



Czesław T. Kowalski

Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych

Wrocław 2005



Czesław T. KOWALSKI

Monitoring and diagnostics of the induction motor faults
using neural networks



Czesław T. Kowalski

**Monitorowanie i diagnostyka
uszkodzeń silników indukcyjnych
z wykorzystaniem sieci neuronowych**



Oficyna Wydawnicza Politechniki Wrocławskiej · Wrocław 2005

130326

Recenzenci

Ignacy DUDZIKOWSKI

Lech M. GRZESIAK

Opracowanie redakcyjne

Maria IZBICKA

Korekta

Alina KACZAK

© Copyright by Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2005

OFICyna WYDAWNICZA POLITECHNIKI WROCLAWSKIEJ

Wybrzeże Wyspiańskiego 27, 50-370 Wrocław

ISSN 1733-0696

Drukarnia Oficyny Wydawniczej Politechniki Wrocławskiej. Zam. nr 953/2005.



324153L/1

518

2006 | 0043 | D

*Elektrotechnika, silnik indukcyjny, uszkodzenia, diagnostyka,
monitorowanie, sieci neuronowe, neuronowy detektor uszkodzeń*

Czesław T. KOWALSKI*

MONITOROWANIE I DIAGNOSTYKA USZKODZEŃ SILNIKÓW INDUKCYJNYCH Z WYKORZYSTANIEM SIECI NEURONOWYCH

Przedstawiono podstawowe problemy związane z monitorowaniem i diagnostyką silników indukcyjnych klasycznymi metodami wykrywania uszkodzeń, w połączeniu z nowymi możliwościami stworzonymi przez sztuczne sieci neuronowe. Omówiono przyczyny powstawania uszkodzeń elektrycznych i mechanicznych w silnikach indukcyjnych klatkowych. Scharakteryzowano podstawowe metody wykrywania uszkodzeń stosowane obecnie w diagnostyce eksploatacyjnej. Szczególną uwagę zwrócono na omówienie metod monitorowania i diagnostyki na podstawie analizy częstotliwościowej sygnałów prądu stojana, strumienia poosiowego oraz drgań mechanicznych. Zaprezentowano metodykę zastosowania sztucznych sieci neuronowych do wykrywania podstawowych uszkodzeń w silnikach indukcyjnych i budowania neuronowych detektorów uszkodzeń, mających za zadanie wspomóc klasyczne metody diagnozowania i zobiektywizować proces wykrywania i oceny uszkodzenia. Szczególną uwagę zwrócono na zastosowanie sieci typu perceptron wielowarstwowy oraz sieci samoorganizujących Kohonena do budowy neurodetektorów uszkodzeń, realizujących funkcje klasyfikatora uszkodzeń. Zbadano neuronowe detektory uszkodzeń wirników klatkowych, zwarć międzyzwojowych w stojanie oraz łożysk tocznych, opracowane na podstawie danych zebranych klasycznymi metodami na rzeczywistym obiekcie. Wykazano przydatność analizy falkowej do wstępnego przetwarzania sygnałów diagnostycznych w celu otrzymania danych przydatnych do trenowania i testowania neuronowych detektorów uszkodzeń. Przedstawiono wstępne wyniki badań laboratoryjnych neuronowych detektorów uszkodzeń wirników i łożysk tocznych, pracujących on-line na rzeczywistej maszynie i zrealizowanych programowo w komputerze PC z kartą kontrolera DSP.

* Politechnika Wrocławska, Instytut Maszyn, Napędów i Pomiarów Elektrycznych, 50-372 Wrocław, ul. Smoluchowskiego 19.

Wykaz ważniejszych oznaczeń

- B – indukcja magnetyczna [T]
 F – częstotliwość [Hz]
 f_c – 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 nieruchomym układzie współrzędnych α, β
- 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 kątowna, pulsacja [rad/s]
- ω_m – prędkość kątowna mechaniczna wirowania wirnika
- ω_s – pulsacja w stojanie

1. Wstęp

1.1. Diagnostyka techniczna obiektów przemysłowych

W ostatnich dziesięcioleciach nastąpił znaczny wzrost rozmiarów instalacji technologicznych w przemyśle energetycznym, maszynowym, chemicznym, hutniczym i wielu innych. Wynika to z dążenia do obniżenia kosztów jednostkowych produkcji, wzrostu wydajności i pociąga za sobą zwiększenie koncentracji wszelkiego rodzaju urządzeń (pomiarowych, sterujących, wykonawczych, napędowych). Tym samym gwałtownie wzrasta 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*) są wykorzystywane w ostatecznej, katastroficznej fazie awarii, natomiast stosowanie redundancji sprzętowej związane jest z dużymi kosztami i koniecznością rozbudowy systemów sterowania i nadzoru. 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 technik teorii sterowania, przetwarzania sygnałów i modelowania.

Diagnostyka techniczna stanowi obecnie nową dyscyplinę naukową rozwijającą się bardzo intensywnie w kraju i na świecie i dotyczy rozpoznawania stanu technicznego obiektu (urządzeń, maszyn, procesów) na podstawie aktualnie dostępnych informacji o obiekcie [36, 122, 123, 146, 148, 230]. Celem nadrzędnym diagnostyki technicznej jest zapewnienie wysokiej dyspozycyjności eksploatacyjnej maszyn i urządzeń, maksymalne zabezpieczenie ich przed awariami, ustalenie przyczyn powstałych uszkodzeń oraz sposobów ich uniknięcia. Współczesna diagnostyka tech-

niczna wykorzystuje najnowsze osiągnięcia teorii sterowania, teorii systemów, metod sztucznej inteligencji, informatyki, budowy maszyn i urządzeń, technologii procesów.

W skład działań związanych z diagnostyką wchodzi [238]:

- diagnozowanie, czyli szereg działań mających 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 Isermann'a i zaakceptowanej przez IFAC Komitet SAFEPROCESS w roku 1997 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 dalszej części pracy pojęcie *diagnostyka uszkodzeń* będzie 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** stanu obiektu (ang. *monitoring*), rozumiany jako realizowane w czasie rzeczywistym diagnozowanie obiektu polegające na zbieraniu i przetwarzaniu zmiennych procesowych oraz rozpoznawaniu nieprawidłowych zachowań obiektu (rozpoznawanie uszkodzeń) [146, 148]. Monitorowanie jest więc cyklicznie powtarzaniem formułowania diagnoz o stanie obiektu (zmianach stanu obiektu) i jest zwykle 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, mówi się o **nadzorowaniu** (ang. *supervision*). Do realizacji nadzorowania procesów służą systemy typu SCADA (ang. *Supervisory Control and Data Acquisition*) [146].


W obszarze diagnostyki technicznej rozwijane są obecnie różne metody i techniki. Inną drogą idą badania związane z diagnostyką techniczną procesów technologicznych [146, 148], a inną diagnostyka ogólnie rozumianych maszyn i urządzeń [38, 39, 216, 290].

Pierwsza faza badania stanu obiektu to detekcja uszkodzeń, czyli wykrywanie (ekstrakcja) symptomów uszkodzeń S , występujących w sygnałach diagnostycznych. Sygnałem diagnostycznym nazywany jest przebieg dowolnej zmiennej będącej nośnikiem informacji o stanie diagnozowanego obiektu. Za sygnały diagnostyczne można przyjąć wszystkie dostępne na obiekcie sygnały fizyczne lub tylko wybrane z tych

sygnałów pewne cechy (np. wartość skuteczna, częstotliwość itp.), czyli tzw. zmienne procesowe. Sygnałami diagnostycznymi mogą być również wielkości obliczane na podstawie wartości mierzonych sygnałów. Schemat ideowy procesu diagnozowania przedstawiono na rys. 1.1.

Ze względu na sposób pozyskiwania (generowania) sygnałów diagnostycznych można wyróżnić dwie podstawowe grupy metod detekcji uszkodzeń [146]:

- 1) metody wykorzystujące związki między zmiennymi charakteryzującymi obiekt (metody porównawcze),
- 2) metody bazujące na analizie i kontroli parametrów zmiennych charakteryzujących obiekt (metody bezpośrednie).




Rys. 1.1. Idea procesu diagnozowania

Fig. 1.1. The idea of diagnostic process

W metodach porównawczych system diagnostyczny wyposażony jest w model obiektu pracujący równolegle z obiektem diagnozowania. Ideę detekcji uszkodzeń

metodami porównawczymi przedstawiono na rys. 1.2. Sygnał diagnostyczny obliczany jest jako różnica między sygnałami wyjściowymi mierzonymi na obiekcie i używanymi z modelu. 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.

Modele analityczne (modele ilościowe) mogą być w postaci: estymatorów lub obserwatorów stanu, filtrów Kalmana, równań parzystości typu wejście–wyjście [96, 148, 230]. Metody porównawcze wywodzą się bezpośrednio z metod redundancyjnych i w przypadku gdy model ma postać analityczną, mówi się o tzw. redundancji analitycznej. Gdy residuum otrzymuje się z porównania sygnałów rzeczywistych z sygnałami z modeli neuronowych lub rozmytych, można mówić o redundancji informatycznej [96, 123, 124, 146], rozumianej jako szczególny przypadek redundancji analitycznej. Modele tworzone z wykorzystaniem metod sztucznej inteligencji są modelami jakościowymi lub jakościowo-ilościowymi.




Rys. 1.2. Ideowy schemat detekcji uszkodzenia przy zastosowaniu metody porównawczej

Fig. 1.2. Schematic diagram of fault detection using comparative method

Metody diagnostyki wykorzystujące modele matematyczne są bardzo wrażliwe na adekwatność zastosowanych modeli i zakłócenia pomiarowe. Podczas 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 [96].

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 itp. poszczególnych zmiennych lub dokonywana jest analiza tych zmiennych (np. analiza spektralna, analiza parametrów statystycznych, kontrola trendów, kontrola ograniczeń itp.) w celu wykrycia i wyodrębnienia symptomów uszkodzeń (rys. 1.3).



Rys. 1.3. Ilustracja działania z zastosowaniem klasycznych metod diagnostyki opartych na analizie sygnałów

Fig. 1.3. Operation scheme for classical diagnosis methods based on signal analysis

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

Aktualnie obserwuje się rosnące zainteresowanie zastosowaniem metod i technik sztucznej inteligencji (sieci neuronowych, logiki rozmytej i sieci neuro-rozmytych) w monitorowaniu i diagnostyce uszkodzeń obiektów [146, 148, 291]. Metody te w odniesieniu do diagnostyki procesów technologicznych umożliwiają zastąpienie modeli analitycznych modelami ilościowymi, natomiast w odniesieniu do diagnostyki takich obiektów, jak maszyny i urządzenia, stanowią atrakcyjne narzędzie ułatwiające przetwarzanie informacji diagnostycznej i detekcję uszkodzeń [86, 90, 152, 163, 168, 277, 290, 291].

1.2. Podstawowe zagadnienia monitorowania i diagnostyki silników indukcyjnych


1.2.1. Obsługa techniczna maszyn i układów napędowych

Współczesne zautomatyzowane procesy produkcyjne wymagają stosowania coraz bardziej skomplikowanych urządzeń, w tym również napędów elektrycznych. Maszyny elektryczne wraz z 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. Pozwala uniknąć przerw w produkcji, obniżyć koszty remontu i nakłady na bieżącą eksploatację [68, 152, 168].

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, pozwalające na 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 (rys. 1.4).



Rys. 1.4. Obsługa techniczna maszyn i układów napędowych:


a) środki obsługi, b) sposoby obsługi

Fig. 1.4. Technical maintenance of electrical machines and drives:

a) maintenance means, b) maintenance methods

W przypadku obsługi technicznej powiązanej z rodzajem uszkodzenia, użytkownik nie ma żadnego wpływu na stan maszyny elektrycznej. Każdy przestój zdarza się nagle i niezapowiedziane, a obsługa techniczna jest realizowana dopiero po wystąpieniu uszkodzenia. Ma to w praktyce sens tylko w niektórych sektorach działalności gospodarczej (np. w drobnym przemyśle i gospodarstwie domowym). 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 wysokie koszty związane z taką obsługą techniczną. Eksploatacja maszyny będzie optymalna, gdy wypadkowy koszt działań prewencyjnych i remontowych (plus ewentualnie straty produkcyjne spowodowane awariami) jest minimalny, a ponadto zapewnione jest bezpieczeństwo obsługi. Na rysunku 1.5 przedstawiono zależność globalnego kosztu eksploatacji od zakresu obsługi technicznej [196].



Rys. 1.5. Globalny koszt eksploatacji w funkcji zakresu zapobiegania

Fig. 1.5. Global operating costs as function of prevention level

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. Jednakże systematyczna ocena aktualnego stanu technicznego maszyny jest zagadnieniem trudnym, kosztownym i aktualnie rozwijanym w obszarze dyscypliny naukowej diagnostyka techniczna.

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:

1. Maszyny i układy newralgiczne.
2. Maszyny i układy ważne ze względu na realizowane funkcje i moc.
3. 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:

1. *Monitorowanie ciągłe (on-line)*, podczas funkcjonowania maszyny, wymagające zainstalowania aparatury diagnostycznej na stałe.
2. *Monitorowanie okresowe*, prowadzone według określonego harmonogramu.
3. *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 zastosowanie 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 [68, 127, 128, 161]. Ten rodzaj monitorowania wiąże się zwykle ze zwiększonym zakresem diagnostyki eksploatacyjnej, która ma dostarczać informacji o aktualnym stanie technicznym w postaci widm 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 technik przetwarzania sygnałów oraz potanieniu 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 oparte jest na prostych kryteriach wynikających z norm, zaleceń producentów czy też warunków technicznych eksploatacji układu. Są to zwykle kryteria dopuszczenia maszyny do ruchu, poziomy alarmowe, przekroczenie których wymaga działań korekcyjnych. Tego typu monitorowanie jest zwykle 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 [36, 154, 196]. Na rysunku 1.6 przedstawiono zestawienie wielkości fizycznych wykorzystywanych do monitorowania stanu technicznego napędów elektrycznych.

W eksploatacji napędów elektrycznych dominują metody monitorowania i diagnostyki polegające na pomiarach wybranych wielkości fizycznych i porównywaniu ich (lub parametrów na ich podstawie obliczonych) z wartościami granicznymi albo na

analizie tych wielkości w dziedzinie czasu i częstotliwości. Brak jest natomiast zastosowań na szerszą skalę metod diagnostyki, w których korzysta się z modeli ilościowych i jakościowych.




Rys. 1.6. Wielkości fizyczne stosowane do monitorowania i diagnostyki układu napędowego
Fig. 1.6. Physical values used for monitoring and diagnosis of electrical drive

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 [48, 49, 263]. Zagadnienia monitorowania napędów przekształtnikowych nie są przedmiotem pracy. Przedmiotem badań są klasyczne napędy zasilane z sieci.

Obserwując aktualne tendencje w zakresie rozwoju diagnostyki napędów z silnikami indukcyjnymi, można zauważyć, że są rozwijane trzy podejścia do tej problematyki (rys. 1.7):

- 1) diagnostyka na podstawie modeli matematycznych.
- 2) diagnostyka oparta na analizie sygnałów.
- 3) diagnostyka z zastosowaniem metod i technik sztucznej inteligencji.



Rys. 1.7. Klasyfikacja metod diagnostyki napędów z silnikami indukcyjnymi
 Fig. 1.7. Classification of the diagnosis methods of induction motor drives


Podejście oparte na analizie sygnałów ma obecnie podstawowe znaczenie w diagnostyce silników indukcyjnych. Diagnostyka wykorzystująca metody oparte na modelach matematycznych jest na etapie badań laboratoryjnych, rozwiązań prototypowych i jednostkowych wdrożeń. Trzecia droga jest we wstępnej fazie badania i rozpoznawania przydatności w praktyce przemysłowej.

1.2.2. Diagnostyka silników indukcyjnych z zastosowaniem modeli matematycznych

Metody diagnozowania uszkodzeń z zastosowaniem modeli matematycznych (metody porównawcze) są wdrażane w systemach monitorowania procesów przemysłowych [96, 121, 124, 228, 229]. 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 zmianach są dobrym źródłem sygnałów diagnostycznych. Zwrócenie się specjalistów od diagnostyki w stronę tych metod wynika z tego, 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, to sygnały diagnostyczne stają się niestacjonarne i korzystniejsze jest stosowanie metod parametrycznych bazujących na ciągłej (*on-line*) identyfikacji parametrów i zmiennych stanu.

Na rysunku 1.8 przedstawiono schemat ideowy metod diagnostyki uszkodzeń maszyn elektrycznych wykorzystujących modele matematyczne i techniki estymacji [124, 152, 169].



Rys. 1.8. Diagnostyka obiektów technicznych
z zastosowaniem modeli matematycznych i techniki estymacji

Fig. 1.8. Technical diagnosis using methods based on mathematical models and estimation techniques

Pierwsze informacje o badaniach nad zastosowaniem modelowania i estymacji do monitorowania silników indukcyjnych zostały podane na przełomie lat 90. [211, 212, 213, 289, 290]. Dotyczyły one głównie estymacji (odtwarzania) niemierzalnych zmiennych stanu (momentu elektromagnetycznego i strumienia) oraz parametrów schematu zastępczego silnika indukcyjnego na podstawie znajomości obwodowego modelu matematycznego maszyny [37]. Jednakże podstawowe zastosowania tych metod związane były ze sterowaniem napędami indukcyjnymi, gdzie niedostępne pomiarowo zmienne stanu i parametry były wykorzystywane do realizacji odpowiednich sprzężeń zwrotnych, w tym do odtwarzania prędkości kątowej w różnych strukturach sterowania [132, 215, 291].

Dopiero w ostatnich latach obserwuje się duże zainteresowanie specjalistów z zakresu diagnostyki metodami identyfikacji i estymacji na bieżąco parametrów silnika indukcyjnego, przy zastosowaniu teorii obserwatorów i filtru Kalmana, bazujących na modelach obwodowych maszyn [7, 8, 9, 21, 27, 127].

Do realizacji diagnostyki *on-line* za pomocą metod estymacji niezbędne jest wcześniejsze opracowanie odpowiednich modeli matematycznych silnika indukcyjnego

uwzględniających uszkodzenia obwodu elektrycznego i magnetycznego. Jednakże dokładny model, sformułowany przy minimalnych założeniach upraszczających opartych na metodzie elementów skończonych, gwarantuje dużą dokładność, ale równocześnie wymaga dłuższego 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.

Tak więc, w praktyce diagnostycznej poszukuje się alternatywnych modeli matematycznych, które zapewniłyby pewną równowagę pomiędzy czasem i dokładnością obliczeń, w związku z czym nadawałby się do realizacji w czasie rzeczywistym w systemach diagnostycznych. Przykłady takich modeli można znaleźć między innymi w najnowszych publikacjach z tego zakresu [1, 4, 5, 7, 9, 10, 18, 19, 27, 30, 59, 181, 182, 269].

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.

Rozbudowany model obwodowy lub polowo-obwodowy, uwzględniający budowę obwodów elektrycznych i magnetycznych, ich nieliniowe właściwości, umożliwia badanie 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 w drodze badań symulacyjnych.

Istnieje bardzo bogata literatura krajowa i zagraniczna dotycząca obwodowych modeli matematycznych silników indukcyjnych, uwzględniających w mniejszym lub większym stopniu różnego typu uszkodzenia maszyny [140, 202, 220, 242, 244, 253, 255, 257, 282, 286, 289].

Obecnie dostępne obwodowe modele matematyczne silników są jednak w większości przypadków ciągle za mało dokładne na potrzeby diagnostyki. Przy nieprecyzyjnym modelu bardzo prawdopodobne będzie 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 polowo-obwodowe, które są coraz bardziej wiarygodne i mogą być wykorzystywane jako źródło wzorców diagnostycznych [95, 275, 283].


Zagadnienia diagnostyki porównawczej opartej na modelowaniu i estymacji nie będą przedmiotem zainteresowania w dalszej części pracy. Do generowania wzorców diagnostycznych zostaną zastosowane metody eksperymentalne realizowane na obiektach rzeczywistych, a nie na modelach matematycznych.

1.2.3. Diagnostyka silników indukcyjnych oparta na analizie sygnałów pomiarowych

Obecnie, w monitorowaniu i diagnostyce uszkodzeń silników indukcyjnych dominujące znaczenie ma podejście oparte na analizie sygnałów bezpośrednio mierzonych na obiekcie (rys. 1.7). W tej grupie metod diagnostyki można zauważyć poszukiwania nowych technik, które udoskonaliłyby problem wyodrębniania cech charakteryzujących uszkodzenia oraz oceny stopnia uszkodzenia. Analiza wykorzystująca szybką transformatę Fouriera (FFT) jest bardzo wygodnym narzędziem, ale w przypadkach wielu wariantów uszkodzeń, gdy sygnały mierzone mają 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 [16, 45, 46, 90].

Inną, testowaną obecnie, drogą jest zastosowanie transformacji krótkoczasowej STFT (*Short Time Fourier Transformation*) lub falkowej (*Wavelet Transformation*) [15, 16, 105, 133, 175, 235]. Metody te umożliwiają lokalną analizę i wyodrębnienie symptomów uszkodzeń w krótkich (informacja wysokoczęstotliwościowa) i długich okresach czasu (informacja niskoczęstotliwościowa). Techniki te pozwalają lepiej wykrywać symptomy uszkodzeń we wczesnej fazie ich powstawania. Dzięki nim obecnie stosowane metody analizy sygnałów drgań, prądów i strumieni mogą być doskonalone i wzbogacane o nowe możliwości diagnostyczne. Należy oczekiwać, że w niedalekiej przyszłości przemysłowa aparatura diagnostyczna zostanie wzbogacona o nowe możliwości badawcze wynikające z analiz wyższych rzędów.

Diagnostyka, oparta na metodach analizy sygnałów, wykorzystuje wiedzę i doświadczenie człowieka – eksperta. To on dokonuje na bieżąco interpretacji aktualnych danych uzyskiwanych z pomiarów i analizy, realizowanych przez systemy pomiarowe (rys. 1.9). 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 zobjektywizowanie procesu wykrywania i oceny uszkodzenia. Można to osiągnąć przez wykorzystanie możliwości tkwiących w metodach i technikach sztucznej inteligencji.



Rys. 1.9. Diagnostyka obiektu technicznego z wykorzystaniem wiedzy eksperta

Fig. 1.9. Technical diagnosis using expert knowledge


W dalszej części pracy metody analizy sygnałów będą stanowiły podstawowe narzędzie do zbierania informacji diagnostycznej.

1.2.4. Diagnostyka silników indukcyjnych z zastosowaniem metod sztucznej inteligencji

Na rysunku 1.10 przedstawiono postępowanie podczas realizacji diagnostyki z zastosowaniem metod sztucznej inteligencji, przede wszystkim sztucznych sieci neuronowych i logiki rozmytej używanych do budowy tzw. detektorów i klasyfikatorów uszkodzeń. Zadaniem sieci neuronowej lub systemu rozmytego jest wykrycie uszkodzenia i jego klasyfikacja (ocena stopnia uszkodzenia).

Neuronowe i rozmyte detektory uszkodzeń można budować na podstawie 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 wiedzy pozyskanej w procesie uczenia oraz udzielanie szybkiej odpowiedzi diagnostycznej.

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.



Rys. 1.10. Diagnostyka obiektu technicznego z wykorzystaniem sztucznych sieci neuronowych lub logiki rozmytej

Fig. 1.10. Technical diagnosis using artificial neural networks or fuzzy logic system

W dalszej części pracy sprawdzono możliwość realizacji detektorów i klasyfikatorów podstawowych uszkodzeń silnika indukcyjnego za pomocą sztucznych sieci neuronowych. Jednakże klasyczne metody analizy sygnałów stanowiły punkt wyjściowy do generowania wzorców diagnostycznych opartych na danych eksperymentalnych, niezbędnych do uczenia sieci neuronowych.

1.3. Przegląd literatury dotyczącej monitorowania i diagnostyki silników indukcyjnych

Zagadnienia monitorowania i diagnostyki obiektów przemysłowych były i są przedmiotem zainteresowania różnych specjalistów, początkowo głównie z zakresu mechaniki oraz budowy i eksploatacji maszyn, następnie zajmujących się procesami technologicznymi i ich sterowaniem (automatyków przemysłowych). Obecnie, ponieważ diagnostyka techniczna stała się odrębną dyscypliną naukową, interesują się nią specjaliści ze wszystkich branż.

Istnieje bardzo obszerna literatura dotycząca badań diagnostycznych różnych klas obiektów przemysłowych. Między innymi dotyczy ona diagnostyki komputerów [50], maszyn i pojazdów mechanicznych [11, 12, 35, 36, 38, 78] oraz procesów przemy-

słowych [146, 148, 218, 230, 288]. Duża część prac została poświęcona różnym elementom teorii diagnostyki, między innymi [39, 96, 121, 122, 123, 124, 238].

Liczne ośrodki naukowe za granicą i w Polsce zajmują się problematyką wykrywania uszkodzeń w maszynach elektrycznych, modelowaniem maszyn z uszkodzeniami oraz poszukiwaniem nowych metod monitorowania i diagnostyki. Od początku lat 80. tematyka ta jest poruszana na ważnych konferencjach i w renomowanych czasopismach naukowych i technicznych. Podstawowe opracowania zagraniczne to [28, 83, 106, 137, 138, 185, 196, 223, 225, 226, 270, 271, 273, 274, 275, 290].

W Polsce zagadnieniem wykrywania uszkodzeń w silnikach indukcyjnych zajmują się od wielu lat zespoły badawcze w AGH, Politechnice Krakowskiej, Śląskiej, Opolskiej i Wrocławskiej. Pierwsze polskie opracowania z zakresu uszkodzeń maszyn elektrycznych to [98, 103]. Prace [36, 101] są jedynymi polskimi opracowaniami monograficznymi dotyczącymi diagnostyki maszyn elektrycznych.

Stosunkowo najwcześniej powstały prace z zakresu modelowania matematycznego silników indukcyjnych z asymetrią wewnętrzną będącą skutkiem uszkodzenia. Podstawowe prace to [66, 67, 202, 203, 242, 243, 244, 253, 254, 255, 256, 282, 286].

Głównie znaczenie w diagnostyce eksploatacyjnej, realizowanej obecnie w przemyśle, ma analiza spektralna drgań oraz prądu stojana. Przegląd i ocenę najważniejszych metod stosowanych aktualnie w diagnostyce uszkodzeń silników indukcyjnych przedstawiono w [13, 14, 15, 31, 34, 133, 197, 277].

Wykorzystanie analizy drgań w monitorowaniu i diagnostyce silników indukcyjnych jest opisane w literaturze najobszerniej, ponieważ jest to sygnał najczęściej stosowany w systemach monitorowania i diagnostyki w przemyśle. Podstawowe opracowania [35, 78, 189, 196] zawierają informacje o metodach pomiaru i analizy sygnału drganiowego oraz zastosowania go do ciągłego i okresowego monitorowania ogólnie rozumianych układów maszynowych

Problematykę drgań napędów z silnikami indukcyjnymi uwzględniają prace autorów z Politechniki Opolskiej [72, 74, 75, 76, 77, 111, 112, 114, 265]. W publikacjach tych zawarte są doświadczenia autorów z diagnostyki uszkodzeń łożysk tocznych, osiowania napędów i wpływu fundamentów na pracę silników indukcyjnych. Przedstawiono w nich liczne przykłady uszkodzeń mechanicznych i związanych z nimi widm drgań. Również w pracach [161, 174] zostały przedstawione i porównane metody wykrywania uszkodzeń w łożyskach silników dużej mocy na podstawie analizy drgań mechanicznych (metoda ogólna i metoda obwiedni). Przedstawiono przykłady stanów awaryjnych silników wysokonapięciowych i ich symptomy w widmach drgań.

Drugim co do częstości wykorzystywania w diagnostyce silników indukcyjnych sygnałem jest prąd uzwojenia stojana. Na analizie częstotliwości prądu stojana oparta jest współczesna diagnostyka wirników klatkowych, ekscentryczności statycznej i dynamicznej oraz, w ograniczonym zakresie, diagnostyka łożysk tocznych. Podstawy diagnostyki wykorzystującej prąd stojana zostały przedstawione w [136, 137, 138, 270, 271].

Za najważniejszy symptom uszkodzenia wirnika autorzy przyjmują wzrost amplitudy harmonicznych położonych po obu stronach harmonicznej podstawowej i przesuniętych względem niej o podwójną wartość poślizgu. Metoda ta została opisana w wielu publikacjach. Między innymi w [88, 92] wyjaśniono oddziaływanie oscylacji prędkości wirnika na widmo prądu stojana oraz tłumiący wpływ bezwładności wypadkowej napędu na amplitudę charakterystycznych harmonicznych. W pracach [20, 272] została opisana metoda diagnostyki wirników dużej mocy ze szczególnym uwzględnieniem mechanizmu powstawania symptomów uszkodzenia obwodu elektrycznego i magnetycznego. Wyjaśniono wpływ konstrukcji wirnika (typu *fluted rotor* lub *spider rotor*) na kształt widma i powstawanie dodatkowych harmonicznych o częstotliwościach zbliżonych do takich, jakie występują przy uszkodzeniach wirnika.

Zagadnienia wpływu oscylacji momentu obciążenia na widmo prądowe, a tym samym na utrudnienie interpretacji uszkodzenia, przedstawiono w [56, 208, 248, 249].

W pracach [236, 246, 262] przedstawiono możliwości wykorzystania analizy częstotliwościowej prądu stojana do diagnostyki łożysk tocznych silników indukcyjnych oraz wyjaśniono relacje zachodzące między drganiami mechanicznymi i harmonicznymi prądu.

Prace na metodami diagnozowania klatek wirników były i są prowadzone w kilku ośrodkach naukowo-badawczych w Polsce. Między innymi w Politechnice Opolskiej badano przydatność różnych metod wykrywania uszkodzeń oraz rozwijano metodę częstotliwościową dla silników wysokonapięciowych [73, 75, 110, 114, 264]. Podobne badania były prowadzone w Politechnice Śląskiej [99, 125, 126] oraz AGH Kraków [206, 233, 234, 244].

Analiza widmowa prądu ma podstawowe znaczenie w detekcji ekscentryczności statycznej i dynamicznej. Zagadnieniu temu jest poświęcona duża liczba publikacji polskich i zagranicznych. W Politechnice Krakowskiej oraz AGH Kraków powstały prace, które teoretycznie i praktycznie wykazały przydatność analizy widmowej prądu stojana do wykrywania ekscentryczności [104, 243, 254, 255, 256, 286].

W ostatnich latach duża liczba publikacji dotyczyła możliwości wyodrębnienia symptomów uszkodzeń z widma prądowego przez stosowanie transformacji wyższych rzędów, przekształceń o zwiększonej dokładności cyfrowego przetwarzania sygnałów oraz techniki rozpoznawania sygnałów [13, 14, 16, 45, 46, 105, 133]. Niektóre publikacje proponują rozwiązania sprzętowe i programowe systemów diagnostycznych oparte na analizie częstotliwościowej prądów stojana [20, 80, 150, 191, 247].

Pewnym udoskonaleniem metody analizy częstotliwościowej jest analiza modułu wektora przestrzennego prądu stojana. Metoda ta polega na wyodrębnieniu charakterystycznych składowych harmonicznych, pojawiających się w tym widmie na skutek uszkodzenia wirnika. Najciekawsze wyniki badań zostały opublikowane w [32, 33, 54, 55, 170, 200, 201], gdzie autorzy wykazali teoretycznie i praktycznie zalety tej metody.

Szeroko zakrojone badania eksperymentalne potwierdzające dużą przydatność analizy modułu wektora przestrzennego prądu stojana w diagnostyce wirnika klatko-

wego zostały przedstawione w [167, 172, 176, 219]. W pracy [33] pokazano możliwość zastosowania analizy wektora przestrzennego prądu stojana do wykrywania zwarc zwojowych stojana.

W diagnostyce opartej na analizie sygnałów mierzonych bezpośrednio na obiekcie rzeczywistym wykorzystuje się również strumień poosiowy. Strumień ten mierzy się za pomocą cewek pomiarowych, umieszczonych współosiowo względem wału silnika (na zewnątrz lub wewnątrz maszyny). Analiza widmowa sygnału napięciowego indukującego się w cewkach pomiarowych pozwala wykryć uszkodzenia w stojanie (zwarcie zwojowe) lub w wirniku. W pracach [79, 107, 204, 205, 241, 290] przedstawiono zastosowanie tej metody do diagnostyki wirników, a w [164, 165, 193, 223, 226] do wykrywania zwarc zwojowych.

W pracy [108] porównano wyniki diagnostyki opartej na analizie prądu stojana i strumienia poosiowego, wykazując większą efektywność analizy strumienia w przypadkach zwarc zwojowych.

W ostatnich latach pojawiły się publikacje wykazujące przydatność sygnału momentu elektromagnetycznego w diagnostyce uszkodzeń silnika indukcyjnego, przede wszystkim do wykrywania zwarc zwojowych [119, 192, 193].

Charakterystyczne częstotliwości pochodzące od uszkodzeń uzwojeń stojana i wirnika można również wykrywać w widmie mocy chwilowej [186, 278, 279].

Rozwój teorii sztucznych sieci neuronowych oraz technologii układów wielkiej skali integracji, w tym technologii wieloprocesorowej, spowodowały ogromny wzrost zainteresowania układami równoległego przetwarzania informacji i poszukiwania możliwości wykorzystania ich w wielu dyscyplinach technicznych [147, 209, 210, 266, 294].

W początkach lat 90. pojawiły się pierwsze doniesienia o możliwości wykorzystania metod sztucznej inteligencji w diagnostyce silników indukcyjnych [3, 40, 41, 42, 224]. W pracy [224] sformułowano po raz pierwszy w Europie ideę zastosowania sztucznych sieci neuronowych do monitorowania i diagnostyki napędów z silnikiem indukcyjnym. Przedstawiono wyniki badań laboratoryjnych detektora neuronowego, zrealizowanego w komputerze PC, który wykrywał trzy stany silnika: zdrowy, niesymetrię zasilania i luzy mechaniczne. Sieć neuronowa została wytrenowana wybranymi harmonicznymi drgań mechanicznych oraz prądu stojana. Nie podano jednak żadnych szczegółowych danych na temat zasad doboru harmonicznych, trenowania i testowania sieci.

W pracach [40, 41, 42] autor przedstawił detektor neuronowy do wykrywania zwarc w silniku jednofazowym z wirnikiem klatkowym. Detektor został wytrenowany danymi wygenerowanymi w badaniach symulacyjnych na podstawie modelu matematycznego. Na podstawie mierzonych sygnałów prądu i prędkości kątowej silnika detektor określał dwie wielkości wyjściowe: N_c i B_c określające stan uzwojeń i łożysk. Wielkości wyjściowe mogły przyjmować trzy wartości charakteryzujące stan: dobry, poprawny, zły. Doświadczenia z projektowania neuronowych i rozmytych detektorów

uszkodzeń stojana i łożysk przy wykorzystaniu badań modelowych zostały zebrane w monografii [43] oraz artykule [44].

W pracy [3] przedstawiono koncepcję monitorowania i diagnostyki łożysk tocznych za pomocą perceptronowego detektora oraz harmonicznego sygnału drganiowego jako wielkości wejściowych. Bardzo ciekawe wyniki badań neuronowego detektora uszkodzeń łożysk tocznych przedstawiono w pracy [187], gdzie do generacji wzorców uczących sieci (spektrum drgań) zastosowano profesjonalny program „Machinery Fault Simulator” firmy SPECTRAQUEST oraz związane z nim stanowisko laboratoryjne. Uzyskano, dzięki dużej liczbie wzorców uczących, bardzo dobrą dokładność detektora (na poziomie 90% poprawnych odpowiedzi).

Najszerzy zakres badań nad zastosowaniem sztucznych sieci neuronowych oraz logiki rozmytej do diagnostyki silników indukcyjnych prowadził zespół pod kierunkiem prof. Filippettiego. W pracach [83, 84, 87, 91] przedstawiono wyniki badań nad uszkodzeniami typu zwarcia zwojowe w stojanie i wykrywaniem ich we wstępnej fazie za pomocą neuronowych detektorów. Wykorzystano matematyczne modelowanie silnika za pomocą składowych symetrycznych [87] i wykazano, że składowe kolejności przeciwnej i zgodnej prądu stojana zmieniają się w różny sposób wraz ze zmianą stopnia zwarcia. Zmiany składowej kolejności przeciwnej praktycznie nie zależą od warunków pracy silnika (poślizgu), w przeciwieństwie do składowej zgodnej prądu. Opracowany detektor perceptronowy, trenowany danymi z badań symulacyjnych, umożliwiał z zadowalającą dokładnością wykrywanie zwarć w stojanie (w jednej fazie) w zakresie $0 \div 12\%$. W pracy [93] przedstawiono podsumowanie badań nad modelowaniem matematycznym zwarć międzyzwojowych w stojanie silnika indukcyjnego oraz zastosowaniem go do generowania wzorców do uczenia sieci neuronowej.

Drugi nurt badań zespołu Filippettiego dotyczył uszkodzeń wirników. Wykorzystano doświadczenia związane z zastosowaniem analizy widmowej prądu stojana do diagnostyki uzwojeń wirnika [17, 19, 20, 86, 88]. Podstawowe publikacje dotyczące zastosowania sieci neuronowych to [85, 89, 90, 92, 94]. Przedstawiono w nich propozycje budowy perceptronowego detektora do określania liczby pękniętych prętów. Jako sygnały wejściowe były podawane amplitudy harmonicznego „poślizgowych” z widma prądu oraz poślizg, moc elektryczna i moment bezwładności. Autorzy nie sprecyzowali, w jaki sposób były zbierane dane do uczenia i testowania sieci. Uzyskano bardzo dobrą dokładność w wykrywaniu liczby uszkodzonych prętów.

W pracy [20] zostały podsumowane doświadczenia autorów w zakresie diagnostyki uszkodzeń wirników silników wysokonapięciowych za pomocą metody analizy widmowej prądu stojana. W najnowszych pracach zespołu Filippettiego [18, 19, 21] jest przedstawiona próba rozszerzenia dotychczasowych doświadczeń w zakresie diagnostyki silników indukcyjnych na beczujnikowe przekształtnikowe układy napędowe.

Przegląd zastosowań metod i technik sztucznej inteligencji w napędzie elektrycznym oraz obszernie omówienie podstaw teoretycznych sieci neuronowych i logiki

rozmytej znajduje się w monografii Vasa [291]. W zakresie diagnostyki uszkodzeń silników indukcyjnych Vas przytacza i komentuje przykłady rozwiązań opublikowanych w pracach Filippettiego, Penmana i Schoena. Są to przykłady neuronowych detektorów uszkodzeń wirnika i stojana. Proponuje on również w sposób ogólny rozwiązanie problemu diagnostyki łożysk tocznych (propozycje prostych detektorów oparte na prądzie, prędkości i drganiach). Jednakże nie przytacza żadnych konkretnych rozwiązań oraz wyników.

W pracach Penmana i Yina [227] przedstawiono po raz pierwszy, w odniesieniu do silników indukcyjnych, koncepcję zastosowania samoorganizującej się sieci neuronowej do klasyfikowania uszkodzeń i prezentowania wyników na tzw. mapie Kohonena. Dane do uczenia i testowania sieci były zbierane na stanowisku laboratoryjnym, gdzie realizowano badania silników z uszkodzonym stojanem, nieosiowym zamocowaniem wirnika oraz niesymetrią zasilania. Sprawdzono przydatność różnych sygnałów wejściowych do sieci Kohonena, w tym drgań mechanicznych, prądów stojana i strumienia poosiowego. Przedstawiono możliwość obrazowania rozkładu uszkodzeń na dwu i trójwymiarowej mapie Kohonena i ich przydatność we wstępnej klasyfikacji uszkodzeń.

Również w pracach [91, 291] przedstawiono wstępną analizę możliwości zastosowania sieci samoorganizującej do klasyfikacji uszkodzeń typu asymetria stojana i wirnika.

W publikacji [247] oraz monografii [291] została wstępnie scharakteryzowana koncepcja neuronowego systemu diagnostycznego oparta na dwóch sieciach neuronowych, tworzących odpowiednie podsystemy. Jeden podsystem, oparty na sieci samoorganizującej, przeznaczony jest do wstępnej klasyfikacji uszkodzeń, natomiast drugi podsystem, oparty na sieci perceptronowej, realizuje ocenę stopnia uszkodzenia. Dotychczas brak jest informacji o praktycznej realizacji tej koncepcji.

Oprócz omówionych podstawowych publikacji, na temat zastosowania sztucznych sieci neuronowych do detekcji uszkodzeń w silnikach indukcyjnych, spotyka się przyczynkowe prace z tego zakresu w materiałach różnych konferencji, np. [23, 118, 145, 201, 245].

Bardzo mało prac z zakresu neuronowej diagnostyki silników indukcyjnych zostało opublikowanych w języku polskim. Są to publikacje [130, 207, 261]. Najszerzej zakrojone badania dotyczące monitorowania i diagnostyki silników indukcyjnych za pomocą sieci neuronowych realizowane są w ośrodku wrocławskim [149, 152, 153, 154, 157, 159, 160, 162, 165, 169].

Z przedstawionego przeglądu literatury wynika, że bibliografia opracowań związanych z zastosowaniem sztucznych sieci neuronowych do monitorowania i diagnostyki silników indukcyjnych jest bardzo ograniczona liczbowo i problemowo. Liczba istotnych prac opublikowanych w ciągu ostatnich 10 lat w renomowanych czasopiśmie i materiałach liczących się konferencji nie przekracza kilkunastu pozycji. Po okresie wstępnego dużego zainteresowania (w latach 1992–1997) zapanował okres

stagnacji, trwający do chwili obecnej. W okresie tym powstały dwie monografie [43, 291], które formułują pewne wytyczne w zakresie projektowania detektorów neuronowych oraz uzasadniają celowość ich stosowania

W okresie rozwijania teorii i metod sieci neuronowych od lat pięćdziesiątych począwszy, wielokrotnie już występowały okresy intensywnego rozwoju i stagnacji. Należy przypuszczać, że przyczynami obecnego zastoju aplikacji w obszarze zagadnień diagnostyki są następujące fakty:

1. Brak jest układów o dużej skali integracji realizujących duże struktury sieci neuronowych i wynikająca stąd konieczność ich realizacji w układach procesorowych.
2. Brak odpowiednio dużych baz danych o uszkodzeniach maszyn elektrycznych, które mogłyby dostarczać informacji do uczenia i testowania sieci neuronowych. Dopiero od kilku lat w dużych zakładach przemysłowych są systematycznie zbierane dane z analiz sygnałów diagnostycznych, co pozwoli zbudować banki informacji dla ważnych napędów i projektować wiarygodne detektory uszkodzeń. Bez odpowiednio dużych wektorów uczących i testujących trudno jest osiągnąć zadowalającą dokładność działania systemów diagnostycznych wykorzystujących neuronowe detektory uszkodzeń.
3. Projektowanie neuronowych detektorów uszkodzeń na podstawie modelowania matematycznego napotyka ciągle ograniczenia wynikające z niedoskonałości tych modeli. Powoduje to, że generowanie wzorców sygnałów diagnostycznych dla poszczególnych rodzajów uszkodzeń jest mało dokładne i sieci neuronowe uczone nimi, po podaniu na wejście rzeczywistych sygnałów, działają z dużymi błędami.

Z analizy publikacji dotyczących zastosowań sieci neuronowych w diagnostyce uszkodzeń silników indukcyjnych wynikają spostrzeżenia:

- w większości publikacji omawiane są neuronowe detektory uszkodzeń wirnika z wykorzystaniem jako sygnałów wejściowych amplitud charakterystycznych harmonicznych z widma prądu stojana;
- detektory uszkodzeń stojana realizowane są na bazie składowych symetrycznych prądu stojana;
- detektory uszkodzeń łożysk projektowane są na podstawie danych o drganiach uzyskanych z badań symulacyjnych realizowanych na specjalistycznych symulatorach. Zakres prac nad detektorami uszkodzeń łożysk z zastosowaniem innych sygnałów jest bardzo ograniczony;
- badania nad przydatnością sieci samoorganizujących do wstępnej klasyfikacji uszkodzeń mają bardzo ograniczony zakres;
- w badaniach neuronowych detektorów przeważa uczenie ich wzorcami generowanymi przez programy symulujące pracę uszkodzonej maszyny;
- nie były prowadzone badania nad optymalizacją struktur poszczególnych detektorów; ze względów realizacyjnych powinny to być jak najprostsze struktury neuronowe;

- w przypadku detektorów uszkodzeń wirnika z reguły ograniczano się do wykrywania liczby uszkodzonych prętów, nie podejmowano próby wykrywania ich rozkładu na obwodzie klatki wirnika;
- nie sprawdzono możliwości jednoczesnego wykorzystywania informacji uzyskiwanych z analizy drgań i prądu stojana;
- nie wykorzystuje się możliwości projektowania neuronowych detektorów na podstawie informacji diagnostycznych zawartych w innych sygnałach, np. strumieniu poosiowym lub przyspieszeniu drgań mechanicznych;
- do uczenia sieci neuronowych nie wykorzystuje się informacji dostarczanych z analiz wyższych rzędów, np. transformacji falkowej;
- brak jest opracowań, które omawiałyby kompleksowo problematykę neuronowych detektorów uszkodzeń silników indukcyjnych.

Mając na uwadze powyższe spostrzeżenia, można stwierdzić, że celowe jest rozszerzenie badań nad zagadnieniem monitorowania i diagnostyki silników indukcyjnych za pomocą sztucznych sieci neuronowych.

W literaturze polskiej nie ma dotychczas opracowania, w którym przedstawionoby obecny stan diagnostyki silników indukcyjnych całościowo i spróbowanoby usystematyzować stosowane dotychczas metody.

Dlatego autor od kilku lat prowadzi badania, których celem jest opracowanie kompleksowego podejścia do zagadnienia monitorowania i diagnostyki silników indukcyjnych za pomocą neuronowych detektorów uszkodzeń.

1.4. Cel i zakres pracy

Na podstawie przeglądu literatury można sformułować wniosek, że nie ma opracowania systematyzującego problematykę monitorowania i diagnostyki silników indukcyjnych oraz proponującego nowe rozwiązania w tym zakresie. Zastosowanie metod sztucznej inteligencji, a przede wszystkim sztucznych sieci neuronowych wydaje się najbardziej perspektywiczną propozycją rozwoju monitorowania i diagnostyki silników indukcyjnych, która nie została do tej pory w pełni opracowana.

Podstawowym celem pracy jest zbadanie możliwości zastosowania sztucznych sieci neuronowych do budowy detektorów podstawowych uszkodzeń silników indukcyjnych oraz opracowanie metodyki projektowania takich neurodetektorów.

Dodatkowym celem jest zebranie, usystematyzowanie oraz analiza istniejących i stosowanych w diagnostyce eksploatacyjnej metod monitorowania i diagnostyki napędów z silnikami indukcyjnymi.

Praca obejmuje:

- zebranie i usystematyzowanie problematyki monitorowania i diagnostyki silników indukcyjnych,

- przegląd podstawowych uszkodzeń silników indukcyjnych,
- analizę istniejących i stosowanych metod diagnostyki eksploatacyjnej silników indukcyjnych,
- analizę nowych tendencji w zakresie metod i technik monitorowania i diagnostyki napędów z silnikami indukcyjnymi,
- opracowanie metodyki projektowania neurodetektorów podstawowych uszkodzeń silników indukcyjnych,
- zbadanie możliwości realizacji praktycznej neuronowych detektorów uszkodzeń silników indukcyjnych.

W rozdziale 1 zdefiniowano podstawowe problemy związane z monitorowaniem i diagnostyką obiektów technicznych. Przedstawiono podział metod i zakres ich stosowania. Scharakteryzowano główne problemy związane z diagnostyką uszkodzeń silników indukcyjnych oraz dokonano krytycznego przeglądu literatury związanej z tymi uszkodzeniami.

Rozdział 2 zawiera przegląd podstawowych uszkodzeń silników indukcyjnych i omówienie przyczyn ich powstawania. Omówiono charakterystyczne zjawiska towarzyszące poszczególnym uszkodzeniom.

Szczegółowa charakterystyka aktualnie stosowanych metod monitorowania i diagnostyki silników indukcyjnych została przedstawiona w rozdziale 3. Po wstępnym omówieniu analizy sygnałów jako podstawy diagnostyki eksploatacyjnej oraz scharakteryzowaniu najczęściej stosowanych sygnałów diagnostycznych, przedstawiono szczegółową charakterystykę metod wykrywania uszkodzeń w wirniku klatkowym, stojanie i łożyskach tocznych. W podsumowaniu tego rozdziału zamieszczono w formie tabel zestawienie podstawowych uszkodzeń oraz towarzyszących im harmonicznych o charakterystycznych częstotliwościach, wykorzystywanych w omawianych metodach do wykrywania symptomów poszczególnych uszkodzeń.

Rozdział 4 dotyczy zagadnień związanych z zastosowaniem sieci neuronowych w diagnostyce. Przedstawiono podstawowe informacje o sieciach neuronowych oraz możliwościach ich wykorzystania w diagnostyce uszkodzeń. Scharakteryzowano metody projektowania neuronowych detektorów uszkodzeń za pomocą sieci perceptronowych i samoorganizujących.

Na podstawie opracowanej metodyki zostały przeprowadzone gruntowne badania neuronowych detektorów uszkodzeń wirnika, stojana i łożysk tocznych. Wyniki tych badań zostały zamieszczone w rozdziale 5. Dla poszczególnych rodzajów uszkodzeń przedstawiono propozycje rozwiązań struktury neuronowych detektorów oraz wyniki ich testowania. Zbadana została możliwość zastosowania sieci perceptronowej i samoorganizującej Kohonena.

W rozdziale 6 przedstawiono możliwość zastosowania analizy falkowej do określania sygnałów, które następnie mogą być wykorzystane w uczeniu i testowaniu neuronowych detektorów uszkodzeń wirników i łożysk tocznych.

Podstawowym problemom technicznej realizacji systemów diagnostycznych wykorzystujących neuronowe detektory uszkodzeń poświęcony został rozdział 7.

Po uwagach i wnioskach końcowych (rozdział 8) zostały zamieszczone załączniki, w których przedstawiono niektóre dane techniczne związane z badanymi silnikami, łożyskami oraz aparaturą techniczną używaną w badaniach.

2. Przegląd podstawowych uszkodzeń napędów z silnikami indukcyjnymi


2.1. Rodzaje, przyczyny i statystyka uszkodzeń

Podczas eksploatacji silników indukcyjnych powstają w nich uszkodzenia w obwodach elektrycznych stojana i wirnika oraz w układzie mechanicznym silnika, współpracującej maszyny roboczej oraz w elementach sprzęgających. Przyczyny uszkodzeń zależą od konstrukcji silnika, 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.

Na rysunku 2.1 pokazano rodzaje i lokalizację uszkodzeń występujących w napędzie elektrycznym z silnikami indukcyjnymi. Przyczyny uszkodzeń napędów z silnikami indukcyjnymi mogą być: wewnętrzne i zewnętrzne (rys. 2.2). Wśród wewnętrznych przyczyn uszkodzeń można wyróżnić 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 cztery grupy uszkodzeń:

- 1) uszkodzenia stojana (uszkodzenia izolacji i wynikające stąd zwarcia),
- 2) uszkodzenia wirnika (pęknięte pręty lub pierścienie),
- 3) uszkodzenia układu mechanicznego (uszkodzenia łożysk, niewspółosiowe połączenie silnika i maszyny roboczej, luzy pakietów obwodów magnetycznych, luzy cewek stojana, ekscentryczność wirnika),
- 4) uszkodzenia maszyny roboczej, sprzęgła, przekładni zębatej lub pasowej itp.

Wszystkim uszkodzeniom towarzyszą zjawiska elektryczne, magnetyczne, wibroakustyczne i ciepłne.



Rys. 2.1. Rodzaje i lokalizacja uszkodzeń
w napędach elektrycznych z silnikami indukcyjnymi
Fig. 2.1. Types and localization of faults

Zwarciom zwojowym towarzyszą:

- bardzo duży prąd w zwojach zwartych,
- asymetria prądów fazowych,
- zmiana widma prądu,
- zmiana widma drgań i hałasu wynikająca z pojawienia się dodatkowych składowych w siłach i momentach,
- pojawienie się strumieni unipolarnych.

