg jałowy), poziome (c) i pionowe (d) przesunięcie równoległe (obciążenie znamionowe)

Wpływ wielkości niewyosiowania na widmo drgań mechanicznych przedstawiono na rys. 10.13. Pomiaru drgań dokonano w kierunku promieniowym. W przypadku silnika pracującego na biegu jałowym do wykrywania poziomego przesunięcia równoległego najlepiej nadaje się składowa $3f_r$ (rys. 10.13a), natomiast podczas pracy pod obciążeniem znamionowym do monitorowania można wykorzystać również składową $2f_r$ (rys. 10.13c). Zmiany pionowego przesunięcia równoległego są dobrze odwzorowane w zmianach amplitud harmonicznych 2, 3 i $4f_r$ w przypadku silnika nieobciążonego (rys. 10.13b) oraz 2 i $3f_r$ dla silnika obciążonego znamionowo (rys. 10.13d).



Rys. 10.13. Zależność amplitudy harmonicznych kf_r w widmie drgań mechanicznych od wielkości niewyosiowania: poziome (a) i pionowe (b) przesunięcie równoległe (bieg jałowy), poziome (c) i pionowe (d) przesunięcie równoległe (obciążenie znamionowe)

Z przedstawionych przykładów wynika, że klasyczna analiza widmowa drgań i prądu jest dobrą metodą wykrywania niesiowości układów napędowych z silnikami indukcyjnymi zasilanymi z przekształtnika. Warunkiem koniecznym do prawidłowej oceny poziomu niesiowości jest zapewnienie odpowiednio dużej dokładności i rozdzielczości aparatury pomiarowo-przetwarzającej.

Na podstawie przeprowadzonych pomiarów można stwierdzić, że wartość przesunięcia równoległego układu napędowego ma największy wpływ na zmianę amplitudy składowych widma prądu stojana dla $f_s \pm f_r$ oraz $f_s - 3f_r$, natomiast w przypadku przy-

spieszenia drgań na składowe $2f_r$, $3f_r$ i $4f_r$. W badaniach przedstawiono wyniki uzyskane dla pomiaru przyspieszenia drgań w kierunku promieniowym, jednak pozostałe kierunki również mogą posłużyć jako źródło informacji o poziomie niewyosiowania układu napędowego.

Nieinwazyjność oraz łatwość pomiaru prądu stojana oraz drgań mechanicznych przemawia za wykorzystaniem tych sygnałów do monitorowania nieosiowości napędów elektrycznych z silnikami indukcyjnymi. Jednoczesna analiza widma prądu stojana i drgań mechanicznych pozytywnie wpływa na skuteczność wykrywania nieosiowości.

10.4. Monitorowanie ekscentryczności maszyny


Ekscentryczność szczeliny powietrznej może być uszkodzeniem pierwotnym lub wtórnym. Uszkodzenie pierwotne jest wówczas, gdy od początku eksploatacji silnik ma znaczącą niesymetrię, np. niekołowy otwór stojana bądź przekrój poprzeczny wirnika. Uszkodzenie wtórne jest wówczas, gdy na skutek długotrwałej eksploatacji w warunkach np. niewyosiowania napędu, zużycia łożysk, wystąpi niesymetria szczeliny powietrznej.

Diagnozowanie ekscentryczności na podstawie widma prądu polega na odczytaniu charakterystycznego wzorca (określonego na podstawie modelu matematycznego silnika dla stanu ustalonego) lub częstotliwości charakterystycznych dla danego typu uszkodzenia w widmie. Ze względu na złożoność zjawiska ekscentryczności niezbędne jest analizowanie widma w szerokim pasmie częstotliwości, a nie tylko wokół podstawowej częstotliwości zasilania.

Rozróżnia się ekscentryczność statyczną, dynamiczną oraz mieszaną (jednoczesne występowanie obu rodzajów ekscentryczności) [10.23]. Na rysunku 10.14 przedstawiono interpretację graficzną wyjaśniającą poszczególne rodzaje ekscentryczności, przy czym w przypadku ekscentryczności statycznej C1 jest osią wirowania, w ekscentryczności dynamicznej C2 jest osią wirowania, natomiast w przypadku ekscentryczności mieszanej oś wirowania znajduje się gdzieś między C1 i C2. W przypadku ekscentryczności statycznej położenie minimalnego stacjonarnego promienia szczeliny powietrznej jest stałe w przestrzeni. Może być ona spowodowana przez owalność rdzenia stojana, znaczne zużycie łożysk lub nieprawidłowe ustawienie wirnika względem stojana w trakcie montażu. Jeżeli układ mechaniczny wirnik–wał jest wystarczająco sztywny, to poziom ekscentryczności statycznej nie ulega zmianie.

W trakcie eksploatacji silnika ze znacznie zużytymi łożyskami, powstające nierównoważone siły naciągu magnetycznego powodują powstawanie drgań mechanicznych (składowa promieniowa siły) oraz pogłębianie się luzów w łożyskach (składowa styczna siły) i w efekcie tzw. „wyrobienie” się łożyska. Znaczny luz łożysk

powoduje z kolei powstawanie drgań promieniowych i staje się źródłem ekscentryczności dynamicznej. Ekscentryczność statyczna może być pierwotną przyczyną powstania ekscentryczności dynamicznej. Bardzo często oba te zjawiska mogą się na siebie nakładać. W literaturze, między innymi w [10.2, 10.4, 10.35, 10.36], można się spotkać z różnym definiowaniem ekscentryczności dynamicznej. Między innymi różni się jeszcze pojęcie ekscentryczności dynamicznej czystej w odróżnieniu od zwykłej dynamicznej. Z punktu widzenia użytkownika maszyny zwykle wystarczające jest pojęcie ekscentryczności dynamicznej, ale uniemożliwia ono ocenę rozwoju uszkodzenia i określenie jego przyczyny. Taką możliwość daje dopiero wprowadzenie ekscentryczności dynamicznej czystej [10.35, 10.36].



Rys. 10.14. Współosiowe i ekscentryczne usytuowanie wirnika w otworze stojana [10.23]

W przypadku ekscentryczności dynamicznej oś wirnika nie jest osią obrotu wirnika (rys. 10.14). To przesunięcie może być spowodowane przez różne czynniki, takie jak: niewyosiowanie wirnika i napędu, powodujące ugięcie wału (przez siły promieniowe), zużycie łożysk lub powstawanie rezonansów mechanicznych przy krytycznych prędkościach obrotowych. Występowanie ekscentryczności dynamicznej powoduje przedwczesne zużycie łożyska, grzanie się łożyska i niekontrolowany ubytek smarowania i w końcu przy dużym jej poziomie, tarcie wirnika o stojan, co w rezultacie może doprowadzić do zniszczenia maszyny. Powstające drgania mechaniczne o częstotliwościach rzędu kHz powodują mechaniczne niszczenie izolacji w stojanie.

Występowanie ekscentryczności często nie wyklucza maszyny z dalszej eksploatacji, ale jej występowanie powinno być wykryte i kontrolowane, ponieważ zwykle ma ona tendencję do pogłębiania się. W efekcie nieuchronnie prowadzi do uszkodzenia maszyny. Bezpośredni związek z występowaniem ekscentryczności ma stan techniczny łożyska w maszynie elektrycznej. Również występowanie uszkodzeń o naturze elektrycznej (uszkodzenie prętów wirnika, niejednorodne pole elektromagnetyczne wirnika i stojana) powodują zwiększone zmienne obciążenie łożyska i ich przedwczesne uszkodzenia. Dlatego tak duże znaczenie praktyczne ma wczesne wykrycie i zlokalizowanie tych uszkodzeń. Istnieje wówczas czas na spokojne do-

konanie naprawy przez wyważenie, wyosiowanie, smarowanie czy w ostateczności ich wymianę.

W nowych silnikach dopuszczalna jest 10% ekscentryczność szczeliny powietrznej [10.28, 10.41]. Mimo to, producenci zwykle starają się zapewnić niższy całkowity poziom ekscentryczności, aby zredukować drgania i hałas oraz zmniejszyć niesymetryczną siłę promieniową.

Ekscentryczne usytuowanie wirnika silnika indukcyjnego względem stojana wprowadza asymetrię szczeliny powietrznej i w wyniku charakterystycznych zmian we wzajemnych sprzężeniach magnetycznych między uzwojeniami silnika wpływa na postać widma prądów stojana. Dlatego też metoda analizy spektralnej prądu stojana (MCSA) jest podstawowym narzędziem diagnostycznym stosowanym w praktyce badawczej i przemysłowej do kontroli ekscentryczności [10.3, 10.17, 10.32, 10.36].

Każdemu rodzajowi ekscentryczności można przypisać charakterystyczne częstotliwości zawarte w widmie prądu stojana. Najbardziej ogólna zależność określająca obecność częstotliwości charakterystycznych dla ekscentryczności oraz uźłobkowania wirnika, ma postać:

$$f_e = f_s \left[(kN_r \pm n_d) \frac{1-s}{p_b} \pm n_w \right] \quad (10.6)$$

gdzie:

$k = 1, 2, 3, \dots,$

N_r – liczba żłobków wirnika,

$n_d = 0$ ekscentryczność statyczna,

$n_d = 1, 2, 3$ – rząd ekscentryczności dynamicznej (główne harmoniczne żłobkowe),

$n_w = \pm 1, \pm 3, \pm 5, \pm 7 \dots$ – rząd harmonicznych czasowych stojana,

p_b – liczba par biegunów.

Zależność (10.6) umożliwia określenie w prądzie stojana częstotliwości związane z ekscentrycznością statyczną, dynamiczną oraz tzw. *główne harmoniczne żłobkowe*. Główne harmoniczne żłobkowe (ang. *Principal Slot Harmonics PSH*) w zdrowym silniku mogą być wykorzystywane do estymacji prędkości kątowej w napędach przekształtnikowych typu „sensorless” [10.42].

W zależności (10.6) występują trzy grupy harmonicznych:

- k -harmonicznych związanych z wirnikiem,
- n_w harmonicznych związanych ze stojanem,
- n_d harmonicznych związanych z ekscentrycznością.

Dla ekscentryczności statycznej charakterystyczne są częstotliwości określone zależnością:

$$f_{es} = f_s \left[k \frac{N_r}{p_b} (1-s) \pm 1 \right] \quad (10.7)$$

lub w postaci:

$$f_{es} = |kN_r f_r \pm f_s| \quad (10.8)$$

gdzie:

$$k = 0, \pm 1, \pm 2, \dots,$$

$$f_r = f_s \frac{1-s}{p_b} - \text{częstotliwość obrotowa.}$$

W zależności od relacji między N_r i p_b pewne częstotliwości wystąpią również przy pełnej symetrii silnika [10.3, 10.4, 10.28]. Są to wspomniane główne harmoniczne żłobkowe. Wystąpienie wszelkich innych częstotliwości w widmie prądu stojana jest symptomem wystąpienia ekscentryczności.

Jak wykazano w [10.28], tylko szczególne kombinacje liczby par biegunów i liczby żłobków wirnika będą powodowały istotny wzrost harmonicznych charakterystycznych dla ekscentryczności statycznej lub dynamicznej.

Jeżeli spełniony jest warunek:

$$N_r = 2p_b[3(m \pm q) \pm r] \quad (10.9)$$

gdzie: $m \pm q = 0, 1, 2, 3, \dots$ $r = 0$ lub 1 ,

to w widmie widoczne będą zmiany głównych harmonicznych żłobkowych oraz składowe związane z ekscentrycznością mieszaną. Natomiast brak będzie widocznych zmian składowych związanych z ekscentrycznością statyczną lub dynamiczną.

W przypadku gdy:

$$N_r = 2p_b[3(m \pm q) \pm r] \pm k \quad (10.10)$$

gdzie: $m \pm q = 0, 1, 2, 3, \dots$ $r = 0$ lub 1 , $k = 1$ lub 2 ,

to w widmie będą widoczne tylko harmoniczne związane z ekscentrycznością statyczną lub tylko z ekscentrycznością dynamiczną, jak również składowe związane z ekscentrycznością mieszaną. Natomiast nie będą występowały główne harmoniczne żłobkowe.

W przypadku ekscentryczności statycznej prąd stojana jest niesymetryczny. Dlatego z diagnostycznych względów ma znaczenie czy w zasilaniu stojana występuje przewód zerowy, gdyż w razie jego braku wystąpi tylko jedna harmoniczna żłobkowa dla stanu symetrii.

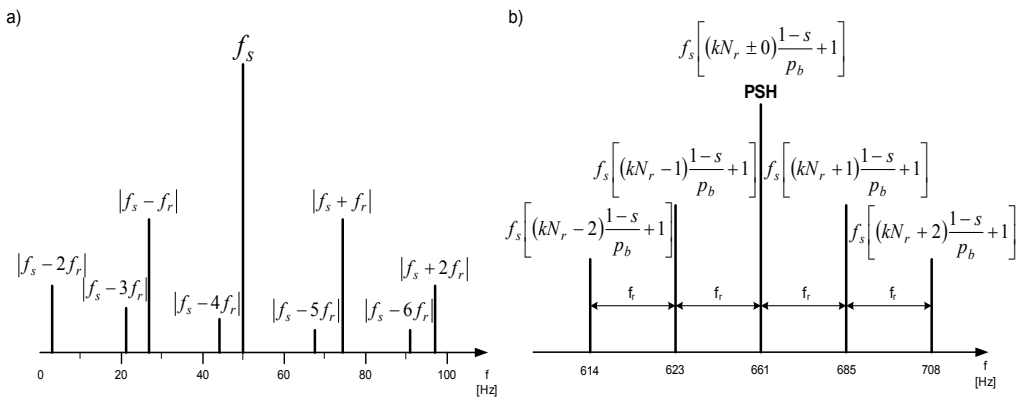
W przypadku wystąpienia ekscentryczności dynamicznej prąd stojana jest symetryczny, a w przypadku braku przewodu zerowego w zasilaniu, ograniczony jest zakres częstotliwości występujących w widmie prądu stojana.

Jeżeli występuje jednocześnie ekscentryczność dynamiczna i statyczna, to wiąże się to z obecnością harmonicznych o częstotliwościach położonych w pobliżu częstotliwości sieciowej:

$$f_{em} = |f_s \pm k f_r| \quad (10.11)$$

Częstotliwości te występują we wszystkich maszynach. Niskoczęstotliwościowe składowe powodują wzrost składowych wysokoczęstotliwościowych opisanych zależnością (10.6). Jednakże składowe wysokoczęstotliwościowe silnie zależą od rozwiązania konstrukcyjnego maszyny (patrz zależności (10.9), (1.10)).

Na rysunku 10.14 przedstawiono przykładowy obraz harmonicznym w prądzie stojana charakteryzujących ekscentryczność mieszaną w pasmie niskich i wysokich częstotliwości [10.23]. W przypadkach gdy jednocześnie występuje uszkodzenie klatki wirnika i ekscentryczność, następuje interakcja efektów tych uszkodzeń z wahaniami prędkości obrotowej, spowodowanymi zmiennym momentem elektromagnetycznym o częstotliwości $2sf_s$. Ponieważ system diagnostyczny dokonuje analizy na podstawie uśrednionej prędkości obrotowej, dlatego bardzo istotna jest duża dokładność wyznaczania prędkości obrotowej. Do tego celu najkorzystniej jest wykorzystywać harmoniczne żłobkowe.



Rys. 10.14. Przykładowy rozkład częstotliwości w widmie prądu o ekscentryczności mieszanej ($p_b = 2$, $N_r = 51$, $s = 0,037$): a) pasmo niskich częstotliwości; b) pasmo wysokich częstotliwości

Ekscentryczność wirnika maszyny elektrycznej powoduje jej drgania w kierunku promieniowym o stacjonarnej amplitudzie. Zgięcie lub poluzowanie wirnika spowodowane naprężeniami termicznymi mogą zmieniać amplitudę i fazę drgań w czasie. W widmie drgań pojawiają się wstęgi boczne w odległości równej dwukrotnej częstotliwości poślizgu wokół składowych f_s i $2f_s$. W wyniku niesymetrii szczeliny powietrznej w widmie drgań pojawiają się harmoniczne żłobkowe. Ponadto w obwiedni sygnału drganiowego, oprócz wymienionych, mogą wystąpić również składowe: obrotowa f_r i $2f_s$ jako efekt modulacji tymi składowymi pozostałymi składowymi sygnału drganiowego węzłów łożyskowych [10.38].

Realizacja ekscentryczności w warunkach laboratoryjnych sprawia wiele trudności i jest wykonywana bardzo rzadko. Obecnie najczęściej do analizy zjawiska ekscentryczności stosuje się modele matematyczne i symulację komputerowej. Dzięki nim

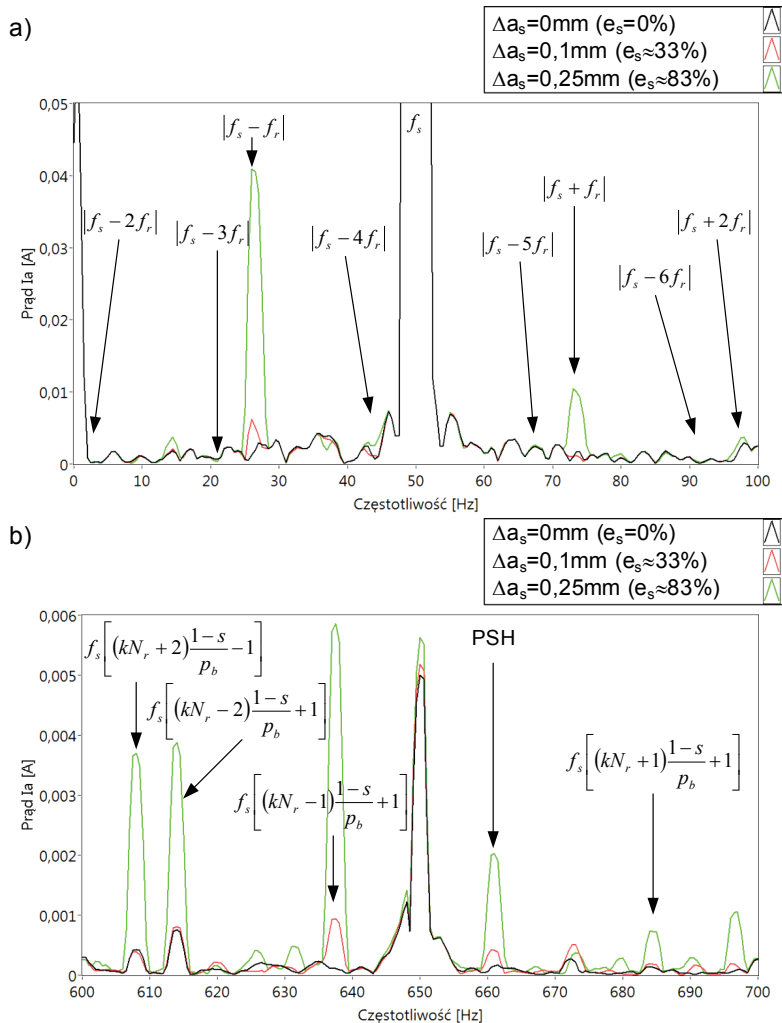
możliwe staje się generowanie różnych wzorców diagnostycznych, niemożliwych lub bardzo trudnych do zrealizowania na obiekcie rzeczywistym. Na podstawie tych wzorców możliwa jest interpretacja zjawiska na obiekcie rzeczywistym, np. przez porównanie widma prądu stojana (lub drgań) uzyskanych z modelu i obiektu rzeczywistego, a w konsekwencji identyfikację typu i określenie stopnia ekscentryczności obiektu rzeczywistego.

Ekscentryczność można badać za pomocą bardzo zaawansowanych modeli obwodowych silnika z rozłożonymi uzwojeniami i ekscentrycznością wirnika reprezentowanych przez indukcyjność uzwojeń. W modelowaniu tego typu stosuje się tzw. metodę bilansu harmonicznego [10.19, 10.32, 10.35, 10.36]. W ostatnich latach coraz częściej stosuje się podejście oparte na modelowaniu połowym lub połowo-obwodowym [10.7, 10.8, 10.12, 10.17], które dzięki nowym środowiskom programistycznym stały się bardzo dobrym i dokładnym narzędziem do analizy zjawiska ekscentryczności

W niniejszej monografii analizę zjawiska związanego z ekscentrycznością przeprowadzono za pomocą modelu połowo-obwodowego (rozdział 5.4) [10.12]. Model połowo-obwodowy silnika SH 90L-4 o parametrach znamionowych przedstawionych w załączniku 1, wykonano korzystając z komercyjnego programu Maxwell 2D (moduł *transient*) [10.7, 10.8, 10.12]. Geometrię części połowej wraz z fragmentem siatki dyskretyzacyjnej przedstawiono na rysunku 5.8. W części połowej uwzględniono czasową zmienność prądu, nieliniowość magnetowodu oraz ruch wirnika o wymuszonej prędkości obrotowej. Część połowa jest odwzorowana w części obwodowej (rys. 5.8) w postaci siły elektromotorycznej (SEM) indukowanej w uzwojeniu stojana oraz litych prętów klatki wirnika. Ze względu na zastosowanie modelu dwuwymiarowego w części obwodowej znajdują się parametry połączeń czołowych uzwojenia stojana (L_{cz}) oraz pierścienia zwierającego klatki wirnika (R_p, L_p), które wyznaczono z zależności konstrukcyjnych.