Przerwie w prętach klatki i pierścieniach zwierających towarzyszą:

- dodatkowe składowe w prądach fazowych zależne od poślizgu,
- pojawienie się zmiennych składowych w momencie elektromagnetycznym oraz siłach promieniowych,
- zmiana strumienia unipolarnego,
- lokalny wzrost prądu.


Ekscentryczności (niesymetrii szczeliny powietrznej) towarzyszą:

- dodatkowe składowe w prądach fazowych maszyny,
- składowe zmienne w momentach i siłach,
- zmiany w widmach drgań, prądu i hałasu.

Uszkodzeniom mechanicznym towarzyszą:

- dodatkowe siły i momenty,
- drgania mechaniczne i zwiększony hałas, zmiany widma drganiowego i akustycznego,
- zmiany widma prądu.


Na rysunku 2.2 przedstawiono podstawowe przyczyny uszkodzeń silników indukcyjnych, a na rys. 2.3 główne uszkodzenia wirników i stojanów silników indukcyjnych wraz z wyszczególnieniem przyczyn ich powstawania.



Rys. 2.2. Przyczyny uszkodzeń silników indukcyjnych

Fig. 2.2. Sources of the induction motor faults

W zależności od typu maszyny, rodzaju napięcia, zasilania, 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 ulegający najczęściej uszkodzeniom. Statystyka uszkodzeń i awarii silników indukcyjnych wysokiego i niskiego napięcia zmienia się w ostatnich latach.




Rys. 2.3. Uszkodzenia silników indukcyjnych oraz przyczyny ich powstawania

Fig. 2.3. The fault tree of induction motors and their causes

Wyraźnie następuje zwiększenie udziału uszkodzeń typu mechanicznego w stosunku do uszkodzeń obwodu elektrycznego oraz magnetycznego silników [25, 26, 63, 65, 161, 277]. Wśród wszystkich uszkodzeń wyraźnie przeważają uszkodzenia typu mechanicznego związane z łożyskami silników. Również stosunkowo często pojawiają się defekty fundamentów i mocowania silników oraz luzy w układzie wał–pakiet wirnika [62, 75, 76, 77, 265].

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, 65, 120, 277]. Ilościowy udział poszczególnych rodzajów uszkodzeń przedstawiono na rys. 2.4.

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 [25, 101, 258].



Rys. 2.4. Procentowy udział uszkodzeń silników indukcyjnych
Fig. 2.4. Percentage share of specific causes of the induction motor faults

Asymetrie uzwojenia stojana wywołane są bądź błędami w budowie maszyny, bądź uszkodzeniami układu izolacyjnego w czasie eksploatacji. Uszkodzenia izolacji objawiają się nagle w postaci zwarc i wymagają możliwie szybkiego odłączenia maszyny. Większość przypadków zwarc jest wykrywana przez układy zabezpieczeń maszyn. Układy te nie reagują zwykle na zwarcia małej liczby zwojów w jednej fazie. Wykrywanie zwarc zwojowych w uzwojeniu stojana w trakcie normalnej eksploatacji silników indukcyjnych jest zagadnieniem trudnym i do tej pory nie opracowano typowego rozwiązania przemysłowego [91,129, 277].

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 rezultacie podczas 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 wirni-

ka, rezonans mechaniczny przy krytycznej prędkości obrotowej, zużycie łożysk [64, 67, 104, 189, 254]. W silnikach indukcyjnych najczęściej ulegają uszkodzeniu łożyska toczne i ślizgowe (rys. 2.4). Łożysko jest jednym z najważniejszych elementów mechanicznych silnika. 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.

Ocena powyższych zjawisk metodami subiektywnymi prowadzi do błędnych ocen stanu technicznego silnika. Niezbędne więc jest stosowanie skutecznych metod diagnozowania silników elektrycznych, umożliwiających wczesne wykrywanie uszkodzeń w trakcie eksploatacji.

2.2. Uszkodzenia uzwojeń wirników klatkowych

Silniki indukcyjne klatkowe o mocy do ok. 100 kW są wyposażone w 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 możliwości powstania drgań w prętach oraz jest bardzo dobra wymiana ciepła. Dlatego uszkodzenia takich wirników występują rzadko i zwykle są związane z błędem technologicznym lub wytopieniem uzwojenia. Dlatego dla takich silników potrzeba diagnozowania wirnika jest minimalna.

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

Takie wirniki powinny być diagnozowane przynajmniej okresowo, ze względu na częste występowania w nich uszkodzeń.

Nawet bardzo drobne, praktycznie niezauważalne pęknięcie klatki, niepowodujące 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 łożysk 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 [99]. Na rysunku 2.5a przedsta-

wiono objaśnienie powstawania siły elektrodynamicznej F_d (w przekroju żłobka i pręta wirnika) jako efektu współdziałania prądu płynącego w pręcie wirnika i strumienia magnetycznego Ψ_r rozproszenia żłobkowego. Siły dynamiczne, występujące w pierwszej chwili po załączeniu, działają niszcząco na uzwojenia, wał i łożyska. Na rysunku 2.5b przedstawiono miejsce typowego występowania pęknięć klatki wirników silników dużej i średniej mocy, powodowanych bardzo dużą liczbą rozruchów lub rozruchami długotrwałymi.



Rys. 2.5. Przyczyny powstawania uszkodzeń prętów wirnika:

a) objaśnienie powstawania siły elektrodynamicznej F_d ; b) miejsce powstawania typowych pęknięć

Fig. 2.5. Causes of rotor bar faults:

a) illustration of electrodynamic force F_d arising; b) place of typical breakdown

Podczas 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. poprzez rozwiązania konstrukcyjne wirnika w postaci jednoklatkowej, głębokożłobkowej lub z prętami biernymi [22]. Szczególnie to ostatnie rozwiązanie umożliwia zminimalizowanie wielkości strat rozruchowych, gdyż pręty bierne, połączone ze sobą pierścieniami, przejmują je i w nich wydzielają 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, wahaniach prądu stojana oraz w drganiach mechanicznych [183]. Pogorszeniu ulegają podstawowe parametry silnika. Jednakże 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.

Aktualnie rozwijane są trzy rodzaje metod:

1) metody wykrywające uszkodzenie w trakcie normalnej eksploatacji maszyny [110, 138];

2) metody wymagające realizacji specjalnych warunków pracy silnika, przy których uwidaczniają się defekty uzwojenia [97, 99, 183];

3) metody oparte na badaniu samego wirnika, polegające na szukaniu uszkodzonego pręta [97, 99, 183].

Literatura dotycząca metod diagnozowania uzwojeń wirnika klatkowego jest bardzo bogata. W dalszych rozważaniach zostanie omówiona jedynie metoda nieinwazyjna, pozwalająca prowadzić monitorowanie i diagnostykę wirników na bieżąco, w trakcie normalnej eksploatacji silnika.

2.3. Uszkodzenia uzwojeń stojana

Najczęstszymi elektrycznymi uszkodzeniami silników indukcyjnych są uszkodzenia uzwojeń stojana wynikające z degradacji izolacji międzyzwojowej, międzyfazowej lub głównej [25, 226]. Na rysunku 2.6 przedstawiono narażenia oddziałujące na system izolacji silnika.




Rys. 2.6. Narażenia oddziałujące na układ izolacyjny silnika

Fig. 2.6. Stresses of the motor insulation system

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.),
- błędy konstrukcyjne i produkcyjne.

Na rysunku 2.7 przedstawiono podstawowe rodzaje uszkodzeń, które mogą wystąpić w uzwojeniach stojana połączonych w gwiazdę.



Rys. 2.7. Podstawowe rodzaje uszkodzeń w stojanie silnika indukcyjnego
Fig. 2.7. Basic kinds of stator faults of the induction motor

Uszkodzenia te można sklasyfikować następująco:

- 1° Zwarcia między zwojami w obrębie cewki.
- 2° Zwarcia między cewkami w tej samej fazie.
- 3° Zwarcia między fazami.
- 4° Zwarcia fazy do ziemi.
- 5° Przerwa w fazie.

W przypadkach 1° i 2° silnik będzie pracował jeszcze przez jakiś czas, trudny do oszacowania. W przypadkach 3° i 4° silnik jest awaryjnie odłączany od sieci przez zabezpieczenia. Natomiast w przypadku 5° silnik może kontynuować pracę zależnie od warunków obciążenia. W przypadkach 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. 2.7). 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 [226]. 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 [101]. Jednakże zależności stanu izolacji od czasu i temperatury nie można wykorzystać 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 może prowadzić do mechanicznego zniszczenia izolacji.

Uszkodzenia izolacji pojawiają się nagle w postaci zwarc 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 [295] 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 bezpieczeństwa 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 [101, 102, 115, 116]. Metoda wyładowań niezupełnych wymaga skomplikowanej aparatury diagnostycznej oraz dużego doświadczenia w interpretacji wyników [100, 101]. 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 nie nadają się do realizacji on-line. W związku z tym 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 [68, 75, 196, 254].

Źródłem nierównomierności szczeliny powietrznej mogą być: niecentryczne osadzenie wirników podczas 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 [36]). Przyczyną uszkodzeń łożysk mogą być uszkodzenia silnika zarówno natury elektrycznej, jak i mechanicznej, jak również uszkodzenia maszyny napędzanej. Jak wskazują statystyki, łożyska toczne są najczęściej uszkadzającymi się elementami maszyn wirnikowych (rys. 2.8). Dlatego diagnostyka łożysk tocznych stała się od lat 50. zeszłego stulecia dynamicznie rozwijającą się dziedziną badań [35, 189, 196].

Praktyka przemysłowa wskazuje, że problem skutecznej diagnostyki eksploatacyjnej węzłów łożyskowych silników elektrycznych jest jednym z najważniejszych zagadnień eksploatacji silników elektrycznych [128, 154, 161, 166, 174]. 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, to 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. 2.8. Przyczyny uszkodzeń mechanicznych maszyn elektrycznych

Fig. 2.8. Causes of mechanical faults of electrical machines


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 [36, 78]. Znaczna część uszkodzeń łożysk to uszkodzenia przedwczesne, wynikające bezpośrednio z:

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

Badania statystyczne wskazują, że tylko 25% uszkodzeń łożyska jest skutkiem naturalnego zużycia (rys. 2.9) [52, 259]. 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 [36, 64, 72, 74].



Rys. 2.9. Procentowy udział przyczyn awarii łożysk tocznych

Fig. 2.9. Percentage share of causes of rolling bearing faults

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 (obce 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. Podczas pracy mogą również występować deformacje wywołane nierównomiernym nagrzewaniem się wirnika [22, 102].

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 [77, 78, 265]:

- 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. Podsumowanie

Przedstawiony przegląd uszkodzeń występujących w silnikach indukcyjnych wykazał, że każdy z wymienionych typów uszkodzeń wytwarza podobne symptomy: drgania mechaniczne, grzanie się uzwojeń, modulację prądu, niszczenie łożysk, kołysanie prędkości oraz uszkodzenia wtórne typu ekscentryczność czy też uszkodzenia izolacji stojana. Uszkodzenia elektryczne i powstające w eksploatacji problemy mechaniczne znajdują swoje odbicia w kształcie i widmie prądu oraz innych wielkości elektrycznych i mechanicznych, np.: strumieniu poosiowym, momencie elektromagnetycznym, mocy chwilowej. W silniku indukcyjnym występuje więc wzajemne oddziaływanie na siebie wszystkich zjawisk elektromagnetycznych, mechanicznych oraz cieplnych, a stopień tych interakcji zależy od warunków pracy, obciążenia, symetrii elektrycznej i magnetycznej. Dlatego w następnym rozdziale przedstawiono szczegółową analizę wpływu poszczególnych rodzajów uszkodzeń na podstawowe wielkości, w których występują symptomy uszkodzeń.

3. Eksploatacyjne metody monitorowania i diagnostyki napędów z silnikami indukcyjnymi

3.1. Charakterystyka sygnałów diagnostycznych

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 tak zwane 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.

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 (monitorowanie czy diagnostyka).

Na podstawie publikacji [13, 15, 93, 138, 277, 278, 291] można zauważyć, że obecnie w badaniach naukowych i praktyce eksploatacyjnej napędów z silnikami indukcyjnymi jako podstawowe sygnały diagnostyczne dominują prąd stojana oraz drgania mechaniczne. Są to sygnały, które można mierzyć nieinwazyjnie i które odzwierciedlają wszystkie nienormalne zjawiska zachodzące w maszynie elektrycznej.

Również w innych sygnałach dostępnych w maszynie elektrycznej zawartych jest dużo cech pozwalających dokonywać oceny symptomów uszkodzeń. Dotyczy to przede wszystkim: mocy elektrycznej chwilowej, momentu elektromagnetycznego

oraz strumienia poosiowego [31, 192, 226, 278, 290]. Wydaje się, że szczególnie moc elektryczna, ze względu na łatwość i nieinwazyjność pomiaru, jest sygnałem szczególnie przydatnym w diagnostyce silników elektrycznych [186, 278, 279]. 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 (prądów i napięć). Również pomiar strumienia poosiowego wiąże się z koniecznością wbudowywania w maszynę dodatkowych cewek pomiarowych, co zwykle nie jest możliwe do zrealizowania w czasie eksploatacji napędów.

W wymienionych sygnałach poszukuje się przede wszystkim charakterystycznych częstotliwości, których amplituda jest cechą służącą do oceny poziomu uszkodzenia. Poniżej zostanie przedstawiona charakterystyka sygnałów prądu, mocy, momentu i strumienia poosiowego ze względu na występowanie w tych sygnałach symptomów uszkodzeń silnika indukcyjnego.

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

$$\begin{aligned} u_{AB}(t) &= \sqrt{2}U_{AB} \cos \omega_s t, \\ u_{CB}(t) &= \sqrt{2}U_{CB} \cos \left(\omega_s t + \frac{\pi}{3} \right), \\ i_A(t) &= \sqrt{2}I_A \cos \left(\omega_s t - \varphi - \frac{\pi}{6} \right), \\ i_C(t) &= \sqrt{2}I_C \cos \left(\omega_s t - \varphi + \frac{\pi}{2} \right), \end{aligned} \quad (3.1)$$

gdzie:

U_{AB}, U_{BC}, I_A, I_C – wartości skuteczne napięć międzyfazowych i prądów fazowych,

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

Wyrażenia na moc chwilową częściową i całkowitą będą miały postać

$$\begin{aligned} p_{AB}(t) &= U_{AB}I_A \left[\cos \left(\varphi + \frac{\pi}{6} \right) + \cos \left(2\omega_s t - \varphi - \frac{\pi}{6} \right) \right], \\ p_{CB}(t) &= U_{CB}I_C \left[\cos \left(\varphi - \frac{\pi}{6} \right) - \cos \left(2\omega_s t - \varphi - \frac{\pi}{6} \right) \right], \\ p_{ABC}(t) &= p_{AB}(t) + p_{CB}(t) = \sqrt{3}U_{AB}I_A \cos(\varphi) = P_{ABC}. \end{aligned} \quad (3.2)$$

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

W sytuacjach, gdy występują uszkodzenia silnika, w prądach, momencie i prędkości pojawiają się oddziaływania o charakterze modulacji okresowej. Prądy będą zawierały dodatkową składową okresową o postaci

$$\begin{aligned} i'_A(t) &= i_A(t)[1 + M \cos(\omega_{\text{osc}}t)], \\ i'_C(t) &= i_C(t)[1 + M \cos(\omega_{\text{osc}}t)], \end{aligned} \quad (3.3)$$

gdzie:

M – parametr modulacji zależny od rodzaju uszkodzenia,
 $\omega_{\text{osc}} = 2\pi f_{\text{osc}}$ – pulsacja oscylacji.

Po podstawieniu (3.3) do zależności (3.1) na prąd otrzymuje się:

$$i'_A(t) = i_A(t) + \frac{M}{\sqrt{2}} I_A \left\{ \cos \left[(\omega_s + \omega_{\text{osc}})t - \varphi - \frac{\pi}{6} \right] + \cos \left[(\omega_s - \omega_{\text{osc}})t - \varphi - \frac{\pi}{6} \right] \right\}. \quad (3.4)$$

Z zależności (3.4) wynika, że prąd stojana, oprócz podstawowej harmonicznej sieciowej f_s , zawiera dwie harmoniczne pasmowe $f_s \pm f_{\text{osc}}$.

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

$$\begin{aligned} p'_{AB}(t) &= p_{AB}(t) + \frac{1}{2} M U_{AB} I_A \left\{ 2 \cos \left(\varphi + \frac{\pi}{6} \right) \cos(\omega_{\text{osc}}t) \right. \\ &\quad \left. + \cos \left[(2\omega_s + \omega_{\text{osc}})t - \varphi - \frac{\pi}{6} \right] + \cos \left[(2\omega_s - \omega_{\text{osc}})t - \varphi - \frac{\pi}{6} \right] \right\} \\ p'_{CB}(t) &= p_{CB}(t) + \frac{1}{2} M U_{CB} I_C \left\{ 2 \cos \left(\varphi + \frac{\pi}{6} \right) \cos(\omega_{\text{osc}}t) \right. \\ &\quad \left. + \cos \left[(2\omega_s + \omega_{\text{osc}})t - \varphi + \frac{\pi}{6} \right] + \cos \left[(2\omega_s - \omega_{\text{osc}})t - \varphi + \frac{\pi}{6} \right] \right\} \\ p'_{ABC}(t) &= P_{ABC} + \sqrt{3} U_{AB} I_A M \cos(\varphi) \cos(\omega_{\text{osc}}t). \end{aligned} \quad (3.5)$$

Z zależności (3.5) wynika, że w widmie mocy chwilowej częściowej występują trzy charakterystyczne częstotliwości: $2f_s + f_{\text{osc}}$, $2f_s - f_{\text{osc}}$ 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 w 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 (3.1), ale również od fazy [92, 278].

W momencie elektromagnetycznym, który jest w przybliżeniu proporcjonalny do mocy p_{ABC} , można oczekiwać podobnego rozkładu częstotliwości charakterystycznych, jak w przypadku mocy elektrycznej. Jednakże jest on kombinacją oddziaływań strumieni rozproszenia i prądów 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 prądów fazowych i napięć międzyfazowych [156, 158].

Na podstawie modelu matematycznego silnika indukcyjnego w układzie $\alpha\beta$ [131, 215, 280], można napisać równania umożliwiające obliczenie składowych strumienia stojana lub wirnika. W przypadku korzystania z modelu napięciowego składowe strumienia skojarzonego z uzwojeniem stojana mają postać

$$\begin{aligned}\Psi_{s\alpha} &= \int (u_{s\alpha} - R_s i_{s\alpha}) dt, \\ \Psi_{s\beta} &= \int (u_{s\beta} - R_s i_{s\beta}) dt.\end{aligned}\quad (3.6)$$

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

$$\begin{aligned}\Psi_{r\alpha} &= \int \left[\frac{R_r}{L_r} (L_M i_{s\alpha} - \Psi_{r\alpha}) - \omega_m \Psi_{r\beta} \right] dt, \\ \Psi_{r\beta} &= \int \left[\frac{R_r}{L_r} (L_M i_{s\beta} - \Psi_{r\beta}) + \omega_m \Psi_{r\alpha} \right] dt,\end{aligned}\quad (3.7)$$

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 obliczeniowe na moment elektromagnetyczny przedstawiają się następująco:

a) moment elektromagnetyczny obliczany ze składowych osiowych wektora strumienia skojarzonego z uzwojeniem stojana

$$M_e = \frac{3}{2} p_b (i_{s\beta} \Psi_{s\alpha} - i_{s\alpha} \Psi_{s\beta}), \quad (3.8)$$

b) moment obliczany ze składowych osiowych wektora strumienia skojarzonego z uzwojeniem wirnika

$$M_e = \frac{3}{2} p_b \frac{L_M}{L_r} (i_{s\beta} \Psi_{r\alpha} - i_{s\alpha} \Psi_{r\beta}). \quad (3.9)$$

Z tych zależności wynika, że składowe uszkodzeniowe występujące w strumieniu rozproszenia, w porównaniu do prądów, mają amplitudy zredukowane co najmniej o rząd, co pozwala z wystarczającą dokładnością przyjąć, że w momencie elektromagnetycznym podstawowe znaczenie będą miały częstotliwości charakterystyczne f_{osc} modulujące prąd stojana oraz częstotliwości pasmowe $2f_s + f_{osc}$ oraz $2f_s - f_{osc}$.

We wszystkich maszynach elektrycznych nieuniknione są pewne asymetrie magnetyczne i geometryczne, które powodują powstawanie poosiowych strumieni rozproszenia. Są one generowane przez prądy płynące przez uzwojenie stojana i wirnika. Konsekwencją występowania asymetrii jest różnica w prądach płynących w różnych miejscach połączeń czołowych. Wynikiem tego jest strumień poosiowy. Ponieważ może być wytwarzany przez prądy stojana i wirnika, więc charakterystyczne częstotliwości w nim występujące są związane z częstotliwościami sieci f_s oraz wirnika sf_s . Zawartość harmonicznnych poosiowych strumieni rozproszenia stojana i wirnika jest bezpośrednio związana z zawartością harmonicznnych prądów stojana i wirnika. Do monitorowania różnych typów asymetrii niezbędna jest wiedza o charakterystycznych częstotliwościach.

Według [226, 277] detekcja strumienia poosiowego może być przydatna w diagnostyce do:

- wykrywania zwarc zwojowych w stojanie,
- wykrywania uszkodzeń prętów wirnika i uszkodzeń uzwojeń wirników zwojowych,
- wykrywania składowej kolejności przeciwnej w napięciu zasilania,
- wykrywania ekscentryczności wirnika.

W zależności od rodzaju uszkodzenia częstotliwość charakterystyczna f_{osc} będzie miała różne przyczyny powstawania, a tym samym różną wartość i amplitudę, na przykład przy asymetrii wirnika $f_{osc} = 2sf_s$, przy uszkodzeniach mechanicznych typu ekscentryczność, niewyważenie lub nieosiowość wałów $f_{osc} = f_r$ (częstotliwość obrotowa). W przypadku uszkodzeń łożysk $f_{osc} = f_{łoż}$ (częstotliwość charakterystyczna dla uszkodzeń elementów łożysk). Oprócz podstawowej harmonicznej o częstotliwości f_{osc} , mogą również występować jej krotności i częstotliwości pasmowe. Szczegółową analizę częstotliwości charakterystycznych dla poszczególnych rodzajów uszkodzeń przedstawiono w dalszych rozdziałach.

3.2. Analiza sygnałów – podstawowa metoda diagnostyki eksploatacyjnej silników indukcyjnych


W diagnostyce napędów elektrycznych z silnikami indukcyjnymi przeważają obecnie metody oparte na kontroli i analizie sygnałów [15, 31, 168, 277], w których korzysta się z pomiarów wybranych wielkości fizycznych (przede wszystkim elektrycznych i mechanicznych), poddawanych następnie matematycznemu przetwarzaniu.

niu. Otrzymane wyniki są porównywane z parametrami granicznymi lub służą do określania trendów.

Podstawowe wielkości fizyczne wykorzystywane w monitorowaniu i diagnostyce silników indukcyjnych, uszeregowane według częstości stosowania, to:

- drgania mechaniczne,
- prąd fazowy stojana,
- moc czynna elektryczna,
- strumień poosiowy,
- moment elektromagnetyczny,
- temperatura.

Na rysunku 3.1 przedstawiono schemat ilustrujący algorytm diagnostyki opartej na analizie wielkości fizycznych.



Rys. 3.1. Schemat ideowy algorytmu diagnostyki opartej na analizie sygnałów fizycznych

Fig. 3.1. Schematic diagram of diagnostics algorithm based on physical signal analysis

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 wymogami analizy widmowej (twierdzenie Shanona). 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 widmach (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 widmach. W przedziałach tych widma muszą być obliczone z wystarczającą rozdzielczością, która umożliwi wyodrębnienie charakterystycznych składowych harmonicznym.

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


W następnych rozdziałach omówiono najczęściej obecnie stosowane w eksploatacji silników indukcyjnych metody monitorowania i diagnostyki, wykorzystujące analizę widmową wybranych sygnałów elektrycznych i mechanicznych.

3.3. Wykrywanie uszkodzeń wirników klatkowych

3.3.1. Charakterystyka zjawisk zachodzących w silniku indukcyjnym z uszkodzonym wirnikiem

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. 3.2).



Rys. 3.2. Strumienie Ψ_r' i Ψ_r'' wzbudzone w wirniku niesymetrycznym

Fig. 3.2. Rotor fluxes Ψ_r' and Ψ_r'' excited in an unsymmetrical rotor

Składowa zgodna wiruje względem stojana z prędkością synchroniczną

$$\omega_2' = \omega_m + \omega_2 = \omega_s(1-s) + s\omega_s = \omega_s. \quad (3.10a)$$

Składowa przeciwbieżna wiruje względem stojana z prędkością

$$\omega_2'' = \omega_m + \omega_2 = \omega_s(1-s) - s\omega_s = (1-2s)\omega_s. \quad (3.10b)$$

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. Tak więc w stojanie płyną prądy wywołane napięciem sieci zasilającej oraz napięciem indukowanym przez pole przeciwbieżne. Występuje pulsacja prądów fazowych stojana. Jednakże w początkowej fazie awarii jest ona słabo widoczna i w związku z tym nie może być sygnałem diagnostycznym. Na rysunku 3.3 przedstawiono mechanizm i następstwo powstawania kolejnych składowych harmonicznych, po raz pierwszy podany w pracy [92].

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. 3.3. Ilustracja mechanizmu generowania częstotliwości w prądach stojana i wirnika
Fig. 3.3. Illustration of frequency generation mechanism in stator and rotor currents

Jeżeli wirnik jest niesymetryczny (uszkodzony), to prąd wirnika wytwarzają 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 3.3 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 $-sf_s$ (na rys. 3.3: $(1-2s)f_s \rightarrow -sf_s$). Prąd i_1^s jest określony zależnością

$$i_1^s = I_1^s \cos[(1-2s)\omega_s t - \alpha_l]. \quad (3.11)$$

Współdziałanie tego prądu z podstawowym strumieniem magnetycznym

$$\psi_s = \Psi_s \cos(\omega_s t - \alpha_\psi), \quad (3.12)$$

wytwarza oscylacje momentu elektromagnetycznego o częstotliwości $2sf_s$,

$$\Delta M_e(t) = 3p_b \Psi_s I_1^s \sin[2s\omega_s t - (\alpha_\psi - \alpha_l)], \quad (3.13)$$

przy czym: p_b – liczba par biegunów, α_l, α_ψ – odpowiednio faza początkowa prądu i strumienia stojana.

Oscylacje momentu powodują zmiany prędkości kątowej $\Delta\omega_m(t)$ wokół wartości średniej prędkości ω_m , które można określić z zależności

$$J \frac{d(\Delta\omega_m)}{dt} = \Delta M_e(t). \quad (3.14)$$


Po przekształceniach z uwzględnieniem (3.12) i (3.13) otrzymuje się

$$\Delta\omega_m(t) = \frac{1}{J} \int \Delta M_e(t) dt = -\frac{3p_b \Psi_s I_1^s}{J 2s\omega_s} \sin[2s\omega_s t - (\alpha_\psi - \alpha_l)]. \quad (3.15)$$

Z zależności (3.15) wynika, że moment bezwładności J ma istotny wpływ na zmiany prędkości, a tym samym na amplitudy składowych harmoniczných prądu stojana [70]. Im mniejszy moment bezwładności, tym większe są oscylacje prędkości silnika.

Efektom oscylacji prędkości jest wyindukowanie się w stojanie dwóch napięć: e_1 i e_2 o prawie równych amplitudach i częstotliwościach $(1 \pm 2s)f_s$ [92, 244]. 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 rys. 3.3 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 rys. 3.3 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. 3.3). Można więc powiedzieć, że w wyniku asymetrii wirnika jego prądy są 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 $(1 \pm 2s)f_s$.

Na rysunku 3.4 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 częstotliwości $2sf_s$, które z kolei są źródłem oscylacji $\Delta\omega_m$ prędkości kątowej silnika (na wielkość tych oscylacji ma wpływ moment bezwładności J).



Rys. 3.4. Schemat ilustrujący mechanizm powstawania oscylacji momentu

Fig. 3.4. Illustration of generation mechanism of torque oscillation

Odpowiedzią układu na oscylacje prędkości są dwa 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}

$$\Delta M_{e1} = 3p_b \Psi_s I_{1d}^s \sin \left[2s\omega_s t - (\alpha_\psi - \alpha_l) + \frac{\pi}{2} + \varphi \right], \quad (3.16)$$

$$\Delta M_{e2} = 3p_b \Psi_s I_{2d}^s \sin \left[2s\omega_s t - (\alpha_\psi - \alpha_l) - \frac{\pi}{2} - \varphi \right]. \quad (3.17)$$

Wypadkowe oscylacje momentu $\Delta M_{e\Sigma}$

$$\Delta M_{e\Sigma} = \Delta M_e + \Delta M_{e1} + \Delta M_{e2}. \quad (3.18)$$

Przy założeniu $I_{1d}^s \cong I_2^s$ oraz po uproszczeniach trygonometrycznych otrzymuje się

$$\Delta M_{e\Sigma} \cong 3p_b \Psi_s (I_1^s - I_{1d}^s) \cong 3p_b \Psi_s (I_1^s - I_{2d}^s). \quad (3.19)$$

Z zależności (3.19) 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 rys. 3.4 można rozszerzyć o działanie kolejnych sił elektromotorycznych o częstotliwościach $3sf_s$ indukowanych w wirniku przez składowe $(1+2s)f_s$. Jednakże dalsze oddziaływania są już znacznie słabsze i w praktyce mogą być pominięte [92].

3.3.2. Wykrywanie uszkodzeń wirników na podstawie analizy widmowej prądu stojana


Jak zostało to szczegółowo przedstawione w punkcie 3.3.1, uszkodzeniom wirnika towarzyszą w widmie prądu stojana składowe harmoniczne o częstotliwościach

$$f_p = (1 \pm 2ks)f_s, \quad (3.20)$$

gdzie: $k = 1, 2, 3, \dots$

W dalszej części pracy częstotliwości harmonicznych zwanych często poślizgowymi, będą oznaczane odpowiednio: $f_{p1} = (1-2s)f_s$ – „lewa” harmoniczna poślizgowa, $f_{p2} = (1+2s)f_s$ – „prawa” harmoniczna poślizgowa, $f'_{p1} = (1-4s)f_s$, $f'_{p2} = (1+4s)f_s$ itd. (rys. 3.5).

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 tej metody zostały omówione m.in. w publikacjach [110, 136, 138, 247, 270]. Na rysunku 3.5 przedstawiono rozkład charakterystycznych składowych harmoniczných zgodnie z zależnością (3.20).



Rys. 3.5. Ilustracja rozkładu harmoniczných poślizgowych w widmie prądu stojana spowodowanych uszkodzeniem wirnika wg (3.20) dla $k = 1, 2$

Fig. 3.5. Illustration of slip harmonic distribution in stator current spectrum connected with rotor faults according to (3.20) for $k = 1, 2$


Do określenia częstotliwości charakteryzujących składowe prądu stojana mogą również służyć zależności podane w [138], uwzględniające harmoniczne przestrzenne pola

$$f_b = f_s \left[\left(\frac{k}{p_b} \right) (1-s) \pm s \right], \quad (3.21)$$

gdzie: $k/p_b = 1, 5, 7, 11$ w normalnym układzie uzwojeń.

Na rysunku 3.6 pokazano rozkład charakterystycznych składowych harmoniczných wg zależności (3.21).

W tabeli 3.1 przedstawiono przykładowe harmoniczne obliczone z zależności (3.20) dla $k = 1, 2, 3$ i poślizgu $s = 6,5\%$.



Rys. 3.6. Ilustracja rozkładu harmoniczných poślizgowych w widmie prądu stojana spowodowanych uszkodzeniem wirnika wg (3.21) dla $k/p = 1, 5, 7, 11$

Fig. 3.6. Illustration of slip harmonic distribution in stator current spectrum connected with rotor faults according to (3.21) for $k/p = 1, 5, 7, 11$

Tabela 3.1. Wartości częstotliwości charakteryzujących uszkodzony wirnik obliczone wg (3.20) dla $s = 6,5\%$

Table 3.1. Frequency values for faulted rotor calculated according to (3.20) for $s = 6.5\%$

k	f_p [Hz]	
	-	+
1	43,5	56,5
2	37	63
3	30,5	69,5
4	24	76
5	17,5	82,5

Po podstawieniu do zależności (3.21) kolejnych wartości k/p otrzymuje się

$$\begin{aligned} \frac{k}{p} = 1, & \quad f_{b1} = f_s - (1 \pm 1)sf_s, \\ \frac{k}{p} = 5, & \quad f_{b5} = 5f_s - (5 \pm 1)sf_s, \\ \frac{k}{p} = 7, & \quad f_{b7} = 7f_s - (7 \pm 1)sf_s, \end{aligned}$$


W tabeli 3.2 zestawiono częstotliwości obliczone wg (3.21) dla silnika o poślizgu $s = 6,5\%$.

Tabela 3.2. Wartości częstotliwości charakteryzujących uszkodzony wirnik obliczone wg (3.21) dla $s = 6,5\%$

Table 3.2. Frequency values for faulted rotor calculated according to (3.21) for $s = 6.5\%$


$\frac{k}{p}$	f_b [Hz]	
	–	+
1	43,5	50
5	230,5	237,1
7	324,1	330,5

Na rysunkach 3.7 i 3.8 przedstawiono przykładowe widma z zaznaczonymi wybranymi harmonicznymi wymienionymi w tabelach 3.1 i 3.2. Z porównania częstotliwości obliczonych z zależności (3.20) i (3.21) wynika, że dla $k = 1$ i $k/p = 1$, częstotliwości się pokrywają ($f_{p1} = f_{b1}$). Potwierdza to, że z punktu widzenia diagnostyki jest to podstawowa częstotliwość charakteryzująca w widmie prądu stojana asymetrię wirnika. W praktyce diagnostycznej obecnie stosuje się powszechnie zależność (3.20).



Rys. 3.7. Harmoniczne poślizgowe w okolicach częstotliwości $f_s = 50$ Hz (silnik SSh 90L-4)

Fig. 3.7. Slip harmonics in surrounding of frequency $f_s = 50$ Hz (SSh 90L-4 motor)



Rys. 3.8. Harmoniczne poślizgowe w okolicach częstotliwości $5f_s = 250$ Hz
 Fig. 3.8. Slip harmonics in surrounding of frequency $5f_s = 250$ Hz

Równolegle z wystąpieniem w widmie prądu stojana częstotliwości „poślizgowych” i ich kolejnych krotności wokół f_s (rys. 3.5 i rys. 3.7), w silniku z uszkodzoną klatką występują częstotliwości poślizgowe w pobliżu $5f_s$ i $7f_s$ (tabela 3.2 i rys. 3.6 i 3.8). Ma to duże znaczenie diagnostyczne, 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 harmonicznych 5. i 7. Oczywiście 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 obok $5f_s$ i $7f_s$ są stosunkowo wyraźnie wyodrębnione. Na rysunku 3.8 przedstawiono przykład widma prądu w obszarze 5. harmonicznej dla uszkodzonego wirnika.

Według [16, 138, 264], przydatność przedstawionej procedury i posiłkowanie się obszarami wokół 5. i 7. harmonicznej, pozwala na skuteczne diagnozowanie klatki wirnika silników dużej mocy już od obciążeń $M_O > 0,2M_N$. Należy pamiętać, że prowadzenie badań przy zbyt małym i dodatkowo zmiennym obciążeniu może spowodować pokrywanie się harmonicznych poślizgowych z harmonicznymi od oscylacji obciążenia, co w efekcie, przy ewentualnym braku uszkodzenia wirnika i występowaniu wahań obciążenia, może spowodować mylną diagnozę. Procedura diagnostyczna sprowadza się więc do sprawdzenia, czy w widmie prądu stojana obok 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 wy-

nika z badań eksperymentalnych dla silników o dobrym stanie technicznym klatki, różnice w poziomach składowych f_s i $f_s(1 \pm 2s)$ są około 50 dB i więcej (zależnie od jakości technologii). Jeżeli różnice w poziomach tych składowych są poniżej 35 dB, to silnik należy bezwzględnie wyłączyć [15, 265].

W tabeli 3.3 zamieszczono klasyfikację poziomów uszkodzeń wirników klatkowych silników dużej mocy. Zastosowano następujące oznaczenia: I^s – amplituda składowej podstawowej prądu stojana, I_{p1}^s – amplituda składowej poślizgowej prądu stojana.

Tabela 3.3. Klasyfikacja poziomów uszkodzeń wirników klatkowych dla silników dużej mocy
Table 3.3. Classification of the fault levels for squirrel-cage rotors of high-power motors

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)

Często do wstępnego oszacowania amplitudy „lewej” harmonicznej poślizgowej o częstotliwości $(1-2s)f_s$ stosuje się przybliżone wyrażenia analityczne. Między innymi według [106]

$$\frac{I_{p1}^s}{I^s} \cong \frac{\sin \alpha}{2p_b(2\pi - \alpha)}, \quad (3.22)$$

gdzie:

$$\alpha = 2\pi np_b / N_r,$$

n – liczba przerwanych prętów,

N_r – liczba prętów wirnika, przy czym $n \ll N_r$.

Według [17], przy założeniu, że prąd magnesujący i rezystancja pierścieni zwiernających są pominięte

$$\frac{I_{p1}^s}{I^s} \cong \frac{n}{N_r}. \quad (3.23)$$


W przypadku występowania uszkodzeń prętów w różnych miejscach wirnika, na podstawie analizy widmowej można otrzymać zafałszowaną informację dotyczącą poziomu amplitudy I_1^s . Występuje zwłaszcza wtedy, gdy uszkodzenie w prętach jest przesunięte względem siebie o $\pi/2$ [15]. Z badań eksperymentalnych wynika, że zarówno skos żłobkowy, jak i nieizolowane pręty wirnika prowadzą do redukcji amplitudy harmonicznnych poślizgowych [15, 137]. Wiarygodność zależności (3.22) i (3.23) wzrasta wraz ze wzrostem mocy silników.

Przedstawiona procedura diagnostyczna jest obecnie najczęściej stosowana w monitorowaniu i diagnostyce on-line silników indukcyjnych dużej mocy. W praktyce wystarczający jest pomiar prądu stojana tylko w jednej fazie. Jak wynika z rys. 3.9 różnice w widmach dla poszczególnych faz są minimalne. Potwierdzają to również obliczone wartości amplitud charakterystycznych częstotliwości (tabela 3.4).

Tabela 3.4. Amplitudy harmonicznnych poślizgowych obliczone dla trzech prądów fazowych (cztery przypadki uszkodzeń wirnika silnika SSh 90L-4)

Table 3.4. Magnitudes of slip harmonics calculated for three phase currents (four cases of rotor faults of SSh 90L-4 motor)

			Amplitudy dla $k = 1$ [dB]		Amplitudy dla $k = 2$ [dB]	
Prąd	Liczba uszkodzonych prętów	faza	lewa	prawa	lewa	prawa
3,7 A	1	Ia	-42,8	-44,2	-52,2	-57,5
		Ib	-43,1	-45,3	-51,7	-58,0
		Ic	-43,0	-45,5	-51,8	-57,5
	2	Ia	-37,5	-37,8	-50,5	-54,8
		Ib	-37,9	-38,1	-50,3	-55,5
		Ic	-37,8	-38,0	-50,5	-55
	3	Ia	-34,6	-36,1	-53,9	-55,9
		Ib	-34,7	-36,3	-54,2	-56,6
		Ic	-34,7	-36,1	-53,9	-56,0
	4	Ia	-35,2	-34,8	-53,1	-55,2
		Ib	-35,3	-34,9	-53,4	-55,5
		Ic	-35,4	-34,8	-53,3	-55,4



Rys. 3.9. Widma prądu trzech faz silnika SSh 90L-4 z uszkodzonym wirnikiem

Fig. 3.9. Spatial illustration of the current spectra for three phases of SSh 90L-4 motor with faulted rotor

Na widma prądu stojana ma wpływ nie tylko wartość momentu obciążenia, ale również jego charakter. Jeżeli moment obciążenia zmienia się wraz z położeniem wirnika, to widmo prądu stojana zawiera składowe, które mogą się pokrywać ze składowymi będącymi symptomami uszkodzeń. W idealnej maszynie o sinusoidalnym rozkładzie strumienia, każda oscylacja w momencie obciążenia o krotności częstotliwości obrotowej wirnika f_r wytwarza prądy stojana o częstotliwościach [56, 138, 247]

$$f_{\text{obc}} = f_s \pm k f_r = f_s \left[1 \pm m \frac{1-s}{p_b} \right], \quad (3.24)$$

gdzie: $m/p_b = 1, 5, 7, \dots$

Częstotliwości obliczone z zależności (3.24) mogą w niektórych przypadkach uszkodzeń wirnika pokrywać się z charakterystycznymi częstotliwościami określonymi według zależności (3.20) i (3.21). 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).

Analiza widmowa prądu stojana może być także stosowana do wykrywania innych uszkodzeń, np. mechanicznych, związanych z nieosiowością napędu, ekscentrycznością i uszkodzeniami łożysk, co będzie omawiane w dalszych rozdziałach pracy.

Należy podkreślić, że klasyczna metoda analizy widmowej prądów stojana nie rozwiązuje w pełni problemu klasyfikacji uszkodzeń i oszacowywania stopnia uszkodzenia na podstawie wartości amplitud określonych harmoniczných. Jest wrażliwa na

zakłócenia pochodzące od zmian momentu obciążenia i w wielu przypadkach sprawia kłopot z wyizolowaniem charakterystycznych częstotliwości.


Dlatego ciągle prowadzone są badania nad udoskonaleniem metod cyfrowego przetwarzania sygnału prądu i wprowadzania nowych technik przetwarzania opartych na sztucznej inteligencji [13, 15, 46, 105, 175, 194, 222, 235, 251].

3.3.3. Zastosowanie analizy wektora przestrzennego prądu stojana do wykrywania uszkodzeń wirnika

Przedstawiona w rozdziale 3.3.2 metoda analizy prądu stojana do wykrywania uszkodzeń wirnika ma, oprócz oczywistych zalet, również wiele niedogodności związanych z rozdzieleniem wpływu uszkodzenia od efektów wtórnych wywołanych przez oscylacje momentu i prędkości. Dlatego od kilku lat można zauważyć rosnące zainteresowanie innym podejściem, polegającym również na nieinwazyjnym pomiarze sygnału prądu stojana, a następnie jego przetwarzaniu do postaci wektora przestrzennego lub jego modułu [54].

Wykorzystanie wektora przestrzennego sprowadzało się pierwotnie do wykreślania jego hodografu w układzie współrzędnych prostokątnych x, y i na podstawie jego kształtu do wyciągania wniosków odnośnie do stanu wirnika [32]. Ponieważ takie podejście jest bardzo wrażliwe na zakłócenia pomiarowe i trudne do automatyzacji, nie znalazło szerszego zastosowania w monitorowaniu wirników klatkowych. Dopiero tzw. rozszerzone podejście EPVA (ang. *Extended Park's Vector Approach*) do analizy wektora przestrzennego prądu stojana pozwoliło na bardziej przydatne w praktyce zastosowanie tej metody [55, 167, 170, 172, 176, 177]. Większa przydatność związana jest z łatwiejszym wyodrębnieniem harmonicznym $f_p^{(k)} = ksf_s$ ($k = 1, 2, 3, \dots, n$) świadczących o uszkodzeniu wirnika. Jednak jest to okupione zwiększoną złożonością algorytmów przetwarzania sygnału prądu.

Na rysunku 3.10 przedstawiono schemat ilustrujący algorytm diagnozowania oparty na analizie wektora przestrzennego prądu stojana.



Rys. 3.10. Algorytm diagnostyki wirników klatkowych na podstawie analizy wektora przestrzennego prądu stojana

Fig. 3.10. Diagnosis algorithm of cage rotors based on the spatial analysis of the stator current vector

W warunkach idealnego zasilania „zdrowej” maszyny, wektor przestrzenny prądu stojana można określić zależnością [280]

$$\mathbf{i}_s = \sqrt{\frac{2}{3}}(\mathbf{1}i_{sA} + \mathbf{a}i_{sB} + \mathbf{a}^2i_{sC}), \quad (3.25)$$

w której:

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

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

Składowe wektora przestrzennego prądu stojana $\mathbf{i}_s$ w prostokątnym układzie współrzędnych $(\alpha-\beta)$, nieruchomym względem stojana są związane z prądami fazowymi następującymi zależnościami (przekształcenie Clarka)

$$i_{s\alpha} = \sqrt{\frac{2}{3}}\left(i_{sA} - \frac{1}{2}(i_{sB} + i_{sC})\right), \quad (3.26a)$$

$$i_{s\beta} = \frac{1}{\sqrt{2}}(i_{sB} - i_{sC}). \quad (3.26b)$$

Gdy silnik ma wirnik nieuszkodzony, obie składowe wektora prądu stojana można przedstawić jako

$$i_{s\alpha} = \frac{\sqrt{6}}{2} I_m^s \cos \omega_s t, \quad (3.27a)$$

$$i_{s\beta} = \frac{\sqrt{6}}{2} I_m^s \sin \omega_s t, \quad (3.27b)$$

przy czym I_m^s – amplituda wektora przestrzennego prądu stojana.

Moduł wektora przestrzennego prądu stojana można wyrazić następująco:

$$|\mathbf{i}_s| = \sqrt{i_{s\alpha}^2 + i_{s\beta}^2}. \quad (3.28)$$

Moduł ten w przypadku braku asymetrii 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 (3.29a) i (3.29b)

$$i_{s\alpha} = \sqrt{\frac{3}{2}}\{I_m^s \cos(\omega_s t - \alpha) + I_{p1}^s \cos[(1-2s)\omega_s t - \beta_1] + I_{p2}^s \cos[(1+2s)\omega_s t - \beta_2]\}, \quad (3.29a)$$


$$i_{s\beta} = \sqrt{\frac{3}{2}}\{I_m^s \sin(\omega_s t - \alpha) + I_{p1}^s \sin[(1-2s)\omega_s t - \beta_1] + I_{p2}^s \sin[(1+2s)\omega_s t - \beta_2]\}. \quad (3.29b)$$

Po podstawieniu (3.29) do (3.28) otrzymuje się

$$|i_s|^2 = \frac{3}{2}((I_m^s)^2 + (I_{p1}^s)^2 + (I_{p2}^s)^2) + 3I_m^s I_{p1}^s \cos(2s\omega_s t - \alpha + \beta_1) + 3I_m^s I_{p2}^s \cos(2s\omega_s t + \alpha - \beta_1) + 3I_{p1}^s I_{p2}^s \cos(4s\omega_s t + \beta_1 + \beta_2), \quad (3.30)$$

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 (3.30) wynika, że w widmie modułu wektora przestrzennego prądu wystąpi składowa stała, generowana przez składową podstawową prądu stojana oraz dwa składniki o częstotliwościach $2sf_s$ i $4sf_s$. Dlatego widmo modułu wektora prądu stojana jest „czyste” wokół składowej podstawowej 50 Hz, natomiast symptomy uszkodzenia wirnika są widoczne w pobliżu częstotliwości $2sf_s$ i $4sf_s$ (rys. 3.11b).



Rys. 3.11 Widmo prądu fazowego silnika (a) oraz modułu wektora przestrzennego (b) dla silnika z uszkodzonymi 4 prętami wirnika

Fig. 3.11. Spectrum of motor phase current (a) and modulus of current spatial vector (b) for the induction motor with 4 broken rotor bars

Można więc powiedzieć, że diagnostyka wirnika oparta na metodzie analizy modułu wektora przestrzennego prądu stojana ma takie same pozytywne cechy jak konwencjonalna metoda analizy prądu stojana (tzw. metoda MCSA) i jednocześnie eliminuje niektóre ograniczenia i niedogodności widoczne w klasycznym podejściu. Przede wszystkim uwalnia od dodatkowych oddziaływań zmiennego momentu obciążenia na amplitudy harmonicznnych poślizgowych $(1 - 2s)f_s$ i $(1 + 2s)f_s$, zafałszowujących autentyczny stopień uszkodzenia. W module wektora prądu bardzo łatwo dają się wy-

odrębnić 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 3.11 przedstawiono przykładowe obliczone widma prądu fazowego i modułu wektora przestrzennego prądu dla silnika z uszkodzonym wirnikiem.

Należy podkreślić, że metoda ta pozwala wykryć również inne uszkodzenia 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 $f = 2f_s$. W przypadku niewłaściwego sprzęgnięcia silnika z maszyną roboczą w widmie modułu wektora przestrzennego prądu pojawia się natomiast składowa o częstotliwości $f = kf_r$ [167].

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. Zwiększenie nakładów obliczeniowych, a tym samym mocy obliczeniowej procesora wykorzystywanego w procesie diagnozowania, wynika z konieczności transformacji współrzędnych oraz obliczania modułu wektora, a następnie jego analizy częstotliwościowej.

3.4. Wykrywanie uszkodzeń stojana

3.4.1. Uwagi ogólne

Uszkodzenia stojana są jedną z podstawowych przyczyn awarii silników indukcyjnych [16, 133]. Ze względu na różne rodzaje narażeń powodujących uszkodzenia uzwojeń stojana, różny może być ich przebieg i miejsce uszkodzenia. Ponieważ zwarcia zwojowe są podstawowym uszkodzeniem występującym w początkowej fazie wszystkich rodzajów uszkodzeń stojana (patrz punkt 2.3), stosowane obecnie metody wykrywania uszkodzeń oraz poszukiwania nowych metod eksploatacyjnych są skoncentrowane na wykrywaniu ich fazy początkowej (zwarcie 1÷5 zwojów).

W ostatnich latach rozwinęło się kilka metod wczesnego wykrywania zwarc zwojowych. Jednakże brak jest rozwiązania przemysłowego, które realizowałoby monitorowanie i diagnostykę on-line. Wydaje się, że podstawową przyczyną tego stanu jest przekonanie dużej części użytkowników silników WN i NN o nieopłacalności takiej inwestycji i wiara w wystarczalność okresowych badań stanu izolacji oraz w skuteczność działania standardowych zabezpieczeń w stanach awaryjnych [226, 277]. Wielu specjalistów od eksploatacji napędów uważa, że silnik, w którym wystąpi uszkodzenie uzwojeń stojana i tak musi być przezwojony, wobec tego bez znaczenia jest to, kiedy i jak zostanie wyłączony z eksploatacji. Z punktu widzenia no-

woczesnych systemów produkcyjnych jest natomiast bardzo istotne odłączenie silnika bez trwałego uszkodzenia całej instalacji technologicznej i w sposób bezpieczny dla obsługi.

Podstawową trudnością w monitorowaniu uszkodzeń uzwojenia stojana jest fakt, że uszkodzenia te mają silnie destrukcyjny charakter. Rozszerzają się lawinowo i w bardzo krótkim czasie prowadzą do trwałego uszkodzenia stojana. Wobec tego sens mają tylko takie metody monitorowania, które pozwalają wykryć stan początkowy uszkodzenia (ang. *incipient fault*). Obecnie można wyróżnić trzy metody oparte na monitorowaniu następujących wielkości fizycznych:

- strumienia poosiowego [226, 231, 270, 277],
- momentu elektromagnetycznego silnika [192, 193],
- impedancji kolejności przeciwnej [4, 5, 141, 142, 258].


Oprócz wymienionych, istnieją metody monitorowania stanu stojana oparte na analizie prądu stojana i drganiach mechanicznych [111, 112, 197, 199, 277]. Duży prąd płynący w zwojach zwartych wywołuje odkształcenie pola magnetycznego w szczelinie, co powoduje pojawienie się sił przemiennych, działających na wirnik i stojan. Ich wynikiem jest wzrost hałasu i drgań maszyny. Wykrywanie zwarć zwojowych może więc być realizowane na podstawie pomiaru wartości skutecznej prędkości drgań silnika lub tylko składowej $2f_s$ i jej wielokrotności [36, 265]. Najkorzystniej jest mierzyć składową styczną prędkości drgań, gdyż jej wzrost jest największy po zaistnieniu zwarć w stojanie. Jednakże zakres stosowania tych metod jest bardzo ograniczony i najczęściej mają one charakter laboratoryjny.

3.4.2. Zastosowanie strumienia poosiowego do wykrywania zwarć zwojowych

Zagadnienie zastosowania strumienia poosiowego do wykrywania zwarć zwojowych jest znane od dawna i zostało opisane w licznych pracach, m.in. w [107, 108, 129, 193, 226, 231, 277, 290].

Według [226] koncepcja ta powstała z odwrócenia pomysłu wykorzystania prądu stojana do wykrywania uszkodzeń wirnika. W tym przypadku „cewką pomiarową” do wykrywania uszkodzeń stojana jest wirnik i powstający pod wpływem jego prądów strumień poosiowy. Zmiany w widmie prądu wirnika są odzwierciedlone w zmianach widma strumienia poosiowego. Na rysunku 3.12 przedstawiono rozptył strumienia w silniku indukcyjnym z wyodrębnieniem strumienia zamykającego się wzdłuż wału maszyny.

W idealnej maszynie strumień poosiowy powinien być równy zeru. 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.



Rys. 3.12. Rozpływ strumienia w silniku indukcyjnym
Fig. 3.12. Flux distribution in the induction motor

Uszkodzenia stojana powodują asymetrię uzwojenia, wywołującą duże zmiany strumienia poosiowego. Powstałe uszkodzenia powodują zmianę rozkładu harmonicznych przestrzennych indukcji w szczelinie. Harmoniczne przestrzenne nie mogą być wykryte bezpośrednio poprzez pomiar strumienia poosiowego. Natomiast w strumieniu tym można wykryć harmoniczne czasowe, które są pomieszczone 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. Aby określić wzajemną zależność harmonicznych przestrzennych i harmonicznych czasowych, zostanie przeprowadzona uproszczona analiza zjawiska.

Indukcję magnetyczną w szczelinie powietrznej silnika w układzie stacjonarnym względem stojana można zapisać następująco [107, 226]:

$$\begin{aligned} B_s(\theta, t) = & B_1 \cos(\omega_s t - p_b \theta) + B_5 \cos(\omega_s t + 5 p_b \theta) \\ & - B_7 \cos(\omega_s t - 7 p_b \theta) + B_{11} \cos(\omega_s t + 11 p_b \theta) - \dots \end{aligned} \quad (3.31)$$

gdzie:

B_n – amplituda harmonicznej przestrzennej indukcji magnetycznej w szczelinie powietrznej,

$n = 1, 5, 7, 11, 13 \dots$ – rząd harmonicznej,

θ – położenie katowe wirnika,

p_b – liczba par biegunów.

Wyrażenie (3.31) jest słuszne przy założeniu, że uzwojenia maszyny i źródła zasilania są symetryczne.

Aby możliwa była analiza harmoniczna wielkości związanych z wirnikiem, niezbędne jest wprowadzenie do zależności (3.31) prędkości kątowej wirnika ω_m .

Po podstawieniu do (3.31) zależności na położenie kątowe θ w funkcji prędkości kątowej ω_m

$$\theta = \theta_0 + \omega_m t, \quad (3.32)$$

gdzie: θ_0 – położenie kątowe wirnika dla $t = 0$,

oraz uwzględnieniu zależności prędkości kątowej wirnika od poślizgu

$$\omega_m = \frac{\omega_s}{p_b}(1-s), \quad (3.33)$$

otrzymuje się

$$\begin{aligned} B_r(s, t) = & B_1 \cos(s\omega_s t - p_b\theta_0) + B_5 \cos((6-5s)\omega_s t + 5p_b\theta_0) \\ & - B_7 \cos((7s-6)\omega_s t - 7p_b\theta_0) + B_{11} \cos((12-11s)\omega_s t + 11p_b\theta_0) - \dots \end{aligned} \quad (3.34)$$

Równanie (3.34) zawiera już informację o tym, jakie częstotliwości wystąpią w prądzie wirnika i strumieniu poosiowym przy założeniu, że źródło zasilania jest sinusoidalne.

Jeżeli uwzględni się wyższe harmoniczne czasowe f_{sk} w napięciu zasilającym,

$$f_{sk} = k f_s = k \frac{\omega_s}{2\pi}, \quad (3.35)$$

to poszczególne składniki wyrażenia (3.34) będą miały ogólną postać

$$B_{r_n}(s, t) = B_n \cos \left[k \pm n \frac{(1-s)}{p_b} \omega_s t \pm n \theta_0 \right], \quad (3.36)$$

gdzie:

B_{r_n} – składowe harmoniczne indukcji magnetycznej wirnika,

$n \neq 2p_b m, m = 1, 2, 3, \dots$

Na podstawie powyższych rozważań można stwierdzić, że w strumieniu poosiowym zwarcia zwojowe stojana powodują zmiany harmoniczných czasowych o częstotliwościach

$$f_{ax} = k f_s \pm n \frac{1-s}{p_b} f_s \quad (3.37a)$$

lub w innym zapisie

$$f_{ax} = kf_s \pm nf_r, \quad (3.37b)$$

gdzie:

k – rząd harmonicznego czasowego 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 3.5 zestawiono harmoniczne obliczone według zależności (3.37b). Pogrubioną czcionką oznaczono te składowe, które w praktyce eksperymentalnej mają największe znaczenie i wykazują zwykle największe zmiany amplitudy.

Tabela 3.5. Harmoniczne w strumieniu poosiowym obliczone wg (3.37b)

Table 3.5. Harmonics in axial flux calculated according (3.37b)

n	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	$f_s - 5f_r$	$f_s + 5f_r$	$3f_s - 5f_r$	$3f_s + 5f_r$	$5f_s - 5f_r$	$5f_s + 5f_r$

Na rysunku 3.13 przedstawiono trzy możliwe sposoby umieszczenia cewki do pomiaru strumienia poosiowego.




Rys. 3.13. Ilustracja możliwych sposobów rozmieszczenia cewek pomiarowych do detekcji strumienia poosiowego


Fig. 3.13. Illustration of possibilities for placement of measurement coils for axial flux detection

Wybór lokalizacji cewki uzależniony jest od rodzaju, wielkości i konkretnych rozwiązań konstrukcyjnych silnika. Najkorzystniejszy byłby wariant z wewnętrzną cewką pomiarową, jednak z reguły użytkownicy maszyn unikają konstrukcji z inwazyjnym rozwiązaniem przetworników pomiarowych.

Na rysunkach 3.14 i 3.15 przedstawiono przykłady widm napięcia indukowanego w cewkach pomiarowych przez strumień poosiowy dla przypadku zdrowego silnika i przy zwarcu ok. 11% zwojów w jednej fazie [164, 165], z których wynika, że wybrane harmoniczne wyraźnie zwiększają swoją amplitudę wraz ze wzrostem stopnia uszkodzenia.



Rys. 3.14. Widmo strumienia poosiowego silnika zdrowego
Fig. 3.14. Axial flux spectrum for healthy motor



Rys. 3.15. Widmo strumienia poosiowego silnika przy zwarcu ok. 11% zwojów
Fig. 3.15. Axial flux spectrum for the motor with ca. 11% short circuits in the stator

Monitorowanie stanu uzwojenia stojana można więc realizować albo na podstawie zmian wartości skutecznej napięcia indukowanego w cewce pomiarowej przez strumień poosiowy, albo przez analizę harmoniczną tego napięcia.

Metoda wykrywania zwarc zwojowych w stojanie silnika indukcyjnego oparta na pomiarze strumienia poosiowego może mieć duże znaczenie w warunkach eksploatacji przemysłowej ze względu na prostotę realizacji. Może ona również stanowić znakomite uzupełnienie stosowanych standardowo zabezpieczeń, których działanie następuje dopiero przy znacznie większym poziomie uszkodzenia oraz poważnych zniszczeniach w uzwojeniach.

3.4.3. Zastosowanie sygnału momentu elektromagnetycznego do wykrywania zwarc zwojowych

Moment elektromagnetyczny jest bardzo dobrym sygnałem do wykrywania asymetrii w silniku indukcyjnym. Analizując w dziedzinie częstotliwości sygnał momentu elektromagnetycznego, mierzony bezpośrednio lub obliczany pośrednio na podstawie mierzonych napięć i prądów stojana (zależność (3.8) i (3.9)), można poszukiwać w nim charakterystycznych harmonicznym związanych z uszkodzeniem uzwojenia stojana.

W sygnale momentu elektromagnetycznego występują:

- podwójna harmoniczna sieci: $2f_s$ (100 Hz),
- wielokrotności częstotliwości obrotowej: $f_r, 2f_r, 3f_r, \dots$,
- kombinacje częstotliwości sieci i obrotowej: $2f_s + f_r, 2f_s + 2f_r, 2f_s + 3f_r, \dots$

Ponadto podczas zwarc zwojowych pojawiają się harmoniczne pasmowe $\pm 2sf_s$ wokół składowych częstotliwości obrotowej. Z badań przedstawionych w [81, 192, 290] wynika, że w istotny sposób zmienia się wówczas amplituda harmonicznej $2f_s$ oraz $f_r \pm 2sf_s$.

W tabeli 3.6 zestawiono wszystkie częstotliwości, które występują w sygnale momentu elektromagnetycznego podczas zwarc zwojowych. Pogrubioną czcionką zostały wyróżnione harmoniczne najczęściej brane pod uwagę w monitorowaniu i diagnostyce stojanów silników indukcyjnych, ze względu na duży zakres zmian ich amplitud. Na podkreślenie zasługuje mały wpływ zmian obciążenia silnika na zmianę amplitud harmonicznym przy różnych stopniach asymetrii stojana [31].

Tłumiące działanie uzwojeń redukuje lub całkowicie usuwa niektóre harmoniczne pola magnetycznego wytwarzanego przez wirnik lub stojan tak, że ich identyfikacja może być bardzo utrudniona lub wręcz niemożliwa. Również pomiar momentu na wale nie usuwa tego problemu, bo w tym przypadku elementem filtrującym staje się bezwładność układu. Jednakże podstawowe i charakterystyczne dla zwarc harmonicznym są zawsze widoczne w widmie momentu elektromagnetycznego. Dotyczy to przede wszystkim częstotliwości $2f_s$, krotności częstotliwości obrotowej oraz znajdujących się w ich otoczeniu harmonicznym pasmowym $\pm 2sf_s$.

Tabela 3.6. Podstawowe częstotliwości harmonicznych występujące w sygnale momentu elektromagnetycznego przy zwarciah stojanowych
 Table 3.6. Basic frequencies of harmonics included in the electromagnetic torque signal in the case of stator short-circuits

Podwójna częstotliwość sieci	Wielokrotność częstotliwości obrotowej	Harmoniczne pasmowe	Kombinacje
$2f_s$	f_r	$f_r - 2sf_s$ $f_r + 2sf_s$	$2f_s + f_r$
	$2f_r$	–	$2f_s + 2f_r$
	$3f_r$	$3f_r - 2sf_s$ $3f_r + 2sf_s$	$2f_s + 3f_r$
	$4f_r$	–	$2f_s + 4f_r$
	$5f_r$	$5f_r - 2sf_s$ $5f_r + 2sf_s$	$2f_s + 5f_r$
	$6f_r$	–	$2f_s + 6f_r$
	$9f_r$	$9f_r - 2sf_s$ $9f_r + 2sf_s$	–

Praktyczne ograniczenia procedury diagnostycznej opartej na sygnale momentu elektrycznego wiążą się właściwie tylko z zastosowaniem odpowiedniego systemu pomiarowego. Zastosowanie komercyjnego rozwiązania do pomiaru momentu na wale wydaje się w przypadku systemów diagnostycznych rozwiązaniem nieodpowiednim, szczególnie ze względu na konieczność instalowania na wale przetwornika momentu. Gwałtowny rozwój procesorów sygnałowych sprawił, że dominujące znaczenie mają obecnie metody oparte na odtwarzaniu momentu elektromagnetycznego on-line za pomocą modeli matematycznych (patrz punkt 3.1) [156, 158, 192, 213, 215].

3.4.4. Zastosowanie składowych symetrycznych do wykrywania zwarc zwojowych

Wykorzystanie składowych symetrycznych w monitorowaniu i diagnostyce silników indukcyjnych zostało zaproponowane w [287], a następnie rozwinięte przez [5, 191, 193, 258]. W innej formie zaproponowano zastosowanie składowych symetrycznych w [29, 87, 91, 93]. 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 przy 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 [258] jest bardzo prosta i polega na pomiarze wartości chwilowych prądów i napięć, a następnie obliczaniu impedancji kolejności przeciwnej, która wykazuje duże zmiany podczas zwarć stojana. Chociaż 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 [188, 237]). Z reguły algorytmy te ograniczają się do obliczania składowych podstawowych prądów i napięć 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 [5]. Również coraz częściej uwzględnia się w prądach i napięciach całe spektrum harmonicznym [4].

Jeśli założymy, że wektor zespolony napięć fazowych ma postać $[\bar{U}_a \ \bar{U}_b \ \bar{U}_c]^T$, a prądów fazowych $[\bar{I}_a \ \bar{I}_b \ \bar{I}_c]^T$, to po przekształceniu na składowe symetryczne przyjmują one postać: $[\bar{U}_1 \ \bar{U}_2 \ \bar{U}_0]^T$ oraz $[\bar{I}_1 \ \bar{I}_2 \ \bar{I}_0]^T$.

Indeksy 1, 2 i 0 oznaczają składową kolejności zgodnej, przeciwnej i zerowej. W przypadku niezrównoważenia silnika (asymetria zewnętrzna lub wewnętrzna) każda składowa symetryczna związana jest z inną impedancją. Oznacza to, że transformacja współrzędnych z układu (abc) do układu (120) w pełni rozprzega te składowe. Właściwości silnika indukcyjnego z asymetrią stojana lub połączonego z niezrównoważonym źródłem zasilania można w uproszczeniu analizować, posługując się schematami zastępczymi dla składowej zgodnej i przeciwnej (rys. 3.16).

Ogólna postać zależności wyrażonych w zespolonych składowych symetrycznych ma postać


$$\begin{bmatrix} \bar{U}_1 \\ \bar{U}_2 \\ \bar{U}_0 \end{bmatrix} = \begin{bmatrix} \bar{Z}_1 & 0 & 0 \\ 0 & \bar{Z}_2 & 0 \\ 0 & 0 & \bar{Z}_0 \end{bmatrix} \begin{bmatrix} \bar{I}_1 \\ \bar{I}_2 \\ \bar{I}_0 \end{bmatrix}, \quad (3.38a)$$

gdzie:

$$\begin{aligned} \bar{U}_1 &= \frac{1}{3}(\bar{1}U_a + \bar{a}U_b + \bar{a}^2U_c), \\ \bar{U}_2 &= \frac{1}{3}(\bar{1}U_a + \bar{a}^2U_b + \bar{a}U_c), \\ \bar{U}_0 &= \frac{1}{3}(U_a + U_b + U_c), \end{aligned} \quad (3.38b)$$

$$\begin{aligned}
 \bar{I}_1 &= \frac{1}{3}(\bar{1}I_a + \bar{a}I_b + \bar{a}^2I_c), \\
 \bar{I}_2 &= \frac{1}{3}(\bar{1}I_a + \bar{a}^2I_b + \bar{a}I_c), \\
 \bar{I}_0 &= \frac{1}{3}(I_a + I_b + I_c).
 \end{aligned}
 \tag{3.38c}$$

Należy zaznaczyć, że w silnikach indukcyjnych trójfazowych nie występuje składowa zerowa prądów i napięć.



Rys. 3.16. Schematy zastępcze silnika indukcyjnego:
a) dla składowej zgodnej, b) dla składowej przeciwej
Fig. 3.16. Equivalent circuits of the induction motor:
a) for the positive sequence symmetrical component,
b) for the negative sequence symmetrical component

Na rysunku 3.16a zmienny parametr $\left(\frac{1-s}{s}\right)R_r'$, występujący w schemacie zastępczym dla składowej zgodnej, jest bardzo wrażliwy na zmiany poślizgu. Natomiast parametr $-\left(\frac{1-s}{2-s}\right)R_r'$, występujący w schemacie zastępczym na rys. 3.16b dla składo-

wej przeciwnej, jest praktycznie niewrażliwy na zmianę poślizgu. Dlatego impedancja składowej kolejności przeciwnej, definiowana jako

$$\bar{Z}_2 = \frac{\bar{U}_2}{\bar{I}_2}, \quad (3.39)$$

przyjmuje praktycznie stałe wartości podczas zmianach poślizgu. Natomiast wartość impedancji dla składowej zgodnej ulega zmianie wraz ze zmianami poślizgu (obciążenia) silnika. Można więc przyjąć, że w zdrowym silniku, niezależnie od obciążenia impedancja $\bar{Z}_2$ jest stała.

W chwili wystąpienia uszkodzenia uzwojenia stojana, następuje utrata symetrii i w silniku następuje zmiana składowej przeciwnej prądu $\bar{I}_2$ oraz impedancji $\bar{Z}_2$. Dlatego można je traktować jako symptomy wystąpienia zwarcia uzwojenia stojana.

Wyznaczanie impedancji $\bar{Z}_2$ wiąże się z wieloma problemami natury obliczeniowej:

- do obliczania $\bar{Z}_2$ niezbędny jest pomiar 6 sygnałów;
- analiza oparta jest na założeniu wynikającym z teorii składowych symetrycznych, że prądy i napięcia są idealnie sinusoidalne, co w praktyce jest nie do spełnienia i powoduje konieczność stosowania filtrów pasmowych;
- proces obliczeniowy składowych kolejności przeciwnej, ze względu na bardzo małe wartości ich amplitud, jest bardzo wrażliwy na dokładność obliczeń, zakłócenia pomiarowe i zmiany parametrów silnika.


Na rysunku 3.17 przedstawiono przykładowy przebieg zmian $\bar{Z}_2$ badanego silnika Stg80x-4C przed i po wystąpieniu zwarcia stojanowego. W punktach 1, 2, 3, 4 silnik pracował w warunkach symetrii, natomiast w punkcie 5 wystąpiło zwarcie 5 zwojów, a w punkcie 7 – 33 zwojów.



Rys. 3.17. Zależność impedancji kolejności przeciwnej $\bar{Z}_2$ dla silnika Stg80x-4C od stopnia uszkodzenia

Fig. 3.17. The negative sequence impedance $\bar{Z}_2$ for the Stg80x-4C motor versus a fault size

Ze szczegółowych badań przeprowadzonych przez autora pracy [193] wynika, że impedancja $\bar{Z}_2$ w ograniczonym stopniu zależy od obciążenia silnika i jej zmiany w miarę wzrostu stopnia asymetrii stojana są bardzo korzystne z punktu widzenia monitorowania uszkodzenia. Pozwalają zaobserwować początkową fazę powstawania uszkodzenia. Na rysunku 3.18 przedstawiono schemat ilustrujący algorytm obliczania impedancji $\bar{Z}_2$.



Rys. 3.18. Algorytm obliczania impedancji kolejności przeciwnej $\bar{Z}_2$

Fig. 3.18. Calculation algorithm for negative sequence impedance $\bar{Z}_2$

Wymienione wcześniej problemy obliczeniowe impedancji $\bar{Z}_2$ powodują, że nie da się zastosować prostych rozwiązań sprzętowych i niezbędne jest opracowanie systemu diagnostycznego o dużych możliwościach pomiarowo-obliczeniowych. To powoduje, że metoda ta nie jest praktycznie dotychczas stosowana w przemyśle.

Odmienne zastosowanie metody składowych symetrycznych w diagnostyce stojana zaproponowano w [83, 93]. Wykazano, że w miarę wzrostu stopnia asymetrii stojana amplituda składowej kolejności przeciwnej prądu stojana $\bar{I}_2$ zmienia się w dużym zakresie (rośnie w miarę zwiększania się liczby zwojów zwartych). Metoda ta również nie została do tej pory wdrożona w przemysłowych układach monitorowania i diagnostyki.

Na podstawie wyników badań przedstawionych w [5, 93, 193] można stwierdzić, że w chwili obecnej bardziej przydatne jest podejście oparte na wyznaczaniu impedancji kolejności przeciwnej; wymaga ono jednak bardziej złożonych obliczeń.

3.5. Wykrywanie uszkodzeń mechanicznych

3.5.1. Uwagi ogólne

Eksploatacyjne metody wykrywania uszkodzeń typu mechanicznego w silnikach indukcyjnych oparte są w zasadzie na analizie częstotliwościowej dwóch sygnałów: drgań mechanicznych i prądu stojana.

Sygnał drganiowy niesie wiele 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 pozwala na 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. Między innymi należą do nich metody analizy obwiedni i cepstrum [37, 161, 196].

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. Przy wykorzystaniu analizy widmowej prądu stojana do wykrywania uszkodzeń typu mechanicznego, najlepiej rozpoznaną i wdrożoną jest diagnostyka ekscentryczności wirnika [28, 82, 60, 61, 66, 67, 198, 254, 255, 272, 273, 274, 276, 286]. 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 [246, 247, 261].


Ekscentryczność szczeliny powietrznej może być uszkodzeniem pierwotnym lub wtórnym. Uszkodzeniem pierwotnym jest wówczas, gdy od początku eksploatacji silnik ma znaczącą niesymetrię, np. niekołowy otwór stojana bądź przekrój poprzeczny wirnika. Uszkodzenie wtórne ma miejsce 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 odczytywaniu 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 paśmie częstotliwości, a nie tylko wokół podstawowej częstotliwości zasilania.

Rozróżnia się ekscentryczność statyczną, dynamiczną oraz mieszaną (jednoczesne występowanie obu rodzajów ekscentryczności). Na rysunku 3.19 przedstawiono inter-

pretację 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 pomiędzy 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. „wyrobinie” się łożyska. Znaczny luz łożysk powoduje z kolei powstawanie drgań promieniowych i staje się źródłem ekscentryczności dynamicznej. Tak więc ekscentryczność statyczna może być pierwotną przyczyną powstania ekscentryczności dynamicznej. Bardzo często oba te zjawiska nakładają się na siebie. W literaturze, między innymi w [66, 254], można się spotkać z różnym definiowaniem ekscentryczności dynamicznej. Między innymi rozróżnia 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 [256].



Rys. 3.19. Współosiowe i ekscentryczne usytuowanie wirnika w otworze stojana
Fig. 3.19. Coaxial and eccentric rotor placement in the stator

W przypadku ekscentryczności dynamicznej oś wirnika nie jest osią obrotu wirnika (rys. 3.19). To przesunięcie może być spowodowane przez różne czynniki, 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 łożysk, grzanie się łożysk i niekontrolowany ubytek smarowania, i w końcu – przy dużym jej poziomie – tarcie wirnika o stojan, co w efekcie 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 powinna być wykryta i kontrolowana, ponieważ z reguły ma ona tendencję do pogłębiania się, co w konsekwencji nieuchronnie prowadzi do uszkodzenia maszyny. Bezpośredni związek z występowaniem ekscentryczności ma stan techniczny łożysk w maszynie elektrycznej. Również uszkodzenia natury elektrycznej (uszkodzenie prętów wirnika, niejednorodne pole elektromagnetyczne wirnika i stojana) powodują zwiększone zmienne obciążenie łożysk i ich przedwczesne uszkodzenia. Dlatego tak duże znaczenie praktyczne ma wczesne wykrycie i zlokalizowanie tych uszkodzeń. Istnieje wówczas czas na spokojne dokonanie naprawy poprzez wyważenie, wyosiołowanie, smarowanie czy w ostateczności ich wymianę.

3.5.2. Zastosowanie analizy prądu stojana do wykrywania uszkodzeń mechanicznych

3.5.2.1. Wykrywanie ekscentryczności wirnika

Ekscentryczne usytuowanie wirnika silnika indukcyjnego względem stojana wprowadza asymetrię szczeliny powietrznej i w wyniku charakterystycznych zmian we wzajemnych sprzężeniach magnetycznych pomiędzy uzwojeniami silnika wpływa na postać widma prądów stojana. Dlatego metoda analizy spektralnej prądu stojana (MCSA) jest podstawowym narzędziem diagnostycznym stosowanym w praktyce przemysłowej do kontroli ekscentryczności [28, 61, 66, 97, 197, 243, 254, 275].

Każdemu rodzajowi ekscentryczności można przypisać charakterystyczne częstotliwości zawarte w widmie prądów stojana. Najbardziej ogólna zależność określająca obecność częstotliwości charakterystycznych dla ekscentryczności oraz ułobkowania wirnika, ma postać

$$f_e = f_s \left[(kN_r \pm n_d) \frac{1-s}{p_b} \pm n_w \right], \quad (3.40)$$

w której:

$k = 1, 2, 3, \dots$,

N_r – liczba żłobków wirnika,

$n_d = 0$ przy ekscentryczności statycznej,

$n_d = 1, 2, 3$ – rząd ekscentryczności dynamicznej (główne harmoniczne żłobkowe),

$n_w = \pm 1, \pm 3, \pm 5, \pm 7, \dots$ – rząd harmoniczných czasowych stojana,

p_b – liczba par biegunów.

Zależność (3.40) pozwala określić 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” [134]. W zależności (3.40) występują trzy grupy harmoniczných:

- k harmoniczných związanych z wirnikiem,
- n_w harmoniczných związanych ze stojanem,
- n_d harmoniczných związanych z ekscentrycznością.

Dla ekscentryczności statycznej charakterystyczne są częstotliwości określone zależnością

$$f_{es} = f_s \left[k \frac{N_r}{p_b} (1-s) \pm 1 \right] \quad (3.41)$$

lub w postaci

$$f_{es} = |k N_r f_r \pm f_s|, \quad (3.42)$$

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 [67, 104, 256]. Są to wspomniane główne harmoniczne żłobkowe. Wystąpienie wszelkich innych częstotliwości w widmie prądu stojana jest symptomem wystąpienia ekscentryczności.

Jak wykazano w [67, 197], tylko szczególne kombinacje liczby par biegunów i liczby żłobków wirnika będą powodowały istotny wzrost harmoniczných charakterystycznych dla ekscentryczności statycznej lub dynamicznej.

Jeżeli spełniony jest warunek

$$N_r = 2p_b[3(m \pm q) \pm r], \quad (3.43)$$

gdzie: $m \pm q = 0, 1, 2, 3, \dots$, $r = 0$ lub 1 ,


to w widmie widoczne będą zmiany głównych harmoniczných żłobkowych oraz składowe związane z ekscentrycznością mieszaną, brak będzie natomiast widocznych zmian składowych związanych z ekscentrycznością statyczną lub dynamiczną.

Gdy

$$N_r = 2p_b[3(m \pm q) \pm r] \pm k, \quad (3.44)$$

gdzie: $m \pm q = 0, 1, 2, 3, \dots$, $r = 0$ lub 1 , $k = 1$ lub 2 , wówczas w widmie będą widoczne tylko harmoniczne związane z ekscentrycznością statyczną lub tylko z ekscentrycznością dynamiczną, jak również składowe związane z ekscentrycznością mieszaną, nie będą natomiast występowały główne harmoniczne żłobkowe.

W przypadku ekscentryczności statycznej prądy stojana są niesymetryczne. Dlatego z diagnostycznego punktu widzenia ma znaczenie czy w zasilaniu stojana występuje przewód zerowy, gdyż przy jego braku wystąpi tylko jedna harmoniczna żłobkowa dla stanu symetrii.



Rys. 3.20. Przykładowy obraz widm ekscentryczności mieszanej ($p_b = 2$, $N_r = 51$, $s = 0,037$):

a) pasmo niskich częstotliwości; b) pasmo wysokich częstotliwości

Fig. 3.20. Example of mixed eccentricity spectra ($p_b = 2$, $N_r = 51$, $s = 0,037$):

a) low-frequency band; b) high-frequency band

W przypadku wystąpienia ekscentryczności dynamicznej, prądy stojana są symetryczne, a w przypadku braku przewodu zerowego w zasilaniu, ograniczony będzie 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

$$f_{ed} = |f_s \pm k f_r|. \quad (3.45)$$

Częstotliwości te występują we wszystkich maszynach. Te niskoczęstotliwościowe składowe powodują wzrost składowych wysokoczęstotliwościowych określonych zależnością (3.40). Jednakże składowe wysokoczęstotliwościowe silnie zależą od rozwiązania konstrukcyjnego maszyny (patrz zależności (3.43), (3.44)).

Na rysunku 3.20 przedstawiono przykładowy obraz harmonicznych charakteryzujących ekscentryczność mieszaną w paśmie niskich i wysokich częstotliwości. 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, więc bardzo istotna jest duża dokładność wyznaczania prędkości obrotowej. Do tego celu najkorzystniej jest wykorzystywać harmoniczne żłobkowe [67, 290].

3.5.2.2. Wykrywanie uszkodzeń łożysk tocznych

Widmo prądu stojana silnika zawiera harmoniczne charakterystyczne dla poszczególnych rodzajów uszkodzeń łożyska i dlatego można na jego podstawie określać stopień i rodzaj uszkodzenia [246, 261]. Zmiany obciążenia silnika modulują amplitudę prądu, wytwarzając oprócz harmonicznej podstawowej dodatkowe częstotliwości. Drgania pochodzące od uszkodzonego łożyska powodują zmianę wielkości szczeliny powietrznej między wirnikiem a stojanem. Jest to przyczyną powstania dodatkowych harmonicznych niezwiązanych z harmoniczną podstawową napięcia zasilania. Na podstawie analizy częstotliwościowej można wyznaczyć częstotliwości prądu odpowiadające poszczególnym typom uszkodzeń w łożysku

$$f_u = |f_s + k f_l|, \quad (3.46)$$

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 (3.47)–(3.50).

Na rysunku 3.21 przedstawiono przykład widma prądowego silnika małej mocy z uszkodzonym łożyskiem.




Rys. 3.21. Widmo częstotliwościowe prądu fazowego stojana dla łożyska z pękniętą bieżnią zewnętrzną (silnik SSh-90b-4)

Fig. 3.21. Spectrum of the stator phase current for the bearing with broken outer race (SSh-90b-4 motor)

W widmie widoczne są harmoniczne częstotliwości uszkodzeniowej bieżni zewnętrznej ($f_{bz} = 89,75$ Hz) obliczone według zależności (3.46). Można zauważyć, że poziom harmonicznych uszkodzeniowych widocznych w widmie prądu stojana jest bardzo niski, szczególnie dla małych maszyn, co skutecznie ogranicza przydatność tej metody w praktyce przemysłowej.

3.5.3. Zastosowanie analizy drgań mechanicznych

Najczęściej do oceny stanu łożysk stosowana jest diagnostyka oparta na pomiarze drgań mechanicznych. Sygnał drganiowy niesie wiele informacji związanych ze stanem technicznym maszyny indukcyjnej i jest wykorzystywany w ciągłym monitorowaniu napędów dużej mocy. Analiza widmowa sygnałów drganiowych pozwala na identyfikację rodzaju uszkodzenia. Na rysunku 3.22 przedstawiono podział uszkodzeń łożysk. Wynikają one z pojedynczych punktowych uszkodzeń elementów łożysk oraz chropowatości powierzchni bieżni i kulki i wywołują efekty uszkodzeniowe w postaci drgań w obszarze niskich częstotliwości oraz drgania szerokopasmowe. Wobec tego stosowany sprzęt pomiarowy powinien zapewniać pomiar drgań z dużą rozdzielczością w szerokim paśmie częstotliwości.



Rys. 3.22. Uszkodzenia łożysk – efekty i symptomy uszkodzeń

Fig. 3.22. Bearing damages – fault effects and symptoms

Zagadnieniem eksploatacyjnej 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 znane są następujące metody diagnozowania łożysk tocznych w maszynach:

- metoda wykorzystująca ustalenia norm (pomiar ogólnego poziomu drgań),
- metoda analizy częstotliwościowej,
- metoda analizy obwiedni (*Envelop Method*) firmy B&K,
- metoda SPM (*Shock Pulse Method*) firmy SPM,
- metod SE (*Spike Energy*) firmy IRD,
- metoda BCU (*Bearing Condition Unit*) firmy Schenck,
- metoda SEE (*Spectral Emitted Energy*) firmy SKF,
- metoda REBAM (*Rolling Element Bearing Active Monitor*) firmy Bently Nevada.

Wyboru metody diagnostycznej dokonuje się na etapie zakupu sprzętu diagnostycznego. Spowodowane jest to tym, że firmy produkujące sprzęt diagnostyczny narzucają swoją metodę wraz z aparaturą. Najbardziej ogólny charakter ma metoda analizy częstotliwościowej, która pozwala rozdzielić sygnał drganiowy na składniki o różnych częstotliwościach [36, 68, 128, 173, 174, 196]. Porównywanie szerokopasmowych widm drgań węzła łożyskowego w trakcie kolejnych pomiarów (przeważnie od 1 do kilkudziesięciu kHz), w przypadku wystąpienia w łożysku impulsów udarowych, umożliwi wykrycie wzrostu amplitud drgań własnych maszyny. Ponieważ widma drgań tworzone są zazwyczaj na drodze uśredniania, zmiany poziomów drgań wywołane występowaniem krótkotrwałych impulsów udarowych mają znacznie

mniejszą dynamikę (ok. 20–40 dB) niż zmiany amplitud samych impulsów (ok. 60 dB). Dlatego czułość detekcji uszkodzeń łożysk tą metodą jest mniejsza od czułości uzyskiwanych metodami ukierunkowanymi na obserwację samych impulsów udarowych. Zróżnicowanie położenia obszarów drgań własnych w widmie nawet identycznych maszyn oraz dodatkowo często występująca znaczna nieliniowość tych obszarów zmusza do tworzenia indywidualnych kryteriów oceny stanu łożyska. Opieranie się jedynie na wzroście poziomów drgań wysokoczęstotliwościowych może być zawodne ze względu na możliwość wzbudzenia tych obszarów innymi wymuszeniami niż impulsy wynikające z uszkodzenia łożyska. Niemniej jednak, w przypadku prostych węzłów łożyskowych, klasyczna analiza widmowa drgań stanowi dobre narzędzie wykrywania uszkodzeń łożysk. Skutecznymi technikami wspomagającymi badania szerokopasmowych widm drgań łożysk są: funkcja lupy, cepstrum, analizy oktaowej, rzędów i obwiedni.

Te techniki diagnostyczne mogą służyć do wykrycia obecności okresowych składników sygnału drganiowego w obszarze o podwyższonym poziomie drgań. W przypadku występowania punktowych uszkodzeń powierzchni tocznych lub bicia kosza, pracujące łożysko generuje drgania o charakterystycznych częstotliwościach [270, 259, 291]

$$f_{lk} = \frac{1}{2} f_r \left(1 - \frac{d \cos \vartheta}{D} \right), \quad (3.47)$$

$$f_{bz} = \frac{N_k}{2} f_r \left(1 - \frac{d \cos \vartheta}{D} \right), \quad (3.48)$$

$$f_{bw} = \frac{N_k}{2} f_r \left(1 + \frac{d \cos \vartheta}{D} \right), \quad (3.49)$$

$$f_k = \frac{D}{2 \cdot d} f_r \left(1 - \left(\frac{d \cos \vartheta}{D} \right)^2 \right), \quad (3.50)$$

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,

n – prędkość obrotowa maszyny,


d – średnica elementu tocznego,

D – średnica podziałowa łożyska,

ϑ – kąt pracy łożyska (0° dla łożyska kulkowego zwykłego),

N_k – liczba elementów tocznych łożyska.

Wymiary łożysk niezbędne do wyznaczenia częstotliwości charakteryzujących uszkodzenia poszczególnych elementów łożyska przedstawiono na rys. 3.23.



Rys. 3.23. Łożysko toczne kulkowe zwykłe:

d – średnica elementu tocznego, D – średnica podziałowa łożyska

Fig. 3.23. Classical rolling bearing: d – diameter of rolling element, D – diameter of the bearing

Funkcja lupy, dzięki znacznej poprawie rozdzielczości w interesującym zakresie częstotliwości, ułatwia odnalezienie kolejnych harmonicznych sygnału okresowego. Funkcja cepstrum (funkcja „widma z widma”) pozwala na identyfikację harmonicznych i pasm bocznych w sygnale drganiowym [35, 36]. Największą popularnością w diagnostyce łożysk tocznych cieszy się analiza obwiedniowa, umożliwiającą wydzielenie okresowych impulsów występujących w przebiegu czasowym [52, 74, 128, 161, 174].

Zastosowanie analizy częstotliwościowej w połączeniu z analizą obwiedniową pozwala 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.

W widmach drganiowych można wyróżnić kilka podstawowych charakterystycznych częstotliwości drgań:

- f_s – częstotliwość zasilania silnika oraz jej krotności,
- f_r – częstotliwość związana z prędkością obrotową wirnika silnika oraz jej krotności,
- f_z – częstotliwości pochodzące od zewnętrznych układów (przekładni zębatych, sprzęgieł i innych układów napędzanych),
- częstotliwości charakteryzujące uszkodzenia elementów łożyska (wg zależności (3.46)–(3.50)).

Na rysunku 3.24 przedstawiono przykładowy obraz widma z zaznaczonymi charakterystycznymi częstotliwościami powstającymi w uszkodzonym łożysku. W zależności od rodzaju sygnału drganiowego (przesunięcie, prędkość, przyspieszenie), amplitudy harmonicznych mogą być wyrażone w: mm, mm/s, m/s². Pasma częstotliwości na rys. 3.24 zostało zawężone do 200 Hz.




Rys. 3.24. Przykładowe prążki widma drgań maszyny elektrycznej

– częstotliwości związane z uszkodzeniami łożyska przedstawiono dla łożyska o $N_k = 9$


Fig. 3.24. Example of vibration spectrum for electrical machine

– frequencies connected with the rolling bearing faults were presented for the bearing with $N_k = 9$


Na rysunkach 3.25–3.28 przedstawiono przykłady widm drganiowych napędu dużej mocy, w którym badania przeprowadzono przy wykorzystaniu klasycznej analizy częstotliwościowej oraz analizy obwiedni [161]. W napędzie z silnikiem indukcyjnym uszkodzeniu uległo jedno z łożysk zabudowane po stronie przeciwnapędowej. Pomiar drgań wykazały niewielkie zmiany wartości ogólnej prędkości drgań (10–1000 Hz) i duże zmiany wskaźnika BCU (metoda analizy obwiedni) w trzech kierunkach.



Rys. 3.25. Widma prędkości drgań łożyska (strona przeciwnapędowa, kierunek pomiaru: A02 – osiowo, V02 – pionowo; miesiąc przed wymianą łożyska)
 Fig. 3.25. Velocity vibration spectra of the bearing (anti-drive side, measurement direction: A02 – axial, V02 – vertical; a month before the bearing exchange)




Rys. 3.26. Widma obwiedni drgań łożyska (strona przeciwnapędowa, kierunek pomiaru: A02 – osiowo, V02 – pionowo; dzień przed wymianą łożyska)
 Fig. 3.26. Envelope vibration spectra of the bearing (anti-drive side, measurement direction: A02 – axial, V02 – vertical; a day before the bearing exchange)



Rys. 3.27. Widma prędkości drgań łożyska (strona przeciwnapędowa, kierunek pomiaru: A02 – osiowo, V02 – pionowo; po wymianie łożyska)

Fig. 3.27. Velocity vibration spectra of the bearing (anti-drive side, measurement direction: A02 – axial, V02 – vertical; after the bearing exchange)



Rys. 3.28. Widma obwiedni drgań łożyska silnika (strona przeciwnapędowa, kierunek pomiaru: A02 – osiowo, V02 – pionowo; po wymianie łożyska)

Fig. 3.28. Envelope vibration spectra of the bearing (anti-drive side, measurement direction: A02 – axial, V02 – vertical; after the bearing exchange)

W widmach częstotliwości drgań zaobserwowano pojawienie się składowej o częstotliwości $f_i = 193$ Hz i jej harmonicznym: $2f_i$, $3f_i$, $4f_i$ itd., co wskazywało na uszkodzenie łożyska. Temperatura łożyska była w normie. Analizując widma prędkości drgań na miesiąc i dzień przed wymianą łożyska, zauważono stosunkowo subtelne zmiany w widmie (rys. 3.25). Natomiast widma obwiedni drgań jednoznacznie wskazują na złą pracę łożyska (rys. 3.26). Na rysunkach 3. 27 i 3.28 przedstawiono widma prędkości drgań oraz obwiedni drgań po wymianie łożyska.

Doświadczenia z eksploatacji napędów w warunkach przemysłowych potwierdzają, że jedną z najlepszych i najskuteczniejszych metod diagnostyki łożysk tocznych jest metoda oparta na detekcji obwiedni sygnału drganiowego. Na skuteczność zaawansowanych technik diagnostyki łożysk tocznych decydujący wpływ mają: wybór punktu pomiarowego o najlepszej propagacji sygnału pochodzącego z łożyska oraz sposób mocowania przetwornika pomiarowego [75, 161, 174, 265].

3.6. Podsumowanie

Na podstawie przeprowadzonych rozważań można stwierdzić, że w eksploatacji napędów z silnikami indukcyjnymi dominują metody monitorowania i diagnostyki oparte na analizie prądu stojana i drgań mechanicznych. W niektórych przypadkach stosuje się analizy strumienia poosiowego, momentu elektromagnetycznego i składowych symetrycznych prądu.

Omówione w tym rozdziale metody diagnostyki eksploatacyjnej nie wyczerpują wszystkich możliwych przypadków występujących w praktyce. Dlatego w tabelach 3.7, 3.8 i 3.9 zestawiono podstawowe częstotliwości charakteryzujące uszkodzenia silnika indukcyjnego i występujące w prądzie stojana, drganiach mechanicznych i strumieniu poosiowym. Ułatwiają one interpretację widm.

Sygnał drganiowy zawiera bardzo dużo informacji o stanie technicznym silnika i obecnie jest podstawowym sygnałem w systemach monitorowania i diagnostyki. W tabeli 3.7 zestawiono najważniejsze uszkodzenia silnika indukcyjnego oraz ich częstotliwości charakterystyczne, występujące w widmach drgań mechanicznych. W tabeli nie zamieszczono zależności na częstotliwości charakterystyczne dla maszyn roboczych (np. pomp, wentylatorów, kompresorów itp.) i układów sprzęgających (np. sprzęgieł, przekładni zębatych itp.). Z uwagi na złożoność widm drganiowych, obecność zakłóceń, niestacjonarność sygnałów, trafność diagnozy w bardzo dużym stopniu zależy od wiedzy i doświadczenia eksperta oraz w coraz większym stopniu od jakości i złożoności cyfrowego przetwarzania sygnałów. Coraz większego znaczenia nabierają metody transformacji wyższych rzędów, co będzie rozważane w następnych rozdziałach.

Tabela 3.7. Zestawienie podstawowych uszkodzeń silnika indukcyjnego oraz ich symptomów w widmie drgań mechanicznych
Table 3.7. Specification of basic faults of the induction motor and their symptoms in the mechanical vibration spectrum

Rodzaj uszkodzenia	Częstotliwości charakterystyczne	Uwagi
Uszkodzenie wirnika klatkowego	$f_r \pm 2ksf_s$ gdzie: $k = 1, 2, 3, \dots$	Dominujący kierunek osiowy (horyzontalny)
Ekscentryczność	$2f_s$ lub $N_r f_r \pm f_s$ N_r – liczba prętów wirnika $f_r \pm 2kf_s$ $f_s \left[(kN_r \pm n_d) \frac{1-s}{p_b} \pm n_w \right]$ gdzie: $k = 1, 2, 3, \dots$ N_r – liczba prętów wirnika $n_w = 0, 2, 4, 6, \dots$ $n_d = 0$ – przy ekscentryczności statycznej $n_d = 1$ – przy ekscentryczności dynamicznej	Ekscentryczność statyczna Ekscentryczność dynamiczna oraz harmoniczne żłobkowe
Nieosiowość a) równoległa lub kątowa b) luzy łożysk	głównie: $1f_r$ i $2f_r$ czasami: $3f_r$ i $4f_r$	Maksymalne drgania w kierunku osiowym Czasami wszystkie harmoniczne f_r
Uszkodzenia łożysk tocznych a) bieżnia zewnętrzna b) bieżnia wewnętrzna c) elementy toczne d) koszyk	$kf_{bz}, kf_{bw}, kf_{bk}, kf_{lk}$ $f_{bz} \pm kf_r$ gdzie: $f_{bz} = \frac{N_k}{2} f_r \left(1 - \frac{d \cos \vartheta}{D} \right)$ $f_{bw} = \frac{N_k}{2} f_r \left(1 + \frac{d \cos \vartheta}{D} \right)$ $f_k = \frac{D}{2 \cdot d} f_r \left(1 - \left(\frac{d \cos \vartheta}{D} \right)^2 \right)$ $f_{lk} = \frac{1}{2} f_r \left(1 - \frac{d \cos \vartheta}{D} \right)$	Charakterystyczne częstotliwości rezonansowe dla poszczególnych elementów łożysk oraz drgania wysokoczęstotliwościowe 20–60 Hz
Niewyważenie statyczne i dynamiczne	F_r	Największe drgania w kierunku promieniowym
Uszkodzenia stojana	$2f_s$	Drgania w kierunku promieniowym

Diagnozowanie na podstawie widma prądu polega na ocenie amplitud harmonicznych o częstotliwościach charakterystycznych dla poszczególnych uszkodzeń widocznych w widmie. W tabeli 3.8 zestawiono podstawowe uszkodzenia silnika indukcyjnego oraz ich symptomy w widmie prądu stojana.

Tabela 3.8. Zestawienie podstawowych uszkodzeń silnika indukcyjnego oraz ich symptomów w widmie prądu stojana
 Table 3.8. Specification of basic faults of the induction motor and their symptoms in the stator current spectrum

Rodzaj uszkodzenia	Częstotliwości charakterystyczne	Uwagi
Uszkodzenie wirnika klatkowego (przerwane pręty lub pierścień zewnętrzny)	$(1 \pm 2ks)f_s$ gdzie: $k = 1, 2, 3, \dots$ $2sf_s, 4sf_s$	W widmie prądu stojana W widmie wektora przestrzennego prądu stojana
Ekscentryczność wirnika	$f_s \left[(kN_r \pm n_d) \frac{1-s}{p_b} \pm n_w \right]$ gdzie: $k = 1, 2, 3, \dots$ N_r – liczba prętów wirnika $n_w = 1, 3, 5, 7, \dots$ $n_d = 0$ – przy ekscentryczności statycznej $n_d = 1$ – przy ekscentryczności dynamicznej $f_s \pm kN_r f_r$ $f_s \pm kf_r$	Ogólna postać uwzględniająca ekscentryczność statyczną i dynamiczną Ekscentryczność statyczna Ekscentryczność mieszana
Nieosiowość	$f_s \pm kf_r$	
Uszkodzenia łożysk	$f_s \pm kf_{bi}$	W przybliżeniu: $f_{b1} = 0,4n_b f_r$ $f_{b2} = 0,6n_b f_r$ n_b – liczba elementów tocznych
Niewyważenie statyczne i dynamiczne	$f_s \pm f_r$	

Na ogół w systemach diagnostycznych zakłada się, że analiza jest dokonywana w stanie ustalonym i prędkość obrotowa jest stała. Przyjmuje się również założenie, że sygnały pomiarowe są stacjonarne. W rzeczywistości, nawet w przypadku stałego obciążenia, prędkość obrotowa oscyluje wokół wartości średniej. Głębokość kołysań zależy od wypadkowego momentu bezwładności i charakteru momentu obciążenia. Kołysania prędkości obrotowej wnoszą swoje charakterystyczne częstotliwości zawierające również informację diagnostyczną. Jednakże dla poprawności diagnozy konieczne jest prawidłowe oddzielenie w widmie prądu zjawisk wewnętrznych, pochodzących od uszkodzeń, od zewnętrznych oddziaływań, mających charakter zakłóceń. Dlatego analiza powinna być prowadzona w odpowiednio szerokim paśmie częstotliwości. Poprawność diagnozowania zdecydowanie wzrasta ze wzrostem obciążenia silnika, ale zależy również od rodzaju napędzanego układu mechanicznego.

W tabeli 3.9 zestawiono częstotliwości charakterystyczne, występujące w strumieniu poosiowym. Metoda ta jest stosunkowo rzadko stosowana i może być wykorzy-

stana do wykrywania uszkodzeń stojana, wirnika i łożysk. Jednakże podstawowe znaczenie ma ona w wykrywaniu zwarcia w stojanie.

Tabela 3.9. Zestawienie podstawowych uszkodzeń silnika indukcyjnego oraz ich symptomów w widmie strumienia poosiowego

Table 3.9. Specification of basic faults of the induction motor and their symptoms in the axial flux spectrum

Rodzaj uszkodzenia	Częstotliwości charakterystyczne	Uwagi
Zwarcia stojanowe (międzyzwojowe)	$kf_s \pm nf_r$ gdzie: $k = 1, 3, 5, \dots$ $n = 1, 2, 3, \dots, (2p_b - 1)$	Istotny wzrost amplitudy harmonicznych, widoczny w początkowej fazie uszkodzenia
Uszkodzenie wirnika klatkowego	$sf_s, (3 - 2s)f_s, (5 - 4s)f_s$	
Uszkodzenia łożysk tocznych	Częstotliwości z przedziału 600–900 Hz	Ograniczony zakres zastosowań

W diagnostyce, opartej na metodach analizy sygnałów, wykorzystuje się wiedzę i doświadczenie człowieka. To on dokonuje na bieżąco interpretacji aktualnych danych uzyskiwanych z pomiarów i analizy realizowanej przez systemy pomiarowe. Podejście to ma więc jeden słaby punkt w postaci ludzkiego eksperta, którego doświadczenie jest bardzo trudne do zautomatyzowania.

Do analizy sygnałów stosuje się przede wszystkim szybką transformację Fouriera FFT, która zakłada, że sygnały są stacjonarne. Podstawowym zagadnieniem jest, więc prawidłowa interpretacja jakościowa i ilościowa pojawiających się w widmach harmonicznych oraz prawidłowe uwzględnienie wszystkich interakcji.

Niestacjonarność sygnałów diagnostycznych, zakłócenia i złożone interakcje różnych uszkodzeń powodują, że interpretacja widm dla celów diagnostycznych wymaga dużego doświadczenia eksperckiego. Dlatego tak duże znaczenie ma poszukiwanie metod, które wychodząc z klasycznych sposobów diagnozowania, dostarczą obiektywnych informacji do klasyfikacji uszkodzeń. Taką możliwość stwarzają obecnie metody sztucznej inteligencji, a przede wszystkim sztuczne sieci neuronowe.

4. Metodyka wykorzystania sieci neuronowych do monitorowania i diagnostyki napędów z silnikami indukcyjnymi

4.1. Podstawowe informacje o sztucznych sieciach neuronowych

Rozwój teorii sztucznych sieci neuronowych oraz możliwości technologicznych ich praktycznej realizacji (systemy wieloprocesorowe, technologie VLSI) stworzyły nowe efektywne i uniwersalne narzędzie, za pomocą którego rozwiązuje się szereg zadań i problemów w różnych dziedzinach techniki. Chociaż teoria sieci neuropodobnych jest rozwijana od wczesnych lat 50. XX wieku, to dopiero badania prowadzone w ciągu jego ostatniej dekady doprowadziły do opracowania wielu aplikacji, które powszechnie udowodniły swoją skuteczność. Aplikacje te znalazły zastosowanie m.in. w automatyce i robotyce, elektronice, lotnictwie, telekomunikacji, systemach wojskowych, transporcie, medycynie [69, 147, 294].

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.

Bez wątpienia najsilniejszym atutem sieci neuronowych jest możliwość zastosowania ich w sytuacji, kiedy zawodzą metody algorytmiczne, tzn. gdy algorytm rozwiązania zadania nie jest znany. W konsekwencji, 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.

Te korzystne właściwości sztucznych sieci neuronowych spowodowały, że są one stosowane w takich dziedzinach, jak: rozpoznawanie i klasyfikacja obrazów, estymacja funkcji, systemy ekspertowe.