W części połowej ekscentryczność statyczna była modelowana przez przesuwanie stojana wzdłuż osi x ($\Delta a_s = 0 \div 0,25$ mm), a ekscentryczność dynamiczna przez przesuwanie wirnika wzdłuż osi x ($\Delta a_d = 0 \div 0,25$ mm). Ekscentryczność mieszana była modelowana przez jednoczesne przesuwanie stojana ($\Delta a_s = 0 \div 0,14$ mm) i wirnika ($\Delta a_d = 0 \div 0,14$ mm). W każdym przypadku środek obrotu pozostawał w środku nieruchomego układu współrzędnych x - y . Takie podejście do problemu ekscentryczności umożliwiło wykonanie badań symulacyjnych silnika bez ekscentryczności oraz z pięcioma różnymi poziomami ekscentryczności statycznej ($e_s \approx 17 \div 83\%$) i dynamicznej ($e_d \approx 17 \div 83\%$) oraz ośmioma różnymi poziomami ekscentryczności mieszanej ($e_s \approx 17 \div 47\%$ i $e_d \approx 17 \div 47\%$). Nie symulowano ekscentryczności mieszanej dla $e_s \approx 47\%$ i $e_d \approx 47\%$, ponieważ występowała możliwość tarcia wirnika o stojan, o której informował program Maxwella [10.12]. Przyjęto krok obliczeń równy 0,2 ms. Umożliwiło to analizowanie widma FFT prądu stojana w pasmie do 2,5 kHz. Symulacje wykonano dla napięcia idealnie sinusoidalnego oraz napięcia rzeczywistego zmierzonego na obiekcie rzeczywistym, aby modelowane prądy były jak najbardziej zbliżone do rzeczywistych.

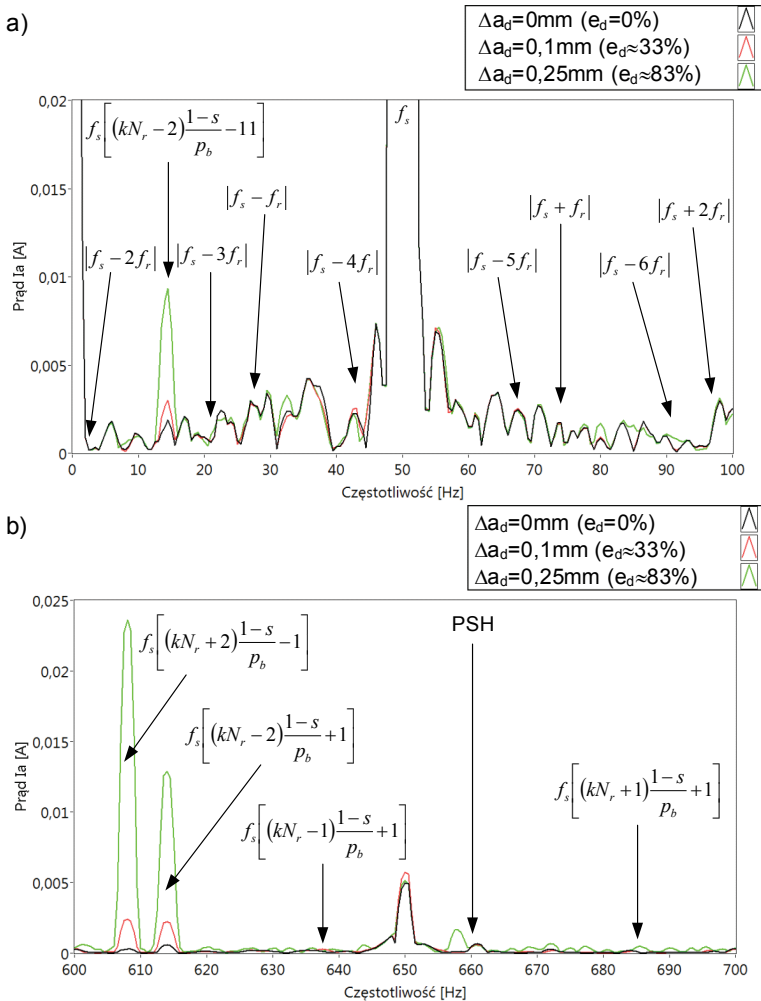
W pracy [10.12] w celu zweryfikowania wpływu wyższych harmonicznych oraz asymetrii zasilania, występujących w rzeczywistej sieci zasilającej, do modelu polo-wo-obwodowego podano napięcie zmierzone na obiekcie rzeczywistym, spróbkowane z krokiem obliczeniowym zastosowanym w symulacji. Przykładowe wyniki uzyskane dla silnika pracującego pod obciążeniem znamionowym (1410 obr/min) przedstawiono na rysunku 10.15 (ekscentryczność statyczna), rysunku 10.16 (ekscentryczność dynamiczna) oraz na rysunku 10.17 (ekscentryczność mieszana).



Rys. 10.15. Widmo FFT prądu stojana dla znamionowego obciążenia silnika Sh90L-4 z ekscentrycznością statyczną: a) składowe niskoczęstotliwościowe, b) składowe wysokoczęstotliwościowe

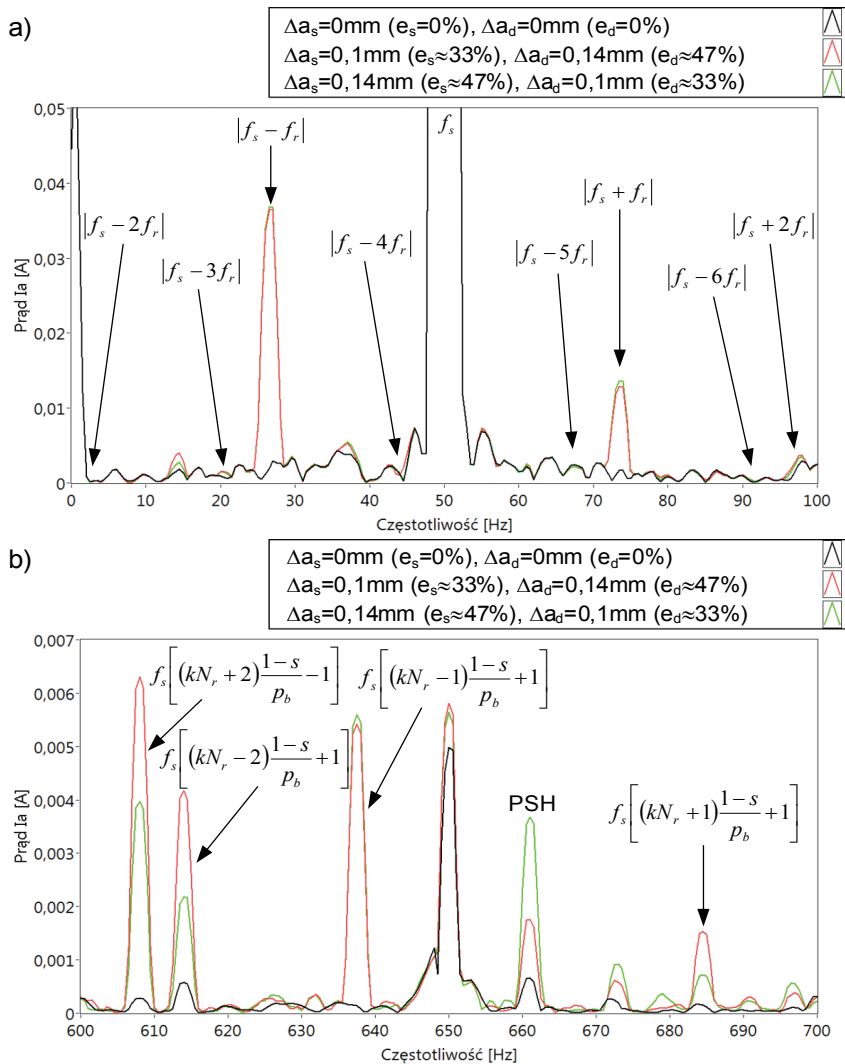
W przypadku dużego poziomu ekscentryczności statycznej w widmie prądu stojana w pasmie niskich częstotliwości pojawiają się częstotliwości obrotowe. Ponadto widoczne są składowe f_{es} opisane zależnością (10.7) dla $n_w = \pm 1, \pm 3, \pm 5, \dots$

Z rysunku 10.15b wynika, że wraz ze wzrostem ekscentryczności statycznej amplituda głównej harmonicznej żłobkowej (PSH) rośnie. Dodatkowo w pasmie wysokich częstotliwości na dużym poziomie ekscentryczności statycznej można zaobserwować pojawienie się dodatkowych składowych opisanych zależnością (10.6) odpowiadających ekscentryczności dynamicznej oraz mieszanej.



Rys. 10.16. Widmo FFT prądu stojana dla znamionowego obciążenia silnika Sh90L-4 z ekscentrycznością dynamiczną: a) składowe niskoczęstotliwościowe, b) składowe wysokoczęstotliwościowe

Na rysunku 10.16 przedstawiono widmo prądu stojana z ekscentrycznością dynamiczną. W pasmie niskich częstotliwości również pojawia się dodatkowa harmoniczna o częstotliwości 14 Hz, co jest zgodne z zależnością (10.6) dla $n_d = -2$ i $n_w = -11$. W pasmie wysokich częstotliwości pojawiają się dodatkowe częstotliwości f_{ed} opisane zależnością (10.6), gdzie $n_d = 2$ i $n_w = 1, 5, 7, 11, \dots$. Amplituda tych częstotliwości zależy od poziomu ekscentryczności dynamicznej.



Rys. 10.17. Widmo FFT prądu stojana dla znamionowego obciążenia silnika Sh90L-4 z ekscentrycznością mieszaną: a) składowe niskoczęstotliwościowe, b) składowe

W przypadku ekscentryczności mieszanej (rys. 10.17) w pasmie niskich częstotliwości widma prądu stojana również pojawiają się częstotliwości obrotowe wynikające z zależności (10.11) dla $k = 1$. W pasmie wysokich częstotliwości występują harmoniczne opisane wyrażeniem (10.6) dla:

- $n_d = -2, -1, 2$ i $n_w = \pm 1, \pm 5, \pm 7, \dots$,
- $n_d = 1$ i $n_w = -3, -1, 3, 5, \dots$,

a także główna harmoniczna żłobkowa (PSH) oraz harmoniczne przesunięte względem niej o $\pm 2kf_s$ (gdzie $k = 1, 2, \dots$).

Wyszczególnione dominujące częstotliwości wykorzystano w projektowaniu neuronowych detektorów do wykrywania i oceny ekscentryczności.

10.5. Neuronowe detektory uszkodzeń łożysk tocznych

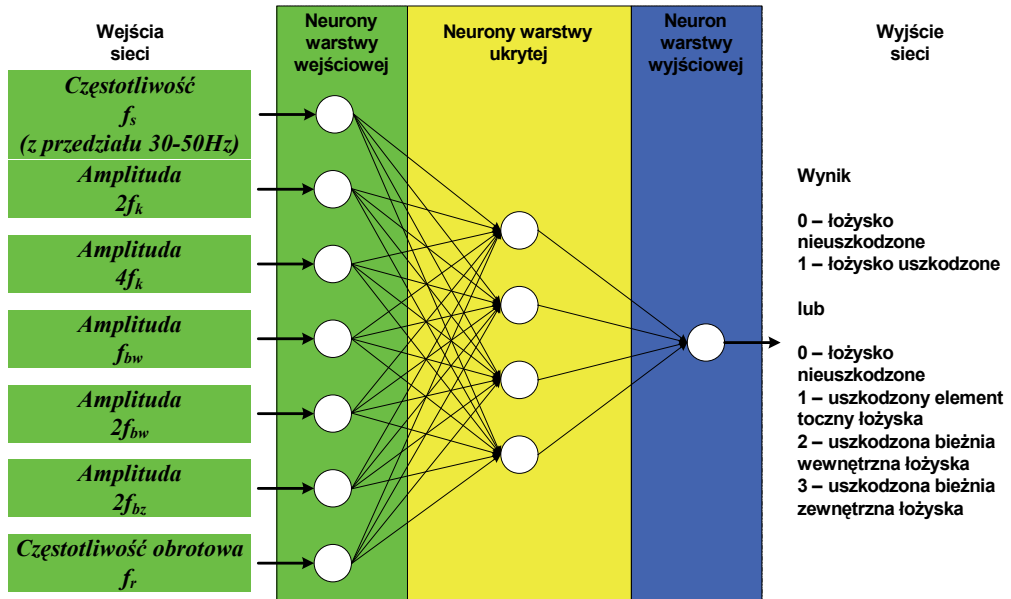
10.5.1. Perceptronowy detektor uszkodzeń łożysk tocznych silnika zasilanego z przemiennika częstotliwości

Na podstawie widma przyspieszenia drgań oraz obwiedni przyspieszenia drgań (rozdział 10.2.1) wyznaczono charakterystyczne częstotliwości uszkodzeniowe. Jako sygnały wejściowe detektora wybrano amplitudy następujących częstotliwości: $2f_k, 4f_k, f_{bw}, 2f_{bw}$ oraz $2f_{bz}$. Dodatkowo wektor wejściowy rozszerzono o częstotliwość obrotową f_r , co umożliwiło uwzględnienie zmiennego obciążenia. Badania przeprowadzono dla częstotliwości napięcia zasilającego z przedziału 30÷50 Hz [10.9, 10.12, 10.13]. Informacja o częstotliwości zasilania była podawana również na wejście detektora.

Opracowano dwa rodzaje detektorów. Zadaniem pierwszego było określenie czy łożysko jest nieuszkodzone (**0** na wyjściu sieci) czy też uszkodzone (**1** na wyjściu sieci). Zadaniem drugiego detektora neuronowego było wykrywanie rodzaju uszkodzonego elementu konstrukcyjnego łożyska. Na wyjściu sieci pojawia się informacja **0** dla łożyska nieuszkodzonego, **1** dla uszkodzonej kulki, **2** dla uszkodzonej bieżni wewnętrznej oraz **3** dla uszkodzonej bieżni zewnętrznej łożyska. W obu przypadkach warstwa wyjściowa składała się tylko z jednego neuronu wyjściowego. Na rysunku 10.18 przedstawiono strukturę neuronowego detektora uszkodzenia łożyska tocznego silnika zasilanego z przemiennika częstotliwości.

Do uczenia sieci neuronowych wybrano dane z dwóch różnych serii pomiarowych, natomiast testowano trzecią serią pomiarową. Wektor wejściowy do uczenia sieci neuronowej składał się ze 122 elementów, natomiast wektor testujący z 60 elementów. Badania zrealizowano dla danych uzyskanych z analizy FFT przyspieszenia drgań oraz obwiedni przyspieszenia drgań. Wykonano 11 serii uczenia oraz testowania w celu uśrednienia wyników wykrywania uszkodzeń. Badania zrealizowano dla dwóch wariantów danych uczących:

- amplitudy częstotliwości wybrane z widma przyspieszenia drgań,
- amplitudy częstotliwości wybrane z widma obwiedni przyspieszenia drgań.



Rys.10.18. Struktura detektora neuronowego do wykrywania uszkodzeń łożysk tocznych silnika zasilanego z przemiennika częstotliwości

W tabeli 10.2 przedstawiono wyniki skuteczności wykrywania uszkodzeń łożysk tocznych dla przypadku, gdy zadaniem detektora jest stwierdzenie, czy łożysko jest uszkodzone, czy też nie. Uzyskana średnia skuteczność z 11 serii uczenia i testowania detektorów jest bardzo wysoka i wynosi ok. 96–97%. W drugim rodzaju detektora określającego rodzaj uszkodzonego elementu konstrukcyjnego łożyska skuteczność spada do poziomu ok. 76% dla struktury 7–3–1 (tabela 10.3). Zwiększanie liczby neuronów w warstwie ukrytej poprawia skuteczność detekcji (do 88%). W pojedynczych przypadkach detektory neuronowe błędnie klasyfikowały łożysko uszkodzone jako nieuszkodzone.

Tabela 10.2. Skuteczność detektora określającego czy łożysko jest nieuszkodzone lub uszkodzone na podstawie danych z analizy FFT przyspieszenia drgań

Skuteczność z 11 kolejnych serii uczenia i testowania %	Struktura sieci neuronowej		
	(7–3–1)	(7–4–1)	(7–5–1)
Średnia	96,2	96,8	97,0
Najmniejsza	93,3	93,3	93,3
Największa	96,7	98,3	98,3

Tabela 10.3. Skuteczność wykrywania uszkodzeń konstrukcyjnych łożysk tocznych na podstawie danych z analizy FFT przyspieszenia drgań

Skuteczność z 11 kolejnych serii uczenia i testowania %	Struktura sieci neuronowej		
	(7-3-1)	(7-4-1)	(7-5-1)
Średnia	76,4	85,5	88,3
Najmniejsza	61,7	76,7	78,3
Największa	90,0	93,3	93,3


Wykorzystanie do uczenia i testowania sieci neuronowej informacji diagnostycznej otrzymanej z analizy obwiedni łożyska zdecydowanie poprawia skuteczność diagnozowania (tabela 10.4). W tym przypadku skuteczność jest na poziomie 99–100%. Detektory neuronowe, określające rodzaj uszkodzonego elementu łożyska tocznego, trenowane informacją uzyskaną z analizy obwiedni również charakteryzują się lepszą skutecznością (tabela 10.5) w porównaniu do tych samych struktur zbudowanych na podstawie danych z widma przyspieszenia drgań. W tym przypadku średnia skuteczność jest na poziomie ok. 96–97%. Najlepiej nauczone detektory neuronowe w procesie testowania nie popełniły żadnego błędu. W przypadku pomyłki błędnie określały tylko rodzaj uszkodzenia, natomiast nie zaobserwowano zaklasyfikowania łożyska uszkodzonego jako nieuszkodzone.

Tabela 10.4. Skuteczność detektora określającego czy łożysko jest nieuszkodzone lub uszkodzone na podstawie danych z widma obwiedni przyspieszenia drgań

Skuteczność z 11 kolejnych serii uczenia i testowania %	Struktura sieci neuronowej		
	(7-3-1)	(7-4-1)	(7-5-1)
Średnia	99,5	99,8	100,0
Najmniejsza	96,7	98,3	100,0
Największa	100,0	100,0	100,0

Tabela 10.5. Skuteczność wykrywania uszkodzeń konstrukcyjnych łożysk tocznych na podstawie danych z widma obwiedni przyspieszenia drgań

Skuteczność z 11 kolejnych serii uczenia i testowania %	Struktura sieci neuronowej		
	(7-3-1)	(7-4-1)	(7-5-1)
Średnia	97,4	96,5	96,2
Najmniejsza	96,7	91,7	93,3
Największa	100,0	100,0	100,0



Rys. 10.19. Wyniki testowania sieci o strukturze 7–5–1 wykrywającej uszkodzenia konstrukcyjne łożysk tocznych na podstawie danych z widma obwiedni przyspieszenia drgań (skuteczność 95%)

Na rysunku 10.19 przedstawiono przykład wyników testowania neuronowego detektora (struktura 7–5–1) wykrywającego uszkodzenia elementów konstrukcyjnych łożyska trenowanego amplitudami częstotliwości uszkodzeniowych z widma obwiedni przyspieszenia drgań [10.12].


Przedstawione wyniki potwierdziły, że w badaniach łożysk tocznych metoda analizy obwiedni najskuteczniej wyodrębnia symptomy uszkodzeń i ta skuteczność przenosi się na działanie detektora neuronowego. Przykłady innych rozwiązań neuronowych detektorów łożyska przedstawiono w [10.9, 10.11–10.13, 10.15]. Uzyskano tam również bardzo dobrą skuteczność wykrywania uszkodzeń. Na podkreślenie zasługuje fakt, że otrzymane perceptronowe struktury sieci neuronowych są bardzo proste, co może mieć istotne znaczenie w ich praktycznej realizacji. Fakt zasilania silnika z przekształtnika oraz praca przy częstotliwościach w przedziale 30–50 Hz nie miała wpływu na skuteczność wykrywania uszkodzeń.

10.5.2. Detektor neuronowy wykorzystujący radialną sieć neuronową

Analizując literaturę można wyróżnić dwa najbardziej efektywne i popularne typy sieci neuronowych. Pierwsza z nich jest klasyczną strukturą perceptronu wielowarstwowego (najczęściej z sigmoidalnymi funkcjami aktywacji). Drugą bardzo atrakcyjną siecią neuronową, charakteryzującą się dodatkowymi korzystnymi cechami, jest sieć wykorzystująca radialne funkcje aktywacji (rozdział 7.7). W związku z tą główną różnicą struktury zmienia się zasada przetwarzania modelu neuronowego. Należy podkreślić, że jednym z głównych problemów projektowych związanych z sieciami

neuronowymi jest dobór ich struktury, a przede wszystkim liczby neuronów w warstwach ukrytych oraz rozmieszczenia centrów funkcji aktywacji. Taka decyzja ma istotny wpływ na dokładność obliczeń oraz właściwości generalizacyjne sieci.

W celu optymalizacji struktury detektorów uszkodzeń wykorzystano metodę klastringu rozmytego [10.12, 10.21, 10.29]. Został on zastosowany do wstępnej analizy danych treningowych, na podstawie czego wyłonione zostały klastry, które przyjęto (centra oraz liczbę) jako parametry sieci neuronowej. Praktyczne zastosowanie sieci neuronowych w analizie rozbudowanych zbiorów danych liczbowych, będących rzeczywistymi pomiarami lub ich przekształceniami, okazuje się korzystne. Grupowanie danych jest realizowane bardzo precyzyjnie również w obecności zakłóceń, jak szумы pomiarowe lub zewnętrzne zakłócenia. Sieć neuronowa w trakcie procesu treningu zdobywa zdolność do analizy relacji między danymi wejściowymi oraz wyjściowymi modelu. Przygotowana w ten sposób struktura umożliwia, dzięki właściwościom generalizacyjnym, poprawną analizę również danych spoza zbioru treningowego. W niniejszym zastosowaniu klasyfikacja danych jest bardzo istotna, dotyczy ona podziału danych zawierających symptomy uszkodzeń silnika indukcyjnego na zbiory charakteryzujące się podobnymi cechami, odpowiadającymi konkretnemu stanowi technicznemu maszyny [10.30]. Sygnałami wejściowymi do sieci są takie same symptomy uszkodzeń jak w sieci opisanej w rozdziale 10.5.1. Najczęściej w strukturze sieci neuronowej tego typu zawarta jest tylko jedna warstwa ukryta. W niniejszym przypadku pominięto sygnały biasu. Wewnątrz struktury nie występują sprzężenia zwrotne, sygnał jest propagowany bezpośrednio od wejść do wyjść. Budowę analizowanego modelu zaprezentowano na rysunku 10.20.