Sztuczna sieć neuronowa to system przetwarzania informacji, którego architektura i sposób funkcjonowania zostały zaczerpnięte z modeli biologicznych układów nerwowych [69, 147, 210, 240, 266]. Sieć neuronowa składa się z dużej liczby prostych elementów przetwarzających – neuronów. 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. 4.1). Sygnał ten jest następnie używany jako wejście dla innych neuronów. Schematowi z rysunku 4.1 odpowiada następujący opis, traktowany jako model matematyczny neuronu


$$u(x) = \sum_{j=1}^n w_j x_j + w_0, \quad (4.1)$$

$$y(x) = f(u(x)),$$

gdzie:

w_0 – wartość progowa,

w_j – współczynniki wagowe.



Rys. 4.1. Budowa neuronu i przykład sieci dwuwarstwowej

Fig. 4.1. Neuron structure and an example of the two-layer neural network

Pojedyncze neurony można łączyć równolegle w dowolną liczbę poziomów – tzw. warstw. W każdym z poziomów stosuje 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. W przypadku sieci wielowarstwowych (rys. 4.1b) wejścia są transmitowane do wyjść zgodnie z następującym równaniem:

$$y_j^{(s)} = f \left(\sum_i (w_{ij}^{(s)} x_i^{(s-1)}) \right), \quad (4.2)$$

w którym:

$y_j^{(s)}$ – 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. Tak więc, za sieć na przykład 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. Z reguły algorytm, którego sieć dopracowuje się podczas uczenia jest nieznanym 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. Taki 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 80–90% praktyki inżynierskiej stosuje się uczenie z nauczycielem [209, 210]. W uproszczeniu procedura ta wygląda następująco:

- Faza prezentacji:** na wejście sieci jest podawane wymuszenie x , a sieć udziela odpowiedzi $y(x)$.
- Faza porównania:** odpowiedź sieci jest porównywana z odpowiedzią pożądaną $d(x)$ i jest obliczany sygnał błędu, np. $\varepsilon = d(x) - y(x)$.
- Faza uczenia:** na podstawie sygnału błędu, w sposób zależny od wybranego algorytmu uczenia, są modyfikowane wartości wag tak, aby kolejna odpowiedź stała się bliższa požądanej.

Taki trójfazowy cykl jest stosowany dla całego zestawu przykładów i powtarzany wielokrotnie. Uczenie się kończy, gdy błąd sumaryczny dla tego zestawu zejdzie poniżej 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 $\{X\}$ na R^m wymiarową przestrzeń $\{Y\}$, przy czym postać przekształcenia formowana jest w procesie uczenia.

Istnieje wiele algorytmów uczenia sztucznych sieci neuronowych (SSN). Najbardziej rozpowszechnione to tzw. uogólnione zasady delty (ang. *Delta Rules*) oraz powszechnie stosowany do uczenia sieci wielowarstwowych algorytm wstecznej propagacji błędów (ang. *backpropagation*) [209, 267].

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)

$$\Delta w_{ij} = -\eta(y_i - d_i) \frac{df(u_i)}{du_i} x_j, \quad (4.3)$$

gdzie:

η – współczynnik uczenia,

$f(u_i)$ – funkcja aktywacji.


W przypadku kiedy funkcja aktywacji jest funkcją liniową, powyższy wzór sprowadza się do następującej zależności:

$$\Delta w_{ij} = -\eta(y_i - d_i)x_j. \quad (4.4)$$

Jedną z istotnych niedogodności metody propagacji wstecznej jako sposobu uczenia sieci neuronowej jest to, że wymaga ona „nauczyciela”, którego zadaniem jest podawanie do każdego wzorcowego wektora wejściowego, wektora oczekiwanej odpowiedzi sieci. Dlatego rozwinięty 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 [109, 143, 227, 267]. 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. 4.2) [47, 69, 227, 291]. Przy 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.




Rys. 4.2. Schemat ideowy sieci neuronowej typu Kohonena

Fig. 4.2. Schematic diagram of the Kohonen neural network

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 będzie musiała posłużyć się określoną miarą podobieństwa zaprezentowanego jej obrazu do obrazów znanych z przeszłości.

Najpopularniejszą miarą podobieństwa obrazów x i x_i jest odległość Euklidesa. 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 pozwala określić sąsiedztwo danego neuronu w postaci zbioru neuronów powiązanych między sobą odpowiednimi relacjami topologicznymi. Sąsiedztwa różnych rozmiarów w przypadku siatki prostokątnej przedstawiono na rys. 4.3. W mniejszym prostokącie znalazły się neurony będące sąsiadami wybranego centralnego neuronu, w większym prostokącie zawarte są natomiast neurony należące do sąsiedztwa drugiego rzędu. Analogicznie określa się sąsiedztwa w innych topologiach sieci.



Rys. 4.3. Sąsiedztwo pierwszego i drugiego rzędu w sieci samoorganizującej z topologią prostokątną

Fig. 4.3. The first- and second-order neighbourhood in the self-organising network with rectangular topology

W podstawowym algorytmie sieci samoorganizującej się zarówno liczba neuronów, jak i topologia sieci są określone 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 chwilami czasu $t = 1, 2, \dots$

Algorytmy samouczenia się sieci prowadzą do sensownej adaptacji wag w trakcie procesu zwanego samoorganizacją. Sieci uczone w tym trybie będą reagowały nie tylko na wartości sygnałów wejściowych, lecz również na prawdopodobieństwo ich pojawienia się. Uczenie będzie więc wymagało nadmiarowych danych wejściowych.

Rzadko występujące wektory wejściowe będą miały 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 wg 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 [294].

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.

$$\|\mathbf{x} - \mathbf{w}_m\| = \min_i \{\|\mathbf{x} - \mathbf{w}_i\|\}. \quad (4.5)$$

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 zależny 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

$$\Delta \mathbf{w}_i(t+1) = \alpha(S_i, t)[\mathbf{x} - \mathbf{w}_i(t)], \quad (4.6)$$

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 (4.5) 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, jednakże 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 sam 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.

4.2. 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. Jednakże ekspert ma również wiedzę intuicyjną, niejawną, trudną do sformalizowania, którą bardzo trudno 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 zadaniem 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 [240, 291, 294].

Szczególnie przydatne w diagnostyce wydają się być sztuczne sieci neuronowe. Ponieważ sieci neuronowe nie wymagają znajomości formalnych zależności pomiędzy przetwarzanymi danymi, mogą one stanowić istotną alternatywę dla systemów regułowych. W systemach tego rodzaju (tzw. systemach konekjonistycznych) 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 poprzez doświadczenie uzupełniać wielką moc obliczeniową komputerów programowalnych. Przy dużej liczbie powiązań neuronowych możliwe jest znaczne przyspieszenie procesu przetwarzania informacji. W wielu przypadkach jest możliwe przetwarzanie sygnałów w czasie rzeczywistym. Sieć staje się ponadto odporna na błędy występujące w niektórych powiązaniach.

O popularności sieci neuronowych w diagnostyce obiektów technicznych świadczą coraz liczniejsze ich zastosowania, między innymi:

- zastosowanie perceptronu wielowarstwowego do wykrywania wycieków w napędzie elektro-hydraulicznym elektrowni wodnej [284],
- system detekcji uszkodzeń urządzeń hydraulicznych [53],
- system detekcji wybranych uszkodzeń w elektrowni jądrowej [285],
- detekcja uszkodzeń w manipulatorze robota [292].

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 stosowanym w zadaniach modelowania, identyfikacji i przetwarzania sygnałów [147, 210, 291].

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 mogą być wykorzystywane 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 będzie dalej 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 kategorii uszkodzenia rozumie się rodzaj uszkodzenia, np. uszkodzenie wirnika, stojana lub łożysk.

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 takie samo jak przed kompresją prawdopodobieństwo poprawnej klasyfikacji i w rezultacie dalsze przetwarzanie danych staje się łatwiejsze. Spotyka się również rozwiązania bez preprocesora cech. Wtedy na wejście klasyfikatora podawany jest bezpośrednio obraz wejściowy z przetworników obrazu. Na rysunku 4.4 przedstawiono schemat ideowy systemu diagnostycznego traktowanego jako system rozpoznający i klasyfikujący w rozumieniu teorii sieci neuronowych [294].



Rys. 4.4. System diagnostyczny jako system rozpoznający i klasyfikujący:

a – schemat ogólny, b – klasyfikator

Fig. 4.4. Diagnostic system as a recognition and classification system:

a – general scheme, b – classifier

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 4.3.

Spośród wielu znanych struktur sieci i sposobów ich uczenia najczęściej w układach diagnostycznych stosuje się:

- 1) perceptrony wielowarstwowe ze standardowym algorytmem uczenia typu propagacji wstecznej,
- 2) sieci samoorganizujące się typu Kohonena.

Dlatego w następnych rozdziałach skoncentrowano się na zagadnieniach projektowania neuronowych detektorów uszkodzeń realizowanych za pomocą tego typu sieci neuronowych.

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 na wyznaczonych w procesie uczenia współczynnikach wagowych.

Aby proces detekcji uszkodzenia za pomocą perceptronowego detektora przebiegał prawidłowo, muszą być spełnione następujące wymagania [230]:

- 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 przy występowaniu szumów i zniekształceń sygnałów wejściowych.

Kolejnym problemem występującym przy 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 podczas uczenia nie zapewnia dobrego diagnozowania [210].

Istotną zaletą sieci neuronowych jest możliwość ich realizacji w technice o wielkim stopniu scalenia. Zróżnicowanie elementów sieci jest niewielkie, a ich powtarzalność bardzo duża, co stwarza perspektywę zbudowania neurokomputera [210]. Możliwości zastosowań sieci neuronowych w przetwarzaniu sygnałów są ciągle jeszcze nie do końca zbadane i wydaje się, że będą one jeszcze przez wiele lat stanowić o postępie w technice informacji i diagnostyce.


4.3. Metodyka uczenia i testowania neuronowych detektorów uszkodzeń

Projektowanie sztucznej sieci neuronowej (SSN) do celów diagnostycznych składa się z kilku podstawowych etapów. Jest to ciąg czynności realizowanych cyklicznie w strukturze wielopętlowej (rys. 4.5).

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 (NeuralWare, Neural Network Toolbox) [58];
- implementacja sieci neuronowej (programowa lub sprzętowa) w komputerze lub procesorze sygnałowym i jej testowanie na obiekcie rzeczywistym.




Rys. 4.5. Cykl przygotowania SSN do wdrożenia
Fig. 4.5. Preparation of ANN for a practical implementation

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 4.6 przedstawiono ideę takiego sposobu uczenia sieci. Różnica $e = y - \hat{y}$ między decyzją eksperta y a decyzją generowaną przez sztuczną sieć neuronową $\hat{y}$ służy do przestrojenia wewnętrznych parametrów (wag) sieci.



Rys. 4.6. Idea uczenia SSN jako detektora uszkodzeń silnika

Fig. 4.6. Idea of NN training in the application to motor fault detection

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) [210, 266]. Dotyczy to przede wszystkim 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. Jednakże należy pamiętać, że stosowanie zbyt dużych zbiorów uczących prowadzi do nadmiernego dopasowania sieci [210, 268]. Skłonność do nadmiernego dopasowania jest proporcjonalna do wielkości sieci. Jedy-

nym sposobem uchronienia sieci przed uczeniem się unikatowej charakterystyki zbioru uczącego z uszczerbkiem uczenia się charakterystyki uniwersalnej jest podać jej tyle przykładów, aby nie mogła się nauczyć wszystkich szczegółów. W publikacji [210] zaleca się, aby minimalna liczba próbek w zbiorze uczącym była dwa razy większa od liczby wag sieci.

Kolejnym krokiem jest wybór typu sieci oraz określenie jej struktury. W zastosowaniach diagnostycznych dotyczących z silników indukcyjnych dominują obecnie dwa typy sieci:

- wielowarstwowy perceptron,
- sieć odwzorowań Kohonena.

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 wprowadzenia przypadkowych zmian próbek uczących w określonych cyklach. Istnieją również inne wyspecjalizowane techniki, np. tzw. wyżarzanie [69, 210, 294] dostępne w niektórych 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 warstw ukrytych i liczby neuronów w każdej warstwie. W większości problemów praktycznych używa się jednej warstwy ukrytej. Nie ma również żadnych teoretycznych przesłanek, aby używać więcej niż dwóch warstw ukrytych [266, 294].

Duże znaczenie ma wybór odpowiedniej liczby neuronów ukrytych. Użycie zbyt małej ich 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 będzie miała tak duże zdolności przetwarzania informacji, że będzie się uczyła 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 dwojako:

- poprzez redukcję sieci,
- poprzez rozszerzanie sieci.


W metodzie redukcji sieci przyjmuje się na starcie maksymalną liczbę neuronów wynikającą z twierdzenia Kołmogorowa [209, 291]. 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 równocześnie z uczeniem sieci (rys. 4.5).

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 [210, 247, 291]. Na rysunku 4.7 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.

Wirtualnie sieć Kohonena jest klasyfikatorem. Po obliczeniu wag w równaniu (4.6) w procesie uczenia, prezentuje się sieci nieznany przypadek. 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 [147, 294] 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.



Rys. 4.7. Sieć Kohonena z blokiem normalizacji wejść

Fig. 4.7. The Kohonen neural network with the input normalization block

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 [143, 294]. 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 $+1$. Przy 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 [294]. Proces uczenia sieci Kohonena przerywa się, gdy zmiany wektorów wag stają się nieznaczne. Wytrenowane sieci podlegają testowaniu. Jeżeli wyniki testu użytkownik uznaje za zadowalające, to następuje implementacja wytrenowanej sieci jako detektora uszkodzeń.

Na podstawie obszernej literatury można sformułować praktyczne wskazówki dotyczące wykrywania istotnych cech z zastosowaniem sieci Kohonena. Liczba kroków uczenia musi być duża, gdyż uczenie jest tu procesem wychwytyującym właściwości statystyczne sygnałów wejściowych. Według [294] 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 liczbę razy,
- korekcji podlegają tylko wagi w pobudzonym sąsiedztwie,
- korekcja jest proporcjonalna do pobudzenia neuronu.


Podczas samoorganizującego uczenia mapy cech stosuje się kolejno formuły (4.5) i (4.6) dla każdego obrazu uczącego. Jeśli w rzeczywistych sytuacjach występuje jakaś naturalna kolejność pojawiania się obrazów, to należy to uwzględnić podczas konstruowania ciągu uczącego.

Detektor uszkodzeń oparty na strukturze sieci Kohonena potrafi wyróżnić grupy uszkodzeń (kategorie uszkodzeń) nawet wtedy, gdy pewne cechy wzorców dla różnych uszkodzeń są takie same, a węzły w mapie Kohonena są bliskie sobie. Zdarza się jednak [144], że sieć tworzy grupy nierozdzielone dla danego wzorca, czyli wzorce opisujące różne uszkodzenia są klasyfikowane do tych samych elementów warstwy Kohonena.

W strukturze systemu do monitorowania i diagnostyki uszkodzeń silników indukcyjnych wdrożenie struktury neuronowego detektora uszkodzeń może być zrealizowane w dwojaki sposób:

- 1° jako układ rozpoznawania uszkodzeń, którego zadaniem jest wykrycie rodzaju uszkodzenia (np. sieć samoorganizująca Kohonena),

2° jako układ analizatora uszkodzeń, którego zadaniem jest określenie stopnia uszkodzenia (np. sieć perceptronowa).



Rys. 4.8. Struktura systemu monitorowania i diagnostyki z zastosowaniem dwóch rodzajów sieci neuronowych

Fig. 4.8. Structure of monitoring and diagnostic system with application of two types of neural networks

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 4.8 przedstawiono strukturę takiego systemu. Struktura ta będzie przedmiotem dalszych rozważań (rozdział 6), zmierzających do realizacji systemu ekspertowego do wykrywania uszkodzeń w silnikach indukcyjnych klatkowych.

4.4. Wstępne przetwarzanie sygnałów pomiarowych dla neuronowych detektorów uszkodzeń

4.4.1. Uwagi ogólne

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 niejednoznaczną 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. Współczesne układy pomiaru i analizy sygnałów projektowane są zwykle przy założeniu, że analizie poddawany jest sygnał cyfrowy dostarczany bezpośrednio ze źródła sygnału lub cyfrowego systemu pomiarowego (rozdział 3.2).

Poprawnie zbudowany układ pomiarowy nie rozwiązuje tych problemów, które są istotne dla sieci neuronowych, a w szczególności dla neuronowych detektorów uszkodzeń. Niezbędne jest zastosowanie bloku wstępnego przetwarzania (tzw. pre-procesora), którego zadaniem będzie transformacja mierzonych sygnałów (obrazów) do takiej postaci, która będzie odpowiednia do wykorzystania na wejściu sieci neuronowej. Proces wstępnego przetwarzania danych w każdym konkretnym przypadku będzie inny, jednak można przyjąć, że będzie się on składał z kilku podstawowych etapów:

- 1) przetwarzanie sygnałów pomiarowych (danych pierwotnych),
- 2) tworzenie zbiorów danych uczących i testujących,
- 3) przetwarzanie zbiorów danych uczących i testujących.

Ze względu na charakter informacji pomiarowej oraz poziom jej przetworzenia, dane poddawane wstępnej obróbce mogą być różnego typu, np.: dane pierwotne nieprzetworzone lub dane wstępnie przetworzone (np. z analizatora), dane w dziedzinie czasu lub częstotliwości, dane wielowymiarowe i szeregi czasowe itp.

W pierwszym etapie, przed przystąpieniem do ekstrakcji cech uszkodzenia, z reguły należy wyeliminować wpływ zakłóceń, zjawisk ubocznych, sieci zasilającej. Te 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 [38, 69, 148]. 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.

Proces wygładzania sygnału wiąże się z usunięciem z niego składowych o wyższych częstotliwościach. W odróżnieniu od filtracji, w algorytmach wygładzania dopuszcza się wykorzystanie zarówno pomiarów przeszłych, jak i przyszłych w stosunku do wygładzanego punktu [148].

Uśrednianie chwilowych wartości sygnału może być realizowane w dziedzinie czasu i częstotliwości. W dziedzinie czasu uśrednianie może być:

- 1) wygładzające, którego celem jest usunięcie krótkotrwałych, wysokoczęstotliwościowych fluktuacji występujących w sygnale,

- 2) synchroniczne, stosowane w analizie sygnałów generowanych przez zjawiska cykliczne (np. w łożyskach), którego celem jest wykrycie powtarzających się charakterystycznych sekwencji zmian amplitudy sygnału.

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.

4.4.2. Nieparametryczne metody wyznaczania cech sygnałów diagnostycznych

4.4.2.1. Przekształcenie Fouriera

W diagnostyce obiektów technicznych, a przede wszystkim maszyn, dominujące znaczenia mają nieparametryczne metody wyznaczania cech charakteryzujących uszkodzenia [38, 39]. Szczególnie przydatna jest analiza widmowa bazująca na szybkim przekształceniu Fouriera (ang. *Fast Fourier Transform* – FFT). Wyniki transformaty Fouriera mogą być dostępne w kilku postaciach widm:

- amplitudowe (rzedną jest moduł transformaty Fouriera),
- fazowe (rzedną jest faza transformaty Fouriera),
- energetyczne (rzedną jest kwadrat modułu transformaty Fouriera),
- gęstość mocy (rzedną 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 stosowane jest widmo amplitudowe sygnału, którego wybrane amplitudy dla charakterystycznych częstotliwości są cechami uszkodzenia (patrz rozdział 3).

Transformacja Fouriera (ang. *Fourier Transform* – FT) ma następującą postać:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi f t} dt. \quad (4.7)$$

Informacja zawarta w widmie analizowanego sygnału $x(t)$ odnosi się do całego przedziału czasowego (wynika to z granic całkowania w równaniu (4.7)). 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 chwili, w której dane zdarzenie częstotliwościowe miało miejsce. Oznacza to, że transformata Fouriera nie jest odpowiednim narzędziem analizowania sygnałów o zmiennej często-

tliwości (sygnałów 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 (ang. *Discrete Fourier Transform* – DFT) sygnału dyskretnego $X(n)$ o długości N , w jego dyskretne widmo o tej samej długości N

$$X(n) = \sum_{i=0}^{N-1} x_i \exp\left(-j \frac{2\pi i \Delta f}{N}\right) \Delta t, \quad 0 \leq k \leq N-1. \quad (4.8)$$

Równanie (4.8) 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 (4.8) jest dosyć skomplikowane obliczeniowo. W latach 60. XX wieku opracowano algorytm tzw. szybkiej transformacji Fouriera FFT. Pozwolił on na znaczną redukcję obliczeń i umożliwił praktyczne zastosowanie dyskretnej transformaty Fouriera.

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 pozwalającym wprowadzić dodatkowo czas do transformaty Fouriera jest założenie, że sygnał niestacjonarny jest czasowo (w określonych okresach) stacjonarny. Takie podejście jest zmodyfikowaną wersją przekształcenia Fouriera i jest nazywane krótkoczasową transformatą Fouriera (ang. *Short Time Fourier Transform* – STFT). Główna różnica pomiędzy 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 $t > t_w$ [237]. Krótkoczasowa transformata Fouriera jest określona zależnością

$$X(t, f) = \int_{-\infty}^{\infty} x(t)w(t-\tau)e^{-j2\pi f\tau} d\tau, \quad (4.9)$$

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

Jak wynika z porównania równań (4.7) i (4.9), 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).

tudę składowych). Rezultat tego przekształcenia w dużym stopniu zależy od parametrów wybranej funkcji okna – jego rodzaju i długości.

STFT pozwala na analizę sygnałów zmiennych w czasie. Poprzez wprowadzenie podziału sygnału $x(t)$ na okna czasowe umożliwia analizowanie składowych sygnału pojawiających się w kolejnych odcinkach czasu. W oryginalnej transformacie Fouriera (4.7) nie istnieje problem rozdzielczości częstotliwościowej; zapewnia ona jednoznaczną informację, które składowe istnieją, a które nie. Można to interpretować w następujący sposób: w FT (4.7) 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 pomiędzy czasem trwania okna a rozdzielczością częstotliwościową przybiera następującą formę w STFT: im węższe okno zostanie użyte do analizy, tym lepsza jest uzyskana rozdzielczość czasowa (dodatkowo można uzyskać lepsze założenie stacjonarności sygnału); jednakże 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, uzyska się zerową rozdzielczość częstotliwościową, ale straci się informacje o czasie pojawienia się danej składowej. Można wówczas uważać, 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 zmiennej w funkcji czasu. Do identyfikacji parametrów harmoniczných wysokich rzędów nie potrzeba stosowania takiej długości okna czasowego jak do identyfikacji parametrów pierwszej harmonicznej.

Dyskretna postać krótkoczasowego przekształcenia Fouriera jest określona zależnością

$$X(n, m) = \sum_{k=0}^{M-1} x(k) w(k-m) e^{-jank}, \quad (4.10)$$

w której:

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).

4.4.2.2. 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. 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 [6, 24, 237]

$$CWT x(a, b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}^*(t) dt, \quad (4.11)$$

w którym:

a – współczynnik skali,

b – współczynnik przesunięcia,

* – oznacza sprzężenie funkcji zespolonej

oraz

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right), \quad a, b \in R, \quad a \neq 0. \quad (4.12)$$

Ponadto musi być spełniony warunek

$$C_{\psi} = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty. \quad (4.13)$$

Operacja ta, podobnie jak transformata Fouriera, jest operacją o charakterze ciągłym, jednak jądrem przekształcenia jest funkcja $\psi(t)$, a nie $e^{-j2\pi ft}$. Zapis $\Psi(\omega)$ w wyrażeniu (4.13) oznacza transformatę Fouriera funkcji $\psi(t)$. Z warunku zdefiniowanego w (4.13) wynika, że $\Psi(0) = 0$, wobec tego średnia wartość funkcji $\psi(t)$ musi wynosić zero

$$\int_{-\infty}^{\infty} \psi(t) dt = \Psi(0) = 0. \quad (4.14)$$

Funkcja $\psi(t)$ jest nazywana falką – matką lub główną (ang. *mother wavelet*). Ma 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 (4.12) 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 (4.11) można więc traktować jako pasmowoprzepustową 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, a zmienna a jest proporcjonalna do odwrotności częstotliwości

$$a \sim \frac{1}{f}. \quad (4.15)$$

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 (4.11) przedstawia korelację analizowanej funkcji $x(t)$ z odpowiednimi falkami, czego rezultatem jest funkcja określająca stopień ich podobieństwa. Wynikiem transformacji (4.11) 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 (4.11), funkcje $CWT_f(a, b)$ reprezentują specyficzne cechy sygnału. Stanowi to podstawę jego dalszej analizy. Wykorzystuje się fakt, że przekształcenie (4.11) dla ustalonej wartości skali a jest filtrem środkowoprzepustowym, 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 odcin-

ku 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 o 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

$$\frac{\Delta\omega}{\omega} = c, \quad (4.16)$$

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

Na rysunku 4.9 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. 4.9. Przykłady konfiguracji komponentów sygnału w dziedzinie czas – częstotliwość w STFT (a) i CWT (b)

Fig. 4.9. Examples of signal components configuration in the time – frequency domain in STFT (a) and CWT (b)

W omawianym ciągłym przekształceniu falkowym zakłada się, że parametry przekształcenia: skala a oraz przesunięcie b są funkcjami ciągłymi. Gdy skala a i przesunięcie b są funkcjami dyskretnymi, przekształcenie (4.11) 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 jeśli się uwzględni, że $a = \frac{1}{2^j}$, $b = \frac{k}{2^j}$, $j, k \in \mathbb{Z}$ ($\mathbb{Z}$ – zbiór liczb całkowitych), otrzymuje się inną formę zależności (4.12)

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k). \quad (4.17)$$

Przekształcenie (4.11) w warunkach próbkowania skali a i przesunięcia b przyjmuje postać

$$CWT x(a_j, b) = DWT x_{jk} = \int_{-\infty}^{\infty} x(t) \psi_{jk}^*(t) dt. \quad (4.18)$$

Przetwarzany sygnał można zrekonstruować bez strat informacji po ważonym sumowaniu obliczonych współczynników $DWT x_{jk}$

$$x(t) = \sum_j \sum_n DWT x_{jk} \Psi_{jk}(t). \quad (4.19)$$

Operacja ta nosi nazwę odwrotnej dyskretnej transformaty falkowej. W dyskretnych przekształceniach falkowych ((4.18) i (4.19)) 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

$$DWT x_{jk} = \sum_{n=0}^{N-1} x(n) \psi_{jk}^*(n), \quad (4.20)$$

gdzie:

$$\psi_{j,k}(n) = 2^{-j/2} \psi(2^{-j}n - k), \quad (4.21)$$


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 [24, 237].

DWT umożliwia zbudowanie efektywnych algorytmów do numerycznego wyznaczania współczynników transformacji, jeśli się uwzględni fakt, 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 dzięki zastosowaniu 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. Idea wielorozdzielczej analizy sygnału została przedstawiona na rys. 4.10.




Rys. 4.10. Wielorozdzielcza analiza sygnału

Fig. 4.10. Multiresolution signal analysis

W kroku początkowym sygnał czasowy $s(t)$ zostaje poprzez 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 – może zostać rozbita na dwie kolejne składowe: drugą aproksymację cA_2 i drugi detal cD_2 . Ważną właściwość przeprowadzonej obróbki sygnału określa zależność

$$s(t) = cA_2 + cD_2 + cD_1. \quad (4.22)$$



Rys. 4.11. Przykład dekompozycji falkowej sygnału do poziomu trzeciego

Fig. 4.11. An example of signal wavelet decomposition up to the third level

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 4.11 przedstawiono przykładową dekompozycję sygnału do poziomu trzeciego (przy założeniu częstotliwości próbkowania sygnału 10 kHz).

Zastosowanie dekompozycji sygnału umożliwia analizę poszczególnych zakresów częstotliwości. Poszczególnym węzłom drzewa dekompozycji odpowiada ściśle określony zakres częstotliwości. Jednym z najczęściej spotykanych w diagnostyce wskaźników charakteryzujących poszczególny węzeł jest wartość własna energii


$$E = \sum_{k=1}^N |S_{j,k}|^2, \quad (4.23)$$

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.

4.4.3. Formowanie i przetwarzanie zbiorów uczących

Wstępnie przetworzone pierwotne dane pomiarowe, czyli cechy uszkodzeń zwykłe, przed wprowadzeniem na wejście sieci neuronowej, wymagają jeszcze właściwej selekcji i poprawnej organizacji (tzw. II etap wstępnego przetwarzania – rys. 4.12).



Rys. 4.12. Wstępne przetwarzanie sygnałów pomiarowych dla potrzeb neuronowego detektora uszkodzeń

Fig. 4.12. Preprocessing of measurement signals for neural fault detector

Jeżeli dane mają postać jakościową a nie ilościową, to może zachodzić potrzeba ich kodowania do postaci numerycznej tak, aby były użyteczne dla sieci neuronowej [268]. Gdy są to zmienne dwustanowe, wówczas oczywiście 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 zbiór 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 zbiór 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 [268]. Takie zbiory są najczęściej używane przy strojeniu wag i ich obecność pozwala 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.

Podczas selekcji sygnałów wejściowych na sieć neuronową można posłużyć się analizą statystyczną. Pozwala to sprawdzić, czy pomiędzy wybranymi cechami (zmiennymi wejściowymi) nie istnieją korelacje. Jeżeli dwie z nich są silnie skorelowane, to należy jedną pominąć. Aby ocenić stopień korelacji pomiędzy zmiennymi, należy obliczyć korelację w następujący sposób:

$$r = \frac{\sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v})}{(n-1)\sigma_u \sigma_v}, \quad (4.24)$$

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

$$\sigma_u = \sqrt{\frac{\sum_{i=1}^n (u_i - \bar{u})^2}{n-1}}, \quad \sigma_v = \sqrt{\frac{\sum_{i=1}^n (v_i - \bar{v})^2}{n-1}}. \quad (4.25)$$

Jeżeli dwie zmienne są dokładnie skorelowane, to współczynnik $r = 1$. Jeżeli 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 jakichś nietypowych nieprawidłowości, aby wykluczyć nieprawidłowe dane z zestawu treningowego. W tym celu należy wykreślić każdy z zestawów danych. Dane wybiegające poza spodziewany zakres 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 (III etap wstępnego przetwarzania – rys. 4.12). 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 ujednoliconym 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 treningowym. 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 SN.

Tabela 4.1. Podstawowe metody normalizacji danych
Table 4.1. Basic methods for data normalisation

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 średniej	$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}}$	Przedział zmienności $(0, 1)$ $x_{\text{norm śr}} = 0,5$

W tabeli 4.1 przedstawiono podstawowe metody normalizacji danych. Najczęściej stosowana jest metoda skalowania względem wartości średniej.

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 (I i II etap wstępnego przetwarzania) zwykle nie wiadomo, które z nich mogą być najbardziej użyteczne. Z zagadnieniem tym związany jest problem wymiarowości wektora uczącego oraz współzależności pomiędzy 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 wagowych dostarcza pewnych informacji. Każde z wejść, które nie jest niezbędne do właściwego odwzorowania relacji wejście–wyjście, będzie charakteryzowało się bardzo małymi wartościami współczynników wagowych w porównaniu z innymi. Nie należy jednak od razu eliminować tych wejść. Doświadczenie wskazuje, że należy prowadzić w dalszym ciągu proces uczenia i dopiero jeśli wartości tych „małych” współczynników wagowych nie ulegną większym zmianom, należy wyeliminować odpowiadające im wejścia do SN.

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 [69, 268]. Zbiór uczący powinien być bardziej liczny niż zbiór testowy.

4.5. Podsumowanie

Wstępne przetwarzanie danych odgrywa istotną rolę w procesie uczenia i testowania sieci neuronowej. Wynika to z oczywistego faktu, że sieć neuronowa będzie dobrze nabywała wiedzę tylko wtedy, gdy dane należące do zbioru uczącego i testującego będą reprezentatywne dla danego zagadnienia. Często spełnienie tych wymagań

wiąże się z trudnymi problemami selekcji cech i ich przetwarzania złożonymi metodami.

Przedstawiona w tym rozdziale metodyka opracowywania neuronowych detektorów uszkodzeń została wykorzystana do przygotowywania danych uczących i testujących oraz do syntezy neuronowych detektorów uszkodzeń wirnika, stojana oraz łożysk silników indukcyjnych klatkowych, co przedstawiono w rozdziale 5.

5. Neuronowe detektory uszkodzeń silników indukcyjnych

5.1. Wprowadzenie

Stosowana obecnie detekcja uszkodzeń za pomocą klasycznych metod analitycznych napotyka coraz częściej bariery związane z automatyzacją tego procesu. Stosowane systemy ekspertowe wykorzystują wiedzę i doświadczenie człowieka oraz jego interpretację na bieżąco aktualnych wyników pomiarów na diagnozowanym obiekcie. Doświadczenie eksperta – człowieka jest bardzo trudne do zautomatyzowania. Dlatego niezbędne staje się poszukiwanie metod, które wykorzystując informacje pochodzące od systemów analizujących sygnały mierzone na obiekcie, dostarczą obiektywnej informacji o rodzaju i zakresie uszkodzenia.

Jednym z możliwych rozwiązań tego problemu jest zastosowanie sztucznych sieci neuronowych jako detektorów uszkodzeń. Detektor neuronowy, nauczony odpowiednią liczbą obrazów uszkodzeń, powinien umożliwić ich grupowanie i klasyfikację. Realizacja praktyczna sieci neuronowej jest możliwa przy wykorzystaniu techniki analogowej lub cyfrowej. Zastosowanie techniki mikroprocesorowej nie jest najkorzystniejsze z punktu widzenia teorii sieci neuronowych, gdyż nie wykorzystuje właściwości równoległego przetwarzania sygnałów. Jest jednak obecnie rozwiązaniem najtańszym. Niezależnie od zastosowanej techniki realizacji sieci neuronowej niezbędne jest wcześniejsze rozwiązanie następujących problemów sformułowanych w formie pytań:

- 1° Jakimi danymi uczyć sieć neuronową, jak je zbierać i wstępnie przetwarzać?
- 2° Jakie typy i struktury sieci neuronowych są najbardziej przydatne do realizacji detektorów uszkodzeń w silniku indukcyjnym?

W niniejszym rozdziale zostaną przedstawione wybrane wyniki badań neuronowych detektorów uszkodzeń wirnika, stojana i łożysk. Zostały one opracowane na podstawie badań laboratoryjnych zrealizowanych na stanowisku badawczym wyposażonym w multianalizator PULSE 3560 firmy Brüel&Kjær, komputerowy system pomiarowy, przetworniki pomiarowe prądów stojana, drgań i strumienia poosiowego oraz niezbędne oprogramowanie. Struktura sprzętowa stanowiska została przedstawiona w załączniku 2. Zastosowany sprzęt pomiarowy gwarantował bardzo dużą dokładność pomiarów i analiz widmowych sygnałów.


W kolejnych podrozdziałach zostaną przedstawione struktury sieci neuronowych, które wykazały się w trakcie testów najmniejszą liczbą błędów przy możliwie prostej strukturze, gwarantującej możliwość technicznej realizacji. W szerszym zakresie wyniki badań opublikowano w publikacjach [154, 157–162, 165, 167, 169, 176–178].

5.2. Neuronowe detektory uszkodzeń wirnika klatkowego


5.2.1. Charakterystyka badań eksperymentalnych uszkodzonych wirników

Badania przeprowadzono na silnikach indukcyjnych małej mocy typu Stg 80X-4c (1,1 kW) firmy Besel oraz SSh 90L-4 (1,5 kW) firmy INDUKTA (parametry silników przedstawiono w załączniku nr 1). Uszkodzenia wirników były modelowane fizycznie poprzez niszczenie (rozwiercanie) wybranych prętów i pierścienia zwierającego (patrz załącznik nr 2 – fotografia uszkodzonego wirnika na rys. Z2). Wirniki miały skos żłobkowy oraz nieizolowane pręty, co powoduje pewną redukcję amplitud harmonicznych poślizgowych (rozdział 3).


Uszkodzone pręty – rozłożone niesymetrycznie (1)



Uszkodzone pręty – rozłożone symetrycznie (2)



Uszkodzone pręty – rozłożone równomiernie (3)




Rys. 5.1. Rodzaje uszkodzeń wirników i sposób ich oznaczania
Fig. 5.1. Types of rotor damages and their notation

Rozkład modelowanych uszkodzeń przedstawiono na rys. 5.1. Przyjęto następujące rozłożenie uszkodzonych prętów:

- rozłożenie niesymetryczne,
- rozłożenie symetryczne wzdłuż jednej osi,
- rozłożenie symetryczne wzdłuż dwóch osi (równomierne),
- pęknięty pierścień zwierający.

Każdy z wymienionych wariantów jest dalej określany jako *rodzaj uszkodzenia* wirnika klatkowego. W każdym rodzaju uszkodzenie było stopniowane przez zmianę liczby pękniętych prętów. Tak więc każdy uszkodzony wirnik charakteryzował się *rodzajem* i *stopniem uszkodzenia*. Zadaniem neuronowych detektorów uszkodzeń wirnika jest wykrycie *rodzaju* i *stopnia* uszkodzenia.


Badania przeprowadzono metodą analizy widmowej prądu stojana (rozdział 3.3.2). Analizowano przebiegi prądu stojana w paśmie 0–400 Hz z rozdzielczością 0,03 Hz, co wymagało stosunkowo długiego czasu zbierania próbek przez analizator (około 32 sekund). Długi czas zbierania próbek pomiarowych wymagał zapewnienia możliwie stałych warunków pracy silnika, aby w prawidłowy sposób określony został poślizg silnika. W warunkach przemysłowych spełnienie tych wymagań może być trudne ze względu na zmieniający się moment obciążenia i różnego rodzaju zakłócenia. Wartość poślizgu ma istotne znaczenie przy obliczaniu harmonicznych charakteryzujących uszkodzenie wirnika (rozdział 3) i dlatego niezbędne jest określanie go na bieżąco i uśrednianie [150, 155, 176, 264].



Rys. 5.2. Zależność amplitudy harmonicznej poślizgowej prądu I_{p1}^s od liczby niesymetrycznie uszkodzonych prętów wirnika (silnik STg80X-4c)


Fig. 5.2. Dependence of the current slip harmonic magnitude I_{p1}^s on the number of asymmetrically broken bars (STg80X-4c motor)

Przed przystąpieniem do projektowania struktury neuronowych detektorów zbadano kształtowanie się amplitud charakterystycznych harmonicznych w zależności od stopnia i rodzaju uszkodzenia. Na rysunkach 5.2–5.4 przedstawiono jak kształtuje się amplituda harmonicznej poślizgowej f_{p1} w silniku STg 80X-4c z uszkodzonymi w różny sposób prętami wirnika. Amplitudę harmonicznej f_{p1} dla poszczególnych przypadków uszkodzeń przedstawiono w skali decybelowej.



Rys. 5.3. Zależność amplitudy harmonicznej poślizgowej prądu I_{p1}^s od liczby symetrycznie uszkodzonych prętów (silnik STg80X-4c)


Fig. 5.3. Dependence of the current slip harmonic magnitude I_{p1}^s on the number of symmetrically broken bars (STg80X-4c motor)



Rys. 5.4. Zależność amplitudy harmonicznej poślizgowej prądu I_{p1}^s od liczby równomiernie uszkodzonych prętów (silnik STg80X-4c)

Fig. 5.4. Dependence of the current slip harmonic magnitude I_{p1}^s on the number of uniformly broken bars (STg80X-4c motor)

Na rysunku 5.5 przedstawiono natomiast jak kształtują się te amplitudy dla silnika SSh 90L-4. Z porównania przebiegów widać, że mają one w każdym silniku inny charakter ilościowy, a ponadto są silnie nieliniowe i zależą od obciążenia silnika (rys. 5.6). Ponadto w silniku STg 80X-4c występuje zdecydowanie większe zróżnicowanie wartości amplitud harmonicznych poślizgowych dla różnych rodzajów uszkodzeń, co istotnie ułatwia ich identyfikację.




Rys. 5.5. Zależność amplitudy harmonicznej poślizgowej prądu I_{p1}^s od liczby uszkodzonych prętów:

1 – symetrycznie, 2 – niesymetrycznie, 3 – równomiernie (silnik SSh 90L-4)

Fig. 5.5. Dependence of the current slip harmonic magnitude I_{p1}^s on the number of broken bars :

1 – symmetrically, 2 – asymmetrically, 3 – uniformly (SSh 90L-4 motor)



Rys. 5.6. Zależność amplitudy harmonicznej poślizgowej prądu I_{p1}^s od liczby niesymetrycznie uszkodzonych prętów, dla różnych prądów obciążenia:

1 – $I = I_N = 3,70$ A, 2 – $I = 3,38$ A, 3 – $I = 3,07$ A (silnik SSh 90L-4)


Fig. 5.6. Dependence of the current slip harmonic magnitude I_{p1}^s on the number of asymmetrically broken bars, for different load currents:

1 – $I = I_N = 3,70$ A, 2 – $I = 3,38$ A, 3 – $I = 3,07$ A (SSh 90L-4 motor)

Badania widm prądu stojana silników z uszkodzonymi wirnikami prowadzone były dla trzech faz, dla różnych wartości momentu obciążenia, dla silnika zimnego oraz nagrzanego. Widma nieznacznie różniły się w poszczególnych fazach. Na podstawie widm dokonywane było wyodrębnienie charakterystycznych częstotliwości, obliczana ich amplituda i tworzone dwie grupy danych: dane uczące i dane testujące. Dane z dwóch faz i wybranych stopni uszkodzenia stanowiły materiał uczący, natomiast dane z trzeciej fazy dla innych stopni uszkodzenia stanowiły materiał testujący.

5.2.2. Perceptronowy detektor uszkodzeń wirników klatkowych

W badaniach nad zastosowaniem sieci neuronowych do wykrywania uszkodzeń wirnika prowadzonych przez inne ośrodki badawcze, przedstawionych przede wszystkim w pracach [86, 90, 92, 94, 291], zaproponowano kilka wariantów struktur sieci neuronowych opartych na perceptronie wielowarstwowym. Zadaniem sieci było określenie liczby uszkodzonych prętów wirnika. Na rysunkach 5.7 i 5.8 przedstawiono podstawowe struktury sieci zaproponowane w [86, 92, 94].




Rys. 5.7. Struktura neuronowego detektora uszkodzeń wirnika – wariant 1 [86]

Fig. 5.7. Structure of neural detector of rotor faults – case 1 [86]

Sieci te z dużą dokładnością określały liczbę uszkodzonych prętów podczas uczenia ich przede wszystkim danymi z symulacji. Autorzy również sprawdzali z dobrym efektem poprawność ich działania na danych z obiektów rzeczywistych [94]. Wariant 1 (rys. 5.7) był testowany na silnikach małej mocy, natomiast wariant 2 (rys. 5.8) został zastosowany do diagnostyki silników dużej mocy i był trenowany danymi pochodzącymi z badania różnych silników [86, 94, 291]. Wielkościami wejściowymi neuronowego detektora z rys. 5.5 były amplitudy harmonicznych poślizgowych f_{p1} i f_{p2} oraz moment obciążenia silnika M_{obc} . W detektorze z rysunku 5.8 wielkościami wejściowymi były:

- s – poślizg,
 s/s_N – poślizg względny,
 $I_1/I_{s0} \cdot N/N_{\max}$ – stosunek wartości skutecznej harmonicznej poślizgowej do wartości skutecznej harmonicznej podstawowej pomnożony przez stosunek liczby uszkodzonych prętów do maksymalnej liczby prętów wirnika,
 I_s / I_{sN} – stosunek wartości skutecznej prądu stojana do prądu nominalnego,
 $P_1 / 3U_N I_N$ – stosunek mocy wejściowej do mocy pozornej znamionowej,
 $P_N / P_{\max}$ – stosunek mocy znamionowej silnika do mocy maksymalnej.




Rys. 5.8. Struktura neuronowego detektora uszkodzeń wirnika – wariant 2 [86]

Fig. 5.8. Structure of neural detector of rotor faults – case 2 [86]

Zastosowanie omówionych rozwiązań detektorów neuronowych powoduje, że niezbędne staje się mierzenie i obliczanie większej liczby zmiennych (większe wektory uczące i testujące), wzrasta złożoność sieci neuronowej oraz wydłuża się czas jej trenowania. Ponadto sieć wykorzystuje sygnały liniowo zależne (poślizg i poślizg względny), co niepotrzebnie rozbudowuje jej strukturę i tym samym komplikuje problem technicznej realizacji takiego detektora.

Autor przyjął, że zadaniem neuronowego detektora będzie wykrywanie liczby uszkodzonych prętów oraz rodzaju uszkodzenia (sposób rozłożenia uszkodzonych prętów). Z uwagi na problemy realizacji technicznej przyjęto również, że sieć powinna mieć możliwie prostą strukturę (jak najmniejszą liczbę warstw i neuronów). Na rysunku 5.9 przedstawiono ideę detektora, na wejście którego podawane są amplitudy harmonicznych poślizgowych prądu stojana I_{p1}^s, I_{p2}^s oraz ich stosunek I_{p1}^s / I_{p2}^s . Struktura ta stanowiła punkt wyjściowy do poszukiwania optymalnego wariantu detektora.



Rys. 5.9. Idea neuronowego detektora uszkodzeń wirnika


Fig. 5.9. Idea of neural detector of rotor faults

Przeprowadzono badania na następujących perceptronowych detektorach uszkodzeń wirników:

- a) sieci neuronowej wykrywającej liczbę uszkodzonych prętów,
- b) sieci neuronowej wykrywającej liczbę uszkodzonych prętów oraz ich rozłożenie.

Poszukując optymalnej struktury sieci neuronowej, przyjmowano różne warianty wielkości wejściowych. Oprócz amplitud harmonicznych poślizgowych prądów stojana, dla $k = 1$ i 2 (wzór (3.20)), ich stosunku, na wejście sieci wprowadzano również poślizg s charakteryzujący aktualną wartość obciążenia silnika.

Na rysunku 5.10 przedstawiono podstawowe struktury badanych neuronowych detektorów uszkodzeń wirnika, a na rys. 5.11 – przykładowy przebieg procesu uczenia takiego detektora. Detektory te okazały się szczególnie skuteczne dla silnika Stg 80X-4c przy rozróżnianiu rodzaju i stopnia uszkodzenia.




Rys. 5.10. Podstawowe struktury neuronowych detektorów uszkodzeń wirnika

Fig. 5.10. Basic structures of neural detectors of rotor faults

Do uczenia sieci neuronowych posłużono się aplikacją Neural Network Toolbox wchodzącą w skład pakietu programowego środowiska Matlab [58]. Jako blok aktywacji w warstwie wyjściowej wykorzystano funkcję liniową $f(x) = ax$, natomiast w pozostałych warstwach stosowano funkcję sigmoidalną bipolarną $f(x) = \tanh(\beta x)$. Wybrano jako algorytm uczenia sieci metodę wstecznej propagacji błędów Levenber-

ga-Marquardta. W tabelach 5.1–5.4 zamieszczono przykładowo wyniki testowania neuronowych detektorów z jedną warstwą ukrytą o różnej liczbie neuronów.



Rys. 5.11. Ilustracja procesu uczenia neuronowego detektora uszkodzeń wirnika

Fig. 5.11. Graphical representation of neural network training process

Tabela 5.1. Odpowiedzi neuronowego detektora uszkodzeń wirnika (9 neuronów w warstwie ukrytej)

Table 5.1. Responses of neural detector of rotor faults (9 neurons in the hidden layer)

Wektor odpowiedzi sieci	Liczba uszk. prętów	0	1	2	2	3	4	4	4	6	8	8
	Liczba uszk. prętów	0,002	1,194	1,992	2,355	3,290	3,918	3,999	4,108	6,171	8,209	7,705
Zaokrąglone odpowiedzi	Liczba uszk. prętów	0	1	2	2	3	4	4	4	6	8	8

Tabela 5.2. Odpowiedzi neuronowego detektora uszkodzeń wirnika (6 neuronów w warstwie ukrytej)

Table 5.2. Responses of neural detector of rotor faults (6 neurons in the hidden layer)

Wektor odpowiedzi sieci	Liczba uszk. prętów	0	1	2	2	3	4	4	4	6	8	8
	Liczba uszk. prętów	0,005	1,198	2,007	2,349	3,290	3,939	3,890	4,035	6,208	8,0	8,003
Zaokrąglone odpowiedzi	Liczba uszk. prętów	0	1	2	2	3	4	4	4	6	8	8

Tabela 5.3. Odpowiedzi neuronowego detektora uszkodzeń wirnika – wykrywanie stopnia i rodzaju uszkodzenia (9 neuronów w warstwie ukrytej)
 Table 5.3. Responses of neural detector of rotor faults – detection of fault size and type (9 neurons in the hidden layer)

Wektor testujący	Liczba uszk. prętów	0	1	2	3	4	5	2	4	6	8	4	8
	Rodzaj uszkodzenia	2	2	2	2	2	2	3	3	3	3	3	3
Odpowiedzi sieci	Liczba uszk. prętów	-0.013	1.179	2.265	3.311	3.661	4.486	2.071	3.961	6.024	8.044	4.033	7.920
	Rodzaj uszkodzenia	2.038	2.147	2.157	2.042	1.991	1.969	3.060	2.904	2.604	2.975	3.103	3.008
Zaokrąglone odpowiedzi sieci	Liczba uszk. prętów	0	1	2	3	4	4	2	4	6	8	4	8
	Rodzaj uszkodzenia	2	2	2	2	2	2	3	3	3	3	3	3

Tabela 5.4. Odpowiedzi neuronowego detektora uszkodzeń wirnika – wykrywanie stopnia i rodzaju uszkodzenia (6 neuronów w warstwie ukrytej)
 Table 5.4. Responses of neural detector of rotor faults – detection of fault size and type (6 neurons in the hidden layer)

Wektor testujący	Liczba uszk. prętów	0	1	2	3	4	5	2	4	6	8	4	8
	Rodzaj uszkodzenia	2	2	2	2	2	2	3	3	3	3	3	3
Odpowiedzi sieci	Liczba uszk. prętów	0.032	0.989	2.472	3.307	3.684	4.236	1.765	3.995	6.790	8.002	4.010	8.004
	Rodzaj uszkodzenia	2.065	1.909	2.085	2.228	2.060	2.129	2.727	2.994	3.001	2.999	3.007	2.999
Zaokrąglone odpowiedzi sieci	Liczba uszk. prętów	0	1	2	3	4	4	2	4	7	8	4	8
	Rodzaj uszkodzenia	2	2	2	2	2	2	3	3	3	3	3	3

Sieć bezbłędnie nauczyła się wykrywać liczbę uszkodzonych prętów wirnika już od sześciu neuronów w warstwie ukrytej (tab. 5.1 i 5.2), natomiast w przypadku wykrywania stopnia i rodzaju uszkodzenia (tab. 5.3 i 5.4) detektor popełnił kilka błędów (zaznaczonych w tabelach przez pogrubienie cyfr). Dotyczyły one liczby pękniętych prętów. Przedstawione wyniki dotyczyły silnika Stg 80X-4c.

W przypadku silnika SSh 90L-4, który charakteryzuje się bardziej złożoną zależnością amplitud charakterystycznych harmoniczných w prądzie stojana od stopnia i rodzaju uszkodzenia klatki wirnika, przeprowadzono badania bardziej rozbudowanych detektorów. Przyjęto wektor wejściowy rozszerzony o harmoniczne poślizgowe

dla $k = 1$ i 2 oraz poślizg (wzór (3.20)). W tabelach 5.5 i 5.6 przedstawiono wyniki testowania sieci trójwarstwowych, charakteryzujących się najmniejszą liczbą błędnych odpowiedzi.

Tabela 5.5. Odpowiedzi neuronowego detektora uszkodzeń wirnika
– wykrywanie stopnia uszkodzenia
Table 5.5. Responses of neural detector of rotor faults
– detection of the fault size

Struktura sieci				5-9-7-1								
Dane wejściowe				1 – lewa częstotliwość poślizgowa (dla $k = 1$) 2 – prawa częstotliwość poślizgowa (dla $k = 1$) 3 – lewa częstotliwość poślizgowa (dla $k = 2$) 4 – prawa częstotliwość poślizgowa (dla $k = 2$) 5 – poślizg								
Wyjście				Liczba uszkodzonych prętów								
Błąd				$1,3 \cdot 10^{-14}$								
Liczba epok				175								
Wynik otrzymany	0,22	1,30	0,89	2,01	1,67	1,85	2,88	3,08	3,41	3,85	3,84	3,74
Wynik spodziewany	0	1	1	2	2	2	3	3	3	4	4	4
Wynik otrzymany	5,08	5,28	4,97	6,08	5,98	5,08	6,96	6,95	6,72	8,17	8,06	8,01
Wynik spodziewany	5	5	5	6	6	6	7	7	7	8	8	8

Sieć o strukturze 5-9-7-1 charakteryzowała się bardzo krótkim czasem uczenia (175 epok) i tylko jedną błędną odpowiedzią. Próby otrzymania detektora o strukturze dwuwarstwowej i takim samym wektorze wejściowym nie doprowadziły do otrzymania rozwiązania dającego lepsze wyniki.

W tabeli 5.6 przedstawiono wyniki testowania detektora wykrywającego rodzaj uszkodzenia wirnika. Przyjęto następujące oznaczenia:


- 0 – wirnik nieuszkodzony,
- 1 – uszkodzenie symetryczne,
- 2 – uszkodzenie niesymetryczne,
- 3 – pęknięty pierścień.

Tabela 5.6. Odpowiedzi neuronowego detektora uszkodzeń wirnika – wykrywanie rodzaju uszkodzenia
Table 5.6. Responses of neural detector of rotor faults – detection of the fault type

Struktura sieci				6-6-9-1									
Dane wejściowe				1 – lewa częstotliwość poślizgowa (dla $k = 1$) 2 – prawa częstotliwość poślizgowa (dla $k = 1$) 3 – lewa częstotliwość poślizgowa (dla $k = 2$) 4 – prawa częstotliwość poślizgowa (dla $k = 2$) 5 – różnica lewej i prawej częstotliwości poślizgowej (dla $k = 2$) 6 – poślizg									
Wyjście				rodzaj uszkodzenia									
Błąd				$1,1 \cdot 10^{-4}$									
Liczba epok				1000									
Wynik otrzymany	3,02	3,01	0,00	3,41	1,02	1,34	2,10	0,97	2,01	0,98	1,04	2,00	
Wynik spodziewany	3	3	0	2	1	1	2	1	2	1	1	2	
Wynik otrzymany	1,00	0,98	1,81	1,01	1,01	2,07	1,01	0,98	1,96	1,00	1,00	2,01	
Wynik spodziewany	1	1	2	1	1	2	1	1	2	1	1	2	

Zauważono, że detektor wykrywający jednocześnie stopień i rodzaj uszkodzenia w przypadku silnika SSh 90L-4 charakteryzował się stosunkowo dużą liczbą błędnych odpowiedzi w porównaniu z takim samym detektorem dla silnika Stg80X-4c. Wynika to z różnic w budowie wirników i technice modelowania uszkodzeń.

W przypadkach gdy nauczanie jednej sieci do jednoczesnego klasyfikowania rodzaju i stopnia uszkodzenia wirnika jest niemożliwe lub obarczone dużymi błędami, można zastosować detektor składający się z dwóch sieci jednowyjściowych. Strukturę takiego detektora przedstawiono na rys. 5.12.



Rys. 5.12. Struktura detektora uszkodzeń wirnika zawierającego dwie sieci neuronowe
Fig. 5.12. Structure of the rotor fault detector based on two neural networks


Jak wykazały badania, neuronowy detektor składający się z dwóch sieci jednowyjściowych na 48 przeprowadzonych testów klasyfikowania rodzaju i stopnia uszkodzenia popełnił tylko 8 błędów, z czego 7 dotyczyło rodzaju uszkodzenia.

Z podsumowania badań neuronowych detektorów uszkodzeń wirnika widać, że możliwe jest skuteczne klasyfikowanie stopnia uszkodzenia wirnika klatkowego za pomocą sztucznej sieci neuronowej już od uszkodzeń pojedynczych prętów wirnika. Przeprowadzone testy wykazały, że sieć popełnia błędy w przedziale ± 1 przerwanych prętów, co z reguły nie ma znaczenia w praktyce. Również rozróżnianie rodzaju uszkodzenia, rozumianego jako sposób rozkładania się większej ilości uszkodzonych prętów, jest realizowane z zadowalającą do celów praktycznych dokładnością. Jednakże zwykle tego typu klasyfikacja wymaga bardziej rozbudowanej struktury sieci, czyli więcej wejść i warstw ukrytych.

5.3. Neuronowe detektory uszkodzeń stojana


5.3.1. Badania eksperymentalne zwarć stojanowych

Badania zwarć międzyzwojowych przeprowadzono dla silnika STg80x-4c. Został on wykonany w taki sposób, aby istniała możliwość fizycznej realizacji zwarć stojanowych. Uzwojenie fazy A ma 6 odczepów umożliwiających zwieranie zwojów (maksymalnie można uzyskać zwarcie około 10% całego uzwojenia). Zastosowano rezystor ograniczający prąd w zwojach zwartych (rys. 5.13). Pomiaru były wykonywane przy ograniczeniu prądu zwarcia do 5 A i do 7 A.




Rys. 5.13. Schemat połączeń uzwojeń stojana do modelowania zwarć zwojowych
Fig. 5.13. Connection scheme for stator windings for modelling the turn short-circuits

Badania uszkodzeń stojana silnika klatkowego prowadzono metodą pomiaru pola poosiowego z użyciem zewnętrznej cewki pomiarowej (rozdział 3.4). Pomiarów dokonywano zarówno od strony wału napędowego, jak i od strony przewietrznika. W trakcie badań mierzono wartości skuteczne napięcia indukowanego w cewce pomiarowej, proporcjonalnego do wartości strumienia poosiowego oraz obliczano widmo częstotliwościowe tego napięcia za pomocą analizatora sygnałów B&K. Ponadto były mierzone i analizowane drgania mechaniczne na korpusie silnika. Wielkości mierzone i obliczane zostały następnie wykorzystane do trenowania sieci neuronowych.



Rys. 5.14. Zależność napięcia indukowanego w cewce pomiarowej od liczby zwartych zwojów dla prądu zwarcia 7 A

Fig. 5.14. Dependence of the voltage induced in measuring coil on the number of short-circuit turns for short-circuit current 7 A




Rys. 5.15. Widmo napięcia indukowanego w cewce pomiarowej w zdrowym silniku

Fig. 5.15. Spectrum of voltage induced in measuring coil for healthy motor


Przedstawiono wyniki wybranych badań wpływu stopnia zwarcia uzwojenia stojana na zmiany amplitudy i zawartości harmonicznych w strumieniu poosiowym oraz drganiach mechanicznych. Badania zrealizowano na nieobciążonym silniku. Na rysunku 5.14 przedstawiono zależność strumienia poosiowego od liczby zwojów zwartych.

Na rysunkach 5.15 i 5.16 przedstawiono widma napięcia indukowanego w cewce pomiarowej silnika zdrowego oraz silnika, w którym zwarto 33 zwoje.



Rys. 5.16. Widmo napięcia indukowanego w cewce przy zwarcu 33 zwojów i prądzie zwarcia 5 A


Fig. 5.16. Spectrum of the voltage induced in measuring coil in the case of 33 short-circuit turns and 5 A short-circuit current



Rys. 5.17. Zależność składowej napięcia o częstotliwości 50 Hz indukowanego w cewce od liczby zwartych zwojów


Fig. 5.17. Dependence of the voltage of 50 Hz frequency induced in the measuring coil on the number of short-circuit turns

Na rysunkach 5.17–5.18 przedstawiono zależności składowych napięcia o częstotliwościach będących wielokrotnością częstotliwości sieciowej 50 Hz oraz wielokrotnością częstotliwości obrotowej od stopnia zwarcia uzwojenia.



Rys. 5.18. Zależność składowej napięcia o częstotliwości 125 Hz indukowanego w cewce od liczby zwartych zwojów; $I = 5$ A

Fig. 5.18. Dependence of the voltage of 125 Hz frequency induced in the measuring coil on the number of short-circuit turns; $I = 5$ A




Rys. 5.19. Zależność składowej napięcia o częstotliwości 250 Hz indukowanego w cewce od liczby zwartych zwojów; $I = 5$ A


Fig. 5.19. Dependence of the voltage of 250 Hz frequency induced in the measuring coil on the number of short-circuit turns; $I = 5$ A

Można zauważyć wpływ ograniczania prądu zwarcia na wyniki pomiarów (rys. 5.17). Wartość składowej o częstotliwości 50 Hz jest zdecydowanie większa przy prądzie 7 A. Wynika z tego, że w warunkach rzeczywistych, przy uszkodzeniu uzwojeń stojana silnika indukcyjnego, przyrost wartości pola poosiowego będzie o wiele większy, co daje możliwość wczesnego wykrycia uszkodzenia. Oprócz składowej sieciowej, w widmie napięcia indukowanego w cewce pod wpływem strumienia poosiowego, występują również składowe o częstotliwościach równych wielokrotności

częstotliwości sieciowej, a więc 100 Hz, 150 Hz, 200 Hz, 250 Hz itd. oraz składowe o częstotliwościach równych wielokrotności częstotliwości obrotowej 25 Hz (rys. 5.15 i 5.16). Największy wzrost amplitudy można zauważyć dla składowych o częstotliwościach równych nieparzystej krotności częstotliwości sieciowej (150 Hz, 250 Hz) oraz dla krotności częstotliwości obrotowej (125 Hz).




Rys. 5.20. Widmo drgań stycznych w zdrowym silniku
Fig. 5.20. Vibration spectrum in horizontal direction for healthy motor



Rys. 5.21. Widmo drgań stycznych przy 33 zwojach zwartych (prąd zwarcia 7 A)
Fig. 5.21. Vibration spectrum in horizontal direction in the case of 33 short-circuit turns (short-circuit current of 7A)

W widmie drgań stycznych, mierzonych czujnikiem przyspieszenia na korpusie silnika, występuje bogata zawartość różnych częstotliwości. Dominują krotności częstotliwości sieciowej i obrotowej. Ponadto dają się zauważyć częstotliwości, których źródłem mogą być łożyska, niewyważenie oraz drgania zewnętrzne. Wzrost liczby zwartych zwojów najbardziej widoczny jest na składowych 100, 200, 225, 300 i 450 Hz. Na rysunkach 5.20 i 5.21 przedstawiono przykładowe widma drgań dla silnika zdrowego i z maksymalną liczbą zwartych zwojów.



Rys. 5.22. Zależność amplitudy przyspieszenia drgań harmonicznycch o częstotliwościach 100 Hz (a) i 200 Hz (b) od liczby zwartych zwojów (prąd zwarcia 7 A)

Fig. 5.22. Dependence of vibration magnitude of 100 Hz (a) and 200 Hz (b) frequency on the number of short-circuit turns (short-circuit current of 7 A)

Na rysunku 5.22 przedstawiono przykładowo zależność amplitudy przyspieszenia drgań wybranych częstotliwości 100 i 200 Hz od liczby zwojów zwartych. Zależności te są silnie nieliniowe i dla wyższych częstotliwości mają zauważalne zmiany dopiero przy większej liczbie zwojów zwartych.

5.3.2. Perceptronowy detektor zwarcć międzyzwojowych

Do sprawdzenia możliwości wykrywania uszkodzeń uzwojeń stojana za pomocą neuronowego detektora, w możliwie wczesnej fazie powstania uszkodzenia, zastosowano trzy metody analizy cech charakteryzujących tę kategorię uszkodzeń:

- na podstawie pomiaru drgań mechanicznych,
- na podstawie pomiaru strumienia poosiowego.

Przy konstruowaniu neuronowego detektora uszkodzeń stojana, przyjmując amplitudy drgań jako cechy wejściowe, wykorzystano harmoniczne z widma przyspieszenia drgań stycznych o częstotliwościach 100, 200, 225 i 300 Hz, oznaczone na rys. 5.23c, d jako A1–A4. Amplitudy wybranych harmonicznych rosną w miarę wzrostu liczby zwartych zwojów w stojanie (rozdział 5.3.1).


Do projektowania perceptronowego detektora, opartego na obrazach uszkodzenia zawartych w strumieniu poosiowym, wykorzystano wyniki pomiarów wartości skutecznej napięcia indukowanego w zewnętrznej cewce pomiarowej oraz jego harmonicznej o częstotliwości 50 Hz (w analizowanym zakresie widma ma ona największą amplitudę) mierzonych po stronie napędowej U_{nap} i przewietrznika U_{przew} [164, 165, 169].

Wymienione wielkości dla różnych stopni uszkodzenia stojana stanowią zbiór danych wejściowych sieci neuronowej (obrazy uczące), na podstawie których możliwe jest jej wytrenowanie. Przyjęto trzy rodzaje wyjść neuronowego detektora uszkodzeń:

- liczba zwartych zwojów (sieć neuronowa o jednym wyjściu);
- stopień uszkodzenia (sieć neuronowa o jednym wyjściu); na wyjściu może być liczba 0, 1, 2 lub 3, w zależności od stopnia uszkodzenia (0 – brak uszkodzenia; 1 – zwarte 1–9 zwojów; 2 – zwarte 10–20 zwojów; 3 – zwarte 21–33 zwojów);
- stopień uszkodzenia (sieć o trzech neuronach wyjściowych); wartość 1 na kolejnych wyjściach informuje o stopniu uszkodzenia.

Na rysunku 5.23 przedstawiono schematy ideowe rozważanych neuronowych detektorów uszkodzeń stojana.

Do uczenia detektorów uszkodzeń opartych na perceptronowej sieci neuronowej opracowano dwa wektory uczące, z których jeden jest wektorem danych (**P**), a drugi jest wektorem celu (**T**). Wektor celu zawiera informacje na temat liczby zwartych zwojów bądź stopnia uszkodzenia. W tabelach 5.7 i 5.8 przedstawiono przykłady wektorów uczących opracowane dla wybranych przypadków uszkodzeń uzwojenia stojana.



Rys. 5.23. Struktury neuronowych detektorów uszkodzeń stojana: wykorzystujące pomiary pola poosiowego (a, b), pomiary drgań stycznych (c, d)

Fig. 5.23. Structures of neural detectors of stator faults: using measurements of axial flux (a, b), using measurements of vibrations in horizontal direction (c, d)

Na podstawie przeprowadzonych badań sieci o różnych strukturach, strategiach i parametrach uczenia, mając na celu znalezienie struktury możliwie prostej do realizacji praktycznej, opracowano sieć dwuwarstwową o 6 neuronach w warstwie ukrytej – dla detektora wykorzystującego dane z pomiaru pola poosiowego, oraz sieć o 8 neuronach w warstwie ukrytej – dla detektora wykorzystującego dane z pomiaru przyspieszenia drgań stycznych. Dalsze zmniejszanie wymiarów sieci powodowało pogorszenie jej działania.

Opracowana sieć miała następujące parametry:

- strategia uczenia – metoda propagacji wstecznej, z adaptacyjnym współczynnikiem uczenia i momentum;
- architektura sieci:
 - liczba warstw: 2,
 - liczba neuronów w warstwie ukrytej: 8 lub 6,
 - funkcja aktywacji neuronów w warstwie ukrytej: sigmoidalna,
 - funkcja aktywacji neuronów w warstwie wyjściowej: liniowa,
- parametry uczące:
 - stała uczenia: adaptacyjny współczynnik uczenia,
 - błąd dopuszczalny: 0,05,
 - maksymalna liczba cykli uczących: 500 000.

Tabela 5.7. Wektor uczący opracowany na podstawie pomiarów strumienia poosiowego
Table 5.7. Training vector based on axial flux measurements

Wektor	Liczba zwartych zwojów	4	8	10	13	15	18	19	23	28	31	33
P	U_{nap}	0,017	0,057	0,074	0,138	0,186	0,290	0,332	0,474	0,705	0,924	1,085
	U_{przew}	0,010	0,051	0,075	0,125	0,158	0,233	0,255	0,396	0,591	0,711	0,793
	U_{RMS}	0,135	0,221	0,276	0,365	0,453	0,558	0,584	0,698	0,86	0,975	1,067
T	Wyjście 1	4	8	10	13	15	18	19	23	28	31	33

Tabela 5.8. Wektor uczący opracowany na podstawie pomiarów przyspieszenia drgań stycznych
Table 5.8. Training vector based on acceleration of horizontal vibration measurements

Wektor	Liczba zwartych zwojów	0	4	5	10	13	18	19	23	28	33
P	100 Hz	0,05	0,148	0,127	0,224	0,449	0,634	0,613	0,641	0,932	1,664
	200 Hz	0,0	0,088	0,128	0,140	0,168	0,365	0,478	1,110	2,449	5,866
	225 Hz	0,0	0,022	0,035	0,203	0,485	0,707	0,802	1,769	2,167	2,706
	300 Hz	0,05	0,424	0,504	0,734	0,745	0,759	0,817	0,932	0,981	1,120
T	Wyjście 1	0	4	5	10	13	18	19	23	28	33

Przyjęta maksymalna liczba kroków uczenia nigdy nie była realizowana, gdyż sieć znacznie szybciej osiągała założony poziom błędu uczenia. Sieci neuronowe projektowano za pomocą pakietu Matlab Neural Network Toolbox [58].

W tabelach 5.9–5.14 przedstawiono wyniki testowania sieci dla trzech rodzajów detektorów zwarć stojanowych, opartych na pomiarach drgań mechanicznych i na pomiarach pola poosiowego. Nieprawidłowe odpowiedzi wytrenowanej sieci neuronowej oznaczono w tabelach tłustym drukiem.

Tabela 5.9. Wyniki testowania sieci wytrenowanej na podstawie pomiarów strumienia poosiowego (struktura wg rys. 5.23a; na wyjściu sieci liczba zwojów zwartych; 6 neuronów w warstwie ukrytej)

Table 5.9. Testing results of NN trained using axial flux measurements

(structure acc. to fig. 5.23a; number of short-circuit turns as the output; 6 neurons in the hidden layer)

Wektor celu	Liczba zwartych zwojów	7	21	25	26	30	6	9	11
Odpowiedzi sieci	Liczba zwartych zwojów	6,784	20,992	25,002	26,083	29,885	5,811	8,986	11,115
Zaokrąglone odpowiedzi	Liczba zwartych zwojów	7	21	25	26	30	6	9	11

Liczba cykli uczących: 8009

Na podstawie wyników przedstawionych w tabelach można zauważyć, że w przypadku uczenia sieci wektorem opartym na pomiarach strumienia poosiowego,

sieć dawała lepsze odpowiedzi. Może to być spowodowane tym, że dysponowano znacznie większym wektorem uczącym oraz z faktu, że cechy uszkodzeń widoczne w drganiach są bardziej zakłócone innymi oddziaływaniami typu mechanicznego. W związku z tym amplitudy charakterystycznych harmonicznnych miały zafałszowane wartości. Otrzymano struktury o małej liczbie neuronów w warstwie ukrytej (6 i 8 neuronów w warstwie ukrytej), co ma duże znaczenie w zagadnieniach realizacji technicznej.

Tabela 5.10. Wyniki testowania sieci wytrenowanej na podstawie widma drgań (struktura wg rys. 5.23c; na wyjściu sieci liczba zwojów zwartych; 8 neuronów w warstwie ukrytej)

Table 5.10. Testing results of NN trained using vibration spectra (structure acc. to fig. 5.23c; number of short-circuit turns as the output; 8 neurons in the hidden layer)

Wektor celu	Liczba zwartych zwojów	8	15	31
Odpowiedzi sieci	Liczba zwartych zwojów	7,763	12,043	30,991
Zaokrąglone odpowiedzi	Liczba zwartych zwojów	8	12	31

Liczba cykli uczących: 2055

Tabela 5.11. Wyniki testowania sieci wytrenowanej na podstawie pomiarów strumienia poosiowego (struktura wg rys. 5.23a; na wyjściu sieci stopień zwarcia uzwojenia; 6 neuronów w warstwie ukrytej)

Table 5.11. Testing results of NN trained using axial flux measurements (structure acc. to Fig. 5.23a; size of short-circuit as the output; 6 neurons in the hidden layer)

Wektor celu	Stopień zwarcia	1	3	3	3	3	1	1	2
Odpowiedzi sieci	Stopień zwarcia	0,892	2,703	3,056	3,074	2,991	0,902	1,091	1,391
Zaokrąglone odpowiedzi	Stopień zwarcia	1	3	3	3	3	1	1	1

Liczba cykli uczących: 22 543; 0 – brak zwarcia; 1 – oznacza zwarcie 1–10 zwojów; 2 – oznacza zwarcie 11–20 zwojów; 3 – oznacza zwarcie 21–33 zwojów

Tabela 5.12. Wyniki testowania sieci wytrenowanej na podstawie widma drgań (struktura wg rys. 6.23c; na wyjściu sieci stopień zwarcia uzwojenia; 8 neuronów w warstwie ukrytej)

Table 5.12. Testing results of NN trained using vibration spectra (structure acc. to fig. 5.23c; size of short-circuit as the output; 8 neurons in the hidden layer)

Wektor celu	Stopień zwarcia	1	2	3
Odpowiedzi sieci	Stopień zwarcia	1,163	2,283	2,910
Zaokrąglone odpowiedzi	Stopień zwarcia	1	2	3

Liczba cykli uczących: 3447

Tabela 5.13. Wyniki testowania sieci wytrenowanej na podstawie pomiarów strumienia poosiowego (struktura wg rys. 5.23b; na wyjściu sieci stopień zwarcia uzwojenia; 6 neuronów w warstwie ukrytej)

Table 5.13. Testing results of NN trained using axial flux measurements (structure acc. to fig. 5.23b; size of short-circuit as the output; 6 neurons in the hidden layer)

Wektor celu	Stopień zwarcia	Wyj1	1	0	0	0	0	1	1	0
		Wyj2	0	0	0	0	0	0	0	1
		Wyj3	0	1	1	1	1	0	0	0
Odpowiedzi sieci	Stopień zwarcia	Wyj1	1,064	-0,018	-0,144	-0,017	-0,058	1,065	1,152	0,645
		Wyj2	-0,045	0,546	0,091	-0,006	0,074	-0,079	-0,046	0,432
		Wyj3	0,000	0,505	0,995	1,034	0,989	0,003	0,037	-0,037
Zaokrąglone odpowiedzi	Stopień zwarcia	Wyj1	1	0	0	0	0	1	1	1
		Wyj2	0	1	0	0	0	0	0	0
		Wyj3	0	1	1	1	1	0	0	0

Liczba cykli uczących: 30 847; 0 na wszystkich wyjściach oznacza brak zwarcia, 1 na pierwszym wyjściu, a na innych zero oznacza zwarcie mniej niż 10 zwojów, 2 na drugim wyjściu oznacza zwarcie 10–20 zwojów, 1 na trzecim wyjściu oznacza zwarcie więcej niż 20 zwojów

Tabela 5.14. Wyniki testowania sieci wytrenowanej na podstawie widma drgań (struktura wg rys. 5.23d; na wyjściu sieci stopień zwarcia uzwojenia; 8 neuronów w warstwie ukrytej)

Table 5.14. Testing results of NN trained using vibration spectra (structure acc. to Fig. 5.23d; size of short-circuit as the output; 8 neurons in the hidden layer)

Wektor celu	Stopień Zwarcia	Wyj1	1	0	0
		Wyj2	0	1	0
		Wyj3	0	0	1
Odpowiedzi sieci	Stopień zwarcia	Wyj1	1,133	0,131	0,192
		Wyj2	0,089	1,034	0,663
		Wyj3	-0,034	-0,003	0,9698
Zaokrąglone odpowiedzi	Stopień zwarcia	Wyj1	1	0	0
		Wyj2	0	1	1
		Wyj3	0	0	1

Liczba cykli uczących: 7208; 0 na wszystkich wyjściach oznacza brak zwarcia, 1 na pierwszym wyjściu, a na innych zero oznacza zwarcie mniej niż 10 zwojów, 2 na drugim wyjściu oznacza zwarcie 10–20 zwojów, 1 na trzecim wyjściu oznacza zwarcie więcej niż 20 zwojów

Najmniej błędów popełniła sieć o jednym wyjściu, gdy na wyjściu była informacja zarówno o liczbie zwartych zwojów, jak i informacja o stopniu uszkodzenia. Sieć uczona wektorem opartym na pomiarze pola poosiowego miała wszystkie odpowiedzi prawidłowe, natomiast sieć wytrenowana za pomocą wektora wykorzystującego wyniki pomiaru drgań zrobiła jeden błąd. Należy podkreślić, że wszystkie dane uczące i testujące były zebrane w badaniach eksperymentalnych, gdzie destrukcyjny charakter zwarć był celowo ograniczany.

Podjęto również próbę wytrenowania sieci neuronowej na podstawie obydwu wektorów uczących jednocześnie (połączenie struktury z rys. 5.23a i 5.23c oraz z rys. 5.23b i 5.23d). Sieć taka miała największe rozmiary, ale jej odpowiedzi były porównywalne z odpowiedziami sieci wytrenowanych za pomocą jednego wektora. Zwiększenie liczby wejść zdecydowanie nie poprawiło ani nie pogorszyło wyników uczenia, przy znacznie większej strukturze sieci. W tabelach 5.15–5.17 przedstawiono przykłady wyników testowania takich sieci.

Tabela 5.15. Wyniki testowania sieci trenowanej rozszerzonym wektorem uczącym (dane ze strumienia poosiowego i drgań); liczba neuronów w warstwie ukrytej 24

Table 5.15. Testing results of NN trained using extended training vector (training data from axial flux measurements and vibration spectra); 24 neurons in the hidden layer

Wektor celu	Stopień zwarcia	1	2	3
Odpowiedzi sieci	Stopień zwarcia	1,2229	1,6820	2,0005
Zaokrąglone odpowiedzi	Stopień zwarcia	1	2	2

Tabela 5.16. Wyniki testowania sieci trenowanej rozszerzonym wektorem uczącym (dane ze strumienia poosiowego i drgań); liczba neuronów w warstwie ukrytej 22

Table 5.16. Testing results of NN trained using extended training vector (training data from axial flux measurements and vibration spectra); 22 neurons in the hidden layer

Wektor celu	Stopień zwarcia	1	2	3
Odpowiedzi sieci	Stopień zwarcia	1,2224	1,5442	2,6165
Zaokrąglone odpowiedzi	Stopień zwarcia	1	2	3

Tabela 5.17. Wyniki testowania sieci trenowanej rozszerzonym wektorem uczącym (dane ze strumienia poosiowego i drgań); liczba neuronów w warstwie ukrytej 16

Table 5.17. Testing results of NN trained using extended training vector (training data from axial flux measurements and vibration spectra); 16 neurons in the hidden layer

Wektor celu	Stopień zwarcia	Wyj1	1	0	0
		Wyj2	0	1	0
		Wyj3	0	0	1
Odpowiedzi sieci	Stopień zwarcia	Wyj1	0,9009	0,3416	0,0081
		Wyj2	0,1760	0,8868	0,1079
		Wyj3	-0,0514	0,0075	1,0526
Zaokrąglone odpowiedzi	Stopień Zwarcia	Wyj1	1	0	0
		Wyj2	0	1	0
		Wyj3	0	0	1

W klasyfikowaniu poziomu uszkodzenia najmniej błędów robiła sieć o jednym wyjściu, gdy na wyjściu była zarówno informacja o liczbie zwartych zwojów, jak

i informacja o stopniu uszkodzenia. Sieć uczona wektorem opartym na pomiarze pola poosiowego udzieliła tylko jednej błędnej odpowiedzi (tabela 5.9 i 5.13), natomiast sieć wytrenowana za pomocą wektora wykorzystującego wyniki pomiaru drgań zrobiła jeden błąd (tabela 5.10 i 5.14). Sieć neuronowa wytrenowana na obu wektorach uczących jednocześnie miała najwięcej wejść, a co za tym idzie najwięcej neuronów w warstwie ukrytej. Odpowiedzi tej sieci były porównywalne z odpowiedziami sieci wytrenowanymi za pomocą jednego wektora.

Zwiększenie liczby wejść nie poprawiło ani nie pogorszyło wyników uczenia. Można zauważyć, że sieć o jednym wyjściu jest mniej czuła na liczbę neuronów w warstwie ukrytej, natomiast sieć o trzech wyjściach jest bardziej czuła na liczbę neuronów ukrytych i jej poprawne działanie w dużym stopniu zależy od prawidłowego doboru liczby neuronów w warstwie ukrytej. Rozbudowa sieci o jeszcze jedną warstwę ukrytą nie wносиła większych zmian do działania sieci, a jedynie wydłużała proces uczenia.

Zrealizowane badania dowodzą, że perceptronowe detektory uszkodzeń stojana mogą stworzyć nowe możliwości techniczne w zakresie szybkiego wykrywania zwarc zwojowych w początkowej fazie ich powstawania (mała liczba zwartych zwojów). Dalszych badań wymaga sposób zbierania informacji o uszkodzeniu, wykorzystywanej do uczenia sieci. Podstawową trudnością w analizie uszkodzeń stojana jest to, że mają one silnie destrukcyjny charakter i tendencję do lawinowego rozszerzania się. Wyodrębnianie cech uszkodzeń oparte na pomiarach strumienia poosiowego i drgań okazało się bardzo skuteczne. Sprawdzenia wymaga również możliwość wykorzystania do uczenia detektorów danych uzyskiwanych z symulacji opartej na modelach matematycznych. Wymaga to jednak istotnego poprawienia dokładności tych modeli, gdyż dotychczasowe próby opracowania neuronowego detektora zwarc stojanowych na podstawie danych z modelowania były nieudane [31, 91, 151].

5.3.3. Klasyfikator zwarc międzyzwojowych oparty na sieci Kohonena

Sieć samoorganizująca typu Kohonena (rozdział 4) może być stosowana w diagnostyce do grupowania danych wejściowych w pewne klasy podobieństwa. Innymi słowy, spośród obiektów wejściowych powinna wykrywać automatycznie takie grupy, które są podobne do siebie nawzajem i jednocześnie wyraźnie odmienne od innych grup. Sieć po zakończeniu uczenia powinna zatem mieć neurony wyspecjalizowane w rozpoznawaniu klas sygnałów wejściowych, a więc powinna być detektorem sygnalizującym określoną klasę sygnału. W omawianym przypadku sieć Kohonena powinna sygnalizować aktualny stan uzwojenia stojana, czyli klasę określoną liczbą zwojów zwartych uzwojenia (od 0 do 33 zwojów). Przyjęto, że badane będą sieci Kohonena jedno- i dwuwymiarowe.

W dwuwymiarowej sieci Kohonena zakłada się, że neurony ułożone są w dwu wymiarach, w wierszach i w kolumnach. Każdy neuron ma zatem 8 najbliższych są-

siadów tworzących sąsiedztwo pierwsze. Neuron wygrywający współzawodnictwo daje sieci prawo modyfikacji wag własnych oraz neuronów z sąsiedztwa. W odróżnieniu od sieci jednowymiarowej, gdzie neurony tworzące sąsiedztwo układają się w linię, w przypadku sieci dwuwymiarowej następuje odwzorowanie całego obszaru w postaci siatki kwadratowej, w której węzłami są poszczególne neurony.

Do uczenia sieci jedno- i dwuwymiarowej opracowano dwa zestawy dwuwymiarowych danych wejściowych $\mathbf{x} = [x_1, x_2]$:

1) dane z analizy strumienia poosiowego, tzn. wartość skuteczna napięcia indukowanego w cewce pomiarowej (U_{RMS}) oraz amplituda harmonicznej o częstotliwości 50 Hz ($U_{\text{nap}50 \text{ Hz}}$),

2) dane z analizy drgań mechanicznych, tzn. amplitudy dwóch harmonicznych (100 i 200 Hz) przyspieszenia drgań.

W tabelach 5.18 i 5.19 przedstawiono przykładowe zestawy danych uczących.

Tabela 5.18. Wektor uczący wykorzystujący dwuwymiarową sieć Kohonena dla detektora opierającego się na pomiarze pola poosiowego

Table 5.18. Training vector of the two-dimensional Kohonen network for the fault detector based on axial flux measurements

Wektor	Liczba zwartych zwojów	0	4	5	8	10	13	15	18	19	23	28	31	33
P	$U_{\text{nap}50 \text{ Hz}}$	0	0,017	0,022	0,057	0,074	0,135	0,186	0,290	0,332	0,473	0,705	0,924	1,085
	U_{RMS}	0	0,135	0,147	0,221	0,276	0,365	0,453	0,558	0,584	0,698	0,86	0,975	1,067

Tabela 5.19. Wektor uczący wykorzystujący dwuwymiarową sieć Kohonena dla detektora opierającego się na pomiarze drgań stycznych

Table 5.19. Training vector of the two-dimensional Kohonen network for the fault detector based on horizontal vibration measurements

Wektor	Liczba zwartych zwojów	0	4	5	10	13	18	19	23	28	33
P	100 Hz	0,05	0,148	0,127	0,224	0,449	0,634	0,613	0,640	0,932	1,664
	200 Hz	0	0,088	0,128	0,140	0,168	0,365	0,478	1,110	2,449	5,866


Wektory uczące i testujące zostały przygotowane zgodnie z zaleceniami przedstawionymi w rozdziale 4. Ze względu na specyfikę analizowanego uszkodzenia oraz sposób zbierania danych (badania na rzeczywistym obiekcie) i związanych z tym ograniczeń konstrukcyjnych, istniała ograniczona liczba możliwych do zrealizowania wariantów uszkodzenia (13 wzorców uczących i 8 testujących).

Na rysunkach 5.24–5.29 przedstawiono kolejno mapy Kohonena o topologii kwadratowej, o wymiarach siatek (5×5), (10×10), (20×20). Mapy te zostały otrzymane na podstawie uczenia sieci omówionymi zestawami uczącymi. Na zamieszczonych ma-

pach neurony aktywne przy kolejnych zestawach uczących zostały oznaczone symbolem Δ , natomiast neurony aktywne przy zestawach testujących – symbolem O. Cyfry opisujące poszczególne neurony aktywne sieci oznaczają liczbę zwojów zwartych. Neuronem aktywnym dającym na wyjściu sygnał 1 jest ten, którego wagi są najbliższe wektorowi wejściowemu.


W zależności od stopnia uszkodzenia są pobudzane inne obszary mapy, wobec czego uzyskuje się informację o aktualnym stanie silnika.

Na mapach (5x5) uczonych danymi z pola poosiowego (rys. 5.24) oraz drgań (rys. 5.25), niektóre odpowiedzi pokrywają się ze sobą. Te same neurony są aktywne dla kilku zestawów danych. Świadczy to o zbyt małym rozmiarze sieci i zbyt małym rozmiarze wektora wejściowego.



Rys. 5.24. Odpowiedzi sieci Kohonena (5×5) uczonej i testowanej danymi z pomiarów strumienia poosiowego


Fig. 5.24. Responses of the Kohonen network (5×5) trained and tested using axial flux measurements



Rys. 5.25. Odpowiedzi sieci Kohonena (5x5) uczonej i testowanej danymi z pomiarów drgań


Fig. 5.25. Responses of the Kohonen network (5×5) trained and tested using vibration measurements

Powiększenie mapy do rozmiaru (10×10) (rys. 5.26 – dane z pomiaru pola poosiowego i rys. 5.27 – dane z drgań), znacznie poprawia możliwość rozróżniania poszczególnych klas uszkodzeń. Uzyskuje się wyraźne rozróżnienie obszarów zdrowego uzwojenia oraz małej liczby zwartych zwojów (0÷8), średniego uszkodzenia (9÷17), dużego (18÷28) i bardzo dużego (30÷33). Na rysunkach 5.26–5.29 obszary te zostały zaznaczone liniami przerywanymi.



Rys. 5.26. Odpowiedzi sieci Kohonena (10×10) uczonej i testowanej danymi z pomiarów strumienia poosiowego


Fig. 5.26. Responses of the Kohonen network (10×10) trained and tested using axial flux measurements



Rys. 5.27. Odpowiedzi sieci Kohonena (10×10) uczonej i testowanej danymi z pomiarów drgań


Fig. 5.27. Responses of the Kohonen network (10×10) trained and tested using vibration measurements

Lepszą jakość w wyodrębnianiu klas uszkodzeń wykazują sieci uczone danymi z pomiaru strumienia poosiowego. Jednakże w obu przypadkach wyraźnie widać, że liczba danych uczących jest zbyt mała, co zostało już wcześniej omówione i uzasadnione.



Rys. 5.28. Odpowiedzi sieci Kohonena (20×20) uczonej i testowanej danymi z pomiarów pola poosiowego

Fig. 5.28. Responses of the Kohonen network (20×20) trained and tested using axial flux measurements




Rys. 5.29. Odpowiedzi sieci Kohonena (20×20) uczonej i testowanej danymi z pomiarów drgań

Fig. 5.29. Responses of the Kohonen network (20×20) trained and tested using vibration measurements


Powiększenie rozmiarów mapy do (20×20) nie wprowadziło istotnego polepszenia jakości grupowania (rys. 5.28 i 5.29). We wszystkich przedstawionych przypadkach uczenie wynosiło 1000 cykli.

Na rysunkach 5.30 i 5.31 przedstawiono wyniki trenowania sieci jednowymiarowej (1×10). Wyniki uczenia i testowania zostały oznaczone w taki sam sposób jak poprzednio. W obu przypadkach odpowiedzi sieci są pogrupowane równomiernie. Najmniejszym uszkodzeniom (0 zwartych zwojów) odpowiadają odpowiedzi neuronu zwycięzcy nr 10, a największym (33 zwoje zwarte) – neuron nr 1.



Rys. 5.30. Odpowiedzi sieci Kohonena (1×10) uczoney i testowanej danymi z pomiarów pola poosiowego

Fig. 5.30. Responses of the Kohonen network (1×10) trained and tested using axial flux measurements



Rys. 5.31. Odpowiedzi sieci Kohonena (1×20) uczoney i testowanej danymi z pomiarów drgań

Fig. 5.31. Responses of the Kohonen network (1×20) trained and tested using vibration measurements

Można zauważyć, że nawet prosta jednowymiarowa sieć odwzorowań Kohonena umożliwia w łatwy sposób sygnalizowanie aktualnego stanu uzwojenia.

Podsumowując można stwierdzić, że sieć Kohonena jest wygodnym narzędziem do zbudowania prostego detektora zwojów zwartych stojana. Przeprowadzone badania wykazały, że dysponując nawet bardzo ograniczoną liczbą wzorców oraz budując mapę o małych wymiarach (jedno- lub dwuwymiarową), uzyskuje się dobre grupowanie obrazów uszkodzeń. Poszczególne grupy uszkodzeń są wyraźnie rozróżniane. Nie widać również specjalnej różnicy w jakości klasyfikacji uszkodzeń w detektorach opartych na danych z pomiarów strumienia poosiowego i drgań. Należy jednak zauważyć, że z powodów ograniczeń istniejących w badanym silniku liczba dostępnych danych uczących i testujących jest bardzo ograniczona, co spowodowało, że otrzymane mapy Kohonena nie są w pełni zadowalające.

5.4. Neuronowe detektory uszkodzeń łożysk tocznych

5.4.1. Badania eksperymentalne łożysk tocznych

W rozdziale 3 przedstawiono podstawowe metody wykrywania uszkodzeń w łożyskach tocznych silników indukcyjnych. Opierają się one przede wszystkim na analizie widmowej drgań mechanicznych oraz prądu stojana. Ze względu na bardzo duży procentowy udział uszkodzeń łożysk, w ogólnej liczbie uszkodzeń silników indukcyjnych, problem szybkiego wykrywania anomalii w pracy poszczególnych elementów łożysk ma duże znaczenie w praktyce eksploatacyjnej [161, 174].

Do projektowania struktur sieci neuronowej w detektorach uszkodzeń łożysk wykorzystano dane eksperymentalne zebrane z badań dwóch silników: Stg 80X-4c oraz SSh 90L-4. Przedmiotem badań były łożyska toczne typu 6204 2RS zamontowane w silniku typ STg 80X-4C oraz łożyska 6250 ZZ zamontowane w silniku SSh 90L-4. Parametry konstrukcyjne badanych łożysk zamieszczono w załączniku nr 3. W trakcie badań w silnikach montowano wirniki z łożyskami zdrowymi i uszkodzonymi, przy czym uszkodzenia dotyczyły poszczególnych elementów składowych (bieżnia wewnętrzna, zewnętrzna, kulka, koszyk). Również stopień uszkodzeń był różny. Uszkodzenia łożysk były wprowadzane świadomie przez niszczenie wybranych elementów konstrukcyjnych. Należy jednak zwrócić uwagę, że uszkadzanie z premedytacją wybranych elementów mogło mieć wpływ na prawidłowość działania całego łożyska i komplikować zawartość widm drganiowych i prądowych.

W celu uzyskania danych potrzebnych do uczenia i testowania sieci neuronowych zostały wykonane pomiary:


- prądu stojana i drgań korpusu w kierunku promieniowym dla silnika obciążonego momentem znamionowym,
- drgań korpusu w kierunku promieniowym dla silnika rozprężniętego z maszyną obciążającą, pracującego na biegu jałowym.

Badane łożyska o znanych typach i stopniach uszkodzeń zostały sklasyfikowane w następujących grupach:

- łożyska „zdrowe”,
- łożyska z biciem bieżni,
- łożyska z uszkodzoną bieżnią zewnętrzną,
- łożyska z uszkodzoną bieżnią wewnętrzną,
- łożyska z uszkodzoną kulką,
- łożyska ogólnie zużyte (nieznany typ oraz stopień uszkodzenia),

Ogółem zastosowano 20 łożysk dla każdego badanego silnika. Na podstawie wzorów (3.46)–(3.49) przedstawionych w rozdziale 3 oraz danych katalogowych łożysk (załącznik nr 3) można określić częstotliwości charakterystyczne dla danego typu uszkodzenia łożyska.

Na rysunkach 5.32 i 5.33 przedstawiono przykłady widm drganiowych (przyspieszenie drgań) wykorzystywane do uczenia sieci neuronowych. Na rysunku 5.32 przedstawiono widma drgań dla silnika STg80x-4c z łożyskiem „zdrowym” i uszkodzonym.




Rys. 5.32. Widmo drgań silnika STg80x-4c z łożyskiem „zdrowym” (a)
oraz z łożyskiem o uszkodzonej bieżni zewnętrznej (b)


Fig. 5.32. Vibration spectrum of the STg80x-4c motor with “healthy” bearing (a)
and with faulted outer race of the bearing (b)

Przeprowadzono ponadto badania silnika z łożyskiem „zdrowym” przy różnych stopniach asymetrii napięcia zasilania (rys. 5.33). Zgodnie z tym, co przedstawiono w rozdziale 3, do trenowania neurodetektorów zastosowano również widma prądu stojana dla silników z uszkodzonymi łożyskami. Przykłady tych widm przedstawiono na rysunku 5.34.


a)



b)




c)




Rys. 5.33. Widma drgań silnika przy 10% (a), 8% (b) i 4% (c)
asymetrii napięcia zasilania silnika STg80x-4c

Fig. 5.33. Vibration spectra of the motor with 10% (a), 8% (b) i 4% (c)
supply asymmetry (STg80x-4c motor)

a)

 $[dB/1.00 V]$ 

b)



Rys. 5.34. Widmo prądu stojana silnika STg80x-4c z łożyskiem „zdrowym” (a)
oraz z łożyskiem o uszkodzonej bieżni zewnętrznej (b)

Fig. 5.34. Current spectrum of the STg80x-4c motor with “healthy” bearing (a)
and with faulted outer race of the bearing (b)

5.4.2. Perceptronowe detektory uszkodzeń łożysk tocznych

Zadaniem neuronowego detektora uszkodzeń łożyska jest rozpoznanie stanu łożyska, tzn. zakwalifikowanie go do grupy – łożysko „zdrowe” lub uszkodzone. Przyjęto, że danymi wejściowymi detektora są amplitudy harmoniczných drgań silnika i prądów stojana określone na podstawie odpowiednich widm. Wybór konkretnych harmoniczných z sygnału drganiowego i prądowego wynika z wcześniej przeprowadzonych rozważań na temat przyczyn uszkodzeń łożysk (rozdział 3.5). Są to przede wszystkim harmoniczne wynikające z geometrii łożyska (zależności (3.46)–(3.50)), prędkości obrotowej, momentu zewnętrznego, ekscentryczności i modulacji prądu stojana (zależności (3.45), (3.40)–(3.42)).

Do opracowania neuronowego klasyfikatora zastosowano sieć neuronową jednokierunkową wielowarstwową. Opracowano i przebadano trzy typy klasyfikatorów:

- detektor dwustanowy do określenia stanu łożyska (łożysko dobre – łożysko uszkodzone) na podstawie danych z widma drgań;
- detektor trójstanowy do określenia stanu łożyska oraz wykrycia asymetrii zasilania na podstawie danych z widma drgań (łożysko dobre – łożysko uszkodzone – asymetria zasilania);

- detektor dwustanowy do określenia stanu łożyska (łożysko dobre – łożysko uszkodzone) na podstawie danych z widma prądu;
- detektor trójstanowy do określenia stanu elementów składowych łożyska, tzn. kulki, bieżni zewnętrznej i wewnętrznej.

W przypadku uczenia sieci jednokierunkowych, oprócz wektora danych uczących, należało również podać wektor celu określający wartość oczekiwaną na wyjściu sieci. Dla sieci mających jedno wyjście wartościami tymi są: 0 – dla łożyska zdrowego i 1 – dla łożyska uszkodzonego.

W sieci o trzech wyjściach każde z nich odpowiada za inny stan łożyska silnika:

- wyjście 1 odpowiada łożysku zdrowemu,
- wyjście 2 odpowiada łożysku uszkodzonemu,
- wyjście 3 odpowiada asymetrii zasilania.

Pojawienie się na jednym z wyjść wartości 1 informuje o aktualnym stanie łożyska, przy czym wyjście 3 informuje jedynie o wystąpieniu asymetrii zasilania (może wystąpić przy łożysku dobrym i uszkodzonym).

W celu znalezienia najlepszej struktury (tzn. zawierającej możliwie małą liczbę neuronów i odpowiadającą na dane testowe z minimalną liczbą błędów), kierując się wstępnie ogólnymi zasadami doboru liczby neuronów [190, 210] oraz metodą prób i błędów, wykonano szereg badań symulacyjnych za pomocą środowiska MATLAB. Przyjęto następujące funkcje aktywacji dla poszczególnych typów sieci:

1. Dla sieci dwuwarstwowej w warstwie ukrytej – funkcja sigmoidalna, natomiast w warstwie wyjściowej funkcja liniowa.
2. Dla sieci trójwarstwowych w pierwszej warstwie ukrytej funkcja sigmoidalna, w drugiej tangens hiperboliczny, natomiast w warstwie wyjściowej funkcja liniowa.

Do opracowania wektorów uczących wykorzystano dane pomiarowe z badania 15 łożysk, natomiast dane z 5 łożysk zastosowano do testowania otrzymanych sieci neuronowych. Dane te podlegały wcześniejszej obróbce normalizacyjnej zgodnie z zasadami przedstawionymi w rozdziale 4. Przyjmowano różne rozmiary wektora wejściowego od 7 do 28 neuronów wejściowych. Zauważono, że im liczba neuronów wejściowych była większa, tym krótszy był czas uczenia (kilkanaście epok), jednak wyniki testów były nieprawidłowe. Dobre odtwarzanie wektora uczącego i błędne testowego oraz mała liczba epok uczących wskazują na to, że sieć nie nauczyła się rozpoznawać uszkodzeń, a jedynie zapamiętała wektor uczący. Ponieważ sieć była uczona wektorem o dużej liczbie wejść i zbyt małej liczbie wzorców uczących (15), niezbędne było zredukowanie liczby wejść do 7.

W tabelach 5.20–5.22 przedstawiono wybrane wyniki testowania najlepszych otrzymanych struktur detektorów neuronowych z jednym neuronem wyjściowym, uczonych na podstawie widma drgań. Można przyjąć, że wszystkie przedstawione architektury sieci są dobre, gdyż bezbłędnie odtwarzają obrazy testujące. Jeżeli jednak założyć jako kryterium częstość, z jaką sieć uczyła się poprawnie, to struktura z 5 neuronami w warstwie ukrytej (tabela 5.22) jest najlepsza [157, 159, 169].

Tabela 5.20. Odpowiedzi na dane testujące sieci dwuwarstwowej z 3 neuronami w warstwie ukrytej (sieć trenowana z wykorzystaniem danych z widma drgań)

Table 5.20. Responses of two-layer NN with 3 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedzi	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2
Neuron wyj.	0,321	1,016	0,977

Tabela 5.21. Odpowiedzi na dane testujące sieci trójwarstwowej z 5 i 4 neuronami w warstwach ukrytych (sieć trenowana z wykorzystaniem danych z widma drgań)

Table 5.21. Responses of three-layer NN with 5 and 4 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedź	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2
Neuron wyj.	0,127	0,999	0,993

Tabela 5.22. Odpowiedzi na dane testujące sieci dwuwarstwowej z 5 neuronami w warstwie ukrytej (sieć trenowana z wykorzystaniem danych z widma drgań)

Table 5.22. Responses of two-layer NN with 5 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedzi	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2
Neuron wyj.	0,087	0,995	1,004

Podobne rezultaty uzyskano, ucząc sieć danymi z widma prądowego [159, 160]. W tym przypadku występują jednak duże trudności z wyodrębnieniem interesujących harmonicznych z widma prądowego. Dotyczy to przede wszystkim harmonicznych wynikających z modulacji prądu stojana przez mechaniczne uszkodzenia elementów składowych łożyska (wzór (3.45)). W silnikach małej mocy harmoniczne charakteryzujące uszkodzenia łożysk mają bardzo małe amplitudy i dlatego niezbędna jest duża dokładność pomiaru i duża rozdzielczość widma. W tabeli 5.23 przedstawiono wynik testowania najprostszego uzyskanego detektora, zbudowanego na sieci dwuwarstwowej z trzema neuronami w warstwie ukrytej. Sieć prawidłowo zinterpretowała dane testujące z trzech łożysk (1 zdrowe i 2 uszkodzone).

Tabela 5.23. Odpowiedzi na dane testujące sieci dwuwarstwowej z 3 neuronami w warstwie ukrytej (sieć trenowana z wykorzystaniem danych z widma prądu stojana)

Table 5.23. Responses of two-layer NN with 3 hidden neurons to testing data (network trained using stator current spectra)

Odpowiedź	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2
Neuron wyj.	-0,0274	0,9810	1,0011

Kolejnym etapem było zbadanie sieci neuronowej zawierającej trzy neurony wyjściowe. W tabelach 5.24–5.27 przedstawiono wyniki uczenia sieci dla trzech neuronów wyjściowych (uczenie na podstawie widma drgań). Założono, że każde z wyjść określa inny stan techniczny łożyska. Osiągnięcie danego stanu jest równoznaczne z wartością wyjścia równą 1 (lub bliską 1). Pierwsze wyjście odpowiada łożysku „złowemu”, drugie uszkodzonemu łożysku, natomiast trzecie asymetrii zasilania.

Wyniki testów powinny być następujące:

- dla silnika zdrowego – pierwszy neuron wyjściowy powinien mieć wartość 1 a pozostałe 0,
- dla silnika z uszkodzonym łożyskiem – drugi neuron wyjściowy powinien mieć wartość 1 a pozostałe 0,
- dla silnika zasilanego niesymetrycznym napięciem – trzeci neuron wyjściowy powinien mieć wartość 1 a pozostałe 0.