Rys. 10.20. Struktura sieci neuronowej radialnej

Wartość wyjściowa zastosowanej sieci neuronowej jest wyznaczana za pomocą zależności:

$$y_k = \sum_{j=1}^n w_{jk} h_j \quad (10.12)$$

w której:

- y_k – wartość wyjściowa,
- w_{jk} – współczynniki poszczególnych połączeń sieci,
- h_j – wyjścia neuronów warstwy ukrytej.

Charakterystyczną cechą analizowanych detektorów jest zastosowanie radialnej funkcji aktywacji neuronów warstwy ukrytej w postaci wyrażonej zależnością (7.7). Wartości współczynników wagowych w wyjściowej warstwie wyznaczone są poprzez rozwiązywanie układu równań [10.31]:

$$\mathbf{w} = \mathbf{G}^* \mathbf{d} \quad (10.13)$$

gdzie:

- $\mathbf{d} = [d_1, d_2, d_3 \dots d_n]^T$ – wektor zadanych wartości wyjściowych,
- $\mathbf{w} = [w_0, w_1, w_2 \dots w_n]^T$ – macierz współczynników wagowych,
- \mathbf{G} – macierz Greena definiowana jako:

$$\mathbf{G} = \begin{bmatrix} h(\|x_1 - c_1\|) & h(\|x_1 - c_2\|) & \dots & h(\|x_1 - c_n\|) \\ h(\|x_2 - c_1\|) & h(\|x_2 - c_2\|) & \dots & h(\|x_2 - c_n\|) \\ \dots & \dots & \dots & \dots \\ h(\|x_p - c_1\|) & h(\|x_p - c_2\|) & \dots & h(\|x_p - c_n\|) \end{bmatrix} \quad (10.14)$$

przy czym \mathbf{G}^* oznacza pseudoinwersję macierzy \mathbf{G} :

$$\mathbf{G}^* = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \quad (10.15)$$

Analizując podane zależności, opisujące obliczenia wewnątrz modelu neuronowego, można zauważyć, że dla szybkości przetwarzania, szczególnie w ewentualnych aplikacjach sprzętowych, istotne znaczenie ma złożoność struktury. W sieciach neuronowych, wykorzystujących radialne funkcje aktywacji, jednym z prostszych sposobów doboru struktury jest przepisanie wektora danych wejściowych \mathbf{X} do macierzy centrów funkcji warstwy wewnętrznej \mathbf{C} . W takich przypadkach realizowane obliczenia macierzowe mogą wymagać dużej mocy obliczeniowej. Zastosowanie klasteringu rozmytego umożliwi w takiej sytuacji znacząco zredukować złożoność struktury sieci neuronowej. Ponadto jest to uzasadnione również zwiększoną precyzją uzyskiwanych wyników. W opisywanym przypadku dla realizacji tego zadania wybrano algorytm FCM [10.21, 10.30]. Jest to algorytm iteracyjny, w trakcie którego analizowana jest funkcja celu:

$$F_n = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^n \|x_i - c_j\|^2 \quad (10.16)$$

gdzie:

- u_{ij} – stopień przynależności elementu x_i do j -tego klastra,

- x_i – element z przestrzeni analizowanych danych,
 c_j – oznacza centrum kolejnego klastra,
 n – liczba rzeczywista większa od 1,
 $\| \cdot \|$ – miara odległości elementu ze zbioru danych od centrum danego klastra, w wielu przypadkach wyznaczana jako norma Euklidesa,
 C – liczba klastrów,
 N – liczba elementów zbioru danych.

W kolejnych krokach algorytmu FCM podana zależność jest punktem wyjściowym, ponadto zastosowane są zależności uzyskane przez wyznaczenie pochodnej względem c_j oraz u_{ij} . Poszczególne iteracje metody klasteringu rozmytego:

1. Przyjmowane są początkowe wartości macierzy: $\mathbf{U}=[u_{ij}]$, C ($2 \leq C \leq N$), n ($1 < n < \infty$), ε (współczynnik determinujący zatrzymanie algorytmu).
2. Wyznaczanie centrów c_j poszczególnych klastrów jest realizowane zgodnie z zależnością:

$$c_j = \frac{\sum_{i=1}^N u_{ij}^n x_i}{\sum_{i=1}^N u_{ij}^n} \quad j = 1, \dots, C \quad (10.17)$$

3. Na tej podstawie wyznaczana jest aktualna macierz $\mathbf{U}(k+1)$. W przypadku kiedy $x_i \neq c_j$, obliczenia są wykonywane zgodnie ze wzorem:

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{n-1}}} \quad (10.18)$$

w przeciwnym przypadku: $u_{ij} = 1$ dla $i = j$ lub $u_{ij} = 0$ dla $i \neq j$.

4. Kryterium określające zatrzymanie obliczeń opisane jest zależnością:

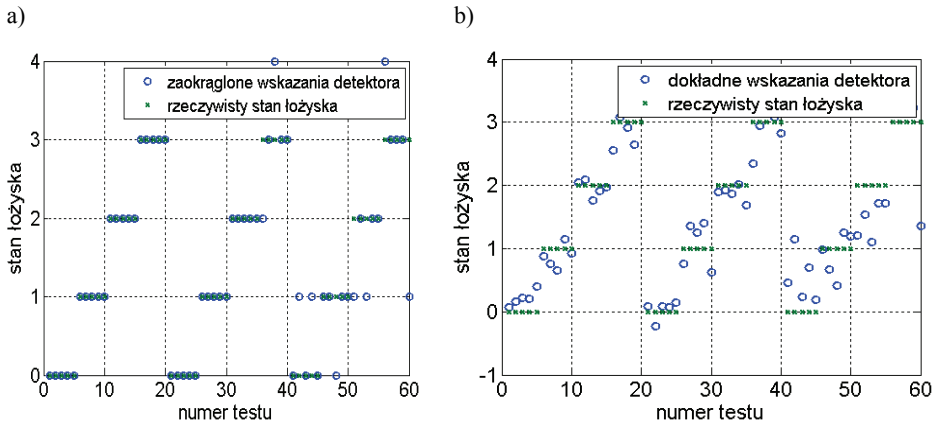
$$\| \mathbf{U}(k+1) - \mathbf{U}(k) \| < \varepsilon \quad (10.19)$$

Jeśli to kryterium nie jest spełnione, kolejny cykl przetwarzania realizowany jest zgodnie z krokiem 2.

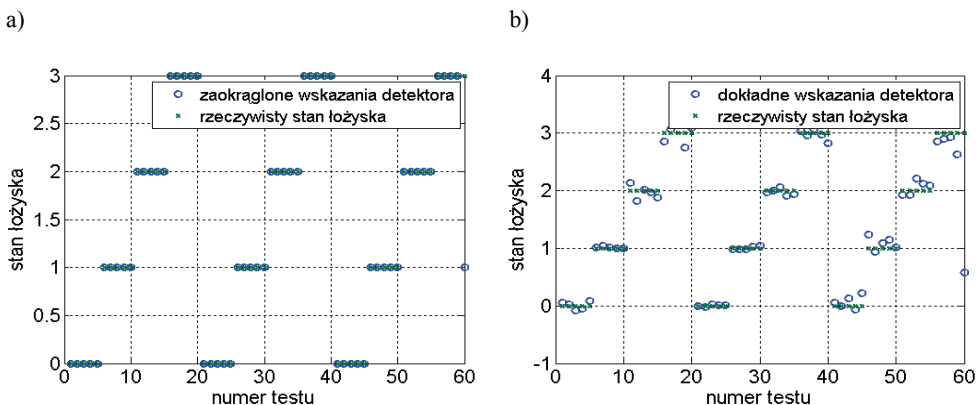
Po zatrzymaniu opisanego algorytmu wektor centrów zostaje przepisany jako parametry centrów radialnej funkcji aktywacji w sieci neuronowej. Jednocześnie w ten sposób determinowana jest liczba neuronów warstwy ukrytej.

Zaprezentowano testy opisanych detektorów uszkodzeń łożysk silnika indukcyjnego. Podobnie jak w przykładzie z punktu 10.5.1, silnik zasilano z przekształtnika napięcia (regulacja częstotliwości w przedziale 30÷50 Hz). Analizowane symptomy uszkodzeń uwzględniają zmiany obciążenia maszyny. Testy zrealizowano dla danych

uzyskanych z analiz widmowych sygnału drganiowego oraz obwiedni przyspieszenia drgań. Zadaniem detektora neuronowego było wykrywanie rodzaju uszkodzonego elementu konstrukcyjnego łożyska.




Rys. 10.21. Wyniki testów sieci neuronowej radialnej (dane z widma przyspieszenia drgań)
a) zaokrąglona wartość, b) wskazania dokładne



Rys. 10.22. Wyniki testów sieci neuronowej radialnej (dane z widma obwiedni przyspieszenia drgań)
a) zaokrąglona wartość, b) wskazania dokładne

Na wyjściu sieci pojawia się informacja **0** dla łożyska nieuszkodzonego, **1** dla uszkodzonej kulki, **2** dla uszkodzonej bieżni wewnętrznej oraz **3** dla uszkodzonej bieżni zewnętrznej łożyska. W obu przypadkach warstwa wyjściowa składała się tylko z jednego neuronu wyjściowego. Do uczenia sieci neuronowych wybrano dane z dwóch różnych serii pomiarowych, natomiast testowano kolejną serią pomiarową. Uzyskane wyniki badań zamieszczono na rysunkach: 10.21 (symptomy z widma

drgań) oraz 10.22 (symptomy z widma obwiedni drgań). Przyjęto 50 neuronów ukrytych sieci. W przypadku sieci trenowanej z symptomami z widma przyspieszenia drgań uzyskano skuteczność około 85%, natomiast sieć trenowana danymi z widma obwiedni przyspieszenia drgań miała skuteczność na poziomie 98%. Uzyskane wyniki badań prezentują bardzo dużą skuteczność wykrywania uszkodzeń. Większą precyzję w wyznaczaniu stanu łożyska można zaobserwować w przypadku symptomów otrzymywanych za pomocą analizy obwiedni.



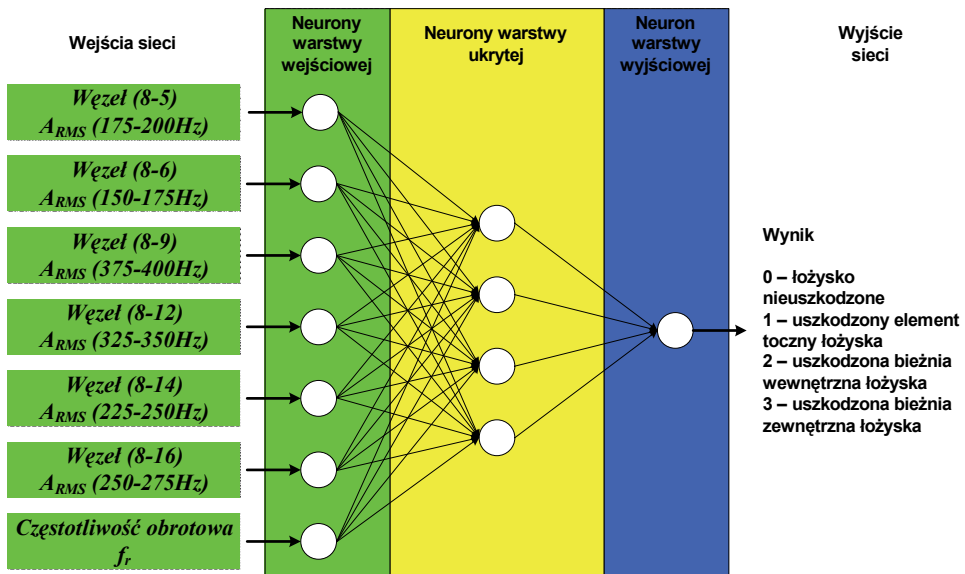
Rys. 10.23. Dokładność detekcji uszkodzeń dla zmiennej liczby neuronów w warstwie ukrytej wyznaczona dla całego zbioru testowego (a) oraz wyłącznie dla przypadku ze sprawnym łożyskiem (b)

Testowano również wpływ liczby neuronów ukrytych na dokładność oceny stanu łożyska. Testy wykonano dla przypadku generowania danych z analizy obwiedni przyspieszenia drgań. Wyniki przedstawiono na rysunku 10.23. Liczba neuronów ukrytych ma istotny wpływ na dokładność detekcji za pomocą sieci neuronowych radialnych. Jeżeli ich liczba jest zbyt mała, skuteczność, nie jest zadowalająca (około 50%). Dołączanie kolejnych neuronów do struktury detektora powoduje poprawę uzyskiwanych wyników. Jednak zbyt duża liczba neuronów warstwy ukrytej pogarsza rezultaty detekcji, jednocześnie wzrasta liczba wykonywanych operacji matematycznych.

Przedstawiona metoda, w której korzysta się z symptomów diagnostycznych w radialnych sieciach neuronowych umożliwiła uzyskanie bardzo dobrej skuteczności wykrywania uszkodzeń w łożyskach. Istotny wpływ na osiągnięty rezultat miało zastosowanie sieci neuronowej radialnej, której parametry funkcji aktywacji dobierano za pomocą klasteringu FCM. Opisana metoda może stanowić samodzielną aplikację w urządzeniu diagnostycznym, gotową do zastosowań przemysłowych.

10.5.3. Detektor neuronowy wykorzystujący analizę falkową

W rozdziale 10.2.2 przedstawiono zasady wykorzystywania analizy falkowej do projektowania neuronowych detektorów uszkodzeń. Przedstawiono możliwość wykorzystania pełnego dyskretnego przekształcenia falkowego do uzyskania informacji diagnostycznej do uczenia i testowania neuronowego detektora zbudowanego na sieci perceptronowej MLP [10.12, 10.14, 10.15]. Poddając sygnał przyspieszenia drgań przekształceniu falkowemu do 8. poziomu dekompozycji, otrzymuje się odpowiednie 25 Hz przedziały analizowanego sygnału dla każdego węzła. Wyboru węzłów dokonano, kierując się wzrostem amplitud częstotliwości charakterystycznych dla uszkodzenia elementu tocznego, bieżni zewnętrznej i wewnętrznej, i wartością skuteczną przyspieszenia drgań w węzłach. Wybrano węzły (8-5), (8-6), (8-9), (8-12), (8-14), (8-16). Wartości skuteczne przyspieszenia drgań w tych węzłach stanowiły sygnały wejściowe sieci neuronowej. Dodatkowo w celu uwzględnienia zmian obciążenia wektor wejściowy rozszerzono o częstotliwość obrotową f_r . Na rysunku 10.24 przedstawiono strukturę detektora neuronowego do wykrywania uszkodzeń elementów konstrukcyjnych łożyska. Warstwa wyjściowa składa się tylko z jednego neuronu wyjściowego.



Rys. 10.24. Struktura detektora neuronowego do wykrywania uszkodzeń elementów konstrukcyjnych łożysk tocznych oparta na informacji z analizy falkowej sygnału przyspieszenia drgań

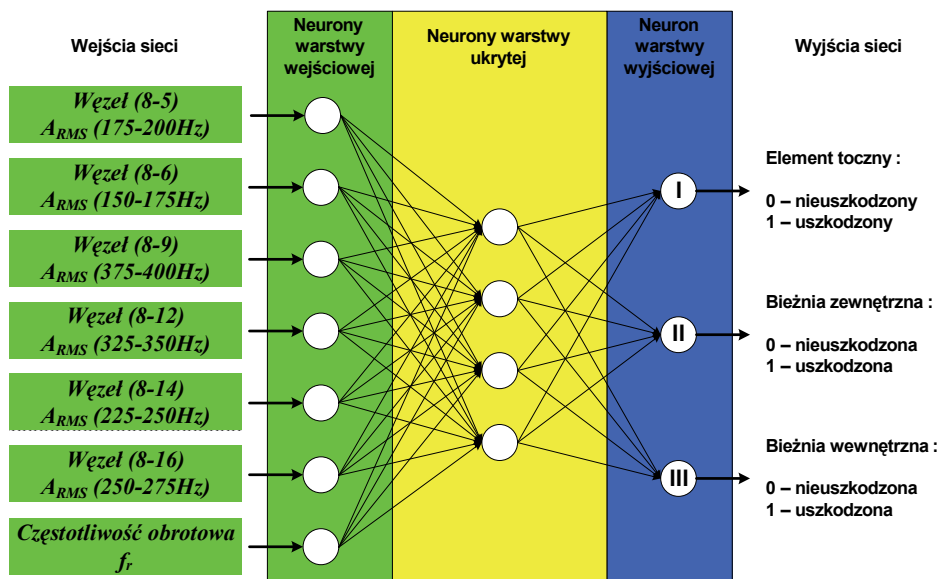
Na wyjściu sieci pojawia się informacja **0** dla łożyska nieuszkodzonego, **1** dla uszkodzonego elementu tocznego, **2** dla uszkodzonej bieżni zewnętrznej oraz **3** dla

uszkodzonej bieźni wewnętrznej łożyska. Do uczenia sieci neuronowych wykorzystano dane z dwóch różnych serii pomiarowych, natomiast testowano trzecią serią pomiarową. Każda seria zawierała po 10 pomiarów dla łożyska: nieuszkodzonego, z uszkodzonym elementem tocznym, bieźnią zewnętrzną i wewnętrzną. Wektor wejściowy do uczenia sieci neuronowej składał się ze 120 elementów, natomiast wektor testujący z 60 elementów. Wszystkie serie pomiarowe wykonano na tej samej grupie łożysk. W celu uśrednienia wyników skuteczności detektorów neuronowych łożysk tocznych wykonano 11 serii uczenia oraz testowania.

W tabeli 10.6 zestawiono skuteczność działania wybranych struktur detektorów neuronowych. Wynika z niej, że wszystkie testowane struktury charakteryzują się bardzo wysoką średnią skutecznością na poziomie ok. 98%. W większości przypadków testowane sieci neuronowe nie popełniły żadnego błędu.

Tabela 10.6. Skuteczność detekcji wybranych uszkodzeń konstrukcyjnych łożysk tocznych na podstawie informacji z analizy falkowej przyspieszenia drgań

Skuteczność z 11 kolejnych serii uczenia i testowania %	Struktura sieci neuronowej		
	(7-3-1)	(7-4-1)	(7-5-1)
Średnia	97,6	99,8	98,5
Najmniejsza	91,7	98,3	95,0
Największa	100,0	100,0	100,0



Rys. 10.25. Struktura detektora neuronowego z trzema neuronami w warstwie wyjściowej opartego na informacji z analizy falkowej

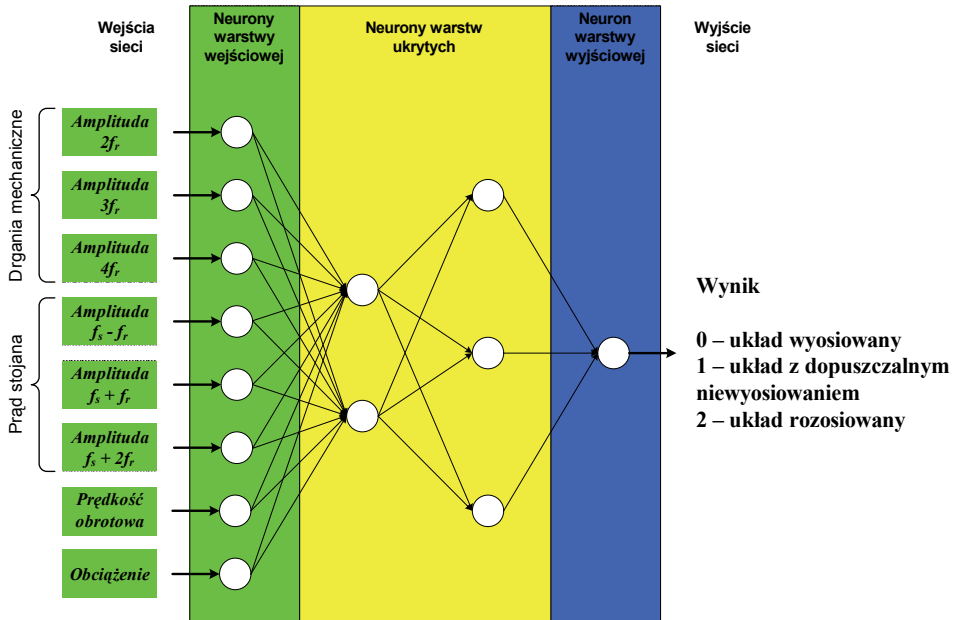
Dodatkowo przetestowano strukturę z trzema neuronami wyjściowymi umożliwiającą wskazanie jednocześnie kilku uszkodzeń. Do badań wykorzystano wektory wejściowe takie same jak w poprzednim rozwiązaniu. Na każdym z neuronów wyjściowych może pojawić się informacja **0** dla elementu nieuszkodzonego i **1** dla elementu uszkodzonego. Na rysunku 10.25 przedstawiono strukturę takiej sieci. Sieć, podobnie jak poprzednia, bardzo dobrze rozróżnia uszkodzony element konstrukcji łożyska (skuteczność na poziomie 98%).