Tabela 5.24. Odpowiedzi na dane testujące sieci dwuwarstwowej z 4 neuronami w warstwie ukrytej (sieć trenowana z wykorzystaniem danych z widma drgań)

Table 5.24. Responses of two-layer NN with 4 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedzi	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2	Asymetria 8%	Asymetria 2%
Neuron 1	0,9463	0,0398	0,4503	0,0196	0,0226
Neuron 2	0,1067	1,0280	0,9239	0,0403	0,2652
Neuron 3	-0,1537	-0,0739	-0,3441	0,9348	0,7130

Tabela 5.25. Odpowiedzi na dane testujące sieci dwuwarstwowej z 9 neuronami w warstwie ukrytej (sieć trenowana z wykorzystaniem danych z widma drgań)

Table 5.25. Responses of two-layer NN with 9 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedzi	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2	Asymetria 8%	Asymetria 2%
Neuron 1	0,9309	-0,0861	0,0149	0,0521	0,0835
Neuron 2	-0,6664	0,8871	1,0880	0,0314	0,0007
Neuron 3	0,1546	0,1088	0,0202	0,9899	0,9337

Pomiary asymetrii zasilania były prowadzone przy zamontowanych zdrowych łożyskach, a pomiary przy uszkodzonych łożyskach prowadzone były przy symetrycznym zasilaniu. Wyklucza to pojawienie się innych odpowiedzi na dane testujące jak te, które zostały wcześniej założone. W omawianym przypadku pojawia się problem, co należy zrobić z wynikami ujemnymi, które mogą wystąpić i mieć duże wartości. Pojawienie się wartości ujemnych wynika z budowy i zasady działania sieci perceptronowych. W przypadku wartości w granicach $(-0,4) \div (-0,2)$ można te wyniki pominąć i przyjąć je jako wartości zbliżone do 0.

W tabelach 5.26 i 5.27 przedstawiono odpowiedzi na dane testujące sieci trójwarstwowych o – odpowiednio – 9 i 6 oraz 4 i 5 neuronach w warstwach ukrytych.

Duże wartości ujemne dla neuronów wyjściowych pojawiły się w neuronie trzecim podczas testowania danymi zdrowego łożyska oraz w neuronie pierwszym podczas testowania danymi charakterystycznymi dla asymetrii zasilania. Można to zinterpretować w ten sposób, że sieć ta bardzo dobrze rozpoznała wszystkie stany i dodatkowo wskazywała, że przy wystąpieniu asymetrii zasilania silnik miał zdrowe łożysko, co wynikało ze sposobu przeprowadzania eksperymentów. Ze wszystkich przebadanych struktur sieć dwuwarstwowa o 4 neuronach w warstwie ukrytej dawała najlepsze odpowiedzi na dane testujące.


Tabela 5.26. Odpowiedzi na dane testujące sieci trójwarstwowej z 9 i 6 neuronami w warstwach ukrytych (sieć trenowana z wykorzystaniem danych z widma drgań)
Table 5.26. Responses of three-layer NN with 9 and 6 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedzi	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2	Asymetria 8%	Asymetria 2%
Neuron 1	1,4889	0,0267	−0,2396	−0,7867	−0,7273
Neuron 2	0,0468	0,9921	0,8754	−0,2603	−0,2195
Neuron 3	−0,8486	0,0386	0,1270	1,2511	1,2026

Tabela 5.27. Odpowiedzi na dane testujące sieci trójwarstwowej z 5 i 4 neuronami w warstwach ukrytych (sieć trenowana z wykorzystaniem danych z widma drgań)
Table 5.27. Responses of three-layer NN with 5 and 4 hidden neurons to testing data (network trained using vibration spectra)

Odpowiedzi	Łożysko zdrowe	Łożysko uszkodzone 1	Łożysko uszkodzone 2	Asymetria 8%	Asymetria 2%
Neuron 1	1,0952	0,0226	−0,0450	−0,1002	0,0349
Neuron 2	0,4428	0,9782	1,0205	0,0400	−0,0149
Neuron 3	−0,5365	−0,0008	0,0242	1,0593	0,9795

Dotychczas rozważane neuronowe detektory wykrywały tylko czy łożysko jest sprawne, czy uszkodzone, z ewentualną jeszcze możliwością sprawdzania symetrii zasilania. Podjęto również próbę zbudowania detektora określającego, który z elementów składowych łożyska jest aktualnie uszkodzony. Do tego celu została zaprojektowana sieć neuronowa o trzech wyjściach (rys. 5.35).



Rys. 5.35. Struktura neuronowego detektora uszkodzeń łożysk tocznych
(sygnałami wejściowymi są amplitudy harmonicznych przyspieszenia drgań)

Fig. 5.35. Structure of neural detector of rolling bearing faults
(magnitudes of harmonics of the acceleration of mechanical vibrations as NN input values)

Na wejścia sieci podawane są wartości amplitud harmonicznych przyspieszenia drgań, związanych z uszkodzeniami poszczególnych elementów łożyska: pierwsza i druga harmoniczna częstotliwości uszkodzeniowej bieżni zewnętrznej f_{bz} , pierwsza, druga i trzecia harmoniczna częstotliwości uszkodzeniowej kulki f_k , pierwsza i druga harmoniczna częstotliwości uszkodzeniowej bieżni wewnętrznej f_{bw} . Każde wyjście odpowiada za uszkodzenie jednego elementu łożyska. Wyjście pierwsze BZ odpowiada uszkodzeniu bieżni zewnętrznej, wyjście drugie K – uszkodzeniu elementu tocznego, wyjście trzecie BW – uszkodzeniu bieżni wewnętrznej. Pojawienie się na którymkolwiek wyjściu wartości 1 oznacza uszkodzenie danego typu. Wartość 0 na wszystkich wyjściach oznacza łożysko nieuszkodzone.

Do trenowania sieci neuronowej wybrano amplitudy przyspieszenia drgań harmonicznych związanych z uszkodzeniami poszczególnych elementów łożyska. Częstotliwości interesujących harmonicznych zostały obliczone wg zależności (3.46)–(3.49) i zweryfikowane dla danego typu łożyska z danymi dostępnymi w bazach danych firm produkujących łożyska. W tabeli 5.28 zestawiono charakterystyczne częstotliwości w widmie drgań dla łożyska typu 6205 podawane przez różnych producentów. Wartości częstotliwości uszkodzeniowych obliczone ze wzorów (3.46)–(3.49) nie odbiegają w znaczący sposób od wartości częstotliwości obliczonych na podstawie informacji

podawanych przez producentów łożysk. W neuronowym detektorze uszkodzeń łożysk tocznych skoncentrowano się na wykrywaniu uszkodzeń kulki oraz obu bieżni. Zrezygnowano z wykrywania uszkodzeń koszyka ze względu na trudności związane z fizycznym modelowaniem tego typu uszkodzenia w łożyskach.

Do trenowania sieci neuronowej wybrano tylko częstotliwości z zakresu 0–200 Hz. Wybór wyższych harmonicznnych częstotliwości uszkodzeniowych jest kłopotliwy ze względu na małe amplitudy i występowanie w ich otoczeniu prążków o wysokich amplitudach i zwykle nieznanym źródle powstawania.

Tabela 5.28. Charakterystyczne częstotliwości w widmach drgań łożyska (silnik SSh90L-4)

Table 5.28. Characteristic frequencies in the vibration spectrum of the bearing (SSh90L-4 motor)

Producent łożyska	Łożysko typu 6205			
	Rodzaj uszkodzenia			
	Bieżnia zewnętrzna	Bieżnia wewnętrzna	Kulka	Koszyk
	Hz			
SKF	89,51	135,19	58,86	9,95
Fafnir	89,21	135,52	57,97	9,91
FAG	88,98	136,32	57,52	9,89
NSK	89,48	135,22	58,79	9,94
NTN	89,63	135,07	58,92	9,99
Wartości obliczone	89,30	135,40	58,30	9,92
Średnia	89,35	135,45	58,39	9,93

Tabela 5.29. Harmoniczne o częstotliwościach uszkodzeniowych badanego łożyska

Table 5.29. Harmonics with fault frequencies of tested bearing

Numer harmonicznej	Łożysko typu 6205			
	Rodzaj uszkodzenia			
	Bieżnia zewnętrzna	Bieżnia wewnętrzna	Kulka	Koszyk
	Hz			
1	89,3	135,4	58,3	9,92
2	178,6	270,8	116,6	19,84
3	267,9	406,2	174,9	29,76
4	357,2	541,6	233,2	39,68

W tabeli 5.29 przedstawiono przykładowo wartości kolejnych harmonicznnych łożyska 6205. Ze względu na duże różnice pomiędzy wartościami maksymalnymi i minimalnymi pojawiającymi się w wektorze uczącym, znacznie przekraczające stosunek graniczny (3–4) preferowany przez sieci neuronowe, poddano je wstępnemu przetworzeniu. W tabeli 5.30 przedstawiono przykład wektora uczącego dla sieci neuronowej,

a w tabeli 5.31 i 5.32 odpowiedzi sieci o strukturze [7 10 15 3] i [7 15 10 3] na wektor testujący. Symbolem WO określono wartość oczekiwaną, a WU wartość uzyskaną.

Tabela 5.30. Wektor uczący dla sieci neuronowej

Table 5.30. Training vector of neural network

Lp.	Neurony wejściowe	Numer łóżyska						
		1	2	3	4	5	6	7
1	fk	-3,27	-3,27	-3,26	-3,27	-2,94	-3,23	-3,04
2	fbz	-1,57	-1,59	-2,05	-2,76	-2,93	-3,10	-2,58
3	2fk	-3,26	-3,21	-3,12	-3,10	-2,34	-2,80	-1,98
4	fbw	-3,26	-3,24	-3,27	-3,24	-3,24	-3,24	-3,20
5	3fk	-2,91	-3,16	-3,03	-3,15	-2,21	-3,06	-2,84
6	2fbz	-1,98	-1,19	-1,30	-2,26	-2,70	-3,03	-3,15
7	2fbw	-3,17	-1,61	-3,00	-3,24	-2,87	-3,22	-3,14
cd. tabeli 5.30 cont. of the Table 5.30								
Lp.	Neurony wejściowe	Numer łóżyska						
		8	9	10	11	12	13	
1	fk	-3,25	-3,10	-2,95	-3,26	-3,22	-3,27	
2	fbz	-2,67	-2,72	-2,92	-3,23	-3,25	-3,25	
3	2fk	-3,27	-2,83	-2,74	-3,10	-3,25	-3,28	
4	fbw	-2,66	-1,83	-2,73	-3,22	-3,25	-3,15	
5	3fk	-3,06	-3,02	-2,84	-3,28	-3,25	-3,26	
6	2fbz	-2,45	-3,04	-2,71	-2,72	-3,26	-2,97	
7	2fbw	-2,66	-1,35	-1,89	-3,09	-3,22	-3,27	

Tabela 5.31. Odpowiedzi sieci o strukturze [7 10 15 3] na wektor testujący

Table 5.31. Responses of neural network [7 10 15 3] to the testing vector

Neurony wyjściowe	Numer łóżyska											
	5		9		11		17		15		16	
	Uszkodzona bieżnia zewnętrzna		Uszkodzona kulka		Uszkodzona bieżnia wewnętrzna		Łóżysko nieuszkodzone		Łóżysko z uszkodzeniami ogólnymi		Łóżysko z uszkodzeniami ogólnymi	
	WO	WU	WO	WU	WO	WU	WO	WU	WO	WU	WO	WU
Neuron 1	1	0,78	0	0,02	0	-0,39	0	-0,11	1	0,51	1	0,16
Neuron 2	0	-0,13	1	0,87	0	0,37	0	-0,21	1	0,50	1	0,76
Neuron 3	0	0,32	0	0,01	1	1,44	0	0,11	1	0,46	1	1,15

Tabela 5.32. Odpowiedzi sieci o strukturze [7 15 10 3] na wektor testujący
 Table 5.32. Responses of neural network [7 15 10 3] to the testing vector

Neurony wyjściowe	Numer łożyska											
	5		9		11		17		15		16	
	Uszkodzona bieżnia zewnętrzna		Uszkodzona kulka		Uszkodzona bieżnia wewnętrzna		Łożysko nieuszkodzone		Łożysko z uszkodzeniami ogólnymi		Łożysko z uszkodzeniami ogólnymi	
	WO	WU	WO	WU	WO	WU	WO	WU	WO	WU	WO	WU
Neuron 1	1	0,57	0	-0,13	0	-0,15	0	-0,08	1	0,39	1	0,62
Neuron 2	0	0,11	1	1,19	0	0,38	0	0,01	1	0,60	1	-0,12
Neuron 3	0	0,36	0	-0,22	1	0,81	0	0,07	1	0,74	1	1,41

Sieci te dobrze odwzorowują uszkodzenia elementów składowych łożysk, ale nadal słabo rozpoznają uszkodzenia łożysk z uszkodzeniami ogólnymi (nr 15 i nr 16). Sieć o strukturze [7 10 15 3] (tab. 5.31) zbyt słabo sygnalizowała bardzo silne uszkodzenia łożyska nr 15. Z przetestowanych struktur jest to jednak najlepiej uogólniająca struktura. Natomiast sieć o budowie [7 15 10 3] (tab. 5.32) za słabo sygnalizowała uszkodzenie bieżni zewnętrznej w łożyskach nr 5 i nr 15 oraz uszkodzenie kulki w łożysku nr 16.

Tabela 5.33. Zmodyfikowany wektor uczący dla sieci neuronowej
 Table 5.33. Modified training vector for neural network


Lp.	Neurony wejściowe	Numer łożyska						
		1	2	3	4	5	6	7
1	fk	-3,30	-3,30	-3,30	-3,30	-2,94	-3,23	-3,04
2	fbz	-1,57	-1,59	-2,05	-2,76	-3,30	-3,30	-3,30
3	2fk	-3,30	-3,30	-3,30	-3,30	-2,34	-2,80	-1,98
4	fbw	-3,30	-3,30	-3,30	-3,30	-3,30	-3,30	-3,30
5	3fk	-3,30	-3,30	-3,30	-3,30	-2,21	-3,06	-2,84
6	2fbz	-1,98	-1,19	-1,30	-2,26	-3,30	-3,30	-3,30
7	2fbw	-3,30	-3,30	-3,30	-3,30	-3,30	-3,30	-3,30
cd. tabeli 5.33 cont. of the Table 5.33								
Lp.	Neurony wejściowe	Numer łożyska						
		8	9	10	11	12	13	
1	fk	-3,30	-3,30	-3,30	-3,26	-3,22	-3,27	
2	fbz	-3,30	-3,30	-3,30	-3,23	-3,25	-3,25	
3	2fk	-3,30	-3,30	-3,30	-3,10	-3,25	-3,28	
4	fbw	-2,66	-1,83	-2,73	-3,22	-3,25	-3,15	
5	3fk	-3,30	-3,30	-3,30	-3,28	-3,25	-3,26	
6	2fbz	-3,30	-3,30	-3,30	-2,72	-3,26	-2,97	
7	2fbw	-2,66	-1,35	-1,89	-3,09	-3,22	-3,27	

Przygotowując łożyska do badań uszkodzono je w jeden określony sposób, jednak nie uzyskano pewności, czy inne elementy łożyska nie zostały również przypadkowo uszkodzone. W czasie badań silne uszkodzenie jednego elementu łożyska mogło powodować szybkie uszkodzanie się innych elementów. W związku z czym, w widmach drgań łożysk o teoretycznie uszkodzonym jednym elemencie pojawiały się, oprócz prążków odpowiedzialnych za tego rodzaju uszkodzenia, również prążki związane z innymi typami uszkodzeń. Sieć neuronowa jest uczona wektorem o różnych rodzajach uszkodzeń dla jednej próbki, natomiast oczekuje się jednoznacznej odpowiedzi identyfikującej jedno uszkodzenie. Taka sieć ma kłopoty z rozróżnianiem uszkodzeń. Dlatego sprawdzono, czy pewne przekształcenia na danych wejściowych tworzących wektor uczący (tzw. przetwarzanie wstępne) mogą polepszyć działanie sieci. Zwiększenie dokładności wyników jest możliwe do uzyskania przez modyfikację wektora uczącego polegającą na eliminacji harmonicznych uszkodzeniowych niezwiązanych z badanym typem uszkodzenia. Na przykład w łożyskach 1–4 wartości pojawiające się na wejściach niezwiązanych z uszkodzeniem bieżni zewnętrznej zostały sprowadzone do poziomu szumów. Uzyskany w ten sposób wektor uczący przedstawiono w tabeli 5.33. Wektor odpowiedzi wzorcowych oraz wektor testujący nie uległy zmianie.

W badaniach neuronowych detektorów uczonych skorygowanym wektorem sprawdzano wpływ struktury sieci i funkcji przejścia neuronów warstw ukrytych na jakość odpowiedzi na wektor testujący. Zbadano struktury z jedną i dwiema warstwami ukrytymi. Sieci z jedną warstwą ukrytą zawierały w niej 10, 20 i 30 neuronów. Sieci z dwiema warstwami ukrytymi miały wszystkie kombinacje 5, 10, 15 i 20 neuronów w każdej warstwie ukrytej. Każdą strukturę przebadano dla dwóch rodzajów funkcji przejścia warstw ukrytych: tangens hiperboliczny i sigmoidalna. W interpretacji odpowiedzi sieci na wektor testujący przyjęto, że uszkodzenie sygnalizuje pojawienie się na wyjściu wartości większej od 0,5, natomiast wartość mniejsza od 0,5 oznacza brak uszkodzenia.

Większość sieci poprawnie odpowiadała na widma testowych łożysk z jednym rodzajem uszkodzenia, ale błędnie odpowiadały na widma łożysk z dwoma lub trzema rodzajami uszkodzeń. Najlepsze wyniki uzyskały sieci o strukturze [7 10 3] oraz [7 20 5 3] przy funkcji przejścia dla neuronów warstw ukrytych o funkcjach aktywacji typu sigmoidalnego. Na rysunku 5.36 przedstawiono wartości odpowiedzi neuronów wyjściowych na wektor testujący.

Rysunek 5.36a pokazuje poprawne oczekiwane wartości. Rysunki 5.36b i 5.36c przedstawiają poprawne odpowiedzi sieci o strukturach [7 10 3] i [7 20 5 3]. Rysunek 5.36d obrazuje przykładową, błędnie odpowiadającą sieć o strukturze [7 5 5 3] i funkcji przejścia typu tangens hiperboliczny. Detektor uszkodzeń łożysk w postaci sieci o strukturze [7 20 5 3] dawał odpowiedzi najbliższe oczekiwanym.



Rys. 5.36. Odpowiedzi sieci neuronowych na wektor testujący: a – oczekiwana odpowiedź, b – odpowiedź sieci o strukturze [7 20 5 3] i sigmoidalnej funkcji aktywacji, c – odpowiedź sieci o strukturze [7 10 3] i sigmoidalnej funkcji aktywacji, d – odpowiedź sieci o strukturze [7 5 5 3] i funkcji aktywacji typu tangens hiperboliczny


Fig. 5.36. Responses of NNs to the testing vector: a – expected response, b – response of NN [7 20 5 3] with the activation function of sigmoidal type, c – response of NN [7 10 3] with the activation function of sigmoidal type, d – response of NN [7 5 5 3] with the activation function of hyperbolic tangent type

5.4.3. Klasyfikator uszkodzeń łożysk oparty na sieci Kohonena

Jak przedstawiono w rozdziale 4, sieć samoorganizująca typu Kohonena może być bardzo przydatnym narzędziem w monitorowaniu i diagnostyce obiektów do wstępnego klasyfikowania zdarzeń (uszkodzeń), czyli tzw. grupowania (ang. *clustering*). W celu sprawdzenia możliwości grupowania przez sieć uszkodzeń związanych m.in. z łożyskami oraz dodatkowo z asymetrią zasilania, przeprowadzono badania sieci odwzorowań dwuwymiarowych. Do wstępnego określenia rodzaju uszkodzenia może być przydatna znajomość rozmieszczenia neuronów zwycięzców na siatce odwzorowań. Algorytm uczenia sieci odwzorowań jedno- i dwuwymiarowych polega na tym, że w procesie uczenia zwycięzcą zostaje ten neuron, którego wartości współczynników wagowych są najbliższe wartościom danych wejściowych. Uczą się wszystkie neurony, ale im dalej od neuronu zwycięzcy, tym słabsza jest ta nauka. Podczas testowania wytrenowanej sieci na dane testujące odpowiada również ten neuron, którego wartości współczynników wag są najbliższe wartościom zadany.

Na rysunku 5.37 przedstawiono odpowiedzi na dane uczące i testujące sieci odwzorowań dwuwymiarowych (10×10). Przyjęto następujące oznaczenia:

- ▲ △ – odpowiedź neuronu na dane uczące i testujące dla łożyska „zdrowego”,
- ○ – odpowiedź neuronu na dane uczące i testujące dla asymetrii zasilania stojana,
- □ – odpowiedź neuronu na dane uczące i testujące dla łożysk uszkodzonych.



Rys. 5.37. Odpowiedzi dwuwymiarowej sieci Kohonena o strukturze [10×10] uczonej i testowanej danymi z widma drgań

Fig. 5.37. Responses of two-dimensional Kohonen network of [10×10] trained and tested using vibration spectra

Do uczenia sieci wykorzystano dane z analizy widmowej drgań 20 łożysk, natomiast do testowania sieci – dane z badania pięciu łożysk uszkodzonych i pięciu sprawnych. Analizując uzyskane wyniki, można zauważyć, że:

- na siatce odwzorowań wyraźnie widać zgrupowanie neuronów odpowiadające łożyskom uszkodzonym i „zdrowym”,
- obszary odpowiadające za asymetrię zasilania i łożyska „zdrowe” są zgrupowane blisko siebie, co świadczy o podobnym charakterze tych stanów, asymetria zasilania była realizowana dla silnika ze sprawnymi łożyskami.

Uzyskanie lepszej jakości grupowania było niemożliwe przy przyjętym rozmiarze sieci odwzorowań oraz ograniczonym wektorze wejściowym, jednak przyjęty sposób zbierania danych uczących i testujących utrudniał uzyskanie większej liczby wzorców.

5.5. Podsumowanie

Na podstawie badań symulacyjnych neuronowych detektorów uszkodzeń, trenowanych i testowanych danymi uzyskanymi z pomiarów na obiekcie rzeczywistym można sformułować następujące wnioski i uwagi:

- Zastosowanie klasycznej analizy widmowej prądu stojana, strumienia poosiowego oraz przyspieszeń drgań pozwoliło uzyskać bardzo obszerny materiał do uczenia i testowania sieci neuronowych.
- Przeprowadzenie wstępnej analizy i przetwarzania danych pomiarowych pozwoliło wykluczyć te dane, które w bardzo małym stopniu charakteryzują uszkodzenie. Zabieg ten miał na celu zmniejszenie rozmiarów wektorów uczących, a tym samym przyspieszenie procesu uczenia sieci neuronowych.
- W uczeniu sieci neuronowych bardzo ważną rolę odgrywał dobór współczynników wagowych podczas inicjacji sieci. Źle dobrane wartości początkowe mogą spowodować niewłaściwe nauczanie się sieci, pomimo osiągnięcia zadanego poziomu błędu.
- Opracowane neuronowe detektory uszkodzeń potrafiły klasyfikować testowane przypadki uszkodzeń wirników, stojana oraz łożysk tocznych z bardzo małymi błędami.
- Nie zauważono wyraźnej zależności efektywności neuronowego klasyfikatora uszkodzeń od rozmiaru sieci. Sieci o małych rozmiarach dostarczają wyników podobnych jak sieci o bardziej rozbudowanych strukturach. Ma to istotne znaczenie z punktu widzenia praktycznej realizacji – mniejsze wymagania stawiane procesorowi realizującemu przetwarzanie neuronowe.
- Opracowane detektory uszkodzeń wirników klatkowych, pomimo bardzo prostych struktur, skutecznie klasyfikowały stopień uszkodzenia. Pełniane przez

sieć błęd na poziomie ± 1 pręt nie ma praktycznego znaczenia. Znacznie gorzej radziła sobie sieć z wykrywaniem rozłożenia uszkodzonych prętów.

- Perceptronowe detektory zwarć stojanowych w symulacjach wykrywały poprawnie bardzo małą liczbę zwojów zwartych, co pozwala zakładać, że możliwe będzie szybkie reagowanie w początkowej fazie powstawania uszkodzenia w uzwojeniach stojana w rzeczywistych warunkach wykrywania uszkodzenia.
- W przypadku neuronowych detektorów uszkodzeń stojana lepsze rezultaty dawały rozwiązania wykorzystujące strumień poosiowy niż drgania mechaniczne. Zwiększenie liczby wejść nie poprawiało jakości działania detektorów. Sieć jednowyjściowa była mniej wrażliwa na liczbę neuronów w warstwie ukrytej od rozwiązań trójwyjściowych.
- W klasyfikacji uszkodzeń łożysk tocznych zadowalające wyniki dawały sieci jednokierunkowe z jedną warstwą ukrytą, dla wszystkich wariantów zbadanych struktur. Uzyskano praktycznie taką samą skuteczność wykrywania uszkodzonych łożysk w detektorach trenowanych danymi z analizy drgań i prądu stojana. Rozszerzenie listy uszkodzeń o asymetrię zasilania nie zakłóciło działania detektorów.
- Badania neuronowego detektora uszkodzeń elementów konstrukcyjnych łożyska wykazały, że do uzyskania prawidłowej klasyfikacji uszkodzeń niezbędne jest prawidłowe wstępne przetwarzanie danych. Niski poziom amplitud charakterystycznych częstotliwości sprawia, że ich wyodrębnienie wymaga przetwarzania o dużej rozdzielczości i czułości.
- Wyniki testów sieci Kohonena dla uszkodzeń stojana i łożysk wykazały, że możliwe jest pogrupowanie występujących stanów silnika, a tym samym dokonanie wstępnej klasyfikacji uszkodzeń. Na dwuwymiarowej siatce Kohonena otrzymano wyraźne zgrupowania neuronów odpowiadających określonym stanom silnika, mimo że dysponowano stosunkowo mało liczną reprezentacją obrazów.

Badania symulacyjne neuronowych detektorów uszkodzeń wykazały dużą skuteczność zastosowanej metody projektowania neurodetektorów, zarówno w przypadku wykrywania liczby uszkodzonych prętów wirnika, jak i oceny stanu łożysk oraz uzwojeń stojana silnika indukcyjnego. Na efektywność działania detektorów uszkodzeń większy wpływ mają jakość i rodzaj wstępnego przetwarzania danych, niż struktura sieci i metoda jej uczenia.

6. Zastosowanie analizy falkowej do wstępnego przetwarzania sygnałów dla neuronowych detektorów uszkodzeń silników indukcyjnych

6.1. Uwagi wstępne

W ostatnich latach nastąpił gwałtowny wzrost zainteresowania zastosowaniem transformaty falkowej do monitorowania i diagnostyki napędów elektrycznych [16, 46, 222, 252, 260, 293]. Wynika to z niedoskonałości metod klasycznych opartych na przekształceniu FFT. Jak zostało to przedstawione w rozdziale 4.4.2, transformata falkowa umożliwia skuteczniejsze wydobycie osobliwych krótkoczasowych cech analizowanych sygnałów. Niestacjonarny charakter tych 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.

Stosując analizę czasowo-częstotliwościową w odniesieniu do sygnałów drganiowych w [252], wykazano przydatność transformaty falkowej do diagnostyki przekładni mechanicznych. Autorzy, na podstawie sygnału drgań, pokazali możliwość wykrywania wczesnego stadium uszkodzeń. Dokonali porównania metod stosowanych w diagnostyce przekładni mechanicznych, wskazali na ograniczenia metod klasycznych i na transformatę falkową jako narzędzie najbardziej efektywne.

Jednym z możliwych rozwiązań jest wykorzystywanie współczynników falkowych do oceny stanu technicznego urządzenia. 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 [117, 252]. To podejście ma jednak pewne wady. Brak jest precyzyjnych wskazówek mówiących, jakie pasma należy analizować i z reguły dobiera się je eksperymentalnie. Kolejne utrudnienie polega na braku obiektywnego sposobu selekcji współczynników. Najczęściej uwzględnia się wszystkie współczynniki albo takie, których wartości 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. W pracy [221] przedstawiono wykorzystanie transformaty falkowej jako narzędzia generującego sygnały klasyfikowane w dalszej obróbce przez sieć neuronową, co umożliwiło wykrywanie pojedynczych i wielokrotnych uszkodzeń łożysk tocznych.

Można również zastosować analizę falkową i jako wskaźnik uszkodzenia przyjąć wzrost wartości współczynników wysokiego pasma częstotliwości występujący wraz z postępującym uszkodzeniem [250]. W publikacji [239] porównano klasyczną metodę analizy obwiedni i analizy falkowej do wykrywania uszkodzeń łożysk tocznych.

Podstawą wykrywania uszkodzeń silników indukcyjnych są sygnały drganiowy i prądu stojana. W pracach [51, 117, 293] przedstawiono możliwości zastosowania analizy falkowej do diagnostyki silników indukcyjnych. Wykazano, że analizując współczynniki poszczególnych węzłów (pasm częstotliwości), można wykryć uszkodzenia wirnika i ekscentryczności przy różnych poziomach obciążenia silnika. Według autorów zaproponowana metoda może być stosowana do silników zasilanych zarówno bezpośrednio z sieci energetycznej, jak i z przemienników częstotliwości. W pracy [134] przedstawiono zastosowanie wielorozdzielczej analizy sygnału do wykrywania uszkodzeń silników małej i dużej mocy. Analiza falkowa stanowi ważną część zaproponowanego systemu diagnostycznego bazującego na pomiarze prądu, napięcia i prędkości obrotowej.

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. Ich amplituda jest jednak zwykle dość mała, często porównywalna z amplitudą szumów występujących w układzie. Transformata falkowa umożliwia wydobywanie informacji o lokalnych anomaliach wskazujących na postępujące uszkodzenia. W publikacji [260] 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.


W dalszej części pracy przedstawiono przykłady zastosowania transformaty falkowej do wykrywania przerw w prętach silnika indukcyjnego oraz uszkodzeń łożysk tocznych [175, 178]. Analizę oparto na pomiarze prądu stojana w jednej fazie, zarejestrowanego podczas pracy przy znamionowym obciążeniu silnika i podczas rozruchu oraz pomiarze przyspieszenia drgań na korpusie silnika. Ponadto zostanie omówiona

możliwość wykorzystania wyników analizy falkowej do uczenia i testowania neuro-nowego detektora uszkodzeń.

6.2. Zastosowanie transformaty falkowej do wykrywania uszkodzeń wirnika

Badania przydatności analizy falkowej do wykrywania uszkodzeń wirników oraz łożysk tocznych przeprowadzono na silniku SSh-90L-4. W przypadku uszkodzeń wirników stopień uszkodzenia określono na podstawie przebiegów wartości chwilowej prądu stojana w stanie ustalonym i w czasie rozruchu bezpośredniego.

W celu wykonania analizy porównawczej zarejestrowano przebiegi prądów o czasie trwania 1 s z częstotliwością próbkowania 10 kHz. Wykonano badania wirnika bez uszkodzonych prętów, jak również z jednym, czterema i ośmioma uszkodzonymi prętami. Przykładowe zarejestrowane przebiegi prądu stojana silnika nieuszkodzonego i silnika z ośmioma uszkodzonymi prętami zamieszczono na rysunku 6.1.



Rys. 6.1. Przebieg prądu stojana silnika nieuszkodzonego (a)
i z uszkodzonymi ośmioma prętami wirnika (b)

Fig. 6.1. Stator currents in sound condition (a)
and for the motor with 8 broken rotor bars (b)

Za pomocą Wavelet Packet Decomposition (WPD) ze środowiska MATLAB [195] przeprowadzono dekompozycję zarejestrowanych sygnałów do poziomu piątego węzła algorytmu przedstawionego w punkcie 4.4.2. Z przyjętego poziomu dekompozycji wynika szerokość pasma częstotliwości węzła, która wynosi 156,25 Hz. Następnie obliczono wartość energii przenoszonej przez każdy węzeł, zgodnie z równaniem (4.23). Wyniki dla piątego poziomu drzewa dekompozycji zgrupowano w tabeli 6.1.

Z analizy danych w niej zawartych wynika, że wielkości energii w wybranych węzłach można jednoznacznie powiązać z liczbą uszkodzonych prętów wirnika. Należy zwrócić uwagę, że nie każdy węzeł zawiera taką informację. Wraz ze wzrostem stopnia uszkodzenia wartość energii zmniejsza się w niektórych zakresach częstotliwości i wzrasta w innych. W tabeli 6.1 zaznaczono szarym tłem węzły niosące informację o wystąpieniu uszkodzenia. Informacja ta może być podstawą oceny diagnostycznej stanu wirnika i zbudowania systemu diagnostycznego np. neuronowego detektora.

Tabela 6.1. Wartości energii węzłów piątego poziomu drzewa dekompozycji w przypadku uszkodzenia wirnika (silnik obciążony znamionowo)


Table 6.1. Energy values of the fifth level of the wavelet decomposition tree for the faulted rotor (rated load of motor)

Liczba uszk. prętów	0	1	2	3	4	5	6	7
0	13e+4	249	3,76	218	1,58	2,51	2,69	5,05
1	13e+4	227	5,24	177	1,23	1,97	3,27	4,16
4	12e+4	331	7,55	133	0,86	1,48	3,60	2,62
8	14e+4	247	4,83	102	0,83	1,21	2,46	2,19
	8	9	10	11	12	13	14	15
0	0,085	0,042	0,04	427e-4	0,237	0,186	0,114	0,03
1	0,027	0,030	0,03	359e-4	0,127	0,140	0,085	0,02
4	0,037	0,020	0,04	251e-4	0,108	0,078	0,062	0,03
8	0,026	0,021	0,02	248e-4	0,106	0,084	0,058	0,04
	16	17	18	19	20	21	22	23
0	94 e-5	9e-4	0,001	7e-4	13 e-4	13e-4	11 e-4	115e-5
1	91e-5	11 e-4	0,001	9e-4	10 e-4	10e-4	10 e-4	107e-5
4	85 e-5	8 e-4	0,001	9e-4	10 e-4	10e-4	8 e-4	99e-5
8	75 e-5	8 e-4	0,001	8e-4	9 e-4	9e-4	10 e-4	99e-5
	24	25	26	27	28	29	30	31
0	0,011	19e-4	13e-4	10 e-4	0,0012	14e-4	10e-4	116e-5
1	0,004	17e-4	14e-4	13 e-4	0,0015	15e-4	17e-4	134e-5
4	0,010	19e-4	13e-4	13 e-4	0,0012	15e-4	20e-4	145e-5
8	0,001	13e-4	14e-4	10 e-4	0,0013	17e-4	22e-4	149e-5


Na rysunku 6.2 przedstawiono porównanie przebiegów składowych prądów stojana (węzły 5.3 i 5.12), uzyskanych w wyniku dekompozycji całkowitego sygnału prądu dla rozpatrywanych przypadków uszkodzeń wirnika. Węzeł 5.3 przedstawia przebieg składowej prądu w przedziale częstotliwości 468,75–625 Hz, a węzeł 5.12 – przebieg składowej prądu w przedziale częstotliwości 1875–2031,25 Hz. Obserwacja zmienności poszczególnych składowych prądów w wybranych przedziałach częstotliwości ułatwia wybór węzłów do dalszej analizy.

Węzeł 5.3


Wirnik zdrowy




1 pręt uszkodzony



4 pręty




8 prętów




Węzeł 5.12


Wirnik zdrowy




1 pręt uszkodzony



4 pręty



8 prętów



Rys. 6.2. Porównanie przebiegów składowych prądu stojana w węzłach 5.3 i 5.12 drzewa dekompozycji sygnału prądu stojana dla różnych stopni uszkodzenia wirnika


Fig. 6.2. Comparison of stator current components in nodes 5.3 and 5.12 of the decomposition tree of stator current signal for different rotor fault levels

W napędach przemysłowych zapewnienie pełnego obciążenia maszyny podczas wykonywania pomiarów diagnostycznych, takich jak wymagają klasyczne metody, może być w niektórych przypadkach kłopotliwe. Z tego powodu wydaje się istotna możliwość przeprowadzenia analizy dla stanu dynamicznego nieobciążonego silnika. Sprawdzone, czy możliwe jest wykrywanie uszkodzeń maszyny na podstawie prądu rozruchowego.

Podczas rozruchu nieobciążonego silnika rejestrowano prąd stojana w czasie 0,4 s z częstotliwością próbkowania 10 kHz, przy różnych stopniach uszkodzenia wirnika (0, 1, 4, 8 uszkodzonych prętów). Podobnie jak w poprzednim przypadku, przyjęto pięć poziomów dekompozycji. Przykładowe przebiegi prądu rozruchowego wirnika „zdrowego” i uszkodzonego pokazano na rysunku 6.3, a w tabeli 6.2 przedstawiono wartości energii przenoszonej przez każdy węzeł transformaty na piątym poziomie dekompozycji.

Tabela 6.2. Wartości energii węzłów piątego poziomu drzewa dekompozycji w przypadku uszkodzenia wirnika (rozruch silnika nieobciążonego)
Table 6.2. Energy values of the fifth level of the wavelet decomposition tree for the faulted rotor (starting of unloaded motor)

Liczba uszkodz. prętów	0	1	2	3	4	5	6	7
0	34+4	1373	26,0	178	0,434	2,60	6,241	4,1736
1	33+4	1375	24,3	127	0,518	1,97	5,949	4,7968
4	32+4	928	11,9	166	0,203	1,44	2,963	3,4989
8	29e+4	620	8,4	90	0,566	1,38	5,422	3,6439
	8	9	10	11	12	13	14	15
0	312e-4	0,056	0,109	0,077	0,431	0,42	0,274	0,2204
1	209e-4	0,030	0,099	0,047	0,228	0,18	0,134	0,1648
4	392e-4	0,018	0,054	0,049	0,28	0,20	0,169	0,17
8	216e-4	0,020	0,057	0,048	0,109	0,07	0,082	0,0895
	16	17	18	19	20	21	22	23
0	47e-4	0,008	0,011	41e-4	0,018	0,012	0,008	0,0163
1	26e-4	0,002	0,004	35e-4	0,006	0,005	0,001	0,0054
4	98e-4	0,005	0,010	53e-4	0,015	0,014	0,007	0,0078
8	23e-4	0,002	0,002	33e-4	0,004	0,004	0,003	0,0029
	24	25	26	27	28	29	30	31
0	307e-4	0,027	290e-4	0,014	123e-4	152e-4	0,018	0,0180
1	259e-4	0,022	164e-4	0,022	111e-4	114e-4	0,018	0,0133
4	204e-4	0,025	95e-4	0,015	61e-4	98e-4	0,019	0,0137
8	91e-4	0,005	56e-4	0,004	33e-4	38e-4	0,005	0,0068



Rys. 6.3. Przebieg prądu rozruchowego silnika nieuszkodzonego (a) i silnika z uszkodzonymi ośmioma prętami wirnika (b)

Fig. 6.3. Starting stator currents in the sound condition (a) and for the motor with 8 broken rotor bars (b)

Z analizy tabeli 6.2 wynika, że wartości energii w poszczególnych węzłach istotnie zależą od stopnia uszkodzenia wirnika. Węzły, w których wartość energii znacznie zmienia się wraz ze stopniem uszkodzenia, zostały wyróżnione szarym tłem.


Tak więc, na podstawie zmian poziomu energii w wybranych węzłach można klasyfikować stopień uszkodzenia wirnika.

6.3. Zastosowanie transformaty falkowej do wykrywania uszkodzeń łożysk tocznych

Aby wykazać przydatność analizy falkowej do wykrywania uszkodzeń łożysk tocznych, rozpatrzono przypadek uszkodzenia bieżni zewnętrznej. Sygnały drgań silnika na biegu jałowym zarejestrowano w czasie 1 s z częstotliwością próbkowania 1 kHz (rys. 6.4).

Badane łożyska miały różny stopień celowo wprowadzonego uszkodzenia: ogólne zniszczenie bieżni (a), dwa szerokie nacięcia w bieżni (b), szerokie nacięcie w bieżni (c), wąskie nacięcie w bieżni (d), łożysko nieuszkodzone (e). Przeprowadzono kolejno dekompozycję sygnału drgań do poziomu piątego. Szerokość rozpatrywanego pasma częstotliwości wynosiła 15,625 Hz. Na podstawie równania (4.23) wyznaczono ilość energii przenoszanej przez każde z pasm. Wyniki podano w tabeli 6.3.

Analizując wartości zestawione w tabeli 6.3, można zauważyć duży rozrzut wartości energii przenoszanej przez poszczególne węzły dla tego samego stopnia uszkodzenia. Wynika to z nakładania się zakłóceń na sygnał użyteczny w procesie rejestracji.



Rys. 6.4. Sygnał czasowy drgań łożysk o różnym stopniu uszkodzenia; rozwój stopnia zniszczenia łożyska od (a) nieuszkodzone do (e) bardzo uszkodzone
Fig. 6.4. Time-domain signal of vibrations for bearings with various damage size; development of bearing fault from healthy (a) to seriously damaged (e) bearings

Tabela 6.3. Wartości energii węzłów piątego poziomu drzewa dekompozycji
w przypadku uszkodzenia łożysk silnika indukcyjnego


Table 6.3. Energy values of the fifth-level nodes of the wavelet decomposition tree
for the broken IM bearings

Stopień uszkodzenia	0	1	2	3	4	5	6	7
1	4	0,72	0,28	0,58	1,92	7,91	0,65	19,3
2	140	0,34	0,10	0,14	0,47	0,18	0,08	0,12
3	730	0,32	0,10	0,27	0,41	0,26	0,15	0,24
4	36	0,48	0,09	0,15	0,09	0,13	0,11	0,15
5	37	0,31	0,17	0,26	0,08	0,21	0,05	0,12
	8	9	10	11	12	13	14	15
1	1,70	2,36	6,25	2,09	0,88	1,80	7,26	5,24
2	0,80	0,86	0,56	1,20	0,25	0,43	0,58	0,31
3	0,42	0,65	0,96	1,37	0,36	0,29	0,62	0,27
4	0,33	0,45	0,16	0,37	0,10	0,20	0,15	0,20
5	0,17	0,46	0,38	0,38	0,10	0,26	0,19	0,30
	16	17	18	19	20	21	22	23
1	0,51	0,888	3,07	2,07	1,67	4,97	1,67	3,34
2	2,50	0,311	1,00	0,46	41,7	4,50	1,17	2,21
3	0,92	0,156	1,09	0,39	20,5	3,91	0,97	2,30
4	0,45	0,073	0,17	0,11	2,13	1,95	0,21	0,94
5	0,44	0,055	0,04	0,10	2,57	2,28	0,19	1,32
	24	25	26	27	28	29	30	31
1	2,56	3,82	6,59	3,31	4,43	15,7	7,42	12,2
2	1,74	0,97	3,03	2,85	10,4	11,8	4,05	4,99
3	0,33	0,66	1,80	3,25	10,9	7,61	2,51	2,61
4	1,40	0,44	0,63	1,46	1,62	3,85	1,73	2,90
5	0,25	0,44	0,78	1,51	3,08	3,12	1,18	4,12

Podobnie jak dla sygnału prądu, na rysunku 6.5 przedstawiono porównanie przebiegów sygnałów składowych przyspieszenia drgań w węźle 5.30 dla różnych stopni uszkodzenia łożyska. Również w tym przypadku, na podstawie przebiegów zrekonstruowanych sygnałów drgań, można ocenić stopień uszkodzenia.

Natomiast na rys. 6.6 przedstawiono te same składowe sygnały przyspieszenia drgań obserwowane w dłuższym przedziale czasu (10 sekund), przy tej samej częstotliwości próbkowania. Można zauważyć, że podczas dłuższej obserwacji lepiej widoczne są charakterystyczne zmiany składowych w zależności od stopnia uszkodzenia. W przebiegach składowych w węźle widoczny jest duży wpływ zakłóceń związanych z sygnałem drganiowym (co było również widoczne na rys. 6.4).

Węzeł 5.30








Rys. 6.5. Porównanie składowych sygnału przyspieszenia drgań w węźle 5.30 drzewa dekompozycji dla różnych stopni uszkodzenia łożysk (oraz przedziale obserwacji 1 s)

Fig. 6.5. Comparison of the vibration signal components (acceleration) in node 5.30 of the decomposition tree on different bearing fault levels and in measurement period of 1 s

Węzeł 5.30

Łożysko nieuszkodzone

Łożysko lekko uszkodzone
(wąskie nacięcia w bieżni)Łożysko uszkodzone
(1 szerokie nacięcia w bieżni)Łożysko znacznie uszkodzone
(2 szerokie nacięcia w bieżni)Łożysko bardzo uszkodzone
(ogólne zniszczenie łożyska)


Rys. 6.6. Porównanie składowych sygnału przyspieszenia drgań w węźle 5.30 drzewa dekompozycji dla różnych stopni uszkodzenia łożysk w przedziale obserwacji 10 s

Fig. 6.6. Comparison of the vibration signal components (acceleration) in node 5.30 of the decomposition tree on different bearing fault levels and in measurement period of 10 s

Na sygnał drgań łożyska nakładają się zakłócenia, które zmieniają wartość energii przenoszonej przez sygnał podstawowy. Stwarza to możliwość popełnienia błędów w przypadku układów diagnostycznych opartych na klasycznych metodach wnioskowania. Z tego powodu zastosowanie sztucznych sieci neuronowych wydaje się jak najbardziej wskazane ze względu na większą odporność na zakłócenia.

6.4. Neuronowe detektory uszkodzeń wirnika i łożyska

Do wykazania przydatności analizy falkowej w projektowaniu neuronowych detektorów uszkodzeń wykorzystano przedstawione w rozdziale 6.3 przypadki uszkodzenia wirnika i zewnętrznej bieżni łożyska. Na rysunku 6.7 przedstawiono schemat systemu diagnostycznego opartego na analizie falkowej i sieci neuronowej.




Rys. 6.7. Schemat ideowy systemu diagnostycznego

Fig. 6.7. Schematic diagram of the diagnostic system

W bloku pierwszym następuje pomiar sygnału diagnostycznego. Blok ten składa się z odpowiedniego czujnika (prądu bądź drgań) układu pomiarowego. Sygnałem wyjściowym bloku jest sygnał cyfrowy, który w kolejnym bloku jest przetwarzany za pomocą falkowej dekompozycji sygnału (ang. *Wavlet Packet Decomposition*) oraz obliczana jest wartość energii przenoszonej przez każde pasmo. W bloku trzecim następuje wybór odpowiednich pasm analizowanego sygnału, przenoszących informację o szukanym uszkodzeniu. Wartość energii przenoszonej przez wybrane pasma jest następnie podawana na blok wnioskowania. Zawiera on system klasyfikujący stopień uszkodzenia na podstawie wektora wejściowego. System ten jest oparty na metodach sztucznej inteligencji (sieci neuronowe, logika rozmyta). Wyjściem bloku wnioskowania jest liczba określająca stopień uszkodzenia danego elementu. Tak opracowany system diagnostyczny pozwala na ocenę stanu uszkodzenia wybranych elementów silnika indukcyjnego.

Opracowano i przebadano różne struktury neuronowych detektorów uszkodzeń wirnika i łożysk. W przypadku uszkodzeń wirnika opracowano detektor neuronowy o strukturze 2-13-1 mający dwa wejścia, którymi są wartości energii przenoszonej przez 3 i 12 węzeł 5 poziomu dekompozycji. Sieci zostały wytrenowane zestawem czterdziestu próbek uczących i przetestowane podobną liczbą próbek. Na rysunku 6.8

przedstawiono wyniki testowania neuronowego detektora uszkodzeń klatki wirnika, trenowanego danymi zebranymi przy obciążeniu znamionowym. Liczba poprawnych odpowiedzi wynosiła około 91%.



Rys. 6.8. Wyniki testowania neuronowego detektora uszkodzeń klatki wirnika przy obciążeniu znamionowym

Fig. 6.8. Testing results of the rotor fault neural detector under the nominal load

Podczas testowania tej sieci danymi zebranymi przy pracy silnika obciążonego połową momentu znamionowego liczba poprawnych odpowiedzi wynosiła około 86%.

W przypadku detektora uszkodzeń łożyska zastosowano sieć neuronową o strukturze 3-5-4-1, dobraną metodą kolejnych prób. Neuronowy detektor uszkodzeń ma trzy wejścia, którymi są wartości energii przenoszonej przez węzły 22., 29. i 30. Węzły te zostały wybrane jako najbardziej charakterystyczne dla uszkodzenia bieżni łożyska (tabela 6.3). Sieć wytrenowano metodą wstecznej propagacji błędów za pomocą zestawu czterdziestu próbek uczących, zestawionych w tabeli 6.4. Stopnie uszkodzenia łożysk określono od 100%, dla łożyska bardzo uszkodzonego, do 10% dla łożyska niewykazującego widocznych uszkodzeń.

W tabeli 6.5 zestawiono wartości próbek testujących neuronowy detektor uszkodzeń, a jego odpowiedzi zamieszczono w tabeli 6.6. Sieć neuronowa popełniła tylko w jednym przypadku błąd w określeniu stopnia uszkodzenia łożyska. Łożysko o du-

zym stopniu uszkodzenia (75%) zostało zakwalifikowane jako bardzo uszkodzone (100%). W pozostałych przypadkach system diagnostyczny poprawnie wskazywał stan badanego łożyska. Odpowiedzi detektora wykazują najczęściej minimalne odchylenia od wartości oczekiwanej.

Tabela 6.4. Wartości próbek uczących sieć neuronową
Table 6.4. Training values for neural network

Nr próbki	1	2	3	4	5	6	7	8	9	10
Węzeł 22	1,645	0,8228	0,7391	0,2525	0,1771	1,6775	1,174	0,9713	0,2149	0,1904
Węzeł 29	14,005	12,963	6,4188	4,266	3,4009	15,746	11,828	7,6168	3,8547	3,1235
Węzeł 30	6,3148	3,4712	1,3366	0,9740	1,2936	7,4288	4,0537	2,5106	1,7344	1,1863
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%
Nr próbki	11	12	13	14	15	16	17	18	19	20
Węzeł 22	1,9703	0,8726	1,0664	0,0914	0,5596	1,4072	1,1149	0,8543	0,1298	0,6096
Węzeł 29	12,992	11,373	7,6715	5,8885	7,1324	5,9061	9,8024	8,2323	5,1072	7,1947
Węzeł 30	9,3905	2,5922	1,2106	1,1604	5,2373	8,5613	1,8173	1,4132	1,0945	7,2649
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%
Nr próbki	21	22	23	24	25	26	27	28	29	30
Węzeł 22	1,3441	0,6302	1,3792	0,2556	0,2033	0,7667	0,7108	0,6767	0,0920	0,1076
Węzeł 29	6,7246	8,1972	7,3225	4,0331	4,4327	8,6413	7,8249	6,9335	2,461	1,3599
Węzeł 30	7,8571	2,6776	2,5162	0,6757	4,9172	7,1095	4,0292	1,6608	0,5514	0,5055
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%
Nr próbki	31	32	33	34	35	36	37	38	39	40
Węzeł 22	1,1136	0,4454	1,0398	0,1058	0,1057	1,9257	0,6347	0,6833	0,1262	0,1224
Węzeł 29	8,7925	8,6581	7,5495	1,3593	2,688	7,345	7,9012	5,2753	0,8097	1,1067
Węzeł 30	6,0765	3,0018	4,124	0,4989	0,7932	7,7319	2,3291	1,3188	0,6105	0,4242
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%

Neuronowy detektor uczony odpowiednio dużą liczbą wzorców, przy prawidłowym wyborze charakterystycznych pasm sygnału, odpowiada więc prawidłowo, pomimo że sygnały pomiarowe drgań mechanicznych silnika zawierają dużą ilość zakłóceń.