Z przedstawionych przykładów wynika, że informacja diagnostyczna uzyskana z analizy falkowej może być bezpośrednio wykorzystana do monitorowania charakterystycznych częstotliwości w aproksymatach i detalach lub pośrednio, za pomocą wytrenowanych sieci neuronowych. Perceptronowe sieci neuronowe, projektowane na bazie informacji uzyskanej z analizy falkowej przyspieszenia drgań, wykrywają z dużą skutecznością uszkodzenia konstrukcyjne łożyska tocznego. Ponadto są to stosunkowo niewielkie struktury sieci neuronowych, które dość prosto mogą być zrealizowane w systemie komputerowym.

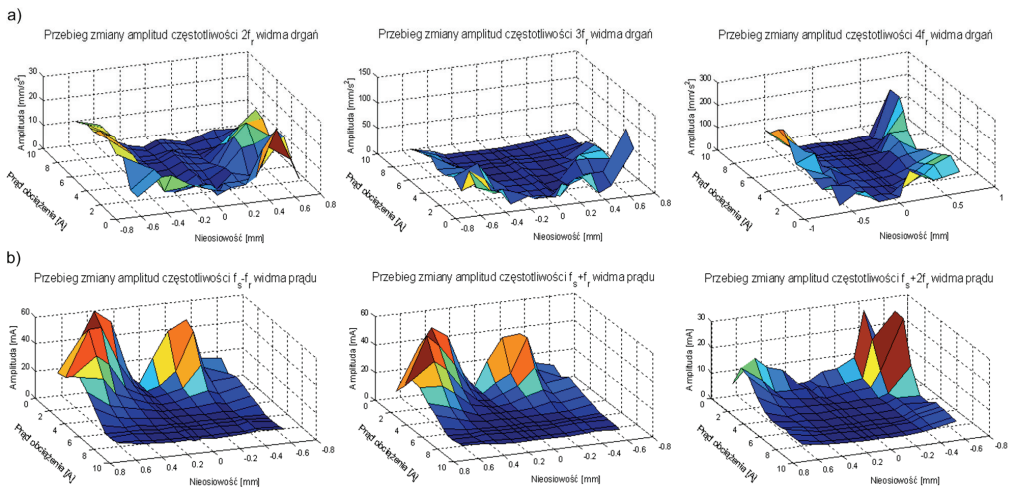
10.6. Neuronowe detektory nieosiowości napędu

Jak wykazano w rozdziale 10.3, symptomami niewyosiowania napędu elektrycznego z silnikiem indukcyjnym są zmiany amplitudy charakterystycznych częstotliwości widocznych w widmach drgań i prądu stojana. Do realizacji detektora monitorującego nieosiowość napędu zastosowano sieci neuronowe typu perceptron wielowarstwowy [10.5, 10.12, 10.26]. Jako wielkości wejściowe sieci wykorzystano amplitudy charakterystycznych składowych widma prądu i drgań, które przy zmianie poziomu nieosiowości oraz obciążenia mają w przybliżeniu linową zależność (ekstrakcja cech). Ponadto na wejście sieci podano informację o obciążeniu i prędkości obrotowej. Na wyjściu sieci oczekiwano informacji o ogólnym stanie nieosiowości badanego układu (0 – układ wyosiowany, 1 – układ z dopuszczalnym niewyosiowaniem, 2 – układ rozosiowany). Strukturę sieci neuronowej przedstawiono na rysunku 10.26.

Dla analizowanego w monografii przykładowego napędu określono jak zmieniają się wybrane składowe widma drgań oraz prądu stojana (wejścia detektora neuronowego) w funkcji obciążenia i poziomego przesunięcia równoległego (rys. 10.27). Do trenowania wybierano metodą prób różne struktury sieci typu perceptron wielowarstwowy. Wektorem uczącym była amplituda z charakterystycznych częstotliwości z dwóch serii pomiarowych, natomiast wektorem testującym była z trzeciej serii pomiarowej (wektor uczący – 264 wartości na każde wejście, wektor testujący – 132 wartości na każde wejście).




Rys. 10.26. Przykład struktury detektora neuronowego do wykrywania niewyosiowania układu napędowego




Rys. 10.27. Zależność częstotliwości charakterystycznych widma drgań mechanicznych (a) i widma prądu stojana (b) w funkcji obciążenia i poziomego przesunięcia równoległego

Przetestowano sieci neuronowe z jedną warstwą ukrytą oraz z dwoma warstwami ukrytymi, na wejścia których podano albo tylko wybrane częstotliwości z sygnału

drganiowego lub prądowego, albo z obu sygnałów jednocześnie. Uzyskane wyniki przedstawiono na rysunkach 10.28–10.30. W celu poprawy wiarygodności odpowiedzi sieci, przeprowadzono 5 serii uczenia i testowania badanych detektorów. Na rysunku 10.28 przedstawiono skuteczność działania sieci o różnych strukturach (z jedną lub z dwoma warstwami ukrytymi) trenowanych informacją z widma sygnału drganiowego. Z rysunku wynika, że zwiększanie liczby neuronów w warstwie ukrytej powoduje wzrost skuteczności testowanej sieci. Ponadto dla tej samej liczby neuronów w warstwie ukrytej większą skuteczność uzyskano dla sieci z dwoma warstwami ukrytymi.




Rys. 10.28. Porównanie skuteczności neuronowych detektorów niewyosiowania różnych struktur sieci (uczenie i testowanie tylko sygnałem drganiowym)



Rys. 10.29. Porównanie skuteczności neuronowych detektorów niewyosiowania różnych struktur sieci (uczenie i testowanie tylko danymi z widma prądu)

Na kolejnym rysunku 10.29 przedstawiono porównanie skuteczności różnych struktur sieci neuronowych trenowanych informacjami z widma sygnału prądowego. Z przeprowadzonej analizy wynika, że zwiększanie neuronów w warstwie ukrytej nie powoduje wyraźnego wzrostu skuteczności testowanej sieci. Ponadto dla tej samej liczby neuronów w warstwie ukrytej skuteczność sieci z jedną, jak i z dwoma warstwami ukrytymi jest do siebie zbliżona (różnica wynosi ok. 1–2%). Średnia skuteczność wszystkich sieci wynosi ok. 97%.



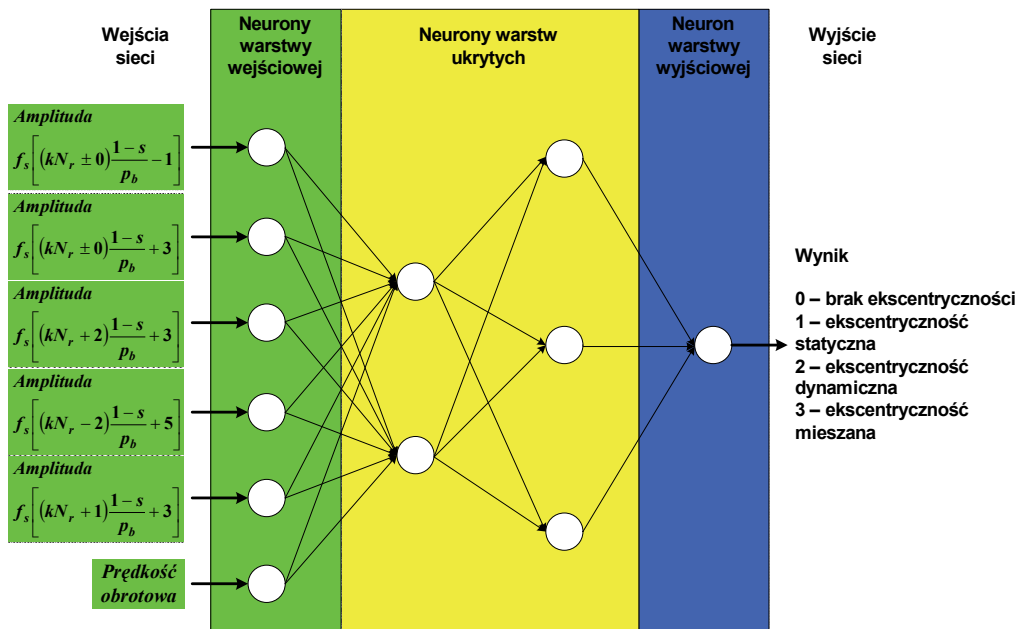
Rys. 10.30. Porównanie skuteczności neuronowych detektorów niewyosiowania różnych struktur sieci (uczenie i testowanie sygnałem drganiowym i prądowym)

Skuteczność różnych sieci neuronowych, na wejścia których podano zarówno informacje z sygnału drganiowego, jak i prądowego została przedstawiona na rysunku 10.30. Zwiększanie neuronów w warstwie ukrytej nieznacznie wpływa na zmianę skuteczności, która oscyluje między 97,7% a 100%. Ponadto dla tej samej liczby neuronów w warstwie ukrytej skuteczność zarówno i sieci z jedną, jak i z dwoma warstwami ukrytymi są do siebie zbliżone. Średnia efektywność wszystkich sieci była bardzo duża i wyniosła ok. 99%. Największą dokładność działania sieci neuronowej obserwuje się podczas uczenia informacją zarówno z sygnału drganiowego, jak i prądowego, ale jest to wzrost istotny.

Z badań wynika, że przy zapewnieniu odpowiedniej jakości pomiaru drgań i prądu oraz ekstrakcji symptomów charakteryzujących jakość wyosiowania napędu, można zbudować neuronowy detektor o dużej skuteczności dokonywania oceny. Tego typu detektor mógłby pełnić rolę monitorującą stan wyosiowania napędu i sygnalizującą operatorowi pojawienie się zagrożenia bez straty czasu na samodzielną ocenę charakterystycznych symptomów.

10.7. Neuronowe detektory ekscentryczności silnika

Jak wyjaśniono w punkcie 10.4, eksperymentalne badanie zjawiska ekscentryczności napotyka trudności techniczne, szczególnie związane z precyzyjnymi zmianami ilościowymi rodzaju i poziomu ekscentryczności, niezbędnymi do opracowania modelu neuronowego. Dlatego, wykorzystując coraz większe możliwości modelowania matematycznego polowo-obwodowego silników indukcyjnych, jest uzasadnione budowanie na ich bazie określonych wzorców diagnostycznych pełniących rolę redundancji analitycznej w systemie diagnostycznym. Tak zbudowany wzorec diagnostyczny dostarcza diagnoście informację (mniej lub bardziej precyzyjną w zależności od dokładności modelu matematycznego), umożliwiającą ocenę poziomu ekscentryczności przez porównanie z aktualną sytuacją na obiekcie rzeczywistym. Na bazie wzorca diagnostycznego możliwe jest projektowanie neuronowego detektora, którego zadaniem będzie dostarczanie na bieżąco operatorowi (diagnoście) informacji czy poziom ekscentryczności na obiekcie w porównaniu z wzorcem jest prawidłowy czy też nie. Taka struktura systemu diagnostycznego przyspieszy i zautomatyzuje proces oceny aktualnej sytuacji na obiekcie.



Rys. 10.31. Struktura detektora neuronowego do wykrywania ekscentryczności (model silnika indukcyjnego zasilany napięciem zmierzonym na obiekcie rzeczywistym)

Na podstawie analizy widmowej prądu stojana, uzyskanego w wyniku symulacji połowo-obwodowej silnika z ekscentrycznością (rozdział 10.4), wybrano częstotliwości, których amplituda zmieniała się w przybliżeniu liniowo wraz ze wzrostem ekscentryczności [10.8, 10.10, 10.12, 10.20, 10.25]. Są częstotliwości opisane zależnościami (10.6) i (10.11) dla $k = 1$ oraz: $n_d = 0$ i $n_w = -1$, $n_d = 0$ i $n_w = 3$, $n_d = 2$ i $n_w = 3$, $n_d = -2$ i $n_w = 5$, $n_d = 1$ i $n_w = 3$. Na rysunku 10.31 przedstawiono strukturę sieci neuronowej wykrywającej rodzaj ekscentryczności.

Wektor uczący składał się z symptomów występujących w widmie prądu stojana fazy A oraz B, natomiast wektor testujący zbudowany był na podstawie fazy C. Aby zmniejszyć strukturę sieci neuronowej wybrano pojedynczy, ciągły neuron wyjściowy, którego zadaniem było tylko określenie rodzaju ekscentryczności (**0** dla silnika bez ekscentryczności, **1** dla ekscentryczności statycznej, **2** dla ekscentryczności dynamicznej oraz **3** dla ekscentryczności mieszanej). Wyniki testowania detektorów neuronowych o różnych strukturach z jedną warstwą ukrytą przedstawiono w tabeli 10.7.

Większość popełnianych przez sieć błędów polegała na błędnym określeniu typu ekscentryczności, natomiast praktycznie bezbłędnie odróżniała stan zadawalający od stanu, w którym występuje ekscentryczność.

Tabela 10.7. Zestawienie skuteczności detektorów różnych struktur sieci neuronowej (jedna warstwa ukryta)

Struktura sieci neuronowej	6-4-1	6-5-1	6-7-1	6-13-1	6-17-1	6-27-1
Skuteczność sieci [%]	42	81	89	84	85	55
	41	58	90	89	62	61
	73	86	85	82	82	45
	42	89	83	91	66	59
	83	69	83	92	76	70
	77	87	88	85	78	51
Średnia skuteczność [%]	60	78	86	87	75	57

Ponieważ prawidłowy dobór struktury zastosowanej sieci neuronowej jest jednym z najistotniejszych zagadnień w procesie projektowania detektorów neuronowych, sprawdzono również skuteczność działania detektora opartego na sieci dwuwarstwowej. Kiedy struktura jest za mała, sieć nie jest w stanie nauczyć się realizacji danego zadania. Natomiast w przypadku kiedy struktura jest zbyt rozbudowana, sieć nie pozwala na uzyskanie zadowalającego poziomu działania. Sieć neuronowa z odpowiednio dobraną liczbą neuronów ukrytych podczas treningu uczy się tendencji zmian sygnałów. W sytuacji kiedy topologia jest za duża, sieć w procesie treningu dopasowuje się do wszelkich zakłóceń lub szumów. W tabeli 10.8 zestawiono wyniki testowania sieci z dwoma warstwami ukrytymi. Uzyskano skuteczność średnią zbliżoną do sieci z jedną warstwą ukrytą.

Tabela 10.8. Zestawienie skuteczności detektorów różnych struktur sieci neuronowej (dwie warstwy ukryte)

Struktura sieci neuronowej	6-2-3-1	6-3-4-1	6-5-8-1	6-7-10-1	6-12-15-1
Skuteczność sieci [%]	83	84	82	82	66
	79	76	89	79	56
	84	85	78	79	83
	89	93	84	72	75
	68	80	79	82	73
	49	86	85	83	75
Średnia skuteczność [%]	75	84	83	79	71

Z przedstawionego przykładu wynika, że zaproponowany sposób wykorzystywania informacji diagnostycznej otrzymywanej z modelowania matematycznego ekscentryczności silnika może być pomocny w ocenie stanu mimośrodowości na rzeczywistym obiekcie.

10.8. Podsumowanie

W rozdziale omówiono trzy wybrane rodzaje uszkodzeń typu mechanicznego, spotykane w napędach z silnikami indukcyjnymi: uszkodzenia łożysk tocznych, niewspółosiowość napędu i ekscentryczność.

Przedstawiono podstawowe metody wykrywania tych uszkodzeń oparte na szukaniu charakterystycznych częstotliwości występujących w widmach drgań mechanicznych i prądu stojana. Charakterystyka wybranych uszkodzeń została ukierunkowana na poszukiwanie najkorzystniejszych cech do projektowania neuronowych detektorów uszkodzeń. Wykazano, że duże korzyści w uzyskiwaniu dodatkowych informacji diagnostycznych można osiągnąć, stosując analizę falkową sygnałów drgań mechanicznych i prądu stojana.

Przedstawiono propozycje rozwiązań neuronowych detektorów uszkodzeń elementów konstrukcyjnych łożysk tocznych trenowanych i testowanych cechami pozytywnymi z widm drganiowych, prądowych oraz analizy falkowej. Badania zrealizowano z wykorzystaniem sieci neuronowych perceptronowych i radialnych. Uzyskano bardzo dobrą skuteczność wykrywania uszkodzeń.

W przypadku detektorów niewspółosiowości, opracowanych również na bazie informacji diagnostycznej otrzymywanej z widma drganiowego i prądu stojana, uzyskano dużą skuteczność monitorowania stanu niewyosiowania napędu. Jednakże, do osiągnięcia dobrej skuteczności detektora niezbędne jest dostarczenia odpowiedniej jakości i liczby danych pomiarowych do uczenia i testowania sieci neuronowych.

Neuronowe detektory ekscentryczności, trenowanie i testowane danymi pozyskanymi z komputerowej symulacji pracy napędu, umożliwiają w zadowalający sposób ocenić aktualny poziom mimośrodowości. Dokładność działania detektora zależy w dużym stopniu od zastosowanego modelu polowo-obwodowego i liczby informacji wykorzystanej do trenowania i testowania.

Przedstawione przykłady realizacji neuronowych detektorów uszkodzeń typu mechanicznego nie wyczerpują wszystkich możliwych rozwiązań. Zadaniem ich jest jedynie wskazanie innej drogi prowadzącej w przyszłości do ułatwienia działań diagnostycznych na obiektach przemysłowych. Badania na obiektach rzeczywistych lub rejestrowanie sygnałów diagnostycznych w trakcie normalnej eksploatacji obiektów, umożliwiłyby zebranie odpowiednio dużej ilości informacji diagnostycznej (bazy danych), umożliwiającej projektowanie m.in. neuronowych detektorów uszkodzeń mechanicznych. Przeprowadzone testy komputerowe wybranych rozwiązań neuronowych detektorów, opracowanych na podstawie sztucznie preparowanych uszkodzeń na obiektach rzeczywistych, wykazały ich dużą skuteczność w wykrywaniu uszkodzeń. Dlatego można z dużym prawdopodobieństwem przyjąć, że realizacja praktyczna proponowanych detektorów i podłączenie ich do pracy on-line na obiekcie będzie dodatkowym narzędziem systemowym, wspomagającym monitorowanie i diagnostykę napędów przemysłowych.

Literatura

- [10.1] Cempel C., Tomaszewski F., *Diagnostyka maszyn*, Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom 1992.
- [10.2] Dorrell D.G., Thomson W.T., Roach S., *Combined Effects of Static and Dynamic Eccentricity on Airgap Flux Waves and the Application of Current Monitoring to Detect Dynamic Eccentricity in 3-phase Induction Motors*, Proc. of the IEE Confer. on Electrical Machines and Drives, 1995, Conf. Publication IEE, No. 412, 151–155.
- [10.3] Dorrell D.G., Thomson W.T., Roach S., *Analysis of Airgap Flux, Current, and Vibration Signal as a Function of the Combination of Static and Dynamic Airgap Eccentricity in 3-Phase Induction motors*, IEEE Trans. on Ind. Applications, Vol. 33, No. 1, 1997, 24–34.
- [10.4] Drozdowski P., Petryna J., Weinreb K., *Interakcja efektów elektrycznych, magnetycznych oraz mechanicznych w silnikach indukcyjnych w aspekcie diagnostyki*, Zeszyty Problemowe Maszyny Elektryczne, Nr 54, 1997, BOBRME Komel, 109–116.
- [10.5] Ewert P., Kowalski C.T., *Monitorowanie nieosiowości napędów elektrycznych z silnikami indukcyjnymi*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały, Nr 29, 2009, 266–275.
- [10.6] Ewert P., Kowalski C.T., *Ocena skuteczności wykrywania uszkodzeń elementów konstrukcyjnych łożysk tocznych w silnikach indukcyjnych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych, 2010, nr 64, seria: Studia i materiały nr 30, 291–302.
- [10.7] Ewert P., Zawilak T., *Zastosowanie modelu polowo-obwodowego do monitorowania ekscentryczności silników indukcyjnych*, Maszyny Elektryczne, KOMEL, Zeszyty Problemowe Nr 87, 2010, 161–166.