Tabela 6.5. Wartości próbek testujących sieć neuronową
Table 6.5. Testing values for neural network

Nr próbki	1	2	3	4	5	6	7	8	9	10
Węzeł 22	1,2473	0,6299	0,7042	0,0873	0,08301	1,2495	0,50346	1,6001	0,0792	0,1321
Węzeł 29	8,7394	6,9728	5,2118	0,9782	0,6519	9,1458	6,069	5,7199	1,3861	1,1641
Węzeł 30	8,7925	3,1698	1,7337	0,3817	0,38459	5,2432	3,6214	1,9374	0,2453	0,4577
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%
Nr próbki	11	12	13	14	15	16	17	18	19	20
Węzeł 22	0,9179	2,276	0,9921	0,4499	0,28482	1,0692	0,5168	1,1181	0,2018	0,1332
Węzeł 29	7,5922	8,2256	5,7251	2,6968	3,3152	5,2154	6	5,1699	3,6278	3,7217
Węzeł 30	7,8145	7,6928	1,6754	1,0942	0,65687	6,3178	1,9024	0,97206	1,3764	1,8402
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%
Nr próbki	21	22	23	24	25	26	27	28	29	30
Węzeł 22	1,4384	0,7858	1,3422	0,2319	0,16918	1,9988	0,45763	1,4123	0,0856	0,1243
Węzeł 29	7,0229	8,4779	4,6066	3,5687	1,5466	13,058	11,652	5,6985	1,9453	2,9093
Węzeł 30	5,0992	2,7974	1,9088	0,8258	0,5259	6,1437	2,9242	2,4469	0,6471	1,3407
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%
Nr próbki	31	32	33	34	35	36	37	38	39	40
Węzeł 22	2,2668	0,6844	0,9742	0,0916	0,18371	2,5774	0,37247	1,4296	0,0714	0,08809
Węzeł 29	6,6994	13,98	6,1452	2,2765	3,1941	10,156	9,358	4,9701	3,3533	0,91386
Węzeł 30	7,3515	3,0136	1,1984	0,4489	1,9623	8,2174	2,5497	1,0273	0,6444	0,95809
Stop. uszk.	100%	75%	50%	25%	10%	100%	75%	50%	25%	10%

Tabela 6.6. Odpowiedzi neuronowego detektora uszkodzeń łożysk
Table 6.6. Responses of neural detector of bearing faults

Wartość oczekiwana	Nr pr. 1-5	Nr pr. 6-10	Nr pr. 11-15	Nr pr. 16-20	Nr pr. 21-25	Nr pr. 26-30	Nr pr. 31-35	Nr pr. 36-40
1,000	0,9723	0,9723	0,9723	0,9723	0,9723	0,9723	0,9723	0,9723
0,7500	0,7500	0,7500	0,9723	0,7496	0,7500	0,7500	0,7500	0,7500
0,5000	0,5066	0,4991	0,4991	0,4991	0,4991	0,4991	0,4991	0,4991
0,2500	0,2492	0,2496	0,2500	0,2489	0,2500	0,2497	0,2519	0,2506
0,1000	0,1000	0,1000	0,1000	0,0994	0,1023	0,0994	0,1002	0,0994

6.5. Podsumowanie

Wstępne badania laboratoryjne wykazały dużą skuteczność analizy falkowej zarówno w wykrywaniu liczby uszkodzonych prętów wirnika, jak i w ocenie stanu łożysk. W porównaniu do klasycznej metody FFT, metoda diagnostyki z wykorzystaniem przekształcenia falkowego wymaga znacznie krótszego czasu rejestracji sygnału

pomiarowego, co jest jej ważną zaletą. W metodzie klasycznej czas rejestracji sygnału musi być znacznie dłuższy w celu zapewnienia wymaganej rozdzielczości w dziedzinie częstotliwości. Występujące w tym czasie zmiany obciążenia powodują zmiany w widmach, co prowadzi do przekłamań w układzie diagnostycznym. Kolejną zaletą transformaty falkowej jest możliwość przeprowadzenia diagnostyki na podstawie pomiarów stanu przejściowego, w czasie rozruchu silnika. Transformata falkowa ma również pewne wady. Numer węzła niosącego w sobie informacje o występującym uszkodzeniu jest wyznaczony eksperymentalnie, podobnie jak poziom energii odpowiadającej poszczególnym stanom. W niektórych węzłach związek na przykład między liczbą uszkodzonych prętów a poziomem energii jest niewielki. Dodatkowo zakłócenia pomiarowe zmieniają wartości energii przenoszonej przez dane pasmo dla danego typu uszkodzenia. Problemem jest również brak metod doboru skali analizowanego sygnału oraz wskazówek dotyczących wyboru pasma analizowanej częstotliwości. Powoduje to istotne utrudnienie w postawieniu prawidłowej diagnozy. Dlatego połączenie zalet transformaty falkowej z możliwościami metod sztucznej inteligencji (klasycznymi lub rozmytymi sieciami neuronowymi) przez wykorzystanie informacji zawartych w wybranych węzłach drzewa dekompozycji znacznie zwiększa przydatność analizy falkowej w monitorowaniu i diagnostyce maszyn elektrycznych.

Jak wykazały przeprowadzone badania, zastosowanie neuronowego detektora typu perceptron wielowarstwowy jest rozwiązaniem bardzo skutecznym z punktu widzenia diagnostyki. Perceptronowy klasyfikator uczony stosunkowo dużą liczbą wzorców, udzielał prawie bezbłędnych odpowiedzi na równie dużą liczbę danych testujących.

7. Modele laboratoryjne neurodetektorów uszkodzeń silników indukcyjnych

7.1. Uwagi wstępne

Przedstawione w rozdziale 5 propozycje struktur neuronowych detektorów uszkodzeń stojana, wirnika i łożysk tocznych zostały wszechstronnie przetestowane w komputerowych symulatorach sztucznych sieci neuronowych. Testowanie zrealizowano na rzeczywistych danych eksperymentalnych w trybie off-line w środowisku programowym MATLAB [58]. 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 opartych na sztucznej inteligencji, zdolnymi do przetwarzania dużej liczby danych do celów diagnostycznych (klasyfikowanie i ocena symptomów).

W ramach prowadzonych badań przetestowano wstępne laboratoryjne wersje neurodetektorów uszkodzeń silnika indukcyjnego, a w niniejszym opracowaniu przedstawiono niektóre z otrzymanych wyników. Zadaniem testów laboratoryjnych było sprawdzenie, czy na obecnym poziomie rozwoju techniki mikroprocesorowej możliwa jest programowa realizacja struktur neuronowych, ocena związanych z tym kosztów oraz odporność na zakłócenia.


Na podstawie przeprowadzonych badań laboratoryjnych sformułowano ogólne wnioski o możliwości i celowości realizacji wersji przemysłowej.

Przyjęto następujące założenia wyjściowe:

- 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° Działanie klasyfikujące i oceniające oparte będzie na sygnałach wejściowych otrzymanych z bloku wyodrębniania symptomów uszkodzeń, którego działanie opisane jest klasycznymi metodami detekcji uszkodzeń (rozdział 3).

4° Neurodetektor powinien działać prawidłowo w szerokim zakresie zmian obciążenia i temperatury oraz być odporny na zakłócenia.

Na rysunku 7.1 przedstawiono schemat ideowy pełnej struktury neurodetektora. Zoptymalizowane struktury neuronowe, otrzymane i przetestowane w symulatorach sieci neuronowych, stanowiły podstawę do opracowania oprogramowania w języku wyższego rzędu (C lub Delphi). Zgodnie ze strukturą z rys. 7.1, do prawidłowego działania neurodetektora niezbędny jest moduł preprocesingu, który dokonuje wyodrębnienia sygnałów wejściowych podawanych na sieć neuronową. Z punktu widzenia poprawnego działania funkcji monitorowania i diagnostyki, moduł ten ma podstawowe znaczenie, przy założeniu, że neuronowy detektor został dobrze nauczony.



Rys. 7.1. Schemat ideowy struktury neurodetektora uszkodzeń

Fig. 7.1. Schematic diagram of neural fault detector

Dlatego oprogramowanie realizujące funkcje modułu preprocesingu ma duży wpływ na efekt końcowy działania neurodetektora. Ta część oprogramowania składa się z:

- bloku sterującego pomiarami (interfejs pomiarowy i obsługa przetworników A/C),
- bloku analizatora widmowego FFT,
- bloku ekstrakcji harmoniczných charakteryzujących uszkodzenia,
- bloku interfejsu operatora do komunikacji i wizualizacji.

Obecny stan techniki mikroprocesorowej umożliwia realizację sztucznej sieci neuronowej w sposób programowy w komputerach ogólnego przeznaczenia (klasy PC) lub w procesorach sygnałowych (kontrolery DSP).

Łącząc oprogramowanie realizujące algorytm wytrenowanej sieci neuronowej z oprogramowaniem uniwersalnej karty pomiarowej i analizatora sygnałów, można otrzymać programową wersję neuronowego detektora wybranych uszkodzeń, zbudowanego na bazie komputera klasy PC wyposażonego w odpowiednią kartę pomiarową. Taki sposób realizacji neuronowego detektora uszkodzeń silnika indukcyjnego przedstawiono szczegółowo w publikacjach [176, 177, 219]. Na podstawie przeprowadzonych testów działania on-line neurodetektora wykazano jego dużą skuteczność przy małych kosztach inwestycyjnych, sprzętowych i programowych.


Ten sposób realizacji praktycznej neurodetektora nie będzie przedmiotem dalszych rozważań w niniejszej pracy.

Drugi sposób realizacji technicznej neurodetektora wykorzystuje możliwości uniwersalnego kontrolera DSP, wyposażonego w szybkie układy pomiarowe oraz duże możliwości obliczeniowe procesora sygnałowego. W badaniach zastosowano kontroler DSP firmy dSPACE typu DS1102. Oprogramowanie realizujące algorytmy preprocesingu oraz detektora neuronowego opracowano w języku C. Dla ułatwienia obsługi i obserwacji działania neurodetektora został opracowany interfejs pomiarowy i wizualizacyjny za pomocą specjalnego oprogramowania firmy dSPACE dla kontrolera DS1102, tzw. Control Desk [300].

Badaniom testowym poddano działanie neurodetektorów uszkodzeń wirników i łożysk tocznych.

7.2. Neurodetektor uszkodzeń wirników klatkowych

Neuronowy detektor uszkodzeń wirnika był testowany w kilku wariantach. Najprostszy wariant (struktura według rys. 5.10) zakładał, że detekcja realizowana jest na podstawie znajomości tylko amplitud podstawowych harmoniczných „poślizgowych” f_{p1} i f_{p2} . Na rysunku 7.2 przedstawiono zestawienie wyników badań testowych zrealizowanych na stanowisku laboratoryjnym, przy obciążeniu znamionowym. Symbolem „o” oznaczono oczekiwaną odpowiedź detektora, a symbolem „+” oznaczono rzeczywistą odpowiedź. W każdym analizowanym przypadku stopnia uszkodzenia wirnika detektor pracował on-line i co zadany okres czasu (5–10 minut) podawał aktualną informację o stanie silnika.



Rys. 7.2. Zestawienie wyników testów on-line neurodetektora uszkodzeń wirnika (struktura wg rys. 5.10); $M_{obc} = M_N$

Fig. 7.2. Setting-up of on-line test results of rotor fault neurodetector (structure according to Fig. 5.10); $M_{load} = M_N$


Sieć neuronowa każdorazowo poprawnie wykrywała uszkodzenie, ale nie zawsze trafnie udzielała odpowiedzi na temat stopnia uszkodzenia. Neuronowemu detektorowi zdarzały się pomyłki, np. mylił pięć uszkodzonych prętów z czterema lub trzy pręty z dwoma. Należy zauważyć, że przy dużych uszkodzeniach (8 prętów) odpowiedzi były prawidłowe.

Liczba mylnych ocen stopnia uszkodzenia wirnika wzrastała wraz ze zmniejszeniem się momentu obciążenia silnika. Przykładowo, dla $M_{obc} = 0,5 M_N$ wzrost błędnych odpowiedzi wynosił około 30%. Należy jednak zauważyć, że błąd dotyczył jedynie oceny stopnia uszkodzenia i z reguły wynosił ± 1 pręt wirnika.

Badaniom testowym na obiekcie rzeczywistym poddano również bardziej złożone struktury neuronowych detektorów uszkodzeń wirników. Między innymi detektor o strukturze (5-9-7-1) składający się z dwóch sieci jednowyjściowych (rys. 5.12). Na rysunku 7.3 przedstawiono widok okna programu detektora uszkodzeń wirnika. Detektor podaje na wyjściu dwie informacje: rodzaj uszkodzenia oraz liczbę pękniętych prętów. Dodatkowo detektor wyposażony jest w diodę sygnalizacyjną, która zmienia kolor w zależności od stopnia uszkodzenia. Dla wirnika zdrowego dioda ma kolor zielony, dla uszkodzonych 1-4 prętów dioda świeci na pomarańczowo, a dla uszkodzenia powyżej 5 prętów – dioda świeci się na czerwono.


Wyniki badań testowych na obiekcie rzeczywistym przedstawiono na rysunku 7.4. Jak wynika z tego rysunku, detektor również w tym przypadku idealnie rozróżnia

przypadek „zdrowego” wirnika, natomiast popełnia czasami błąd w oszacowaniu liczby uszkodzonych prętów.



Rys. 7.3. Widok panelu wirtualnego neuronowego detektora uszkodzeń wirników klatkowych (w trakcie badania wirnika z dwoma uszkodzonymi prętami)

Fig. 7.3. View of the virtual panel of the rotor fault neural detector (during testing the rotor with two broken bars)



Rys. 7.4. Zestawienie wyników testów on-line neurodetektora uszkodzeń wirnika – wyjście określające liczbę uszkodzonych prętów (struktura 5-9-7-1); $M_{obc} = M_N$


Fig. 7.4. Setting-up of on-line test results of rotor fault neurodetector – number of broken rotor bars at the output (structure 5-9-7-1); $M_{load} = M_N$

Błąd ten nie przekracza ± 2 prętów, co z praktycznego punktu widzenia nie ma większego znaczenia. Znacznie gorzej jest z prawidłowym określeniem przez sieć neuronową układu uszkodzonych prętów (tzw. rodzaj uszkodzenia) – liczba poprawnych odpowiedzi wynosiła około 65%. W omawianym przypadku, podobnie jak poprzednio, uzyskano poprawne działanie detektora przy zmianach momentu obciążenia do ok. $0,5 M_N$.

7.3. Neurodetektor uszkodzeń łożysk tocznych

Badaniom testowym na obiekcie rzeczywistym poddano neurodetektor zrealizowany według struktury przedstawionej na rys. 5.36, umożliwiającej określenie, który z elementów składowych łożyska jest aktualnie sprawny lub uszkodzony.

Na rysunku 7.5 przedstawiono widok ekranu z panelem wirtualnym neuronowego detektora uszkodzeń łożysk tocznych, realizowanego w kontrolerze DS1102 i komputerze klasy Pentium III.



Rys. 7.5. Widok ekranu z panelem wirtualnym neuronowego detektora uszkodzeń łożysk (podczas badania łożyska z uszkodzoną bieżnią zewnętrzną)

Fig. 7.5. View of the virtual panel of the bearing fault neural detector (during testing the bearing with damaged outer race)

Panel zawiera po lewej stronie siedem okienek informujących o wartościach amplitud częstotliwości uszkodzeniowych wyselekcjonowanych na podstawie widma

sygnału przyspieszenia drgań. Po prawej stronie znajdują się diody sygnalizujące uszkodzenie bieżni zewnętrznej, wewnętrznej oraz kulki. Kolor zielony oznacza brak uszkodzenia, a kolor czerwony – uszkodzenie. W razie wystąpienia uszkodzenia uaktywnia się dioda alarmowa (miga w kolorze czerwonym).

Podobnie jak w badaniach przeprowadzonych w komputerowym symulatorze sieci neuronowych (ale na podstawie danych z eksperymentów na obiekcie rzeczywistym), poprawne działanie neurodetektora jest bardzo silnie uzależnione od poprawnego wyodrębnienia amplitud częstotliwości charakteryzujących uszkodzenia elementów łożysk, tzn. f_k , f_{bz} i f_{bw} oraz ich harmonicznych. Harmoniczne te (rozdział 3.5) mają stosunkowo małe amplitudy w porównaniu z innymi widocznymi w klasycznym widmie drganiowym i prądowym [173]. Tak więc, możliwe jest popełnienie znacznych błędów w określaniu wartości amplitud częstotliwości charakteryzujących uszkodzenia łożyska. Dlatego w przeprowadzanych badaniach testowych zastosowano łożyska, w których konkretny rodzaj uszkodzenia występował w bardzo silnym stopniu, co znacznie ułatwiało rozpoznanie uszkodzenia. W praktyce uszkodzenie będzie miało charakter bardziej „rozmyty” i z reguły będzie obejmowało jednocześnie kilka elementów łożyska. Dlatego wydaje się, że w dalszych pracach nad rozwojem detektorów uszkodzeń łożysk do analizy częstotliwościowej powinno się stosować metodę specjalnie ukierunkowaną na łożyska, np. metodę analizy obwiedni [161, 173, 174] lub analizę falkową [175, 178].

Łożyska testowe przebadane w neuronowym detektorze uszkodzeń zostały poprawnie sklasyfikowane. Na pięć testowanych łożysk z silnymi uszkodzeniami kulki i bieżni, detektor nie popełnił błędu. Jednakże łożyska z uszkodzeniem o charakterze ogólnym (silnie wyeksploatowane) sprawiały detektorowi neuronowemu trudności z postawieniem diagnozy odnośnie uszkodzenia konkretnego elementu i często były klasyfikowane jako „zdrowe”. Na cztery testowane łożyska wyeksploatowane, trzy odpowiedzi były błędne. Dlatego wydaje się, że docelowo powinno się realizować przede wszystkim detektory dokonujące ogólnej oceny stanu łożyska, a nie ukierunkowane na uszkodzenia jego elementów składowych.

7.4. Podsumowanie

Na podstawie przeprowadzonych badań testowych neurodetektorów w czasie ich pracy on-line na rzeczywistym silniku, do którego wprowadzane były uszkodzane wirniki lub łożyska, można stwierdzić, że:

- wykazały się one prawidłowym działaniem w szerokim zakresie zmian uszkodzeń oraz obciążenia silnika;
- na prawidłowe działanie neurodetektorów ma bardzo duży wpływ jakość danych wejściowych otrzymywanych w wyniku preprocesingu on-line sygnałów

mierzonych bezpośrednio na obiekcie. Dotyczy to przede wszystkim analizy FFT oraz prawidłowego wyodrębniania częstotliwości charakterystycznych i określania ich amplitud (ekstrakcji symptomów);

- aplikacje zrealizowane przy pomocy kontrolerów DSP mogą być z powodzeniem przeniesione na znacznie prostsze (a tym samym i znacznie tańsze) systemy monitorująco-diagnostyczne oparte na kartach pomiarowych i komputerach klasy PC [176, 219];
- aby uzyskać wiarygodne i odporne działanie neurodetektorów, konieczne jest zastosowanie do ich uczenia i testowania dużej liczby wzorców;
- niezbędne są dalsze prace nad stworzeniem systemu wyposażonego w neurodetektory wykrywające uszkodzenia wszystkich elementów silnika.

8. Uwagi i wnioski końcowe

Nowoczesne zautomatyzowane procesy produkcyjne wymagają stosowania coraz bardziej skomplikowanych urządzeń, w tym również układów elektromechanicznych i 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 szybkiej detekcji i lokalizacji uszkodzeń oraz związanej z tym oceny stanu technicznego obiektu mają duże znaczenie praktyczne.

We współczesnych układach napędowych, zwłaszcza dużej mocy, ważne jest stosowanie systemów do monitorowania i diagnostyki eksploatacyjnej na bieżąco, w czasie rzeczywistym. Systemy te powinny dostarczać operatorowi i projektantowi ekstremalnie użytecznej informacji o stanie technicznym maszyny i napędu, a w razie stwierdzenia uszkodzenia, określenie jego rodzaju, miejsca i zakresu. Poprzez ciągłe monitorowanie stanu technicznego otrzymuje się informację o różnych uszkodzeniach we wczesnym stanie ich powstawania, co prowadzi do istotnej redukcji kosztów obsługi technicznej oraz umożliwia znalezienie optymalnych metod i programów remontów.

W eksploatacji napędów elektrycznych z silnikami indukcyjnymi dominują obecnie metody monitorowania i diagnostyki oparte na kontroli i analizie sygnałów. Wykorzystują one pomiary wybranych wielkości fizycznych i porównanie ich lub parametrów na ich podstawie obliczonych z wartościami granicznymi i trendami. Obserwuje się natomiast ograniczony zasięg zastosowań metod diagnostyki opartych na określaniu aktualnego stanu technicznego obiektu na podstawie modeli matematycznych oraz metod wykorzystujących sztuczną inteligencję.

Metody oparte na modelu matematycznym są bardzo wrażliwe na adekwatność zastosowanych modeli, zakłócenia pomiarowe oraz podczas realizacji w czasie rzeczywistym wymagają dużych mocy obliczeniowych. Dlatego obecnie intensywnie są rozwijane metody wykorzystujące sztuczne sieci neuronowe, logikę rozmytą oraz systemy ekspertowe.

Ponieważ ta grupa metod monitorowania i diagnostyki wiąże się ciągle jeszcze z wieloma nierozwiązanymi problemami realizacyjnymi, Autor w swojej działalności

naukowej od kilku lat prowadził badania, których celem było opracowanie efektywnych metod diagnozowania uszkodzeń silników indukcyjnych za pomocą sztucznych sieci neuronowych.

Literatura dotycząca stosowania metod sztucznej inteligencji do monitorowania i diagnostyki układów napędowych z silnikami indukcyjnymi jest ograniczona liczbowo i problemowo oraz obejmuje w zasadzie prace z ostatnich dziesięciu lat. Brakuje jednolitego ujęcia tych zagadnień a prezentowane neuronowe detektory poszczególnych rodzajów uszkodzeń wykorzystują standardowe symptomy diagnostyczne, najczęściej wybrane amplitudy charakterystycznych składowych prądu stojana lub drgań. Nie podejmowano prób łączenia tych sygnałów diagnostycznych w procedurach wykrywania poszczególnych rodzajów uszkodzeń, ani nie uwzględniano informacji diagnostycznych zawartych w innych sygnałach, np. w strumieniu poosiowym. Do analizy sygnałów diagnostycznych, stosowanych do trenowania sieci neuronowych, używano jedynie transformaty Fouriera lub jej odmiany krótkoczasowej; nie stosowano w zasadzie analiz wyższych rzędów, np. transformaty falkowej. Ponadto, najczęściej stosowane są sieci jednokierunkowe uczone metodą wstecznej propagacji błędu, natomiast zastosowanie sieci samoorganizujących się do wstępnej klasyfikacji uszkodzeń ma bardzo ograniczony zakres. Prezentowane struktury sieci neuronowych mają charakter wybiórczy, nie udokumentowano badań dotyczących optymalizacji neuronowych detektorów struktur poszczególnych uszkodzeń silnika z punktu widzenia ich realizacji praktycznej.

Autor, próbując uzupełnić luki dotyczące teorii i praktyki zastosowań sztucznych sieci neuronowych do diagnostyki układów napędowych z silnikami indukcyjnymi, zebrał w niniejszej monografii wyniki swoich prac z ostatnich 10 lat, dotyczących tych zagadnień [150–180] oraz podjął próbę opracowania kompleksowego podejścia do kwestii monitorowania i diagnostyki silników indukcyjnych za pomocą neuronowych detektorów uszkodzeń trenowanych na podstawie danych zebranych w badaniach eksperymentalnych.

W opracowaniu przedstawiono zagadnienia związane z zastosowaniem metod i technik sztucznych sieci neuronowych do wykrywania i klasyfikowania uszkodzeń w silnikach indukcyjnych. Zaproponowano metodykę projektowania neurodetektorów uszkodzeń wirnika, stojana i łożysk tocznych opartą na danych uczących i testujących otrzymanywanych eksperymentalnie na obiekcie rzeczywistym.

Za najważniejsze swoje osiągnięcia Autor uważa:

1. Usystematyzowanie przyczyn powstawania i skutków podstawowych uszkodzeń silników indukcyjnych.
2. Opracowanie wyczerpującej analizy i oceny klasycznych metod monitorowania i diagnostyki silników indukcyjnych opartych na analizie widmowej łatwo mierzalnych sygnałów w silniku indukcyjnym.
3. Opracowanie metod projektowania neuronowych detektorów uszkodzeń wirników, stojana i łożysk silników indukcyjnych na podstawie informacji o symp-

tomach uszkodzeń zawartych w widmach prądu stojana, strumienia poosiowego i drgań mechanicznych.

4. Opracowanie i przetestowanie w badaniach symulacyjnych neuronowych detektorów uszkodzeń wirnika, stojana i łożysk na podstawie wzorców otrzymywanych z badań na obiektach rzeczywistych.
5. Sprawdzenie przydatności sieci neuronowych samoorganizujących Kohonena do wstępnej klasyfikacji rodzajów uszkodzeń silnika.
6. Zastosowanie analizy falkowej do wstępnego przetwarzania sygnałów prądu stojana i przyspieszenia drgań mechanicznych oraz projektowania neuronowych detektorów uszkodzeń wirnika i łożysk. Pozwoliło to na zastosowanie innego podejścia do budowy neuronowego detektora uszkodzeń silnika indukcyjnego, opartego na uwzględnieniu krótkoczasowych zjawisk, niewidocznych w klasycznym widmie częstotliwościowym.
7. Opracowanie i przetestowanie wstępnej realizacji laboratoryjnej neurodetektorów w kontrolerze DSP (praca on-line na obiekcie rzeczywistym).

Z przeprowadzonych badań neuronowych detektorów uszkodzeń (symulacyjnych i na obiekcie rzeczywistym) wynika szereg spostrzeżeń i uwag szczegółowych charakteryzujących proponowane rozwiązania. Przedstawiono je w podpunktach związanych z podsumowaniami poszczególnych rodzajów uszkodzeń. Tutaj zostaną przytoczone tylko najważniejsze z nich, a mianowicie:

- bardzo skutecznym klasyfikatorem stopnia uszkodzenia stojana, wirnika i łożysk okazał się prosty nieliniowy perceptron jednowarstwowy, uczony metodą wstecznej propagacji błędu, pod warunkiem wyboru odpowiednich sygnałów wejściowych;
- lepsze właściwości generalizacji wiedzy zdobytej w procesie uczenia osiągnięto dla sieci o małych rozmiarach, co ma szczególne znaczenie w realizacji praktycznej neuronowych detektorów uszkodzeń;
- efektywność działania neuronowych detektorów uszkodzeń w dużym stopniu zależy od jakości danych wejściowych sieci neuronowych, otrzymywanych w wyniku preprocesingu realizowanego algorytmami FFT oraz selekcji charakterystycznych częstotliwości (symptomów uszkodzeń);
- możliwe jest poprawne nauczanie neuronowych detektorów uszkodzeń danymi wzorcowymi pochodzącymi z badań na obiektach rzeczywistych, jednakże zestawy danych otrzymywane w ten sposób są z natury rzeczy stosunkowo mało liczne, co powoduje często brak istotnych wzorców, a przez to wiarygodność diagnozy może być mniejsza;
- dwuwymiarowe mapy Kohonena, otrzymywane w wyniku działania sieci samoorganizującej, umożliwiają dokonywanie grupowania uszkodzeń i ich klasyfikacji (ze względu na rodzaj uszkodzenia) w stopniu zadowalającym, osiągnięcie znacznie lepszych wyników grupowania możliwe jest jednak w przypadku dysponowania wektorami danych wejściowych o dużych rozmiarach, co w przy-

padkach analizowanych w rozprawie było trudne do osiągnięcia, wiązałoby się to z koniecznością fizycznego modelowania bardzo dużej liczby uszkodzonych maszyn (duże koszty realizacji);

- z przeprowadzonych badań testujących wynika, że sieć Kohonena bardzo dobrze różnicuje uszkodzenia łożysk tocznych i asymetrii zasilania, co można wykorzystać w praktycznych systemach diagnostyki przemysłowej;
- w przypadku zastosowania sieci Kohonena do klasyfikowania stopnia zwarcia uzwojeń stojana wykazano, że poprawne działanie uzyskuje się zarówno w detektorach uczonych danymi z widma drgań, jak i strumienia poosiowego, wykazano również przydatność bardzo prostej, jednowymiarowej sieci odwzorowań Kohonena w sygnalizowaniu stopnia zwarcia uzwojenia stojana;
- zastosowanie analizy falkowej do przetwarzania diagnostycznych sygnałów czasowych prądu stojana i drgań mechanicznych otwiera nowe możliwości w doborze danych do projektowania neuronowych detektorów uszkodzeń, wybrane wartości energii węzłów drzewa dekompozycji pozwalają w lepszym stopniu, w stosunku do informacji otrzymywanej z klasycznej analizy FFT, uwzględnić krótkoczasowe symptomy uszkodzeń;
- w porównaniu do klasycznej metody analizy FFT, analiza oparta na przekształceniu falkowym wymaga znacznie krótszych czasów rejestracji sygnału diagnostycznego, co pozwala skutecznie wyeliminować zakłócenia powodowane przez oscylacje momentu obciążenia i prędkości (zmiany poślizgu w znacznym stopniu komplikują prawidłową ekstrakcję charakterystycznych częstotliwości z widma FFT).

Należy zauważyć, że w badaniach opisanych w niniejszej monografii, zrealizowanych na silnikach indukcyjnych małej mocy, otrzymano proste struktury neuronowych detektorów, klasyfikujące uszkodzenia stojana, wirnika i łożysk z bardzo małymi błędami (liczba błędnych odpowiedzi nie przekraczała 3%).

Jednakże wykorzystanie tych wyników w warunkach przemysłowych, do napędów dużej mocy, wymaga posiadania obszernej bazy danych o uszkodzeniach. Dlatego konieczne jest ciągle uzupełnianie baz danych w jednostkach diagnostycznych nadzorujących przemysłowe instalacje napędowe informacjami pomiarowymi z uszkodzeń i awarii silników. Umożliwi to w przyszłości tworzenie kompletnych zestawów danych uczących i testujących, gwarantujących wiarygodność diagnozy neuronowych detektorów uszkodzeń.

Załącznik nr 1

Parametry badanych silników


Producent	INDUKTA	
Typ	typ SSh-90L-4	
Nr fabryczny	423347	
Napięcie	220/380	V
Prąd	6,4/3,7	A
Moc	1,5	kW
Prędkość obrotowa	1410	obr/min
Współczynnik mocy $\cos\varphi$	0,78	
Liczba żłobków stojana	36	
Liczba żłobków wirnika	26	

Producent	FSE Besel	
Typ	typ STg80x-4c	
Nr fabryczny	423347	
Napięcie	220/380	V
Prąd	5,0/2,9	A
Moc	1,1	kW
Prędkość obrotowa	1400	obr/min
Współczynnik mocy $\cos\varphi$	0,78	
Liczba żłobków stojana	24	
Liczba żłobków wirnika	22	


Załącznik nr 2

Opis stanowiska laboratoryjnego do badania i testowania neuronowych detektorów uszkodzeń


Stanowisko laboratoryjne składa się ze stendu pomiarowego wyposażonego w ruchomą platformę do posadowienia badanego silnika, umożliwiającą regulację położenia silnika w trzech kierunkach. Badany silnik połączony jest sztywnym sprzęgłem z maszyną obciążającą (prądnica prądu stałego). W badaniach prezentowanych w niniejszej pracy silnik indukcyjny podłączony był bezpośrednio do sieci zasilającej. Obciążenie badanego silnika może być regulowane przez zmianę współczynnika wypełnienia sygnału sterującego kluczem tranzystorowym włączonym w obwód twornika prądnicy obciążającej. Prądy w poszczególnych fazach silnika indukcyjnego mierzone są za pomocą wielozakresowych przetworników LA 25-NP firmy LEM. Do pomiaru drgań obudowy silnika stosowano akcelerometry piezoelektryczne Delta Tron typu 4397 i 4506 firmy Bruel&Kjaer. Sygnały wyjściowe z przetworników były wprowadzane bezpośrednio do układu akwizycji Multianalizatora PULSE 3560 firmy Bruel&Kjaer (rys. Z1). Stanowisko laboratoryjne wyposażone jest w zastaw wirników o różnej liczbie uszkodzonych prętów, jak również w zestaw łożysk o różnym stopniu uszkodzenia, co umożliwia realizację badań porównawczych. Na rysunku Z2 przedstawiono widok wirnika ze sztucznie wprowadzonym uszkodzeniem sześciu prętów.



Rys. Z1. Schemat ideowy stanowiska laboratoryjnego do zbierania danych wykorzystywanych do trenowania i testowania sieci neuronowych
Fig. Z1. Schematic diagram of the data acquisition laboratory set up for neural networks training and testing



Rys. Z2. Widok wirnika „zdrowego” oraz z uszkodzonymi 6 prętami
Fig. Z2. View of “healthy” rotor and the rotor with 6 faulty bars



Rys. Z3. Schemat ideowy stanowiska laboratoryjnego
do testowania neuronowych detektorów uszkodzeń silników indukcyjnych
Fig. Z3. Schematic diagram of the laboratory set up for neural detectors training and testing

Neuronowe detektory uszkodzeń testowano na przedstawionym stanowisku badawczym z tą różnicą, że do realizacji neuronowego detektora uszkodzeń zastosowano kontroler DSP typu DS 1102 firmy dSPACE posadowiony w komputerze PC (rys. Z3).

Załącznik nr 3

Parametry badanych łożysk

Dane konstrukcyjne łożyska kulkowego typu 6205ZZ (w silniku SSh-90L-4)

Element łożyska	Oznaczenie	Wartość	Jednostka
Średnica kulki	d	8	mm
Średnica koszyka	D	39	mm
Liczba kulek	Nk	9	–
Kąt pracy łożyska	ϑ	0	deg

Dane konstrukcyjne łożyska kulkowego typu 6204 2RS (w silniku STg80X-4c)

Element łożyska	Oznaczenie	Wartość	Jednostka
Średnica kulki	d	7,3	mm
Średnica koszyka	D	33,5	mm
Liczba kulek	Nk	8	–
Kąt pracy łożyska	ϑ	0	deg

Literatura

- [1] ABED A., BAGHLI L., RAZIK H., REZZOUG A., *Modelling Induction Motors for Diagnostic Purposes*, European Power Electronics Conference EPE' 1999, Lausanne, 1999.
- [2] ALLBRECHT P.F., APPIARIUS J.C., MCCOY R.M., OWEN E.L., SHARMA D.K., *Assessment of reliability of motors in utility applications – updated*, IEEE Trans. on Energy Conversion, nr 1, 1986, s. 39–46.
- [3] ALGUINDIGUE I.E., LOSKIEWICZ-BUCZAK A., UHRIG R.E., *Monitoring and Diagnosis of Rolling Element Bearings Using Artificial Neural Networks*, IEEE Trans. on Industrial Electronics, t. 40, nr 2, April, 1993, s. 209–216.
- [4] ASSAF T., HENAO H., CAPOLINO G.A., *Detection of voltage source dissymmetry using the measurement of the symmetrical components in working induction motors*, Proc. IEEE Inter. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED'2001, Grado, Italy, 2001, s. 441–445.
- [5] ASSAF T., HENAO H., CAPOLINO G.A., *A spectral method for on-line computation of the harmonics of symmetrical components in induction machines*, Proceedings International Conference on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [6] AUGUSTYNIAK P., *Transformacje falkowe w zastosowaniach elektrodiagnostycznych*, AGH, Kraków 2003.
- [7] AWADALLAH M.A., MORCOS M.M., *Application of AI Tools in Fault Diagnosis of Electrical Machines and Drives + An Overview*, IEEE Trans. on Energy Conversion, t. 18, nr 2, June 2003, s. 245–251.
- [8] BACHIR S., TNANI S., TRIGEASSOU J.C., POINOT T., *Stator Fault Diagnosis in Induction Machines by parameter Estimation*, Proc. of IEEE Inter. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'2001, Grado, Italy, 2001, s. 235–239.
- [9] BACHIR S., TRIGEASSOU J.C., TNANI S., CHAMPENOIS G., *Diagnosis by parameter estimation of stator and rotor faults occurring in induction machines*, Proc. of 9th European Power Electronics Conference EPE'2001, Graz, 2001, CD.
- [10] BACHIR S., TRIGEASSOU J.C., TNANI S., *Stator Fault Diagnosis by Parameter Estimation without Speed Sensor*, Proc. Inter. Conf. on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [11] BACHIR S., TRIGEASSOU J.C., TNANI S., *On-line stator faults diagnosis by parameter estimation*, Proc. of 10th European Power Electronics Conf. EPE'2003, Toulouse, France, 2003, CD.
- [12] BASZTURA Cz., *Komputerowe systemy diagnostyki akustycznej*, PWN, Warszawa 1996.
- [13] BARTELMUS W., *Diagnostyka Maszyn Górniczych. Górnictwo Odkrywkowe*, Wydawnictwo Śląsk, 1998.
- [14] BENBOUZID M., BEGUENANE R., VIEIRA M., *Induction Motor Asymmetrical Faults Detection Using Advanced Signal Processing Techniques*, IEEE Trans. on Energy Conversion, t. 14, nr 2, June 1999, s. 147–152.
- [15] BENBOUZID M., VIEIRA M., THEYS C., *Induction Motor's Faults Detection and Localization Using Stator Current Advanced Signal Processing Techniques*, IEEE Trans. on Power Electronics, t. 14, nr 1, 1999, s. 14–22.

- [16] BENBOUZID M., *A Review of Induction Motors Signature Analysis as a Medium for Faults Detection*, IEEE Trans. on Ind. Electronics, t. 47, nr 5, 2000, s. 984–993.
- [17] BENBOUZID M., KLIMAN G.B., *What Stator Current Processing-Based Technique to Use for Induction Motor Rotor Faults Diagnosis*, IEEE Trans. on Energy Conversion, t. 18, nr 2, June 2003, s. 238–244.
- [18] BELLINI A., FRANCESCHINI G., TASSONI C., FILIPPETTI F., *Towards a Correct Quantification of Induction Machines Broken Bars Through Input Electric Signals*, Proceedings International Conference on Electrical Machines ICEM'2000, Espoo, Finland, 2000, s. 781–785.
- [19] BELLINI A., FRANCESCHINI G., LORENZANI E., TASSONI C., FILIPPETTI F., *Closed Loop Control Impact On the Diagnosis of Induction Motors Faults*, IEEE Trans. on Ind. Applications, t. 36, nr 5, 2000, s. 1318–1329.
- [20] BELLINI A., FRANCESCHINI G., PETROLINI N., TASSONI C., FILIPPETTI F., *Induction machine rotor position detection for diagnostic or control aims: possibilities and problems*, Proc. of 9th European Power Electronics Conference EPE'2001, Graz, 2001, CD.
- [21] 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, t. 38, nr 4, 2002, s. 1045–1052.
- [22] BELLINI A., FRANCESCHINI G., LORENZANI E., TASSONI C., FILIPPETTI F., *Sensorless Speed Detection in Induction Machine*, Proceedings International Conference on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [23] BERNATT M., *Silniki indukcyjne klatkowe przeznaczone do pracy przy trudnych warunkach rozruchowych*, Zeszyty Problemowe Maszyny Elektryczne, nr 41–42, 1987, BOBRME Komel, s. 17–19.
- [24] BHARADWAJ R.M., PARLOS A.G., TOLYAT H.A., NANDI S., *A Neural Network- based Speed Filter for Induction Motors: Adapting to Motor Condition Changes*, Proc. of 1999 IEEE Intern. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'99, Gijon, Spain, 1999, s. 359–362.
- [25] BIAŁASIEWICZ J. T., *Falki i aproksymacje*, WNT, Warszawa 2000.
- [26] BONNETT A.H., *Analysis of Winding Failures in Three-Phase Squirrel Cage Induction Motors*, IEEE Trans. on Ind. Applications, t. IA-14, nr 3, 1978, s. 223–226.
- [27] BONNETT A.H., SOUKUP G.C., *Cause and Analysis of Stator and Rotor Failurs in Three-Phase Squirrel Cage Induction Motors*, IEEE Trans. on Ind. Applications, t. 28, July/August, 1992, s. 921–937.
- [28] BOUMEGOURA T., MARQUES J.C., YAHOUH H., HAMMOURI H., Clerc G., *Application of Extended Kalman Observers for Induction Machine Diagnosis*, Proc. of IEEE Intern. Symp. On Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'01, Grado, Italy, 2001, s. 241–245.
- [29] CAMERON J.R., THOMSON W.T., DOW A.B., *Vibration and current monitoring airgap eccentricity in large induction motors*, IEE Proc. t. 133, Pt.B, nr 3, May 1986, s. 155–163.
- [30] CABANAS M.F., MELERO G.A., ORCAJO G.A., CANO J.M., BRIZ DEL BLANCO F., CAPOLINO G.A., *A new methodology for applying the FFT to induction motor on-line diagnosis*, IEEE Int. Symp. On Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'99, Gijon, Spain, 1999, s. 537–543.
- [31] CABANAS M.F., MELERO G.A., CAPOLINO G., HENAO H., BRIZ DEL BRANCO F., *The dispersion in the calculation of effective inverse sequence impedance of induction motors: a solution based on the Complex Fourier Transform*, Inter. Confer. on Electrical Machines ICEM'2000, Espoo, Finland, 2000, s. 766–770.
- [32] CAPOLINO G.A., *A Comprehensive Analysis of the Current Status in Low Voltage Induction Motor Diagnosis*, ICEM'2000, Espoo, Finland, 2000, s. 595–602.

- [33] CARDOSO A.J.M., *The Park's Vector Approach: A general tool for diagnostics of electrical machines, power electronics and adjustable speed drives*, Proc. of IEEE Int. Symp. On Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'97, Carry-le-Rouet, France, 1997, s. 261–269.
- [34] CARDOSO A.J.M., CRUZ S.M.A., FONSECA D.S.B., *Inter-Turn Stator Winding Fault Diagnosis in Three-Phase Induction Motors by Park's Vector Approach*, IEEE Trans. on Energy Conversion, t. 14, nr 3, Sept. 1999, s. 595–598.
- [35] CASIMIR R., BOUTLEUX E., CLERC G., CHAPPUIS F., *Comparative Study of Diagnosis Methods for Induction Motors*, International Conference On Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [35] CEMPEL C., *Diagnostyka wibroakustyczna maszyn*, PWN, Warszawa 1989.
- [36] CEMPEL C., TOMASZEWSKI F., *Diagnostyka maszyn*, Międzyresortowe Centrum Naukowe Eksploatacji Majątku Trwałego, Radom, 1992.
- [37] CHO K.R., LANG J.H., UMANS S.D., *Detection of broken rotor bars in induction motors using state and parameter estimation*, IEEE Trans. on Ind. Appl., t. 28, May/June, 1992, s. 702–709.
- [38] CHOLEWA W., KICIŃSKI J., *Diagnostyka techniczna maszyn. Pomiary i analiza sygnałów*, Wyd. Politechniki Śląskiej, Gliwice 1993.
- [39] CHOLEWA W., KICIŃSKI J., *Diagnostyka techniczna. Odwrotne modele diagnostyczne*, Wyd. Politechniki Śląskiej, Gliwice 1997.
- [40] CHOW M., YEE S.O., *Application of neural networks to incipient fault detection in induction motors*, Journal on Neural Network Comput., t. 2, nr 3, 1991, s. 26–32.
- [41] CHOW M., YEE S.O., *Methodology for On-line incipient Fault Detection in Single-Phase Squirrel Cage Induction Motors Using Artificial Neural Networks*, IEEE Trans. on Energy Conversion, t. 6, nr 3, June 1991, s. 536–545.
- [42] CHOW M., MANGUM P.M., *A Neural Network Approach to Real-Time Condition Monitoring of Induction Motors*, IEEE Trans. on Ind. Electronics, t. 38, December, 1991, s. 448–453.
- [43] CHOW M., *Methodologies of using neural network and fuzzy logic technologies for motor incipient fault detection*, World Scientific, 1993.
- [44] CHOW M., SHARPE R.N., HUNG J.C., *On the Application and Design of Artificial Neural Networks for Motor Fault detection – Part I, Part II*, IEEE Trans. on Ind. Electronics, t. 40, April, 1993, s. 181–197.
- [45] CHOW T.W.S., *Condition Monitoring of Electric Machines Using Third-Order Spectrum Analysis*, Conf. Record IAS Annual Meeting 1996, t. 1, Pt. 1, s. 679–686.
- [46] CHOW T.W.S., TAN H., *HOS – based nonparametric and Parametric Methodologies for Machine Fault Detection*, IEEE Trans. on Ind. Electronics, t. 47, nr 5, 2000, s. 1051–1059.
- [47] CIRINCIONE G., CIRINCIONE M., VITALE G., *A Kohonen neural network for the diagnosis of incipient faults in induction motors*, Inter. Confer. on Electrical Machines ICEM'94, Paris 1994, t. 2, s. 369–373.
- [48] CHRZAN P.J., SZCZĘSNY R., *Fault Diagnostic of Voltage-fed Inverter for Induction Motor Drive*, Proc. of Inter. Conference IEEE/ISIE'96, Warsaw, Poland, t. 2, 1996, s. 1011–1016.
- [49] CHRZAN P.J., RONKOWSKI M., CHAMPENOIS G., NIEZNAŃSKI J., *Detection of Insulation Fault of Inverter-fed IM Drive*, 9th Inter. Conf. on Power Electronic and Motion Control EPE – PESC'2000, Košice Slovak Rep., 2000, CD.
- [50] COFRON J.W., *Lokalizacja uszkodzeń w systemach mikroprocesorowych*, WNT Warszawa 1985.
- [51] COMBASTEL C., LESEEC S., PETROPOL S., GENTIL S., *Model-based and wavelet approaches to induction motor on-line fault detection*, Control Engineering Practice, 2002, s. 493–509.
- [52] COURRECH J., *Envelope analysis for effective rolling-element fault detection – fact or fiction?* UPTIME Magazine, nr 1, 2000, t. 8, s. 14–17.

- [53] CROWTHER W.J., EDGE K.A., BURROWS C.R., ATKINSON R.M., WOOLLOONS D.J., *Fault diagnosis of a hydraulic actuator circuit using NNs: An output vector space classification approach*, Journal on Syst. and Control Engineering, t. 212, nr 1, 1998, s. 57–68.
- [54] CRUZ S.M., CARDOSO A.J.M., *Rotor Cage Fault Diagnosis in Voltage Source Inverter-Fed IM by Extended Park's Vector Approach*, Proc. of SDEMPED'99, Gijon, Spain, 1999, s. 776–780.
- [55] 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, s. 776–780.
- [56] CRUZ S.M., CARDOSO A.J.M., *Rotor Cage Diagnosis in Operating Three-Phase Induction Motors, Under the Presence of Time-Varying Loads*, Proc. of 9th European Power Electronics Conference EPE'2001, Graz, Austria, 2001, CD.
- [57] CRUZ S.M., CARDOSO A.J.M., *Modelling and Simulation of Stator Winding Faults in Three-Phase Induction Motors, Including Rotor Skin Effect*, Proc. Inter. Confer. on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [58] DEMUTH H., BEALE M., *Neural Network Toolbox for use with Matlab*, User's Guide version 4, The MathWorks Inc., 2000.
- [59] DEVANNEAUX V., KABBAJ H., DAGUES B., FAUCHER J., *A Versatile Model of Squirrel Cage Induction Machines for Design, Monitoring and Diagnosis Purposes*, Proc. of 9th European Power Electronics Confer. EPE'2001, Graz, 2001, CD.
- [60] 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 IEE Confer. on Electrical Machines and Drives, 1995, Conf. Publication IEE, nr 412, s. 151–155.
- [61] 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, t. 33, nr 1, 1997, s. 24–34.
- [62] DRAK B., *Analiza sił elektrodynamicznych działających na czoła uzwojeń stojanów silników indukcyjnych dużej mocy*, Zeszyty Naukowe Politechniki Śląskiej, Elektryka, z. 159, Gliwice, 1997, s. 29–42.
- [63] DRAK B., *Analiza awarii silników indukcyjnych dużej mocy*, Zeszyty Problemowe Maszyny Elektryczne, nr 54, 1997, BOBRME Komel, s. 82–87.
- [64] DRAK B., ZIENTEK P., *Uszkodzenia łożysk tocznych silników indukcyjnych dużej mocy*, Zeszyty Problemowe Maszyny Elektryczne, nr 64, 2002, BOBRME Komel, s. 49–52.
- [65] DRAK B., *Statystyka uszkodzeń silników wysokonapięciowych prądu przemiennego w elektrowniach zawodowych*, Zeszyty Problemowe Maszyny Elektryczne, nr 65, 1993, BOBRME Komel, s. 41–46.
- [66] DROZDOWSKI P., PETRYNA J., WEINREB K., *Ocena skuteczności diagnozowania silników indukcyjnych poprzez analizę spektralną prądu stojana*, Proc. XXXII Inter. Symp. on Electrical Machines SME'96, Cracow, 1996, s. 31–36.
- [67] 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, s. 109–116.
- [68] DWOJAK J., RZEPİELA M., *Diagnostyka drganiowa stanu maszyn i urządzeń*, Wydawnictwo Biuro Gamma, Warszawa 1999.
- [69] DUCH W., KORBICZ J., RUTKOWSKI L., TADEUSIEWICZ R. (redaktorzy), *Biocybernetyka i inżynieria biomedyczna 2000*, Tom 6: Sieci neuronowe, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
- [70] DYBOWSKI P., RUSEK J., *Wpływ momentu bezwładności na widmo prądów stojana silników klatkowych niesymetrycznych*, Zeszyty Problemowe Maszyny Elektryczne, nr 62, 2001, BOBRME Komel, s. 195–202.

- [71] DZIERŻANOWSKI A., HICKIEWICZ J., SZYMANIEC S., WACH P., *Diagnostyka eksploatacyjna klatek silników indukcyjnych*, Wiadomości Elektrotechniczne, nr 7–8, 1990, s. 208–210.
- [72] DZIERŻANOWSKI A., HICKIEWICZ J., SZYMANIEC S., WACH P., *Diagnostyka eksploatacyjna łożysk tocznych w silnikach elektrycznych*, Zeszyty Problemowe Maszyny Elektryczne, nr 45, 1992, BOBRME Komel, s. 36–38.
- [73] DZIERŻANOWSKI A., HICKIEWICZ J., SZYMANIEC S., WACH P., *Diagnostyka stanu klatek silników indukcyjnych w oparciu o analizę częstotliwościową prądu stojana*, Mater. XXIX Symp. Maszyn Elektrycznych SME'93, Szklarska Poręba, 1993.
- [74] DZIERŻANOWSKI A., HICKIEWICZ J., SZYMANIEC S., WACH P., *Diagnostyka eksploatacyjna łożysk tocznych w silnikach elektrycznych*, Zeszyty Problemowe Maszyny Elektryczne, nr 48, 1994, BOBRME Komel.
- [75] DZIERŻANOWSKI A., SZYMANIEC S., *Diagnostyka eksploatacyjna silników indukcyjnych. Doświadczenia własne*, Proc. XXXII Inter. Symp. on Electrical Machines, SME'96, Cracow, 1996, s. 37–42.
- [76] DZIERŻANOWSKI A., SZYMANIEC S., *Diagnostyka eksploatacyjna silników indukcyjnych*, Wiadomości Elektrotechniczne 1998, nr 4, Materiały IV Sympozjum SPE-98 w Elektrowni Opole.
- [77] DZIERŻANOWSKI A., SZYMANIEC S., *Osiowanie układów maszynowych z silnikami elektrycznymi*, Zeszyty Problemowe Maszyny Elektryczne, nr 58, 1999, BOBRME Komel, s. 131–134.
- [78] EISENMANN R.C., Sr, EISENMANN R.C., Jr, *Machinery Malfunction Diagnosis and Correction*, Prentice Hall, PTR New Jersey, 1997.
- [79] ELKASABGY N.M., EASTHAM A.R., DAWSON G.E., *Detection of broken bars in the cage rotor on an induction machine*, IEEE Trans. on Ind. Applications, t. 22, nr 6, 1992, s. 165–171.
- [80] FARAD S.F., BARTHELD R.G., HABETLER T.G., *An Integrated On-Line Motor Protection System*, IEEE Industry Applications Magazine, March/April 1996, s. 21–26.
- [81] FAYA F.R., CABANAS M.F., MELERO M.G., ORCAJO G.A., ROJAS C.H., *Elektromagnetic torque as new method for on-line induction motor rolling-element bearing damage protection*, Proc. Inter. Confer. on Electrical Machines ICEM'98, Istanbul, Turkey, 1998, CD.
- [82] FAIZ J., ARDEKANEI I.T., TOLİYAT H.A., *An Evaluation of Inductances of a Squirrel-Cage Induction Motor Under Mixed Eccentric Conditions*, IEEE Trans. on Energy Conversion, t. 18, nr 2, June 2003, s. 252–258.
- [83] FILIPPETTI F., FRENCESCHINI G., TASSONI C., *Analysis approach of induction motors stator fault to on-line diagnostics*, Proc. Inter. Confer. on Electrical Machines ICEM'90, Cambridge, UK, 1990.
- [84] FILIPPETTI F., FRENCESCHINI G., TASSONI C., *Synthesis of artificial intelligence and neural network technologies in power electric system diagnostics*, Proc. Intern. Confer. on Electrical Machines ICEM'94, Paris, t. 4, 1994, s. 353–357.
- [85] FILIPPETTI F., FRENCESCHINI G., TASSONI C., *Neural Network aided on-line diagnostics of induction motor faults*, IEEE Trans. on Ind. Appl., t. 31, nr 4, July/Aug., 1995, s. 892–899.
- [86] FILIPPETTI F., FRENCESCHINI G., TASSONI C., MEO S., OMETTO A., *Neural Techniques For Induction Motor Faults Detection*, Materiały SME'96, Kraków 1996.
- [87] FILIPPETTI F., FRENCESCHINI 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, s. 410–413.
- [88] FILIPPETTI F., FRENCESCHINI G., TASSONI C., VAS P., *Impact of Speed Ripple on Rotor Fault Diagnosis of Induction Machines*, Proc. Intern. Confer. on Electrical Machines ICEM'96, Vigo, Spain, 1996, t. 2, 1996, s. 452–457.
- [89] FILIPPETTI F., FRENCESCHINI G., TASSONI C., *A survey of AI techniques approach for induction machines on-line diagnostics*, Proc. Inter. Confer. PEMC'96, t. 2. Budapest, Hungary, 1996, s. 314–318.