- [10.8] Ewert P., *Zastosowanie komputerowego modelowania ekscentryczności silników indukcyjnych do generowania wzorców diagnostycznych na potrzeby detektorów neuronowych*, XVI Scientific Conf. Computer Applications in Electrical Engineering, ZKwE'2011, Poznań 2011, 157–158.
- [10.9] Ewert P., *Neuronowy detektor uszkodzeń łożysk tocznych*, Maszyny Elektryczne, Zeszyty Problemowe, Nr 92, 2011, 205–210.
- [10.10] Ewert P., Kamiński M., Kowalski C.T., *Eccentricity detection of the induction motors using general regression neural*, 10th Int. Conf. on Modeling and Simulation of Electric Machines, Converters and Systems ELECTRIMACS 2011, Cergy–Pontoise, France, 2011, 1–6.
- [10.11] Ewert P., *Neuronowy detektor uszkodzeń łożysk tocznych silnika zasilanego z przemiennika częstotliwości*, X Krajowa Konferencja Naukowa Sterowanie w Energoelektronice i Napędzie Elektrycznym, SENE 2011, Łódź, 16–18 listopada 2011, 1–6.
- [10.12] Ewert P., *Diagnostyka mechanicznych uszkodzeń napędów z silnikami indukcyjnymi przy wykorzystaniu sieci neuronowych*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, 2012.
- [10.13] Ewert P., *Neuronowy detektor uszkodzeń łożysk tocznych silnika zasilanego z przemiennika częstotliwości*, Przegląd Elektrotechniczny, R. 88, nr 4b, 2012, 70–75.
- [10.14] Ewert P., Kowalski C., *Zastosowanie analizy falkowej do diagnostyki łożysk tocznych silników indukcyjnych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wroclawskiej, Studia i Materiały, nr 32, 2012, 339–345.
- [10.15] Ewert P., Kowalski C.T., Wolkiewicz M., *The application of wavelet analysis and neural networks in the diagnosis of rolling bearing faults in induction motors*, Przegląd Elektrotechniczny, R. 89, nr 2b, 2013, 124–127.
- [10.16] Faiz J., Ebrahimi B.M., Toliyat H.A., *Effect of Magnetic Saturation on Static and Mixed Eccentricity Fault Diagnosis in Induction Motor*, IEEE Trans. on Magnetics, Vol. 45, No. 8, 2009, 3137–3144.
- [10.17] Faiz J., Ebrahimi B.M., Akin B., Toliyat H.A., *Dynamic analysis of mixed eccentricity signatures at various operating points and scrutiny of related indices for induction motors*, IET Electric Power Applications, Vol. 4, No. 1, 2010, 1–16.
- [10.18] Faiz J., Ojaghi M., *Different indexes for eccentricity faults diagnosis in three-phase squirrel-cage induction motors: A review*, ELSEVIER, Mechatronics, Vol. 19, 2009, 2–13.
- [10.19] Faiz J., Ojaghi M., *Stator Inductance Fluctuation of Induction Motor as an Eccentricity Fault Index*, IEEE Trans. on Magnetics, Vol. 47, No. 6, 2011, 1775–1785.
- [10.20] Kamiński M., Ewert P., Kowalski C.T., *Zastosowanie detektorów neuronowych w detekcji ekscentryczności silników indukcyjnych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wroclawskiej, Studia i Materiały, nr 30, 2010, 303–311.
- [10.21] Kamiński M., Kowalski C.T., Orłowska-Kowalska T., *General regression neural networks as rotor bar fault detection of induction motor*, IEEE Int. Conf. on Industrial Technology ICIT 2010, Chile, 1239–1244.
- [10.22] Kowalski C.T., Szabat K., *Application of Wavelet Transform to Diagnosis of the Induction Motor*, Proc. of XVIII Symp. on Electromagnetic Phenomena in Nonlinear Circuits EPNC'04, Poznań, Poland, 2004.
- [10.23] Kowalski C.T., *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wroclawskiej nr 57, seria Monografie nr 18, Wrocław 2005.
- [10.24] Kowalski C.T., *Zastosowanie analizy falkowej w diagnostyce silników indukcyjnych*, Przegląd Elektrotechniczny, R. 82, nr 1, 2006, 21–26.
- [10.25] Kowalski C.T., Ewert P., *Zastosowanie analizy widmowej prądu stojana do monitorowania ekscentryczności silników indukcyjnych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wroclawskiej, Studia i Materiały, nr 27, 2007, 260–270.

- [10.26] Kowalski C.T., Ewert P., *Zastosowanie sieci neuronowych do monitorowania nieosiowości napędów elektrycznych z silnikami indukcyjnymi*, Zeszyty Problemowe Maszyny Elektryczne, BOBRME KOMEL, nr 83, 2009, 189–194.
- [10.27] Morel J., *Drgania maszyn i diagnostyka ich stanu technicznego*, Polskie Towarzystwo Diagnostyki Technicznej, Warszawa, 1994.
- [10.28] Nandi S., Ahmed S., Toliyat H.A., *Detection of Rotor Slot and Other Eccentricity Related Harmonics in a Three Phase Induction Motor with Different Rotor Cages*, IEEE Trans. on Energy Conversion, Vol. 16, No. 3, 2001, 253–260.
- [10.29] Liao T.W., *Clustering of time series data – a survey*, Pattern Recognition, Vol. 38, No. 11, 2005, 1857–1874.
- [10.30] Orr M.J.L., *Recent advances in radial basis function networks*, Technical Report, Inst. for Adaptive and Neural Computation, Univ. of Edinburgh, 1999.
- [10.31] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, 2006.
- [10.32] Rusek J., *Reflection of Eccentricities in Spectral Composition of Currents of Induction Machines*, Proc. Intern. Conf. on Electrical Machines ICEM'96, Paris, France, 1996, 470–475.
- [10.33] Schoen R.R., Habetler T.G., Kamran F., Bartheld R.G., *Motor Bearing Damage Detection Using Stator Current Monitoring*, IEEE Trans. on Industry Applications, Vol. 31, No. 6, 1995, 1274–1279.
- [10.34] Seker S., Ayaz E., *Feature extraction related to bearing damage in electric motors by wavelet analysis*, Journal of the Franklin Institute, 2003, 125–134.
- [10.35] Sobczyk T.J., Vas P., Tassoni C., *Models for Induction Motors with Air Asymmetry for Diagnosis Purposes*, Proc. Intern. Conf. on Electrical Machines ICEM'96, Paris, France, 1996, 79–84.
- [10.36] Sobczyk T.J., Weinreb K., Izvorski A., *Recognition of rotor eccentricity of induction motors based on the Fourier spectra of phase currents*, Proc. Intern. Conf. on Electrical Machines ICEM'98, Lausanne, Switzerland, 1998, 408–413.
- [10.37] Sun Q., Tang Y., *Singularity analysis using continuous wavelet transform for bearing fault diagnosis*, Mechanical Systems and Signal Processing, 2002, 1025–1041.
- [10.38] Swędrowski L., *Nowa metoda diagnostyki łożysk silnika indukcyjnego oparta na pomiarze i analizie widmowej prądu zasilającego*, Wyd. Politechniki Gdańskiej, ser. Monografie nr 54, Gdańsk 2005.
- [10.39] Szymaniec S., *Diagnostyka stanu izolacji uzwojeń i stanu łożysk silników indukcyjnych klatkowych w warunkach przemysłowej eksploatacji*, Studia i Monografie z. 193, Politechnika Opolska, Opole 2006.
- [10.40] Thomson W.T., Rankin D., Dorrell D.G., *On-line Current Monitoring To Diagnose Airgap Eccentricity In Large Three-Phase Induction Motors – Industrial Case Histories Verify The Predictions*, IEEE Trans. on Energy Conversion, Vol. 14, No. 4, 1999, 1372–1378.
- [10.41] Vas P., *Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines*, Oxford University Press, Oxford 1993.
- [10.42] Vas P., *Artificial-Intelligence-Based Electrical Machines and Drives*, Oxford University Press, 1999.
- [10.43] Yang D.-M., *Induction Motor Bearing Fault Detection with Non-stationary Signal Analysis*, Proc. of International Conference on Mechatronics, Kumamoto Japan, 8–10 May 2007, 1–6.
- [10.44] Yang D.-M., Stronach A.F., Macconnell P., *The application of advanced signal processing techniques to induction motor bearing condition diagnosis*, Meccanica, Vol. 38, 2003, 297–308.
- [10.45] Zhang J.-Y., Cui L.-L., Yao G.-Y., Gao L.-X., *Research on the selection of wavelet function for the feature extraction of shock fault in the bearing diagnosis*, Proc. of the 2007 Int. Conf. on Wavelet Analysis and Pattern Recognition, Beijing, China, 2007, 1630–1634.

11. Zagadnienia realizacji praktycznej systemów diagnostycznych

11.1. Wprowadzenie

Przedstawione w rozdziałach 8–10 propozycje struktury neuronowych detektorów uszkodzeń stojana, wirnika i łożyska tocznego zostały wszechstronnie przetestowane w komputerowych symulatorach sztucznych sieci neuronowych. Testowanie zrealizowano na rzeczywistych danych eksperymentalnych w trybie off-line w środowisku programowym MATLAB. Niektóre rozwiązania (np. detektory zwarć zwojowych – rozdział 9.4) były realizowane w środowisku programistycznym LabView i pracowały on-line na rzeczywistym obiekcie. Pozytywne wyniki testów skłaniają do podjęcia działań w kierunku rozwiązania problemu technicznej realizacji neuronowych detektorów działających w trybie on-line. Pozwoliłoby to wesprzeć monitorowanie i diagnostykę, realizowane klasycznymi metodami, nowymi rozwiązaniami systemów opartymi na sztucznej inteligencji, zdolnymi do przetwarzania dużej liczby danych dla celów diagnostycznych (klasyfikowanie i ocena symptomów).

W ramach prowadzonych badań przetestowano laboratoryjne wersje neurodetektorów uszkodzeń silnika indukcyjnego. Zadaniem testów laboratoryjnych było sprawdzenie, czy na obecnym poziomie rozwoju techniki komputerowej możliwa jest programowa realizacja struktur neuronowych, ocena związanych z tym kosztów oraz odporność na zakłócenia.

Na podstawie przeprowadzonych badań laboratoryjnych sformułowano ogólne założenia dotyczące roli detektorów w zastosowaniach przemysłowych:

1. Neuronowy detektor będzie pełnił rolę wspomagającą proces decyzyjny operatora obsługującego monitorowany układ napędowy.
2. Neuronowy detektor będzie pracował on-line i w sposób ciągły dostarczał aktualnej informacji o stanie technicznym silnika.
3. Działania klasyfikujące i oceniające oparte będą na sygnałach wejściowych otrzymanych z modułu realizującego funkcje analizy sygnałów i wyodrębniania symptomów uszkodzeń, którego działanie opisane jest klasycznymi metodami detekcji uszkodzeń (rozdziały 8–10).

4. Neurodetektor powinien działać prawidłowo w szerokim zakresie zmian obciążenia, regulacji częstotliwości napięcia zasilania (regulacji prędkości obrotowej) i temperatury oraz być odporny na zakłócenia.

W trakcie realizacji projektów badawczych opracowano i zrealizowano różne warianty prototypowych systemów pomiarowo-diagnostycznych umożliwiających testowanie badanych metod wczesnego wykrywania uszkodzeń elektrycznych i mechanicznych. Są to następujące rozwiązania:

1. Wersja przenośna systemu, uproszczona (tania), ale zapewniająca realizację podstawowych funkcji monitorowania i diagnostyki, oparta na własnym rozwiązaniu sprzętowym i programowym.
2. Wersja rozbudowana, oparta na komputerowym i pomiarowym sprzęcie firmy National Instruments oraz własnym oprogramowaniu w środowisku LabVIEW:
 - a) system do monitorowania stanu uzwojeń stojana;
 - b) system do wykrywania wybranych uszkodzeń mechanicznych.
3. System do monitorowania stanu stojana i wirnika oparty na estymacji parametrów.

11.2. Przenośny system diagnostyczny silnika indukcyjnego

Do oceny stanu technicznego silników w czasie ich normalnej pracy wykorzystuje się różnego rodzaju urządzenia pomiarowe, które na bieżąco monitorują podstawowe sygnały fizyczne pracujących maszyn. Niestety, aparatura diagnostyczna, w skład której wchodzi bogaty zestaw specjalistycznych czujników, jest bardzo kosztowna, zatem jej stosowanie ogranicza się praktycznie do dużych maszyn. Z kolei silniki małej mocy stanowią najliczniejszą grupę maszyn, które pełnią często odpowiedzialne funkcje w procesach technologicznych. Dlatego ciągle poszukuje się niedrogich rozwiązań sprzętowych, które umożliwią zaimplementowanie zagadnień diagnostyki eksploatacyjnej również do napędów mniejszej mocy.

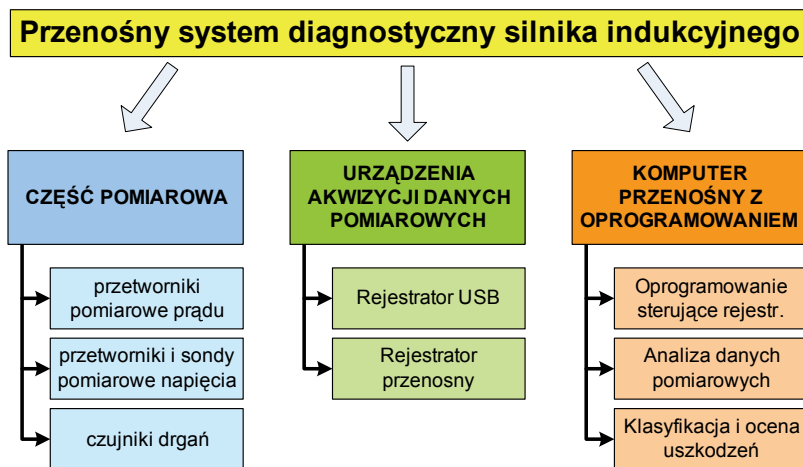
Jedną z metod ograniczenia kosztów aparatury diagnostycznej jest redukcja specjalistycznych czujników wielkości fizycznych. Elementy te są stosunkowo kosztowne, a ponadto nie zawsze istnieje możliwość zainstalowania ich na monitorowanym obiekcie. Skutkiem tego jest eliminacja trudno mierzalnych sygnałów diagnostycznych i zastąpienie ich sygnałami łatwymi do zmierzenia, z wykorzystaniem prostych i tanich przetworników pomiarowych. Jednym z takich sygnałów diagnostycznych jest prąd stojana, który można w prosty sposób zmierzyć, na przykład za pomocą cęgowych przetworników prądu. Przyrządy te mają dodatkową zaletę – umożliwiają wykonanie pomiaru w sposób bezinwazyjny, bez potrzeby rozłączania obwodu elektrycznego badanego silnika.

Koncepcja i wstępna realizacja przenośnego systemu do monitorowania i diagnostyki silnika indukcyjnego powstała w ramach rozprawy doktorskiej dr Marcina Pawlaka [11.6]. Następnie w ramach projektów badawczych, na potrzeby badań diagnostycznych silników indukcyjnych, został zaprojektowany i wykonany przenośny system pomiarowo-diagnostyczny, który do oceny stanu technicznego silnika wykorzystuje metody analizy częstotliwościowej sygnałów prądu stojana [11.5–11.8]. W sygnałach prądów fazowych silnika zawarty jest wiele informacji o różnych uszkodzeniach i nieprawidłowościach występujących w układzie napędowym.

Na podstawie analizy częstotliwościowej prądu można określić:

- uszkodzenia wirnika (przerwane pręty, pęknięty pierścień zwierający),
- zwarcia w uzwojeniach stojana,
- asymetrię napięć zasilających,
- nieprawidłowe sprzęgnięcie silnika z maszyną (niewyosowanie).

Zadaniem systemu diagnostycznego jest zarejestrowanie diagnostycznych sygnałów pomiarowych, a następnie przeprowadzenie analizy tych sygnałów pod kątem detekcji charakterystycznych cech, odpowiadających wybranym uszkodzeniom silnika. Przyjęto, że aparatura diagnostyczna będzie wykonana w formie przenośnej, co umożliwi ocenę stanu technicznego silników o różnych mocach, zainstalowanych w miejscach trudno dostępnych.




Rys. 11.1. Schemat blokowy przenośnego systemu diagnostycznego silnika indukcyjnego

Schemat blokowy przenośnego systemu diagnostycznego przedstawiono na rysunku 11.1. Głównym elementem systemu diagnostycznego jest komputer przenośny typu laptop z zainstalowanym oprogramowaniem diagnostycznym, którego zadaniem jest analiza sygnałów pomiarowych i ekstrakcja cech diagnostycznych. Z komputerem bezpośrednio współpracują urządzenia akwizycji danych pomiarowych, które reje-

strują sygnały prądów fazowych badanego silnika i przesyłają je do komputera za pośrednictwem interfejsu USB.

Część pomiarową systemu diagnostycznego stanowią wszelkiego rodzaju przetworniki pomiarowe prądu, napięcia, prędkości oraz drgań maszyny. Do realizacji badań laboratoryjnych oraz terenowych silników małej mocy opracowano i wykonano zestaw przetworników pomiarowych, który został zrealizowany w formie kompaktowej, przenośnej walizki. Do badań diagnostycznych silników zainstalowanych w trudno dostępnych miejscach można wykorzystać przetworniki cęgowe, które umożliwiają wykonanie pomiarów bez potrzeby rozłączania obwodu elektrycznego badanego silnika. Ponadto przetworniki takie mają najczęściej kilka zakresów pomiarowych, co czyni je uniwersalnymi i pozwala na zastosowanie ich do pomiarów prądów silników o różnych mocach. Do zastosowań diagnostycznych najlepiej nadają się przetworniki cęgowe wykorzystujące efekt Halla, które umożliwiają pomiar prądów silnika w szerokim zakresie częstotliwości, od zera herców (pomiar składowej stałej DC) do kilku kiloherców. Dobrym przykładem może być niedroga przystawka cęgowa typu CA60, która umożliwia pomiar prądu w dwóch podzakresach: 10 mA–15 A oraz 100 mA–60 A, w przedziale częstotliwości 0–20 kHz. Na rysunku 11.2 przedstawiono przykładową strukturę systemu.



Rys. 11.2. Przykładowa konfiguracja komputerowego systemu diagnostycznego silnika indukcyjnego

Bardziej rozbudowany zestaw przetworników pomiarowych przedstawiono na rysunku 11.3. Pełni on rolę przenośnego i scalonego systemu pomiarowego, umożli-

wiąjącego przeprowadzenie pomiarów podstawowych sygnałów silników elektrycznych występujących na obiektach napędowych w przemyśle. Zestaw umożliwia wykonanie pomiarów następujących sygnałów:

- trzech prądów fazowych silnika,
- trzech napięć międzyfazowych,
- prędkości obrotowej,
- przyspieszenia drgań.



Rys. 11.3. Fotografia zestawu przetworników pomiarowych

W projektowaniu systemu uwzględniono kilka aspektów elektrycznych i mechanicznych mających zapewnić wysoki standard pomiarów i bezpieczeństwa w warunkach zróżnicowanych i uciążliwych. Wybierając rozwiązania niestandardowe i zaawansowane technologicznie uzyskano kompaktowe narzędzie pomiarowe odporne na wpływy elektryczne i mechaniczne. W wyborze rozwiązań elektrycznych kierowano się przede wszystkim potrzebą uzyskania dużej dokładności pomiarów w szerokim paśmie częstotliwości i temperatury oraz wiernością odtwarzania sygnału mierzonego. Sprawą bardzo istotną była odporność układu pomiarowego na zewnętrzne zakłócenia elektromagnetyczne.

Równie ważnym zagadnieniem było zapewnienie galwanicznej separacji środowiska pomiarowego od obiektu mierzonego, mając na uwadze bezpieczeństwo obsługi w warunkach przemysłowych oraz zabezpieczenie systemu pomiarowego przed niepożądanymi zmianami warunków pomiarowych (przebiecia, impulsy łączeniowe). Mniej istotny był natomiast pobór mocy przez system pomiarowy, ponieważ nie przewidywano zasilania akumulatorowego. Dla wybranej koncepcji zestawu przenośnego przewidziano metalizowaną obudowę w formie walizki. Ma ona stanowić

ochronę przed polem elektromagnetycznym i jednocześnie zapewnić zestawowi mały ciężar i poręczność w transporcie.

W celu ułatwienia obsługi i podglądu wartości skutecznych mierzonych sygnałów zastosowano czteropozycyjne wyświetlacze siedmiosegmentowe. W przypadku pomiaru prądu i napięcia mają one jednak tylko charakter pomocniczy, ponieważ bardziej istotne są sygnały wartości chwilowych prądu i napięcia na wyjściach BNC. Dla pomiaru prędkości wyświetlacz stanowi natomiast podstawowy miernik.

Zagadnienie pomiaru prądu zostało potraktowane ze szczególną uwagą, ponieważ wierne odtworzenie prądu stanowi podstawę dalszych procesów obliczeniowych. W tym celu wybrano przetworniki pomiarowe prądu typu CT-10T, pracujące na zasadzie detekcji zmiany indukcji z podwójnym rdzeniem magnetycznym *Fluxgate transducer*, charakteryzujące się nieprzeciętnymi parametrami elektrycznymi wynikającymi z zastosowanej zaawansowanej technologii i nowoczesnej konstrukcji. Przetworniki CT-10T mają najszersze pasmo przenoszonych częstotliwości z aktualnie dostępnych przetworników prądowych. Są przeznaczone do pomiaru prądu stałego, przemiennego i impulsowego.

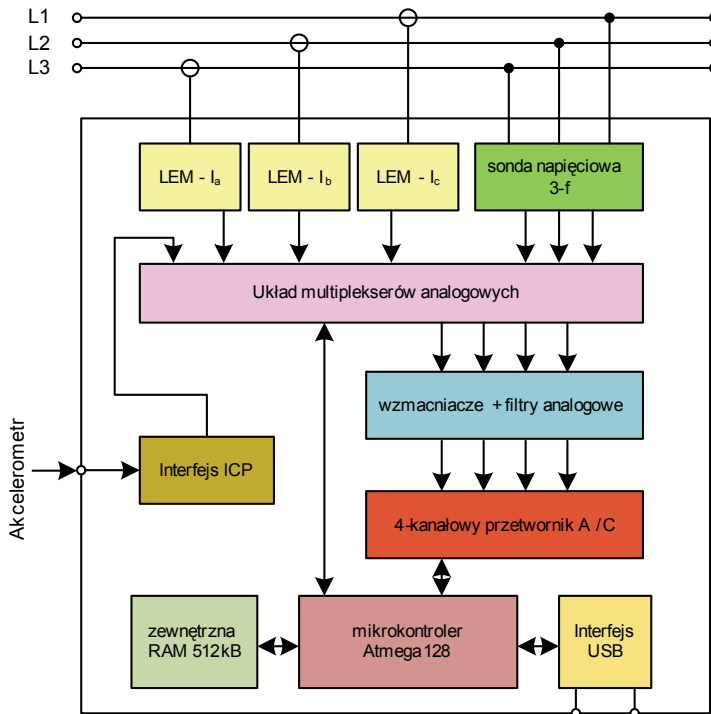
Układ pomiaru napięcia międzyfazowego silnika został wykonany w postaci układu elektronicznego, opracowanego na podstawie aplikacji klasycznego różnicowego wzmacniacza pomiarowego, wykorzystującego wzmacniacze operacyjne. Rozwiązanie to charakteryzuje się bardzo dużą rezystancją wejściową oraz szerokim pasmem częstotliwościowym.

Układ pomiaru przyspieszenia drgań umożliwia współpracę z przemysłowymi akcelerometrami piezoelektrycznymi, które są wyposażone w standardowy interfejs IEPE (ang. *Intrgrated Electronics PiezoElectric*). Układ pomiaru przyspieszenia drgań ma obwód źródła prądowego, który służy do zasilania akcelerometru. Na wyjściu układu znajduje się wzmacniacz sygnału o regulowanej wartości wzmocnienia, dzięki czemu uzyskuje się możliwość dopasowania wartości sygnału wyjściowego do parametrów przetwornika drgań.

Głównym elementem systemu pomiarowego jest 7-kanałowy rejestrator analogowy, który zapisuje próbki pomiarowe do wewnętrznej pamięci RAM, a następnie przesyła je do komputera za pośrednictwem szybkiego łącza USB. „Sercem” rejestratora jest 8-bitowy mikrokontroler ATmega128 rodziny AVR, który nadzoruje jego pracę oraz realizuje funkcje komunikacji z komputerem. Schemat blokowy rejestratora przedstawiono na rysunku 11.4.

Analogowy interfejs wejściowy rejestratora stanowi układ multiplekserów analogowych, które pozwalają na wybór 4 jednocześnie mierzonych sygnałów. Rozwiązanie jest podyktowane ograniczeniami wynikającymi z zastosowania 4-kanałowego przetwornika A/C. W dalszej części układu znajdują się programowalne wzmacniacze wejściowe wraz z obwodami zabezpieczeń. Układy te umożliwiają dopasowanie poziomów napięć sygnałów pomiarowych do poziomów napięć wejściowych przetworników A/C. W każdym kanale, w torze analogowym umieszczone zostały opcjonal-

ne filtry dolnoprzepustowe, o przełączalnych wartościach częstotliwości odcięcia: 100 Hz, 1 kHz i 10 kHz. Przetworniki A/C mają 14-bitową rozdzielczość i umożliwiają rejestrację sygnałów z maksymalną częstotliwością 100 kHz. Próbkę sygnałów pomiarowych są gromadzone w wewnętrznej pamięci RAM rejestratora, a po zakończeniu akwizycji wysyłane są do komputera przez interfejs USB. Wewnętrzna pamięć rejestratora ma pojemność 512 kB, co umożliwia zapisanie w jednym cyklu pomiarowym ok. 256 000 próbek sygnałów. Obwody wejściowe rejestratora są galwanicznie odseparowane od obwodów elektrycznych komputera, w wyniku zastosowania transoptorów na liniach interfejsu komunikacyjnego oraz izolowanej przetwornicy napięcia DC/DC, która dostarcza odpowiednich napięć zasilających do rejestratora bezpośrednio z interfejsu USB. Jeden z kanałów wejściowych systemu pomiarowego wyposażony jest dodatkowo w specjalny interfejs zawierający obwód źródła prądowego, który umożliwia podłączenie piezoelektrycznych akcelometrów pracujących w standardzie IEPE (ang. *Intrgrated Electronics PiezoElectric*).



Rys. 11.4. Schemat blokowy rejestratora analogowego


Oprogramowanie przenośnego systemu pomiarowego zostało napisane w języku Object Pascal, w środowisku Borland Delphi 7.0. Składa się ono z trzech modułów funkcjonalnych:

- modułu akwizycji i przetwarzania danych pomiarowych,
- modułu analizatora diagnostycznego,
- neuronowego detektora uszkodzeń.

Do najważniejszych zadań modułu akwizycji i przetwarzania danych pomiarowych należą:

- parametryzacja sprzętowa rejestratora analogowego,
- sterowanie procesem rejestracji danych pomiarowych,
- analiza zarejestrowanych danych (podstawowe obliczenia, statystyka),
- wykonanie analizy częstotliwościowej FFT danych pomiarowych,
- prezentacja wyników pomiarów i analizy (przebiegi, wykresy, zestawienia),
- archiwizacja i zarządzanie zestawami danych pomiarowych.

Zarejestrowane sygnały pomiarowe mogą być zapisane na dysku komputera w postaci plików typu (*.mat), co pozwoli na ich bezpośrednie wykorzystanie przez oprogramowanie MATLAB, w którym mogą zostać poddane dalszym przekształceniom matematycznym. Próbkę pomiarową można również zapisać w formacie zwykłych plików tekstowych, które mogą być odczytane przez większość arkuszy kalkulacyjnych i innych aplikacji biurowych. Ponadto, program umożliwia eksport danych graficznych (przebiegów i wykresów) do innych aplikacji MS Windows za pośrednictwem standardowej funkcji schowka. Przykładowe okno programu sterującego rejestratora w trybie „analiza FFT” przedstawiono na rysunku 11.5.



Rys. 11.5. Okno programu sterującego w trybie „analiza FFT”.

Głównym celem oprogramowania analizatora diagnostycznego jest analiza częstotliwościowa zarejestrowanych sygnałów prądów stojana, polegająca na ekstrakcji specyficznych cech diagnostycznych, charakteryzujących wybrane uszkodzenia silnika. W programie zastosowano algorytmy szybkiej transformaty Fouriera, które obliczają

widma częstotliwościowe sygnałów prądów fazowych silnika oraz widmo modułu wektora przestrzennego prądu stojana. Na podstawie widma program automatycznie wyznacza prędkość średnią silnika i oblicza wartość poślizgu. Znajomość poślizgu umożliwia z kolei wyznaczenie amplitudy charakterystycznych składowych częstotliwościowych, które mają związek z uszkodzeniami silnika. Oprócz standardowej funkcji analizy częstotliwościowej FFT zarejestrowanych sygnałów, program umożliwia wybór różnych funkcji okien czasowych, których zastosowanie poprawia jakość analizy spektralnej przez redukcję efektu „przecieku widmowego” oraz polepsza dokładność odwzorowania amplitudy poszczególnych prążków. Okno analizatora diagnostycznego, podczas testów silnika indukcyjnego o mocy 1,5 kW z uszkodzonym wirnikiem, w którym przerwano 4 pręty klatki, przedstawiono na rysunku 11.6.

Parametry podstawowe			
Ia_RMS [A]	3.69	Prędkosc [obr/min]	1420
Ib_RMS [A]	3.59	Poslizg [-]	0.053
Ic_RMS [A]	3.54	Częstotliwosc fs [Hz]	50.0

Uszkodzenia wirnika					
f_L1 [Hz]	44.69	L1 [A]	0.221	L1 [%]	4.25
f_L2 [Hz]	39.38	L2 [A]	0.039	L2 [%]	0.75
f_R1 [Hz]	55.31	R1 [A]	0.145	R1 [%]	2.79
f_R2 [Hz]	60.62	R2 [A]	0.017	R2 [%]	0.33
f_P1 [Hz]	5.31	P1 [A]	0.096	P1 [%]	1.52
f_P1 [Hz]	10.62	P2 [A]	0.036	P2 [%]	0.57

Asymetria stojana, asymetria zasilania					
f_las [Hz]	100.0	las [A]	0.083	las [%]	1.32
Asymetria prądów [%]				1.34	

Niewyposiowanie					
f_m1 [Hz]	23.7	m1 [A]	0.058	L1 [%]	0.92
f_m2 [Hz]	47.4	m2 [A]	0.002	m2 [%]	0.03
f_m3 [Hz]	71.0	m3 [A]	0.003	m3 [%]	0.05
f_m4 [Hz]	94.7	m4 [A]	0.010	m4 [%]	0.16

Ustawienia		
Progi alarmowe	Opcje wykresów	Skale i jednostki

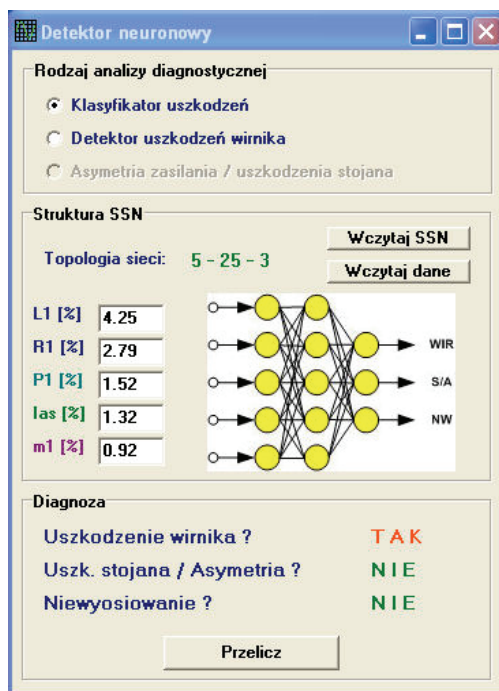
Rys. 11.6. Okno analizatora diagnostycznego

Analizator diagnostyczny umożliwia zdefiniowanie progów alarmowych poszczególnych cech diagnostycznych. Jeżeli jakaś cecha przekroczy próg alarmowy, stan ten zostanie natychmiast zasygnalizowany przez podświetlenie wartości danej cechy w kolorze czerwonym. Funkcja ta ułatwia szybką ocenę stanu technicznego badanego silnika. Oczywiście, skuteczność przeprowadzonej analizy diagnostycznej zależy w głównej mierze od poprawnego zdefiniowania progów alarmowych, stosownie do typu badanego silnika. Dlatego też, czynność ta musi być wykonana przez doświadczonego operatora, mającego odpowiednią wiedzę diagnosty-eksperta.

Moduł detektora neuronowego przeprowadza w sposób automatyczny proces wnioskowania diagnostycznego, którego celem jest postawienie ostatecznej diagnozy dotyczącej rodzaju i stopnia uszkodzenia badanego silnika. Program korzysta bezpośrednio z wyników działania modułu analizatora diagnostycznego, traktując je jako dane wejściowe do uprzednio wytrenowanej sztucznej sieci neuronowej, pełniącej

funkcję analizatora lub detektora uszkodzeń. Przykład działania programu w trybie klasyfikatora uszkodzeń przedstawiono na rysunku 11.7.

Moduł detektora neuronowego umożliwi wczytanie dowolnej sieci neuronowej, której struktura jest zapisana w postaci odpowiednio sformatowanego pliku tekstowego. Dzięki temu, możliwe jest późniejsze dołączanie nowych sieci neuronowych, pełniących różne funkcje diagnostyczne.



Rys. 11.7. Przykład modułu detektora neuronowego w trybie klasyfikatora uszkodzeń

Przedstawiony komputerowy system diagnostyczny silnika indukcyjnego jest praktycznym urządzeniem pomiarowym, umożliwiającym określenie stanu technicznego silników indukcyjnych o różnych mocach, na podstawie pomiaru jedynie sygnałów prądu stojana. Integralną częścią systemu jest oprogramowanie diagnostyczne, które umożliwia przeprowadzenie szczegółowej analizy zarejestrowanych danych pomiarowych oraz ekstrakcję wybranych cech diagnostycznych, charakterystycznych dla wybranych typów uszkodzeń silnika, takich jak uszkodzenia wirnika i stojana, asymetria napięcia zasilającego oraz niewspółosiowe sprzęgnięcie silnika z maszyną roboczą.

Zastosowanie metod sztucznych sieci neuronowych w postaci dodatkowego modułu programowego – neuronowego detektora uszkodzeń, umożliwia rozszerzenie

funkcjonalnego systemu diagnostycznego o automatyczną ocenę rodzaju i stopnia uszkodzenia silnika, co zwalnia użytkownika z konieczności posiadania specjalistycznej wiedzy eksperckiej w zakresie diagnostyki napędu z silnikami indukcyjnymi. Ponadto, otwarta budowa systemu umożliwi bezproblemowe dołączanie nowych struktur sieci neuronowych, uprzednio wytrenowanych i zapisanych w postaci plików tekstowych.

System diagnostyczny ma duże możliwości rozbudowy, zarówno od strony sprzętowej, jak i programowej. Dołączenie do układu pomiarowego dodatkowego czujnika drgań pozwala na rozszerzenie możliwości systemu o kolejne funkcje diagnostyczne, takie jak możliwość oceny stanu łożysk silnika czy też diagnostyka przekładni mechanicznej. Z kolei otwarta, modułowa forma oprogramowania umożliwia łatwe dołączanie kolejnych modułów funkcjonalnych do programu, co praktycznie daje nieograniczone możliwości rozbudowy. Dużą zaletą systemu diagnostycznego jest bardzo niski koszt jego wykonania, który wynika głównie z zastosowania prostych rozwiązań sprzętowych, połączonych z wydajnym oprogramowaniem diagnostycznym.

11.3. Komputerowy system do monitorowania i diagnostyki uzwojenia stojana

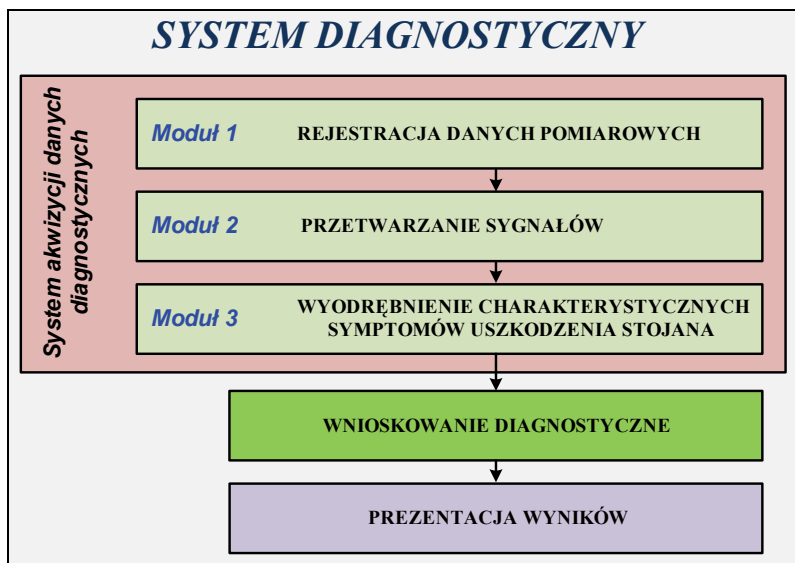
Koncepcja i wstępna realizacja komputerowego systemu do monitorowania i diagnostyki uzwojeń stojana silnika indukcyjnego, pracującego w czasie rzeczywistym, powstała w ramach rozprawy doktorskiej dr Marcina Wolkiewicza [11.10] i jest kontynuowana w ramach projektu badawczego [11.11, 11.12]. System został zrealizowany w środowisku programistycznym LabVIEW i uruchomiony w komputerze przemysłowym NI PXI 8186 firmy National Instruments. Struktura systemu została przedstawiona na rysunku 11.8.

System diagnostyczny ma następujące bloki funkcjonalne:

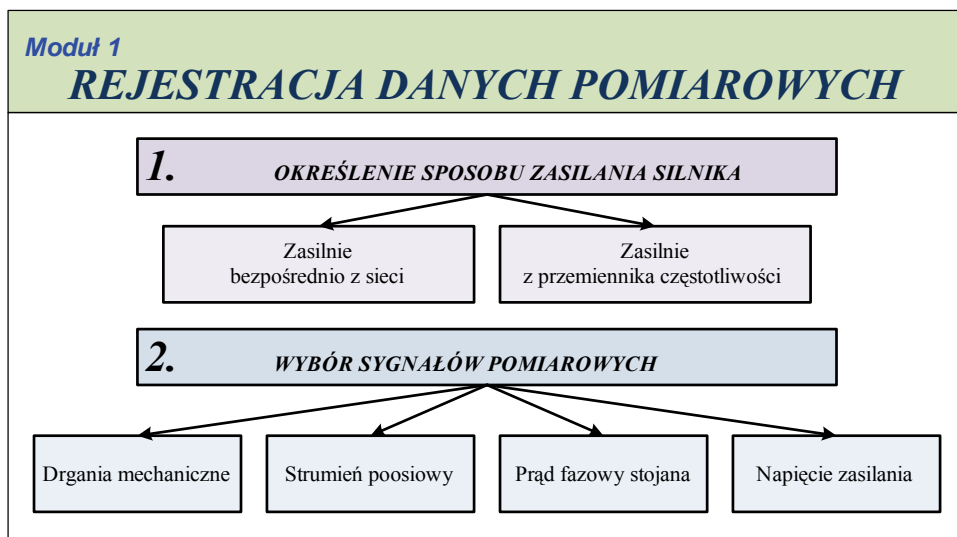
- rejestrację danych pomiarowych (moduł 1),
- przetwarzanie sygnałów (moduł 2),
- wyodrębnienie charakterystycznych symptomów uszkodzenia (moduł 3),
- wnioskowanie diagnostyczne,
- prezentację wyników.

Przed przystąpieniem do właściwej pracy system musi zostać odpowiednio skonfigurowany. Moduł 1, związany z *rejestracją danych pomiarowych*, umożliwia w pierwszej kolejności wybór sposobu zasilania silnika indukcyjnego (rys. 11.9):

- zasilanie bezpośrednio z sieci,
- zasilanie z przemiennika częstotliwości.



Rys. 11.8. Struktura systemu diagnostycznego do monitorowania i diagnostyki uzwojeń stojana



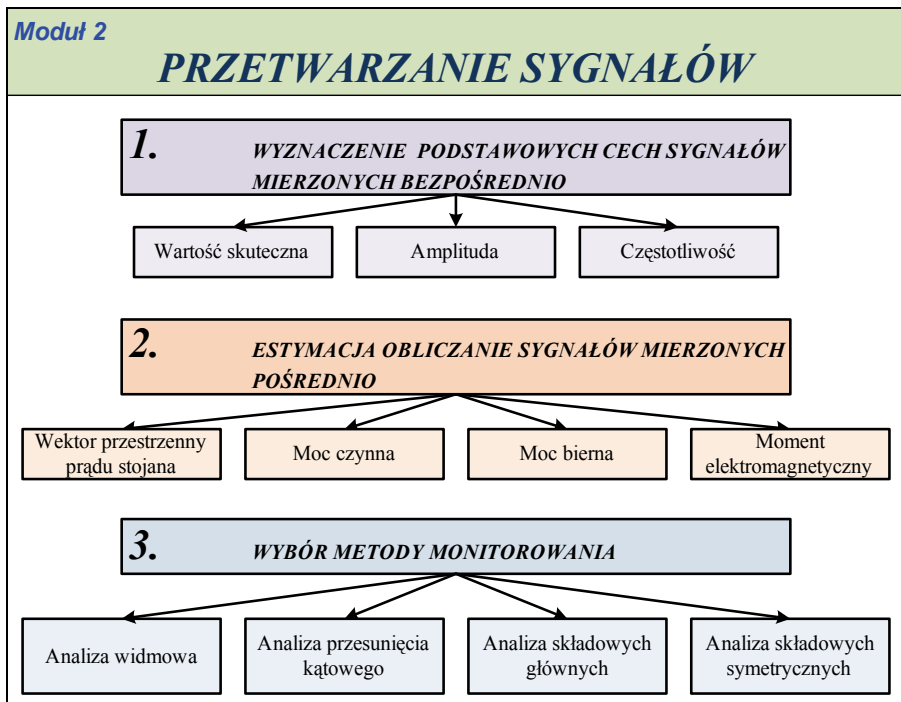
Rys. 11.9. Moduł 1 – rejestracja sygnałów pomiarowych

W przypadku zasilania silnika z przemiennika częstotliwości możliwa jest również zmiana częstotliwości napięcia zasilania $f_s = 20 \div 50$ Hz w otwartej strukturze sterowania ($U/f = \text{const}$). Ponadto niezbędne jest wprowadzenie informacji o parametrach badanego silnika, zakresach pomiarowych itp. Następnie do wyboru jest

kilka torów pomiarowych, związanych z zastosowanymi czujnikami pomiarowymi sygnałami diagnostycznymi. System umożliwi pomiar czterech rodzajów sygnałów diagnostycznych:

- pomiar przyspieszenia drgań mechanicznych w trzech osiach,
- pomiar napięcia indukowanego przez strumień poosiowy z zastosowaniem cewki pomiarowej,
- pomiar prądów fazowych stojana w trzech fazach silnika,
- pomiar napięć międzyfazowych.

Wybór sygnałów pomiarowych jest uzależniony od metod diagnostycznych wybranych w module 2 systemu diagnostycznego.



Rys. 11.10. Moduł 2 – przetwarzanie sygnałów

Na rysunku 11.10 przedstawiono zawartość modułu 2, związanego z *przetwarzaniem sygnałów*. W pierwszym kroku wyznaczane są podstawowe cechy sygnałów mierzonych bezpośrednio na obiekcie: wartość skuteczna, amplituda oraz częstotliwość. W zależności od wyboru analizowanych sygnałów możliwe jest obliczenie (estymacja) sygnałów dostępnych pośrednio, tj. wektora przestrzennego prądu stojana, mocy chwilowej czynnej i biernej oraz momentu elektromagnetycznego. Następnym krokiem jest wybór metody analizy sygnałów diagnostycznych do monitorowania

i diagnostyki uzwojeń stojana. W systemie istnieje możliwość realizacji analizy sygnałów według czterech metod diagnostycznych:

- analiza widmowa sygnałów,
- analiza przesunięcia kąтового sygnałów,
- analiza składowych głównych PCA,
- analiza składowych symetrycznych.

Możliwy jest wybór jednej metody lub grupy metod. Należy jednak zwrócić uwagę na możliwości obliczeniowe sprzętu komputerowego, gdyż każda z metod wymaga przynajmniej kilku procedur obliczeniowych, co może to istotnie wydłużyć czas obliczeń. W szczególności może to być istotne przy konieczności realizacji analizy widmowej kilku sygnałów. Dla wybranej metody należy ustalić wartości parametrów określających dokładność przetwarzania sygnałów.

Moduł 3, przedstawiony na rysunku 11.11, umożliwia wyodrębnienie charakterystycznych symptomów uszkodzenia uzwojenia stojana, na podstawie określonych metod analizy sygnałów diagnostycznych, opisanych w rozdziale 9.

Wyodrębnione symptomy uszkodzenia są następnie poddawane ocenie w bloku funkcjonalnym *wnioskowanie diagnostyczne*. W bloku mogą być wymiennie realizowane procedury diagnostyczne umożliwiające dokonanie oceny aktualnego stanu uzwojeń badanego silnika. W zależności od potrzeb mogą to być proste kryteria oceniające wartości amplitudy charakterystycznych częstotliwości lub bardziej złożone kryteria oceny oparte na wielu charakterystycznych wyodrębnionych cechach. W szczególności w tym bloku mogą być zastosowane neuronowe detektory uszkodzeń przedstawione w rozdziale 9. Struktura detektora musi być wcześniej opracowana poza systemem, metodami off-line i na podstawie danych zebranych w trakcie eksploatacji napędu. Przetestowana struktura sieci neuronowej może być programowo wprowadzona do systemu i dostarczać w czasie rzeczywistym informacji o aktualnym stanie uzwojeń stojana.

Ostatni blok funkcjonalny systemu ma również charakter wymienny i dotyczy prezentacji wyników działania systemu. Może zawierać elementy niezbędne, które pozwolą nawet niedoświadczonemu użytkownikowi na sprawne posługiwanie się systemem, wizualizację aktualnych parametrów badanego napędu, przebiegów mierzonych wielkości oraz mniej lub bardziej szczegółowych wyników analiz sygnałów, odpowiedzi wypracowywane przez detektory neuronowe.

Opracowana wersja laboratoryjna prototypowego systemu diagnostycznego umożliwia analizę i ocenę stanu uzwojeń stojana silnika indukcyjnego w czasie rzeczywistym. Całość została wykonana w środowisku LabVIEW. Przeprowadzone badania wykazały, że proponowane rozwiązania mogą być zastosowane, jako uzupełnienie obecnie stosowanych systemów diagnostycznych lub jako niezależny system.

Moduł 3

WYODRĘBNIANIE CHARAKTERYSTYCZNYCH SYMPTOMÓW USZKODZENIA STOJANA

1. ANALIZA WIDMOWA SYGNAŁÓW

Prąd fazowy stojana	$\hat{f}_{m1} = f_s \left(k \left(\frac{1-s}{p_s} \right) \pm m \right)$	$\hat{f}_{m2} = f_s \left(kN_s \left(\frac{1-s}{p_s} \right) \pm m \right)$
Moduł wektora przestrzennego prądu stojana	$2nf_s$	
Strumień poosiowy	$f_s, f_{st} = kf_s \pm nf_r$	
Moc chwilowa (czynna, bierna)	$2nf_s$	
Moment elektromagnetyczny	$2nf_s$	
Drgania mechaniczne	$2nf_s$	

2. ANALIZA PRZESUNIĘCIA KĄTOWEGO

Przesunięcie fazowe pomiędzy napięciem a prądem stojana	$\xi_A = \phi_0 - \phi_A$	$\xi_B = \phi_0 - \phi_B$	$\xi_C = \phi_0 - \phi_C$
Przesunięcie kątowe pomiędzy prądami fazowymi stojana	$\varepsilon^{AB} = 120 - \phi^{AB}$	$\varepsilon^{BC} = 120 - \phi^{BC}$	$\varepsilon^{CA} = 120 - \phi^{CA}$
Przesunięcie kątowe pomiędzy prądami fazowymi stojana	$\varepsilon^{\alpha\beta} = 90 - \phi^{\alpha\beta}$		

3. ANALIZA SKŁADOWYCH GŁÓWNYCH

Indeks intensywności zmian wartości głównych	$\lambda_{PCA} = \frac{\lambda_1 - \lambda_2}{\lambda_1}$	
Wektory kierunkowe	$\gamma^2 = [\lambda_1 \gamma_1^2 \quad \lambda_2 \gamma_2^2]$	$\gamma^1 = [\lambda_1 \gamma_1^1 \quad \lambda_2 \gamma_2^1]$

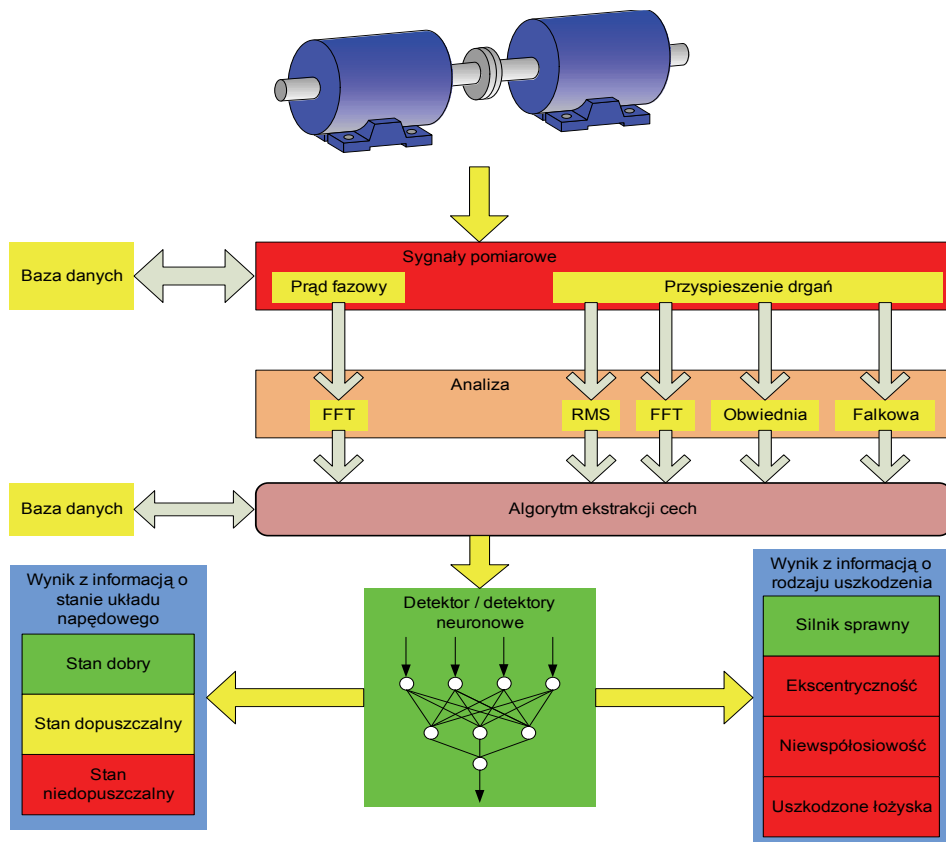
4. ANALIZA SKŁADOWYCH SYMETRYCZNYCH

Składowe symetryczne prądu stojana	$I_1^{(fs)}$	$I_2^{(fs)}$
Składowe symetryczne napięcia zasilania	$U_1^{(fs)}$	$U_2^{(fs)}$
Składowe symetryczne impedancji	$Z_1^{(fs)}$	$Z_2^{(fs)}$

Rys. 11.11. Moduł 3 – wyodrębnianie charakterystycznych symptomów uszkodzenia stojana

11.4. Komputerowy system do monitorowania i diagnostyki uszkodzeń mechanicznych

Koncepcja i wstępna realizacja komputerowego systemu do monitorowania i diagnostyki wybranych uszkodzeń mechanicznych silnika indukcyjnego, pracującego w czasie rzeczywistym, powstała w ramach rozprawy doktorskiej dr. Pawła Ewerta [11.1] i kontynuowana jest w ramach projektu badawczego [11.2]. Komputerowy system do monitorowania uszkodzeń mechanicznych układów napędowych z silnikami indukcyjnymi został opracowany w środowisku LabView, natomiast detektory neuronowe zostały przygotowane w środowisku Matlab–Simulink i stanowią elementy składowe kompletnego systemu diagnostycznego. Na rysunku 11.12 przedstawiono strukturę blokową systemu diagnostycznego opartego na pomiarze i analizie sygnałów prądu stojana i drgań mechanicznych.



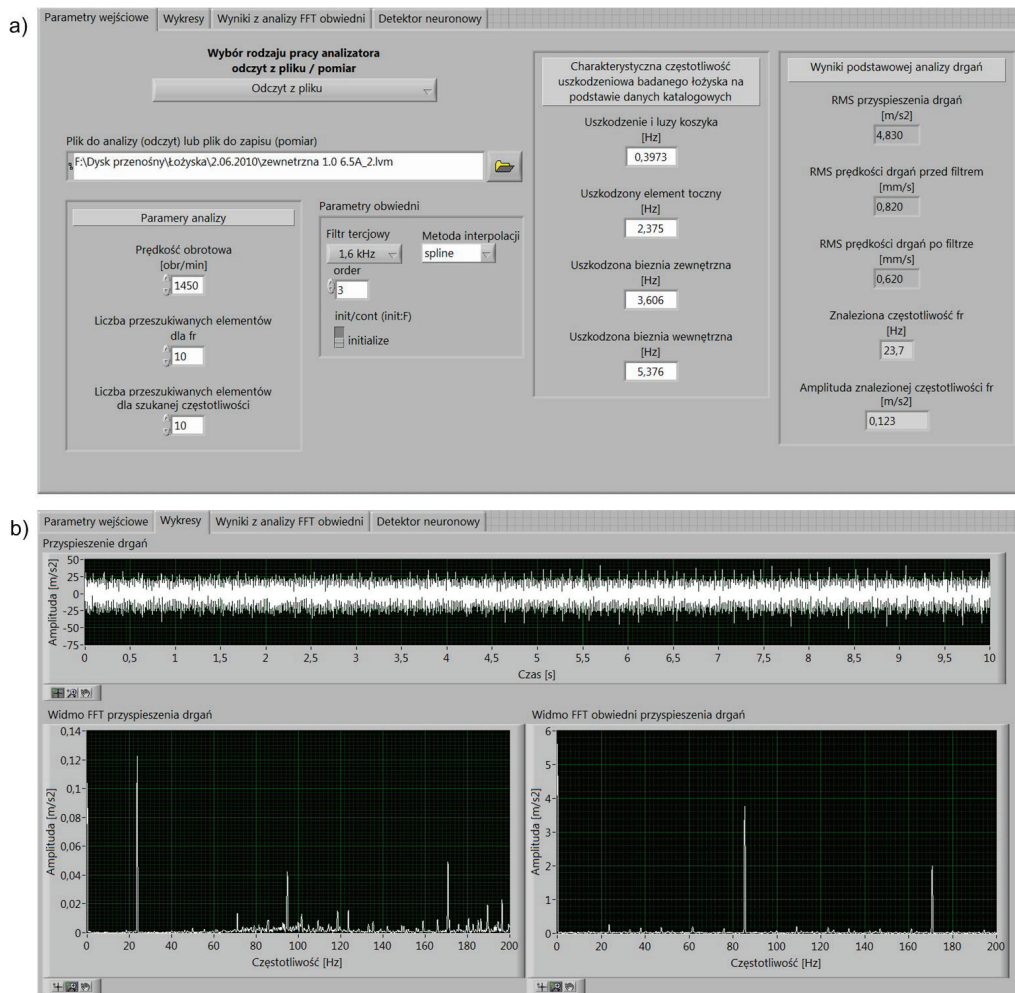
Rys. 11.12. Struktura systemu do monitorowania i diagnostyki uszkodzeń mechanicznych

- W budowie systemu diagnostycznego przyjęto następujące założenia wyjściowe:
- neuronowy detektor pełni rolę wspomagającą proces decyzyjny operatora nadzorującego pracę układu napędowego,
 - detektor pracuje w trybie on-line i na bieżąco dostarcza informacje o stanie technicznym badanego układu oraz rodzaju uszkodzenia,
 - praca detektora neuronowego oparta jest na informacjach dostarczanych na bieżąco do wejść i uzyskanych w procesie ekstrakcji cech diagnostycznych,
 - ekstrakcja cech odbywa się na podstawie analizy sygnałów diagnostycznych: prądu stojana i drgań mechanicznych,
 - podstawowymi analizami wykorzystanymi w systemie diagnostycznym są:
 - klasyczna analiza FFT prądu stojana i drgań mechanicznych,
 - analiza oparta na wartości skutecznej przyspieszenia drgań,
 - analiza obwiedni przyspieszenia drgań,
 - analiza falkowa przyspieszenia drgań.
 - neuronowy detektor uszkodzeń mechanicznych powinien działać prawidłowo w szerokim zakresie zmian obciążenia, częstotliwości napięcia zasilającego oraz być odporny na zakłócenia zewnętrzne.
 - system diagnostyczny powinien umożliwiać tworzenie bazy danych sygnałów diagnostycznych oraz informacji wykorzystywanych do uczenia i testowania sieci neuronowej,
 - sieć neuronowa może być uczona w trybie off-line lub on-line,
 - detektor neuronowy może wskazywać stan napędu, tzn.: dobry, dopuszczalny lub niedopuszczalny lub rodzaj uszkodzenia mechanicznego (ewentualnie stopień uszkodzenia).

Zmierzone sygnały mogą być na bieżąco archiwizowane i przechowywane w bazie danych. W każdej chwili możliwe jest odczytanie zapisanych pomiarów i poddanie ich szczegółowej analizie. W przypadku prezentowanego systemu diagnostycznego prąd stojana poddawany jest szybkiej transformacji Fouriera, natomiast drgania mechaniczne dodatkowo analizie obwiedni, transformacji falkowej oraz analizie wartości skutecznej. W kolejnym kroku obliczeniowym dokonywana jest ekstrakcja cech związanych z uszkodzeniami. Na podstawie literatury oraz licznych badań laboratoryjnych wybrano charakterystyczne częstotliwości, które można uznać za symptomy ekscentryczności, niewyosiowania oraz uszkodzenia łożysk tocznych. Znając wartości charakterystycznych częstotliwości uszkodzeniowych, można je zidentyfikować w widmie analizowanych sygnałów. Opracowano algorytm umożliwiającego automatyczne „przezesywanie” widma i identyfikowanie charakterystycznych częstotliwości uszkodzeniowych.

Algorytm umożliwia wyszukiwanie każdej częstotliwości f w cyfrowym zapisie analizowanego widma. Został on zaimplementowany do programów ekstrakcji symptomów uszkodzeń w widmie prądu stojana, drgań mechanicznych oraz obwiedni drgań mechanicznych. Uzyskane w ten sposób cechy można archiwizować lub też podawać na odpowiednie wejścia detektorów neuronowych. Przykłady przebadanych

off-line detektorów neuronowych, zbudowanych na zarchiwizowanych cechach przedstawiono w rozdziale 10.



Rys. 11.13. *Front Panel* analizatora uszkodzeń łożyska z podziałem na zakładki – część 1:
a) parametry wejściowe, b) wykresy

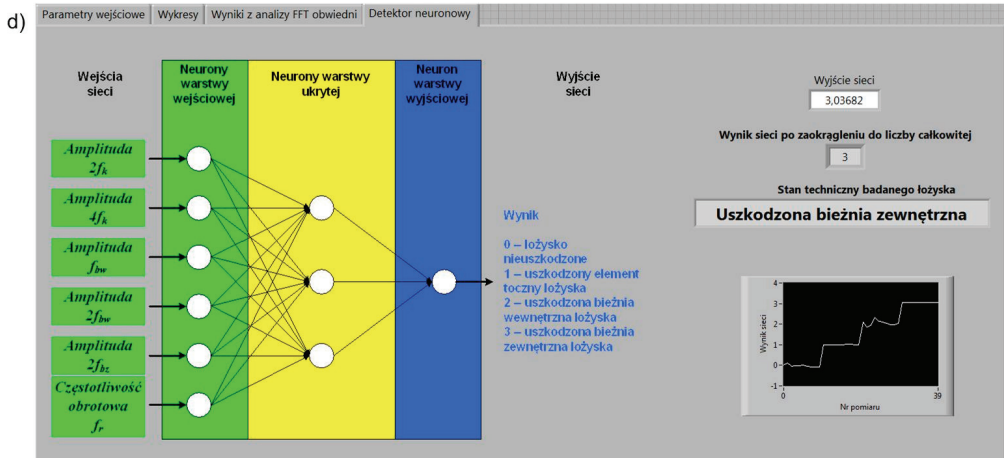
Na rysunku 11.13 – część 1 i 2 przedstawiono *Front Panel* analizatora do wykrywania uszkodzeń łożysk tocznych z podziałem na zakładki:

- parametry wejściowe,
- wykresy,
- wyniki z analizy FFT obwiedni,
- detektor neuronowy.

- wykresy,
- wyniki z analizy FFT obwiedni,
- detektor neuronowy.

c)

Uszkodzenie i luzy koszyka			Uszkodzenie elementu tocznego			Uszkodzenie bieżni zewnętrznej			Uszkodzenie bieżni wewnętrznej		
Szukana częstotliwość [Hz]	Znaleziona częstotliwość [Hz]	Amplituda [m/s ²]	Szukana częstotliwość [Hz]	Znaleziona częstotliwość [Hz]	Amplituda [m/s ²]	Szukana częstotliwość [Hz]	Znaleziona częstotliwość [Hz]	Amplituda [m/s ²]	Szukana częstotliwość [Hz]	Znaleziona częstotliwość [Hz]	Amplituda [m/s ²]
14,284	14,2	0,0662163	32,5875	33,1	0,110116	61,7622	61,8	0,202507	103,711	104,2	0,0266825
9,41601	9,4	0,047816	56,2875	56,1	0,0306281	85,4622	85,3	3,76493	127,411	127,7	0,0371621
33,116	33,1	0,110116	79,9875	79,9	0,0216707	109,162	109	0,194617	151,111	150,5	0,0372469
4,86798	5,5	0,0308041	88,875	89,3	0,0370434	147,224	147,1	0,138616	231,122	230,6	0,0402066
18,832	18,2	0,0237694	112,575	112,5	0,0351187	170,924	170,7	2,00377	254,822	254,2	0,018596
42,532	42,4	0,0341756	136,275	136,5	0,0281069	194,624	194,4	0,103853	278,522	278,1	0,0209846
4,54803	5	0,0265489	145,163	145,3	0,0565209	232,687	232,5	0,0487759	358,534	358,3	0,0183033
28,248	28,3	0,0450231	168,863	168,4	0,0358936	256,387	256,1	0,57595	382,234	381,8	0,0394851
51,948	52,3	0,0696455	192,562	192,1	0,0397816	280,087	279,7	0,0173012	405,934	405,4	0,00973398
13,964	14,2	0,0662163	201,45	201,6	0,0508088	318,149	317,6	0,0176751	485,945	486,8	0,0114792
37,664	38,1	0,150085	225,15	225,4	0,0171488	341,849	341,4	0,123914	509,645	509,8	0,00720967
61,364	61,8	0,202507	248,85	248,9	0,012733	365,549	365,3	0,0234653	533,345	533,3	0,00541931



Rys. 11.13. Front Panel analizatora uszkodzeń łożyska z podziałem na zakładki – część 2:
 c) wyniki z analizy FFT obwiedni, d) detektor neuronowy

Jednocześnie, za pomocą analizy widmowej oraz analizy obwiedni, obliczana jest wartość skuteczna:

- przyspieszenie drgań w całym zmierzonym pasmie częstotliwości,
- prędkość przyspieszenia drgań w całym zmierzonym pasmie częstotliwości,
- prędkość drgań w zakresie 10–1000 Hz.

W zakładce *parametry wejściowe* dokonuje się wstępnych ustawień następujących elementów:

- wybór rodzaju pracy analizatora (pomiar lub odczyt z pliku),
- plik do analizy (odczytu) lub plik do zapisu (pomiar),
- przybliżona prędkość silnika – dokładnie zostanie ona określona przez program na podstawie widma przyspieszenia drgań,
- liczba przeszukiwanych elementów do wyszukania w widmie (częstotliwość f_r i jej krotność oraz charakterystyczne częstotliwości uszkodzeniowe łożyska),
- parametry analizy obwiedni,
- charakterystyczne częstotliwości uszkodzeniowe badanego łożyska na podstawie danych katalogowych.

Ponadto otrzymuje się wyniki podstawowej analizy, takie jak:

- wartość skuteczną przyspieszenia drgań (obliczana z całego analizowanego pasma częstotliwości),
- wartość skuteczną prędkości drgań przed filtrem (obliczana z całego analizowanego pasma częstotliwości),
- wartość skuteczną prędkości drgań po filtrze (obliczana z pasma 10–1000 Hz),
- wyszukaną w widmie częstotliwość f_r oraz jej amplitudę.

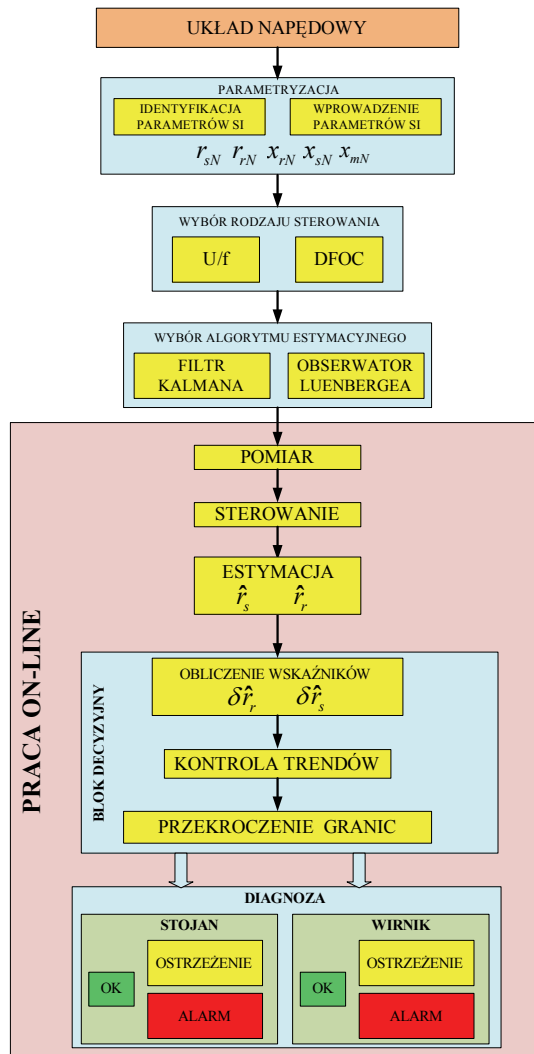
W zakładce *wykresy* umieszczono przebieg czasowy analizowanego sygnału przyspieszenia drgań oraz widmo FFT przyspieszenia drgań i obwiedni przyspieszenia drgań. Wartości osi X oraz Y zostały domyślnie dobrane, jednak możliwa jest ich edycja przez dwukrotne kliknięcie wybranej liczby na osi. W zakładce *wyniki z analizy FFT obwiedni* umieszczono szczegółowe zestawienie dwunastu wybranych częstotliwości dla każdego uszkodzenia konstrukcyjnego łożyska. W zakładce *detektor neuronowy* umieszczono wyniki badania stanu technicznego łożyska przez sieć neuronową o wcześniej zdefiniowanej strukturze. Wyniki prezentowane są w postaci graficznej oraz wartości na wyjściu neuronu wyjściowego (wartość dokładna oraz zaokrąglona do liczby całkowitej). Ponadto wyświetlany jest stosowny komunikat informujący o rodzaju uszkodzenia.

Przeprowadzone badania laboratoryjne na obiekcie rzeczywistym wykazały, że zaproponowana wersja systemu diagnostycznego ułatwia monitorowanie stanu technicznego łożysk tocznych.

11.5. Komputerowy system do monitorowania i diagnostyki uzwojeń stojana i wirnika oparty na estymacji parametrów

Koncepcja i wstępna realizacja komputerowego systemu do monitorowania i diagnostyki uzwojeń stojana i wirnika silnika indukcyjnego, pracującego w zamkniętej

i otwartej strukturze sterowania, powstała w ramach rozprawy doktorskiej dr. Roberta Wierzbickiego [11.9] i kontynuowana jest w ramach projektu badawczego [11.3]. Wyniki badań eksperymentalnych przedstawione w rozdziale 6 wykazały, że do monitorowania stanu uzwojeń wirnika i stojana silnika indukcyjnego, pracującego w otwartej lub zamkniętej strukturze sterowania, można wykorzystać znane algorytmy estymacyjne: rozszerzony filtr Kalmana oraz rozszerzony obserwator Luenbergera. Na rysunku 11.14 przedstawiono schemat ideowy komputerowego systemu do monitorowania stanu uzwojeń.



Rys. 11.14. Schemat blokowy prototypowego systemu do monitorowania stanu uzwojeń

Na podstawie analizy zmian rezystancji zastępczej stojana i wirnika lub wskaźników obliczanych na ekran systemu komputerowego wyprowadzana jest informacja o stanie uzwojeń. Zielona kontrolka OK sygnalizuje poprawny stan uzwojeń, początkowy stan uszkodzenia (dla badanych w laboratorium silników: od 1 do 3 przerwanych prętów wirnika lub zwarcie od 1 do 8 zwojów stojana) sygnalizuje żółta kontrolka OSTRZEŻENIE. W przypadku większego poziomu uszkodzenia następuje automatyczne wyłączenie napędu i wyświetlenie na ekranie napisu ALARM.

Opracowana wersja laboratoryjna prototypowego systemu diagnostycznego umożliwia analizę stanu uzwojeń silnika w czasie rzeczywistym. Ze względu na skomplikowany algorytm obliczeniowy zastosowanych estymatorów, które stawiają wysokie wymagania odnośnie do dokładności obliczeń numerycznych, jedynym rozwiązaniem było zastosowanie w realizacji praktycznej nowoczesnego procesora sygnałowego. W związku z tym, do implementacji systemu wykorzystano komputer PC klasy *Pentium III* 500 MHz wyposażonego w kartę procesora sygnałowego dSpace DS1104 wraz z oprogramowaniem, przeznaczonym do nadzorowania pracy karty oraz akwizycji danych. Jako środowiska programowego użyto oprogramowania dostarczonego przez producenta platformy z procesorem sygnałowym: ControlDesk. Aplikacja laboratoryjna w całości została napisana w języku C. Krok obliczeń numerycznych wynosił $t = 100 \mu\text{s}$. Przeprowadzone badania wykazały, że proponowane rozwiązanie może być zastosowane, jako uzupełnienie obecnie stosowanych systemów diagnostycznych lub jako niezależny system.

Złożoność obliczeniowa algorytmów sterowania i estymacji w czasie rzeczywistym oraz konieczność sterowania i nadzorowania wieloma dodatkowymi czynnościami powodują, że do realizacji systemu diagnostycznego niezbędne jest zastosowanie procesora sygnałowego o dużej mocy i szybkości obliczeniowej. Wydaje się, że proponowane rozwiązanie może być jednym z dodatkowych modułów rozszerzających możliwości procesorów obecnie wykorzystywanych w przemiennikach częstotliwości stosowanych w napędzie przekształtnikowym prądu przemiennego.

Literatura

- [11.1] Ewert.P., *Diagnostyka mechanicznych uszkodzeń napędów z silnikami indukcyjnymi przy wykorzystaniu sieci neuronowych*, Rozprawa doktorska, Politechnika Wroclawska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2012.
- [11.2] Ewert.P., Kowalski C.T., *The system for monitoring and diagnosis of the condition of induction motor rolling bearings*, Proc. of Int. Confer. on Electrical Drives and Power Electronics EDPE 2013, Dubrovnik, Croatia, 2013, CD.
- [11.3] Kowalski C., Wierzbicki R., Wolkiewicz M., *Stator and Rotor Faults Monitoring of the Inverter-Fed Induction Motor Drive using State Estimators*, *Automatika – Int. Journal for Control, Measurement, Electronics, Computing and Communications*, Vol. 54, No. 3, 2013, 348–355.

-
- [11.4] Pawlak M., Kowalski C.T., *Zastosowanie neuronowego detektora do monitorowania i diagnostyki wirników klatkowych silników indukcyjnych*, Maszyny Elektryczne – Zeszyty Problemowe, nr 69, 2004, KOMEL, 110–116.
 - [11.5] Pawlak M., Kowalski C.T., *Zastosowanie analizy częstotliwościowej prądu do wykrywania uszkodzeń wirników silników indukcyjnych zasilanych z przemiennika częstotliwości*, Maszyny Elektryczne – Zeszyty Problemowe, nr 71, 2005, 97–101.
 - [11.6] Pawlak M., *Zastosowanie metod sztucznej inteligencji do wykrywania uszkodzeń wirnika silnika indukcyjnego*, Rozprawa doktorska, Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2005.
 - [11.7] Pawlak M., Kowalski C.T., *Komputerowy system diagnostyczny silnika indukcyjnego*, Przegląd Elektrotechniczny, R. 84, nr 12, 2008, 91–95.
 - [11.8] Pawlak M., Kowalski C.T., *Low-cost embedded system for the IM fault detection using neural networks*, XIX Int. Conf. on Electrical Machines, ICEM 2010, CD, Rome, Italy, 2010, CD.
 - [11.9] Wierzbicki R., *Diagnostyka silników indukcyjnych z zastosowaniem estymatorów stanu i parametrów*, Rozprawa doktorska, Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2011.
 - [11.10] Wolkiewicz M., *Monitorowanie stanu uzwojeń stojana silnika indukcyjnego*, Rozprawa doktorska, Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, Wrocław 2012.
 - [11.11] Wolkiewicz M., Kowalski C.T., *A neural detector of the short-circuits based on the symmetrical components analysis for induction motor drives*, Proc. of Int. Confer. on Electrical Drives and Power Electronics EDPE 2013, Dubrovnik, Croatia, 2013, CD.
 - [11.12] Wolkiewicz M., Kowalski C.T., *On-line Neural Network-based Stator Fault Diagnosis System of the Converter-Fed Induction Motor Drive*, Proc. of the 39th Annual Conf. of the IEEE Industrial Electronics Society IECON'13, Vienna, Austria, 2013, CD.

Załącznik 1

Parametry badanych silników

SILNIK STg 80x-4c FIRMY BESEL

Moc znamionowa P_N	1100 W
Napięcie znamionowe U_N	230/400 V
Znamionowa częstotliwość napięcia zasilania f_N	50 Hz
Prąd znamionowy I_N	5,0/2,9 A
Prędkość znamionowa n_N	1400 obr/min
Liczba par biegunów	2
Sprawność znamionowa η	78 %
Moment znamionowy M_N	7,51 N·m
Liczba prętów w klatce wirnika N_r	22
Liczba zwojów w fazie stojana N_s	292

Parametry schematu zastępczego wyznaczone z próby biegu jałowego i zwarcia w jednostkach względnych:

Rezystancja uzwojenia stojana: $r_s = 0,08$ [pu]

Rezystancja uzwojenia wirnika: $r_r = 0,10$ [pu]

Reaktancja uzwojenia stojana: $x_s = 1,68$ [pu]

Reaktancja uzwojenia wirnika: $x_r = 1,68$ [pu]

Reaktancja główna (magnesująca): $x_m = 1,60$ [pu]

SILNIK SH 90L-4 firmy INDUKTA

Moc znamionowa P_N	1,5 kW
Napięcie znamionowe U_N	400 V
Znamionowa częstotliwość napięcia zasilania f_N	50 Hz
Prąd znamionowy I_N	5,3/3,5 A
Prędkość obrotowa n_N	1410 obr/min
Współczynnik mocy $\cos\varphi$	0,78
Sprawność η	79%
Prąd rozruchowy/prąd znamionowy I_r/I_N	5,3
Moment rozruchowy/moment znamionowy M_r/M_N	2,5
Moment znamionowy M_N	10,16 N·m
Liczba zwojów w fazie stojana N_s	312
Liczba prętów w klatce wirnika N_r	22
Liczba żłobków stojana	36
Liczba żłobków wirnika	26

Parametry schematu zastępczego wyznaczone z próby biegu jałowego i zwarcia w jednostkach względnych:

Rezystancja uzwojenia stojana: $r_s = 0,0737$ [pu]

Rezystancja uzwojenia wirnika: $r_r = 0,10$ [pu]

Reaktancja uzwojenia stojana: $x_s = 1,2918$ [pu]

Reaktancja uzwojenia wirnika: $x_r = 1,2918$ [pu]

Reaktancja główna (magnesująca): $x_m = 1,239$ [pu]

Jednostki bazowe do obliczeń wielkości względnych w modelu matematycznym silnika indukcyjnego

- napięcie bazowe

$$U_b = \sqrt{2}U_{sN} \quad (Z1.1)$$

- prąd bazowy

$$I_b = \sqrt{2}I_{sN} \quad (Z1.2)$$

- pulsacja bazowa

$$\Omega_b = 2\pi f_{sN} \quad (Z1.3)$$

- impedancja i rezystancja bazowa

$$Z_b = \frac{U_b}{I_b} = \Omega_b L_b \quad (\text{Z1.4})$$

- strumień bazowy

$$\Psi_b = \frac{U_b}{\Omega_b} \quad (\text{Z1.5})$$

- indukcyjność bazowa

$$L_b = \frac{\Psi_b}{I_b} = \frac{U_b}{I_b \Omega_b} \quad (\text{Z1.6})$$

- moc bazowa

$$S_b = \frac{3}{2} U_b I_b \quad (\text{Z1.7})$$

- prędkość kątowna mechaniczna bazowa

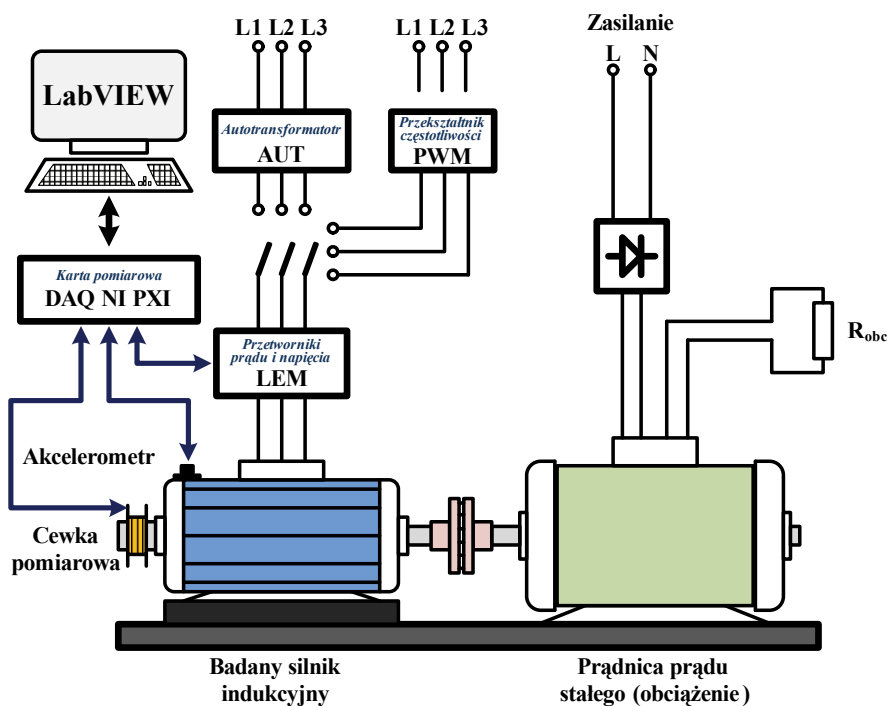
$$\Omega_{mb} = \frac{\Omega_b}{p_b} = \frac{2\pi f_{sN}}{p_b} \quad (\text{Z1.8})$$

- moment bazowy

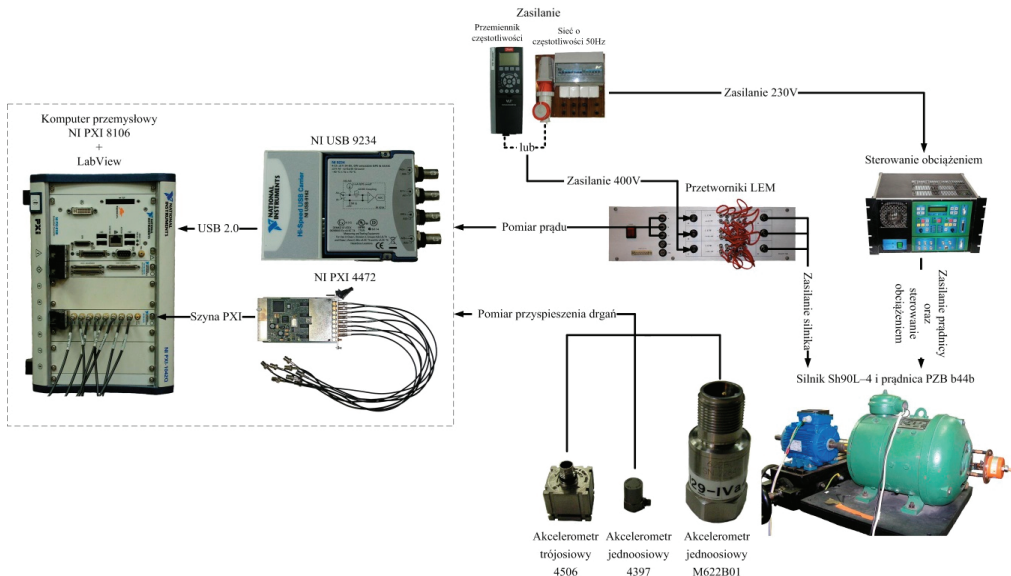
$$M_b = \frac{S_b}{\Omega_b} p_b = \frac{3}{2} p_b \frac{U_b I_b}{\Omega_b} \quad (\text{Z1.9})$$

Załącznik 2

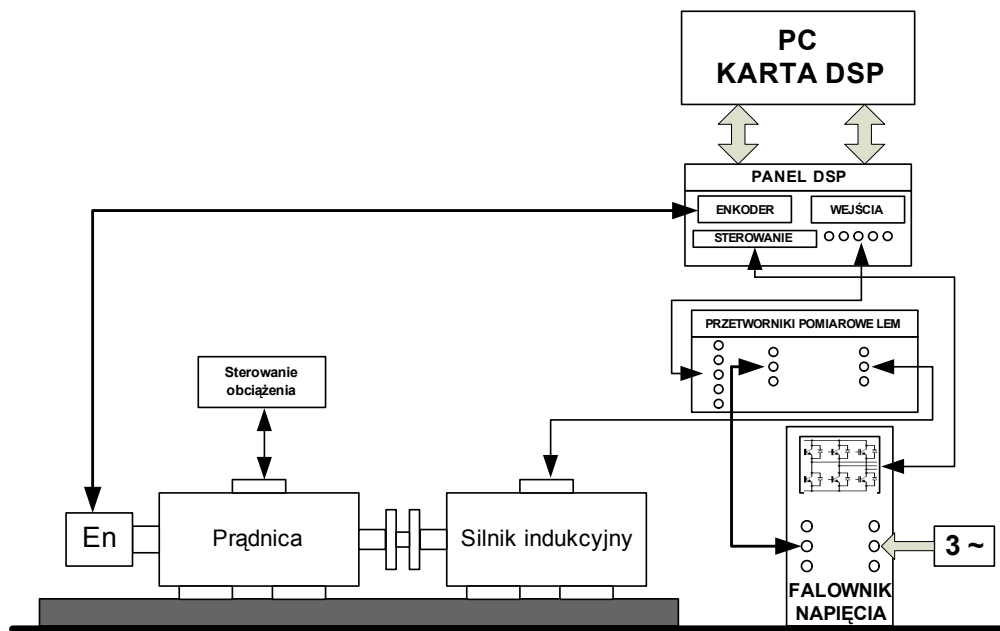
Schematy ideowe stanowisk badawczych



Rys. Z2.1. Schemat ideowy stanowiska laboratoryjnego do testowania metod monitorowania zwarć zwojowych



Rys. Z2.2. Schemat ideowy stanowiska laboratoryjnego do testowania metod monitorowania uszkodzeń mechanicznych



Rys. Z2.3. Schemat ideowy stanowiska laboratoryjnego do testowania metod monitorowania z zastosowaniem estymatorów stanu parametrów

W monografii scharakteryzowano aktualne problemy monitorowania i diagnostyki uszkodzeń maszyn i napędów elektrycznych. Omówiono sposoby pozyskiwania i przetwarzania informacji diagnostycznej za pomocą nieparametrycznych metod przetwarzania sygnałów. Przedstawiono metody wykrywania uszkodzeń najczęściej występujących w napędach elektrycznych z silnikami indukcyjnymi zasilanymi z sieci i przemienników częstotliwości oraz możliwości zastosowania metod sztucznej inteligencji do realizacji detektorów i klasyfikatorów uszkodzeń. Zwrócono również uwagę na problematykę matematycznego modelowania silnika indukcyjnego z uszkodzeniami obwodów elektrycznych oraz na zastosowanie estymatorów zmiennych stanu i parametrów do diagnostyki napędów przekształtnikowych.

Monografia zawiera informacje o metodach wykrywania uszkodzeń elektrycznych w uzwojeniach wirnika i stojana oraz wybranych uszkodzeń mechanicznych (łożysk tocznych, niewyosiowania i ekscentryczności) silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości. Na podstawie danych pomiarowych zebranych na rzeczywistych obiektach laboratoryjnych z zastosowaniem własnych rozwiązań systemów pomiarowo-diagnostycznych przedstawiono praktyczne zagadnienia projektowania detektorów i klasyfikatorów uszkodzeń z wykorzystaniem sieci neuronowych i neuronowo-rozmytych.

Zaprezentowane w monografii wyniki badań zostały zweryfikowane w warunkach laboratoryjnych oraz częściowo w warunkach przemysłowych. Stanowią one podsumowanie prac badawczych prowadzonych pod kierunkiem Autora w ostatnich dziesięciu latach w zespole badawczym w Instytucie Maszyn, Napędów i Pomiarów Elektrycznych na Wydziale Elektrycznym Politechniki Wrocławskiej. Były to prace realizowane w ramach projektów badawczych własnych, rozwojowych i promotorskich oraz prac na stopień kierowanych przez Autora monografii i finansowanych przez KBN, MNiSzW, NCN oraz NCBiR.



Wydawnictwa Politechniki Wrocławskiej są do nabycia w księgarni,
plac Grunwaldzki 13, 50-377 Wrocław, budynek D-1 PWr., tel. 71 320 29 35
Prowadzimy sprzedaż wysyłkową: zamawianie.ksiazek@pwr.wroc.pl

ISBN 978-83-7493-816-7