- [90] FILIPPETTI F., FRENCESCHINI G., TASSONI C., VAS P., *Integrated Condition Monitoring And Diagnosis of Electrical Machines Using Minimum Configuration Artificial Intelligence*, Proc. of European Power Electronics. Confer. EPE'97, Trondheim, Norway, 1997, s. 2983–2988.
- [91] FILIPPETTI F., FRENCESCHINI G., TASSONI C., MEO S., OMETTO A., GENTILE G., ROTONDALE N., *Deterministic Approach and Neural Network Approach for Short Circuits Diagnosis in Induction Machines*, Proc. of Inter. Confer. EPE'97 Trondheim, 1997, s. 2983–2988.
- [92] FILIPPETTI F., FRENCESCHINI G., TASSONI C., VAS P., *AI Techniques in Induction Machines Diagnosis Including the Speed Ripple Effect*, IEEE Trans. on Ind. Appl., t. 34, nr 1, 1998, s. 98–107.
- [93] FILIPPETTI F., FRENCESCHINI 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, s. 19–31.
- [94] FILIPPETTI F., FRENCESCHINI G., TASSONI C., VAS P., *Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques*, IEEE Trans. on Industrial Electr., t. 47, nr 5, 2000, s. 994–1004.
- [95] FISER R., MAKUC D., AMBROZIC V., *Evaluation of the Induction motor cage Fault Stage Using Finite Element method*, Proc. of 2001 IEEE Intern. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'01, Grado, Italy, 2001, s. 627–631.
- [96] FRANK P., *Fault Diagnosis in Dynamic Systems Using Analytical and Knowledge-based Redundancy – A survey and Some New Results*, Automatica, t. 26, nr 3, 1990, s. 459–474.
- [97] GAŚSIOROWSKI T., *Diagnostyka klatki wirnika w trakcie cyklu produkcyjnego silników indukcyjnych*, Zeszyty Naukowe Politechniki Śląskiej, Elektryka z. 177, nr 1501, 2001, s. 145–151.
- [98] GIEMKE R.G., *Niedomagania maszyn elektrycznych*, WNT, Warszawa 1962.
- [99] GLINKA T., GAŚSIOROWSKI T., *Przegląd metod badań diagnostycznych klatki wirnika silnika indukcyjnego*, Przegląd Elektrotechniczny, nr 5, 1999, s. 120–123.
- [100] GLINKA T., KULESZA B., *Badania wyładowań niezupełnych w izolacji zwojowej maszyn indukcyjnych zasilanych z falownika PWM*, Zeszyty Naukowe Pol. Śl., z. 173, Gliwice 2000, s. 7–16.
- [101] GLINKA T., *Badania diagnostyczne maszyn elektrycznych w przemyśle*, BOBRME Komel, Katowice 2002.
- [102] GLINKA T., *Badania diagnostyczne izolacji uzwojeń generatorów napięciem stałym*, Wiadomości Elektrotechniczne, nr 4, 2003, s. 165–170.
- [103] GOGOLEWSKI Z., PASZEK W., GABRYŚ W., KUBICA J., *Uszkodzenia maszyn elektrycznych*, WNT, Warszawa 1967.
- [104] GUZIEC K., PETRYNA J., WEINREB K., *Kompleksowa diagnoza stanu elektrycznego i elektro-mechanicznego maszyn prądu przemiennego przy zastosowaniu bezinwazyjnych systemów pomiarowych*, Zeszyty Problemowe Maszyny Elektryczne, nr 52, 1996, BOBRME Komel, s. 64–73.
- [105] HAJI M., TOLIJAT H.A., *Patern Recognition – A Technique for Induction Machines Rotor Broken Bar Detection*, IEEE Trans. on Energy Conversion, t. 16, nr 4, December 2001, s. 312–317.
- [106] HARGIS C., GAYDON B.G., KAMISH K., *The detection of rotor defects in induction motors*, Proc. IEE Int. Conf. Electric Machines Design and Application, London 1982, s. 216–220.
- [107] HENAO H., ASSAF T., CAPOLINO G.A., *Detection of voltage source dissymmetry in an induction motor using the measurement of axial leakage flux*, Proc. Intern. Confer. on Electrical Machines ICEM'2000, Espoo, Finland, 2000, t. 2, s. 1110–1114.
- [108] HENAO H., CAPOLINO G.A., DEMIAN C., *Correlation between line current and leakage flux in an induction machine*, Proceedings International Conference on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [109] HERTZ J., KROGH A., PALMER R.G., *Wstęp do obliczeń neuronowych*, WNT, 1995.

- [110] 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, s. 247–253.
- [111] HICKIEWICZ J., SZYMANIEC S., WACH P., *Vibroacoustic diagnostics of electric circuits defects of 3-phase induction motors*, Proc. Intern. Confer. on Electrical Machines ICEM'86, München, Germany, 1986, Part 2, s. 496–499.
- [112] HICKIEWICZ J., SZYMANIEC S., WACH P., *Badania wibroakustyczne silników indukcyjnych*, Zeszyty naukowe AGH, nr 1192, Elektrotechnika z. 12, Kraków 1988, s. 247–257.
- [113] HICKIEWICZ J., SZYMANIEC S., WACH P., *Vibration Phenomena in Induction Machines*, Proc. Inter. Confer. on Electrical Machines ICEM'94, Paris, France, 1994, s. 700–703.
- [114] HICKIEWICZ J., *Diagnostyka maszyn elektrycznych*, III Konferencja Diagnostyka Techniczna Urzędzeń i Systemów, Szczyrk 1995, z. 4, s. 89–102.
- [115] HICKIEWICZ J., ŁAWROWSKI Z., *Metody diagnozowania stanu izolacji uzwojeń stojanów maszyn elektrycznych*, Prace III Krajowej Konferencji PES-3, Zakopane-Kościelisko, 2001, s. 31–35.
- [116] HICKIEWICZ J., ŁAWROWSKI Z., OKOŃ A., *Praktyczne doświadczenia z badań stanu izolacji uzwojeń maszyn elektrycznych*, Proc. of 38th Intern. Symp. on Electrical Machines SME'02, Cędzyna-Kielce, 2002, s. 581–588.
- [117] HONGPING C., RITCHIE E., *Wavelet packet method for diagnosis of rotor faults in squirrel-cage induction motor*, Proc. Inter. Confer. on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [118] HO S.L., LAU K.M., *Detection of Faults in Induction Motors Using Artificial Neural Networks*, Proc. IEE Conf. Electrical Machines and Drives, nr 412, 1995, s. 176–181.
- [119] HSU J.S., *Monitoring of Defects in Induction Motors Trough Air-Gap Torque Observation*, IEEE Trans. on Ind. Applications, t. 31, nr 5, 1995, s. 1016–1021.
- [120] IEEE: Motor Reliability Working Group, *Report of Large Motor Reliability Survey of Industrial Commercial Installations*, IEEE Trans. on Ind. Applications, t. IA-21, nr 4, 1985, s. 853–872.
- [121] ISERMANN R., *Process fault detection based on modeling and estimation methods. A survey*, Automatica, t. 20, nr 4, 1984, s. 387–404.
- [122] ISERMANN R., *Fault diagnosis of machines via parameter estimation and knowledge processing. Tutorial paper*, Automatica, t. 29, nr 4, 1993, s. 815–835.
- [123] ISERMANN R., *Supervision, fault detection and fault-diagnosis methods. An introduction*, Control Engineering Practice, t. 5, nr 5, 1997, s. 639–652.
- [124] ISERMANN R., BALLE P., *Trends in the application of model-based fault detection and diagnosis of technical processes*, Control Engineering Practice, t. 5, nr 5, 1997, s. 709–719.
- [125] JANIK T., RÓŻYCKI A., *Urządzenie diagnostyczne do wykrywania asymetrii elektrycznej klatek silników indukcyjnych*, Przegląd Elektrotechniczny, nr 4, 1988, s. 106–108.
- [126] JANIK T., *Diagnostyka klatek silników indukcyjnych*, Zeszyty Problemowe Maszyny Elektryczne, BOBRME Komel, nr 45, 1992, s. 26–29.
- [127] JARZYNA W., *Diagnostyka układu napędowego w czasie rzeczywistym*, Wydawnictwo Politechniki Lubelskiej, Lublin 2003.
- [128] JEZERSKI G., DWOJAK J., RZEPIELA M., *Diagnostyka drganiowa łożysk tocznych silników elektrycznych na podstawie własnych doświadczeń*, Wiadomości Elektrotechniczne, nr 4, 2003, s. 176–181.
- [129] JOKSIMOWIĆ G.M., PENMAN J., *The Detection of Inter-Turn Short Circuitis in the Stator Windings of Operating Motors*, IEEE Trans. on Industrial Electr., t. 47, nr 5, 2000, s. 1078–1084.
- [130] KAPINOS J., KUDŁA J., *Sieci neuronowe w diagnostyce uszkodzeń prętów wirnika silnika indukcyjnego*, Zeszyty Problemowe - Maszyny Elektryczne, nr 54, 1997, s. 104–108.
- [131] KAŻMIERKOWSKI 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), s. 45–94.
- [132] KAZMIERKOWSKI M.P., BLAABJERG F., KRISHNAN R., *Control in Power Electronics – Selected Problems*, Academic Press, USA, 2002.
- [133] KAZZAZ S.A.S., SINGH G.K., *Experimental investigations on induction machine condition monitoring and fault diagnosis using digital signal processing techniques*, Electric Power System Research, t. 65, 2003, s. 197–221.
- [134] KIM K., PARLOS A.G., *induction motor fault diagnosis based on neuropredictors and wavelet signal processing*, IEEE Trans. on Mechatronics, s. 201–219, 2002.
- [135] KIM K., PARLOS A.G., BHARADWAJ R.M., *Sensorless Fault Diagnosis of Induction Motors*, IEEE Trans. on Industrial Electronics, t. 50, nr 5, October 2003, s. 1038–1051.
- [136] KLIMAN G.B., *The Detection of Faulted Rotor Bars Operating Induction Motors*, Proceedings International Conference on Electrical Machines ICEM'86, München, Germany, 1986, part 2, s. 496–499.
- [137] KLIMAN G.B. et al., *Noninvasive detection of broken rotor bars in operating induction motors*, IEEE Trans. on Energy Conversion, t. 3, nr 4, December 1988, s. 873–879.
- [138] KLIMAN G.B., STEIN J., *Methods of motor current signature analysis*, Electric Machines and Power Systems, nr 20, 1992, s. 463–474.
- [139] KLIMAN G.B., PREMERLANI W.J., YAZICI B., *Sensorless, Online Motor Diagnostics*, IEEE Computer Applications in Power, t. 10, nr 2, April, 1997, s. 39–43.
- [140] KLUSZCZYŃSKI K., MIKSIEWICZ R., *Modelowanie 3-fazowych maszyn indukcyjnych przy uwzględnianiu wyższych harmonicznych przestrzennych przepływu*, ZN Pol. Śląskiej, Elektryka, Gliwice, 1995, z. 142.
- [141] KOHLER J.L., SOTTILE J., TRUTT F.C., *Condition Monitoring of Stator Windings in Induction Motors: Part I – Experimental Investigation of the Effective Negative-Sequence Impedance Detector*, Trans. on Industry Applications, t. 38, nr 5, 2002, s. 1447–1452.
- [142] KOHLER J.L., SOTTILE J., TRUTT F.C., *Condition Monitoring of Stator Windings in Induction Motors: Part II – Experimental Investigation of Voltage Mismatch Detectors*, Trans. on Industry Applications, t. 38, nr 5, 2002, s. 1454–1459.
- [143] KOHONEN T., *Self-organization and associative memory*, Springer-Verlag, Berlin 1988.
- [144] KOIVO H.N., *Artificial neural networks in fault diagnosis and control*, Control Engineering Practice, t. 2, nr 1, 1994, s. 89–101.
- [145] KOIKKALINEN P., HEIKKONEN J., HONKANEN T., HAKKINEN E., MONONEN J., *Fault diagnostics of rotating machines via self-organization*, Proc. of SPIE, 1996, t. 2904, s. 460–468.
- [146] KOŚCIELNY J.M., *Diagnostyka zautomatyzowanych procesów przemysłowych*, Akademicka Oficyna Wydawnicza Exit, Warszawa 2001.
- [147] KORBICZ J., OBUCHOWICZ A., UCIŃSKI D., *Sztuczne sieci neuronowe. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [148] KORBICZ J., KOŚCIELNY J.M., KOWALCZUK Z., CHOLEWA W. (red.), *Diagnostyka Procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002.
- [149] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Zastosowanie sieci neuronowych w napędzie elektrycznym*, Mater. Konfer. SENE'95, Łódź, 1995, s. 683–697.
- [150] KOWALSKI Cz. T., *Mikrokomputerowy system monitorowania i diagnostyki napędów elektrycznych z silnikami indukcyjnymi*, Prace Naukowe Instytutu Maszyn i Napędów Elektrycznych PWr., ser. Studia i Materiały, zeszyt 19, 1996, s. 104–108.
- [151] KOWALSKI Cz.T., PATYK A., *Analiza silnika indukcyjnego klatkowego ze zwarciami zwojowymi w stojanie*, Proc. XXII Intern. Symp. on Electrical Machines SME'96, Kraków 1996, s. 55–61.
- [152] KOWALSKI Cz.T., PATYK A., ORŁOWSKA-KOWALSKA T., BANASZEWSKI A., *Zastosowanie sieci neuronowych do monitorowania i diagnostyki silników indukcyjnych*, Raport IMNE PWr. z serii SPR 24/96, 1996 (praca niepublikowana wykonana w ramach grantu KBN nr 8S502 030 07).

- [153] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Neural Networks techniques in electrical drives control and fault detection, for Diagnosis of the Induction Motor Rolling Bearings*, Proc. of Electrical Drives and Power Electronics conf. EDPE'96, Stara Lesna, Slovakia, 1996, s. 27–38.
- [154] KOWALSKI Cz. T., *Zagadnienia diagnostyki eksploatacyjnej napędów z silnikami indukcyjnym*, Mater. II Konfer. Naukowo-Technicznej UNAPEN'99, Łódź, 1999, s. 49–61.
- [155] KOWALSKI Cz. T., *Neuronowy detektor uszkodzeń wirnika silnika klatkowego*, Materiały VIII Symposium PPEE'99, Ustronie, 1999, s. 487–494.
- [156] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., WOJSZNIS P., *Pośrednia metoda pomiaru momentu elektromagnetycznego silnika indukcyjnego*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej Nr 48, ser. Studia i Materiały, nr 20, 2000, s. 29–37.
- [157] KOWALSKI Cz. T., *Zastosowanie sieci neuronowych do diagnostyki łożysk silników indukcyjnych*, Mater. IX Symp. PPEE'2000, Wisła, 2000, s. 240–246.
- [158] KOWALSKI Cz.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, t. 1, 2001, Bologna, Italy, s. 137–140.
- [159] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Bearing Faults Monitoring using Neural Networks*, Proc. of IEEE Intern. Symp. On Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'2001, Grado, Italy, 2001, s. 313–318.
- [160] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Application of Neural Networks for Diagnosis of the Induction Motor Rolling Bearings*, Proc. of Electrical Drives and Power Electronics EDPE'2001, The High Tatras, Slovak Rep., 2001, s. 245–249.
- [161] KOWALSKI Cz.T., WĄSIEL M., WOŹNIAK K., *Wybrane problemy diagnostyki łożysk tocznych w napędach elektrycznych z silnikami dużej mocy*, Zeszyty Problemowe Maszyny Elektryczne BOBRME Komel, nr 64, 2002, s. 41–48.
- [162] KOWALSKI Cz.T., *Zastosowanie sztucznych sieci neuronowych do wykrywania uszkodzeń w silnikach indukcyjnych klatkowych*, Zeszyty Problemowe Maszyny Elektryczne BOBRME Komel, nr 64, 2002, s. 201–208.
- [163] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Neural Networks Application for Induction Motor Faults Diagnosis*, Proc. of 7th Intern. Conf. on Modelling and Simulation of Electric Machines, Converters and Systems ELECTRIMACS'02, Montreal, Canada, 2002, CD.
- [164] KOWALSKI Cz.T., *Wykrywanie uszkodzeń stojana silnika indukcyjnego za pomocą sieci neuronowych*, Proc. XXXVIII Intern. Symp. on Electrical Machines SME'2002, Cędzyna–Kielce, 2002, s. 309–322.
- [165] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Induction Motor Stator Faults Diagnosis using Neural Networks*, Proc. of 10th Intern. Power Electronics and Motion Control Conference PEMC'2002, Dubrovnik, Croatia, 2002, CD.
- [166] KOWALSKI Cz.T., FRONCZAK D., GARDZIEJEWSKI M., WĄSIEL M., *Komputerowe wspomaganie eksploatacji silników elektrycznych w Elektrowni Turów S.A.*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME Komel, nr 65, 2003, s. 89–98.
- [167] KOWALSKI Cz.T., PAWLAK M., *Monitorowanie napędów elektrycznych z silnikami indukcyjnymi za pomocą wektora przestrzennego prądu stojana*, Zeszyty Problemowe – Maszyny Elektryczne, nr 66, 2003, s. 97–102.
- [168] KOWALSKI Cz.T., *Stan obecny i tendencje rozwojowe metod monitorowania i diagnostyki napędów z silnikami indukcyjnymi*, Wiadomości Elektrotechniczne, nr 4, 2003, s. 160–164.
- [169] KOWALSKI Cz.T., ORŁOWSKA-KOWALSKA T., *Neural Networks Application for Induction Motor Faults diagnosis*, IEEE Trans. on Mathematics and Computers in Simulation, t. 63, nr 3–5, 2003, s. 435–448.

- [170] KOWALSKI Cz.T., PAWLAK M., *Monitorowanie napędów elektrycznych z silnikami indukcyjnymi za pomocą wektora przestrzennego prądu stojana*, Proc. of 34th Intern. Symp. on Electrical Machines SME'2003, Gdańsk–Jurata, Poland, 2003, CD.
- [171] KOWALSKI Cz.T., PAWLAK M., *Application of AI methods for rotor faults detection of the induction motor*, Proc. of 10th European Power Electronics Conference EPE'2003, Toulouse, France, 2003, CD.
- [172] KOWALSKI Cz.T., PAWLAK M., *Current Park's Vector Approach in the Induction Motor On-Line Monitoring and Diagnosis*, Proc. of 14th Intern. Confer. EDPE'03, High Tatras, Slovak Rep., 2003, CD.
- [173] KOWALSKI Cz., ANTAL M., *Wykrywanie uszkodzeń elementów tożysk tocznych silników indukcyjnych na podstawie analizy widmowej przyspieszenia drgań*, Prace Naukowe IMNIPE, nr 54, seria Studia i Materiały, nr 23, 2003h, s. 249–260.
- [174] KOWALSKI Cz. T., WĄSIEL M., BIALIK J., *Wykrywanie uszkodzeń mechanicznych w napędach z silnikami indukcyjnymi dużej mocy*, Mater. X Symp. Podstawowe Problemy Energoelektroniki i Elektromechaniki PPEE'03, Wisła, 2003, s. 191–198.
- [175] KOWALSKI Cz.T., SZABAT K., *Zastosowanie analizy falkowej do wykrywania uszkodzeń w układach napędowych z silnikami indukcyjnymi*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME Komel, nr 69, 2004, s. 117–122.
- [176] KOWALSKI Cz.T., PAWLAK M., *Zastosowanie metody analizy wektora przestrzennego prądu stojana do wykrywania uszkodzeń w silnikach indukcyjnych*, Przegląd Elektrotechniczny, nr 7–8, 2004, s. 771–777.
- [177] KOWALSKI Cz.T., PAWLAK M., *Application of artificial intelligence methods for rotor faults detection of the induction motor*, Acta Electrotechnica et Informatica, t. 1, 2004, s. 35–41.
- [178] KOWALSKI Cz.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.
- [179] KOWALSKI Cz.T., *Diagnosis of the induction motor rolling bearings using neural networks*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych PWR., seria Studia i Materiały nr 24, z. 56, 2004, s. 219–228.
- [180] KOWALSKI Cz.T., *Metody monitorowania i diagnostyki napędów z silnikami indukcyjnymi – stan obecny i tendencje rozwojowe*, Mater. IX Symp. Energoelektronika w Nauce i Dydaktyce ENID'2004, Poznań, 2004, s. 95–106.
- [181] KRAL C., PIRKER F., *Vienna monitoring method – detection of faulty rotor bars by means of portable measurement system*, Proc. Intern. Confer. on Electrical Machines ICEM'2000, Espoo, Finland, 2000, t. 2, s. 1110–1114.
- [182] KRAL C., PIRKER F., PASCOLI G., OBERUGGENBERGER H., *Influence of rotor cage fault detection by means of the Vienna Monitoring Method*, Proc. Intern. Conf. on Electrical Machines ICEM'2002, Brugge, Belgium, 2002, CD.
- [183] KRATOCHWIL Z., *Wykrywanie uszkodzeń uzwojeń klatkowych silników indukcyjnych*, Wiadomości Elektrotechniczne, nr 15, 1985, s. 355–359.
- [184] KUCHARSKI T., *System pomiaru drgań mechanicznych*, WNT Warszawa 2002.
- [185] LEITH D., DEANS N., STEWARD I.D., *Condition Monitoring of Electrical Machines Using Real Time Expert Systems*, Proc. Intern. Confer. on Electrical Machines ICEM'88, Pisa, Italy, 1988, s. 297–302.
- [186] LEGOWSKI S.F., ULA A.H., TRZYNADLOWSKI A.M., *Instantaneous stator power as a medium for the signature analysis of induction motors*, Trans. on Ind. Applications, t. 32, nr 4, 1996, s. 904–909.
- [187] LI B., CHOW M.Y., TIPSUWAN Y., HUNG J.C., *Neural Network Based Motor Rolling Bearing Fault Diagnosis*, IEEE Trans. on Industrial Electronics, t. 47, nr 5, 2000, s. 1060–1069.

- [188] ŁOBOS T., *Fast estimation of symmetrical components in real time*, IEE Proceedings C, t. 139, nr 1, January 1992, s. 27–30.
- [189] ŁACZKOWSKI R., *Wibroakustyka maszyn i urządzeń*, WNT, Warszawa 1983.
- [190] MASTERS T., *Sieci neuronowe w praktyce*, Wydawnictwa Naukowo-Techniczne, Warszawa 1993.
- [191] MELERO M.G., CABANAS M.F., ORCAJO G.A., CANO J.M., CAPOLINO G.A., *An Automated Insulation Failure Detection System for Working Induction Motors*, Proc. of European Power Electronics. Confer EPE' 1999, Lausanne, France, 1999, CD.
- [192] MELERO M.G., CABANAS M.F., FAYA F.R., ROJAS C.H., *Electromagnetic Torque Harmonics for On-line Interturn Short Circuits Detecton in Squirrel Cage Induction Motors*, Proc. of European Power Electronics. Confer. EPE' 1999, Lausanne, France, 1999, CD.
- [193] MELERO M.G., CAPOLINO G.A., CABANAS M.F., *The ability of on-line tests to detect interturn short-circuits in squirrel cage motors*, Intern. Conf. on Electrical Machines ICEM'2000, Espoo, Finland, 2000, s. 771–775.
- [194] MILIMONFARED J., KELK H.M., AMINASSIANS A.D., NANDI S., TOLIYAT H.A., *A Novel Approach for Broken Rotors Bar Detection in Cage Induction Motors*, IEEE Trans. on Industry. Applications, t. 35, nr 5, 1999, s. 1000–1006.
- [195] MISITI M., MISITI Y., OPPENHEIM G., POGGI J.M., *Wavelet Toolbox for Use with MATLAB. User's Guide*, The MathWorks 2002.
- [196] MOREL J., *Drgania maszyn i diagnostyka ich stanu technicznego*, Polskie Towarzystwo Diagnostyki Technicznej, Warszawa, 1994.
- [197] NANDI S., TOLIYAT H.A., *Condition Monitoring and Fault Diagnosis of Electrical Machines – A Review*, Conf. Rec. IEEE-IAS Annu. Meeting, Phoenix, AZ, Oct. 1999, s. 197–204.
- [198] 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, t. 16, nr 3, 2001, s. 253–260.
- [199] NANDI S., TOLIYAT H.A., *Novel Frequency-Domain-Based Technique to Detect stator interturn Faults in Induction Machines Using Stator-Induced Voltages After Switch-Off*, IEEE Trans. on Ind. Applications, t. 38, nr 1, 2002, s. 101–109.
- [200] NEJJARI H., BENBOUZID M., *Application of Fuzzy Logic to Induction Motors Condition Monitoring*, IEEE Power Engineering Review, June 1999, s. 52–54.
- [201] NEJJARI H., BENBOUZID M., *Monitoring and Diagnosis of Induction Motors Electrical Faults Using a Current Park's Vector Pattern Learning Approach*, IEEE Trans. on Industry Applications, t. 36, nr 3, 2000, s. 730–735.
- [202] NOGA M., *Analizy awaryjne związane z wewnętrzną niesymetrią silników asynchronicznych*, Zeszyty Naukowe AGH Elektryfikacja i Mechanizacja Górnictwa i Hutnictwa, zesz. 68, 1975.
- [203] NOGA M., *Diagnostyka Maszyn Elektrycznych*, Zesz. Nauk. AGH, Elektrotechnika, t. 8, zesz. 3–4, 1989, s. 489–497.
- [204] NOGA M., SKWARCZYŃSKI J., *Wykorzystanie kontroli symetrii pola szczelinowego w diagnostyce maszyn prądu przemiennego*, Zesz. Nauk. AGH, Elektrotechnika, t. 9, zesz. 3–4, 1990, s. 405–416.
- [205] NOGA M., RAMS W., RUSEK J., SKWARCZYŃSKI J., *Metody i przyrządy do diagnostyki obwodów maszyn elektrycznych indukcyjnych i synchronicznych*, Zeszyty Problemowe – Maszyny Elektryczne BOBRME Komel, Nr 46, 1993, s. 41–48.
- [206] NYKLIŃSKI A., RAMS W., *Wykrywnie uszkodzeń klatek w wirnikach silników indukcyjnych*, Zeszyty Naukowe AGH, Elektrotechnika, t. 9, z. 12, 1988, s. 405–416.
- [207] NYKLIŃSKI A., RAD M., *Sztuczne sieci neuronowe w wykrywaniu uszkodzeń klatki silników indukcyjnych*, Zeszyty Problemowe – Maszyny Elektryczne, BOBRME Komel, nr 66, 2003, s. 81–83.

- [208] OBAID R.R., HABETLER T.G., *Effect of Load on Detecting Mechanical Faults in Small Induction Motors*, Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'03, Atlanta, USA, 2003, s. 307–311.
- [209] OSOWSKI S., *Sieci neuronowe*, Oficyna wydawnicza Politechniki Warszawskiej, Warszawa, 1994.
- [210] OSOWSKI S., *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa, 1996.
- [211] ORŁOWSKA-KOWALSKA T., KOWALSKI Cz.T., *Obliczanie strumienia silnika asynchronicznego za pomocą obserwatora stanu*, Mater. V Krajow. Seminar. Rozwój Teoretycznych Podstaw Optymalizacji Zautomatyzowanych Układów Napędu Elektrycznego, Kraków–Karniowice, 1987, s. 229–240.
- [212] ORŁOWSKA-KOWALSKA T., *Obserwatory zmiennych stanu i parametrów w układach sterowania silników indukcyjnych klatkowych*, Prace Naukowe Instytutu Układów Elektromaszynowych Politechniki Wrocławskiej, seria Monografie, Wydawnictwo Politechniki Wrocławskiej, Wrocław 1990.
- [213] ORŁOWSKA-KOWALSKA T., KOWALSKI Cz.T., *Odtwarzanie wektora zmiennych stanu silnika indukcyjnego za pomocą obserwatorów nieliniowych*, Archiwum Elektrotechniki, 1991, t. 40, z. 1, s. 151–152.
- [214] ORŁOWSKA-KOWALSKA T., KOWALSKI Cz.T., *Neural Network based flux estimators for the induction motor*, Proc. of Int. Conf. on Power Electronics and Motion Control PEMC'96, Budapest, Hungary, 1996, s. 187–191.
- [215] ORŁOWSKA-KOWALSKA T., *Bezczujnikowe układy napędowe z silnikami indukcyjnymi*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2003.
- [216] OVASKA S., SZTANDERA L. (eds.), *Soft computing in industrial electronics*, Physica–Verlag, Springer–Verlag Company, 2002.
- [217] PAOLETTI G.J., ROSE A., *Improving Existing Motor Protection for Medium Voltage Motors*, IEEE Trans. on Industry Appl., t. 25, nr 3, 1989, s. 456–464.
- [218] PATTON R., FRANK P., CLARK R. (eds.), *Fault diagnosis in dynamic systems. Theory and Applications*, Prentice Hall, Englewood Cliffs, New York 1989.
- [219] PAWLAK M., KOWALSKI Cz.T., *Zastosowanie neuronowego detektora do monitorowania i diagnostyki wirników klatkowych silników indukcyjnych*, Zeszyty Problemowe – Maszyny Elektryczne, BOBRME Komel, nr 69, 2004, s. 111–116.
- [220] PAWLAK M., *Uproszczony model silnika klatkowego z uszkodzonym wirnikiem*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych PWr., seria Studia i Materiały, nr 24, Zeszyt 56, 2004, s. 229–240.
- [221] PAYA B.A., ETAT I.I., *Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor*, Mechanical Systems and Signal Processing, 1997, s. 751–765.
- [222] PENG Z.K., CHU F.L., *Application of the wavelet transform in machine condition monitoring and fault diagnosis: a review with bibliography*, Mechanical Systems and Signal Processing, 2004, s. 199–221.
- [223] PENMAN J., DEY M.N., TAIT A.J., BRYAN W.E., *Condition monitoring of electrical drives*, IEE Proceedings, t. 133, Pt. B, nr 3, May 1986, s. 142–148.
- [224] PENMAN J., YIN C.M., *The application of NN in identifying faults in induction machines*, International Conference on Electrical Machines ICEM'92, t. 3, Manchester, U.K., 1992, s. 1256–1260.
- [225] PENMAN J., STAVROU A., YIN C.M., JIANG H., HATZIPANTELIS E., *Machine Diagnostics with ANN's: Possibilities and Problems*, Proc. Intern. Conf. on Electrical Machines ICEM'94, Paris, France, 1994, c. 4, s. 364–368.
- [226] PENMAN J., SEDDING H.G., LLOYD B.A., FINK W.T., *Detection and location of interturn short circuits in the stator windings of operating motors*, IEEE Trans. on Energy Conversion, t. 9, nr 4, Dec. 1994, s. 652–658.

- [227] PENMAN J., YIN C.M., *Feasibility of using unsupervising learning artificial neural networks for the condition monitoring of electrical machines*, IEE Proc. Electr. Power Appl., t. 141, nr 6, 1994, s. 317–322.
- [228] PFEUFER T., AYOUBI M., *Application of hybryd neuro-fuzzy system to fault diagnosis o an automotive electromechanical actuator*, Fuzzy Sets and Systems, t. 89, 1997, s. 351–360.
- [229] PFEUFER T., *Application of model-based fault detection and diagnosis to the quality assurance of an automotive actuator*, Control Engineering Practice, t. 5, nr 5, 1997, s. 703–708.
- [230] PIECZYŃSKI A., *Komputerowe systemy diagnostyczne procesów przemysłowych*, Wyd. Politechniki Zielonogórskiej, Zielona Góra, 1999.
- [231] RAMS W., SKWARCZYŃSKI J., *Wykrywanie asymetrii wewnętrznych w maszynach prądu przemiennego*, Zeszyty Naukowe AGH, Elektrotechnika, t. 8, Zeszyt 3–4, Kraków 1989, s. 499–504.
- [232] RAMS W., RUSEK J., SKWARCZYŃSKI J., *Inspection of the Radial Magnetic Pull in Induction Machines*, Proc. XXX Intern. Symp. on Electrical Machines, SME'94, Kazimierz Dolny, 1994, s. 395–401.
- [233] RAMS W., RUSEK J., WIERZCHOLSKI M., *Kontrola symetrii klatki w silnikach indukcyjnych przy zasilaniu dwufazowym*, Zeszyty Problemowe – Maszyny Elektryczne, BOBRME Komel, nr 50, 1995, s. 92–95.
- [234] RAMS W., RUSEK J., *Praktyczna diagnostyka maszyn indukcyjnych klatkowych*, Zeszyty Problemowe – Maszyny Elektryczne, BOBRME Komel, nr 48, 2004, s. 1–5.
- [235] RAZIK H., ABED A., DIDIER G., WEINACHTER F., REZZOUG A., *Analysis of current spectral of induction motor for diagnostic purposes*, Proc. Intern. Conf. on Electrical Machines ICEM'02, Brugge, Belgium, 2002, CD.
- [236] RILEY C.M., LIN B.K., HABETLER T.G., KLIMAN G.B., *Stor Current Harmonics and Their Causal Vibrations: A Preliminary Investigation of Sensorless Vibration Monitoring Applications*, IEEE Trans. on Industry Applications, t. 35, nr 1, 1999, s. 94–98.
- [237] ROŚOŁOWSKI E., *Cyfrowe przetwarzanie sygnałów w automatyce elektroenergetycznej*, Akademicka Oficyna wydawnicza EXIT, Warszawa 2002.
- [238] ROZWADOWSKI T., *Diagnostyka techniczna obiektów złożonych*, WAT, Warszawa 1983.
- [239] RUBINI R., MENEGHETTI U., *Application of the envelope and wavelet transform analysis for the diagnosis of incipient faults in ball bearings*, Mechanical Systems and Signal Processing, 2001, s. 287–302.
- [240] RUTKOWSKA D., PILIŃSKI M., RUTKOWSKI L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN, Warszawa – Łódź 1997.
- [241] RUSEK J., *Siła elektromotoryczna i strumień sprzężony z cewkami pomiarowymi jako wskaźnik uszkodzeń wirnika silników indukcyjnych*, Zeszyty Naukowe AGH nr 1190, Elektrotechnika, nr 12, Kraków 1988.
- [242] RUSEK J., *Induction Machine Model Aimed At Vibroacoustical Diagnosis*, Elektrotechnika, t. 9, Zeszyt 3–4, 1990, s. 433–446.
- [243] RUSEK J., *Reflection of Eccentricities in Spectral Composition of Currents of Induction Machines*, Proc. Intern. Conf. on Electrical Machines ICEM'96, Paris, France, 1996, s. 470–475.
- [244] RUSEK J., *Komputerowa analiza maszyny indukcyjnej z wykorzystaniem bilansu harmoniczných*, AGH Uczelniane Wydawnictwa Naukowo-Techniczne, Kraków 2000.
- [245] SANZ-BOBI M.A., DONAIRE M.A., *Diagnosis of Electrical Motors Using Artificial Neural Networks*, Proc. of IEEE Intern. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'99, Gijon, Spain, 1999, s. 369–374.
- [246] SCHOEN R.R., HABETLER T.G., KAMRAN F., BARTHELD R.G., *Motor Bearing Damage Detection Using Stator Current Monitoring*, IEEE Trans. on Industry Applications, t. 31, nr 6, Nov./Dec. 1995, s. 1274–1279.

- [247] SCHOEN R.R., LIN B.K., HABETLER T.G., SCHLAG J.H., FARAG S., *An Unsupervised, On-line System for Induction Motor Fault Detection Using Stator Current Monitoring*, IEEE Trans. on Industry Applications, t. 31, nr 6, Nov./Dec. 1995, s. 1280–1286.
- [248] SCHOEN R.R., HABETLER T.G., *Effects of time-varying loads on rotor fault detection in induction machines*, IEEE Trans. on Industry Applications, t. 31, nr 5, July/Aug. 1995, s. 900–906.
- [249] SCHOEN R.R., HABETLER T.G., *Evaluation and Implementation of a System to Eliminate Arbitrary Load Effects in Current-Based Monitoring of Induction Machines*, IEEE Trans. on Industry Applications, t. 33, nr 6, Nov./Dec., 1997, s. 1571–1577.
- [250] SEKER S., AYAZ E., *Feature extraction related to bearing damage in electric motors by wavelet analysis*, Journal of the Franklin Institute, 2003, s. 125–134.
- [251] SINGH G.K., SA'AD AHMED SALEH AL. KAZAZ, *Induction machine drive condition monitoring and diagnostic research – a survey*, Electric Power Systems Research, t. 64, 2003, s. 145–158.
- [252] 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, s. 119–136.
- [253] SOBCZYK T.J., WEINREB K., *Synthesis of mathematical models of induction machines with non uniform air gap*, Proc. Intern. Conf. on Electrical Machines ICEM'88, Pisa, Italy, 1988, s. 213–218.
- [254] SOBCZYK T.J., WEINREB K., *A general approach to on-line current-based diagnostics of induction motors*, Proc. XXXII Intern. Symp. on Electrical Machines, SME'96, Cracow, 1996, s. 11–16.
- [255] 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, s. 79–84.
- [256] SOBCZYK T.J., WEINREB K., IZWORSKI 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, s. 408–413.
- [257] SOBCZYK T.J., *Metodyczne aspekty modelowania matematycznego maszyn indukcyjnych*, WNT, Warszawa 2004.
- [258] 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, t. 8, nr 4, December 1993, s. 762–768.
- [259] SORDYL F., *Diagnostyka łożysk tocznych silników elektrycznych*, Materiały konferencyjne III Sympozjum Technicznego, BOBRME, Ustroń, 1994.
- [260] SUN Q., TANG Y., *Singularity analysis using continuous wavelet transform for bearing fault diagnosis*, Mechanical Systems and Signal Processing 2002, s. 1025–1041.
- [261] SWĘDROWSKI L., *Neural networks in the induction motors rotor cage diagnostics*, Metrol. and Measurement Syst., 2002, s. 391–400.
- [262] SWĘDROWSKI L., *Nowa metoda diagnostyki łożysk silnika indukcyjnego oparta na pomiarze i analizie widmowej prądu zasilającego*, ser. Monografie nr 54, Wyd. Politechniki Gdańskiej, Gdańsk 2005.
- [263] SZCZĘŚNY R., PIQUET H., KURZYŃSKI P., *Fault detection and diagnosis in electrical drives*, Proc. of 7th European Power Electronics Conference EPE'97, Trondheim, Norway 1997, t. 2, s. 995–1000.
- [264] SZYMANIEC S., *Diagnostyka eksploatacyjna klatek silników indukcyjnych*, Mater. XXX Sympozjum Maszyn Elektrycznych SME'94, Kazimierz, 1994, s. 478–485.
- [265] SZYMANIEC S., DZIERŻANOWSKI A., *Diagnostyka eksploatacyjna silników indukcyjnych*, II Krajowa Konferencja Postępy w Elektrotechnice Stosowanej PES-2, 1999.
- [266] TADEUSIEWICZ R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1995.
- [267] TADEUSIEWICZ R., *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998.

- [268] 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, s. 43–54.
- [269] TALLAM R.M., HABETLER G., HARLEY R.G., *Limitation of model-based methods for electric machine condition monitoring*, Proc. of IEEE Intern. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'01, Grado, Italy, 2001, s. 361–366.
- [270] TAVNER P.J., PENMAN J., *Condition monitoring of electrical machines*, Research Studies Press Ltd, Leathwoth, John Wiley & Sons Inc., Hertfordshire – England, 1987.
- [271] THOMSON W.T., *Diagnosis Faults in Induction Motors – Engineering Ideas*, Electrical Review, t. 215, nr 17, Nov., 1984, s. 21–22.
- [272] THOMSON W.T., *On-line Current Monitoring the Influence of Mechanical Loads or a Unique Rotor Design on the Diagnosis of Broken Bars in Induction Motors*, Proc. of Inter. Confer. on Electrical Machines ICEM'92, Manchester, UK, s. 1236–1240.
- [273] THOMSON W.T., *On-line analysis of the current signal to diagnose mechanical shaft misalignment in asynchronous motor drive systems*, Mater. XXX Symp. Maszyn Elektrycznych SME'94, Kazimierz, 1994, s. 505–510.
- [274] THOMSON W.T., *On-line current monitoring to diagnose shaft misalignment in three-phase induction motor drive systems*, Proc. Intern. Conf. on Electrical Machines ICEM'94, Paris, France, 1994, s. 238–243.
- [275] THOMSON W.T., BARBOUR A., *On-line Current Monitoring and Application of a Finite Element Method to predict the Level of Static Airgap Eccentricity in Three-Phase Induction Motors*, IEEE Trans. on Energy Conversion, t. 13, nr 4, December 1998, s. 347–357.
- [276] 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, t. 14, nr 4, December 1999, s. 1372–1378.
- [277] THOMSON W.T., *A review of on-line condition monitoring techniques for three-phase squirrel-cage induction motors – past, present and future*, Proc. of IEEE Int. Symp. on Diagnostics for Electrical Machines, Power Electronics and Drives SDEMPED'99, Gijon, Spain, 1999, s. 3–18.
- [278] TRZYNADLOWSKI A., GHASSEMZADEH M., LEGOWSKI S.F., *Diagnostics of Mechanical Abnormalities in Induction Motors Using Instantaneous Electric Power*, IEEE Trans. on Energy Conversion, t. 14, nr 4, Dec. 1999, s. 1417–1423.
- [279] TRZYNADLOWSKI A., RITCHIE E., *Comparative Investigation of Diagnostic Media for Induction Motors: A Case of Rotor Cage Faults*, IEEE Trans. on Industrial Electr., t. 47, nr 5, 2000, s. 1092–1099.
- [280] TUNIA H., KĄŻMIERKOWSKI M.P., *Automatyka Napędu Przekształtnikowego*, PWN Warszawa 1987.
- [281] YE Z., WU B., *Current Signature Analysis of induction motor mechanical faults by wavelet packet decomposition*, IEEE Trans. on Industrial Electronic, t. 50, nr 6, 2003, s. 1217–1228.
- [282] WACH P., *Niesymetrie wewnętrzne maszyn elektrycznych*, ZN WSI Opole nr 77, Elektryka nr 19, 1982.
- [283] WATSON J.F., DORRELL D.G., *The Use of Finite Element Methods to Improve Techniques for the Early Detection of Faults in 3-phase Induction Motors*, IEEE Trans. on Energy Conversion, t. 14, nr 3, Sept. 1999, s. 635–660.
- [284] WATTON J., PHAM D.T., *An artificial NN based approach to fault diagnosis and classification of fluid power systems*, J. Syst. and Control Engineering, t. 211, nr 4, 1997, s. 307–317.
- [285] WEERASINGHE M., GOMM J.B., WILLIAMS D., *Neural networks for fault diagnosis of nuclear fuel processing plant at different operating points*, Control Engineering Practice, t. 6, nr 2, 1998, s. 281–289.
- [286] WEINREB K., *Modele matematyczne maszyn indukcyjnych z nierównomierną szczeliną powietrzną. Modelowanie matematyczne zjawisk elektromagnetycznych w maszynach elektrycznych*, Politechnika Krakowska, Monografia, nr 169, Kraków 1994, s. 57–87.

- [287] WILLIAMSON S., MIRZOIAN K., *Analysis of cage induction motors with stator winding faults*, IEEE Trans. on Power Apparatus and Systems, t. 104, nr 7, 1985, s. 1838–1842.
- [288] WIŚNIEWSKI W., *Diagnostyka techniczna wytwórczych urządzeń energetycznych w elektrowniach*, PWN, Warszawa 1991.
- [289] VAS P., *Electrical Machines and Drives. A Space-Vector Theory Approach*, Oxford University Press, 1992.
- [290] VAS P., *Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines*, Oxford University Press, Oxford 1993.
- [291] VAS P., *Artificial-Intelligence-Based Electrical Machines and Drives*, Oxford University Press, 1999.
- [292] VEMURI A.T., POLICARPOU M.M., *Neural-Network-based robust fault diagnosis in robotic systems*, IEEE Trans. Neural Networks, t. 8, nr 6, 1997, s. 1410–1420.
- [293] YE Z., WU B., SADEGHIAN A., *Current Signature Analysis of induction motor mechanical faults by wavelet packet decomposition*, IEEE Trans. on Industrial Electronics, t. 50, nr 6, December 2003, s. 1217–1228.
- [294] ŻURADA J., BARSKI M., JĘDRUCH W., *Sztuczne sieci neuronowe*, Wydawnictwo Naukowe PWN, Warszawa 1996.

Normy

- [295] PN-EN 60034-1:2001, *Maszyny elektryczne wirujące. Dane znamionowe i parametry*.
- [296] PN-IEC 34-14:1998, *Drgania mechaniczne określonych maszyn o wzniosach osi wału 56 mm i większych*.
- [297] PN-90/N-01358, *Drgania. Metody pomiarów i oceny drgań maszyn*.
- [298] PN-ISO 10816, *Ocena drgań maszyn na podstawie pomiarów na częściach niewirujących*.
- [299] PN-ISO 10816-1, *Drgania mechaniczne. Ocena drgań maszyny na podstawie pomiarów na częściach wirujących*.

Dokumentacje techniczne

- [300] Control Desk, *Experimental Guide Control Desk for DS1102*, dSPACE 1999.
- [301] DS1102, *Hardware Reference DS1102 Controller Board*, dSPACE 1999.
- [302] RTW, *Real-Time Workshop for use with SIMULINK – User's Guide*, The MathWorks Inc., 2000.

Monitoring and diagnostics of the induction motor faults using neural networks

In the monograph, the basic problems connected with the monitoring and diagnostics of induction motors using classical fault detection methods, supported by new possibilities generated by artificial neural networks, have been presented. The main sources of electrical and mechanical faults of the squirrel cage induction motors are described. Basic methods of fault detection used in the industrial diagnostics of induction machines are characterized. The main attention was focused on the monitoring and diagnosis methods based on the frequency analysis of the motor current, the axial flux and mechanical vibration signals.

The possibility of applying the neural networks to fault detection in the stator, rotor and bearings of the induction motors is presented. A methodology for the design of neural detectors, supporting the classical diagnostics methods and making fault detection and evaluation process reliable, has been developed. Special attention is focused on the application of multilayer perceptron and Kohonen networks for the design of fault detectors, used as fault classifiers. Various structures of neural detectors of rotor cages, stator inter-turn short-circuits and rolling bearings, trained using experimental data obtained from a real machine, have been tested and evaluated.

It has also been proved that wavelet analysis applied to the initial preprocessing of the diagnostic signals, is a useful and powerful tool for collection of the training and testing data for neural fault detectors.

The developed neural detectors of the rotor and bearing faults were implemented in the laboratory test bench using a digital signal processor, which performed the data acquisition of the stator current and/or vibration signals, Fast Fourier Transformation of Wavelet Transformation of the diagnostic signals in the real-time operation. Experimental results of laboratory tests for are demonstrated and evaluated.

Verified by Ewa Sobesto

Spis treści

Wykaz ważniejszych oznaczeń	4
1. Wstęp	6
1.1. Diagnostyka techniczna obiektów przemysłowych	6
1.2. Podstawowe zagadnienia monitorowania i diagnostyki silników indukcyjnych	10
1.2.1. Obsługa techniczna maszyn i układów napędowych	10
1.2.2. Diagnostyka silników indukcyjnych z zastosowaniem modeli matematycznych	15
1.2.3. Diagnostyka silników indukcyjnych oparta na analizie sygnałów pomiarowych	18
1.2.4. Diagnostyka silników indukcyjnych z zastosowaniem metod sztucznej inteligencji	19
1.3. Przegląd literatury dotyczącej monitorowania i diagnostyki silników indukcyjnych	20
1.4. Cel i zakres pracy	27
2. Przegląd podstawowych uszkodzeń napędów z silnikami indukcyjnymi	30
2.1. Rodzaje, przyczyny i statystyka uszkodzeń	30
2.2. Uszkodzenia uzwojeń wirników klatkowych	35
2.3. Uszkodzenia uzwojeń stojana	37
2.4. Uszkodzenia mechaniczne	40
2.5. Podsumowanie	43
3. Eksploatacyjne metody monitorowania i diagnostyki napędów z silnikami indukcyjnymi	44
3.1. Charakterystyka sygnałów diagnostycznych	44
3.2. Analiza sygnałów – podstawowa metoda diagnostyki eksploatacyjnej silników indukcyjnych	48
3.3. Wykrywanie uszkodzeń wirników klatkowych	50
3.3.1. Charakterystyka zjawisk zachodzących w silniku indukcyjnym z uszkodzonym wirnikiem	50
3.3.2. Wykrywanie uszkodzeń wirnika na podstawie analizy widmowej prądu stojana	54
3.3.3. Zastosowanie analizy wektora przestrzennego prądu stojana do wykrywania uszkodzeń wirnika	62
3.4. Wykrywanie uszkodzeń stojana	65
3.4.1. Uwagi ogólne	65
3.4.2. Zastosowanie strumienia poosiowego do wykrywania zwarć zwojowych	66
3.4.3. Zastosowanie momentu elektromagnetycznego do wykrywania zwarć zwojowych	71
3.4.4. Zastosowanie składowych symetrycznych do wykrywania zwarć zwojowych	72
3.5. Wykrywanie uszkodzeń mechanicznych	77
3.5.1. Uwagi ogólne	77
3.5.2. Zastosowanie analizy prądu stojana do wykrywania uszkodzeń mechanicznych	79
3.5.2.1. Wykrywanie ekscentryczności wirnika	79
3.5.2.2. Wykrywanie uszkodzeń łożysk tocznych	82

3.5.3. Zastosowanie analizy drgań mechanicznych	83
3.6. Podsumowanie	90
4. Metodyka wykorzystania sieci neuronowych do monitorowania i diagnostyki napędów z silnikami indukcyjnymi	94
4.1. Podstawowe informacje o sztucznych sieciach neuronowych	94
4.2. Sieci neuronowe w diagnostyce	101
4.3. Metodyka uczenia i testowania neuronowych detektorów uszkodzeń	104
4.4. Wstępne przetwarzanie sygnałów pomiarowych dla neuronowych detektorów uszkodzeń	110
4.4.1. Uwagi ogólne	110
4.4.2. Nieparametryczne metody wyznaczania cech sygnałów diagnostycznych	112
4.4.2.1. Przekształcenie Fouriera	112
4.4.2.2. Przekształcenie falkowe	115
4.4.3. Formowanie i przetwarzanie zbiorów uczących	120
4.5. Podsumowanie	123
5. Neuronowe detektory uszkodzeń silników indukcyjnych	125
5.1. Wprowadzenie	125
5.2. Neuronowe detektory uszkodzeń wirnika klatkowego	126
5.2.1. Charakterystyka badań eksperymentalnych uszkodzonych wirników	126
5.2.2. Perceptronowy detektor uszkodzeń wirników klatkowych	130
5.3. Neuronowe detektory uszkodzeń stojana	137
5.3.1. Badania eksperymentalne badań zwarć stojanowych	137
5.3.2. Perceptronowy detektor zwarć międzyzwojowych	143
5.3.3. Klasyfikator zwarć międzyzwojowych oparty na sieci Kohonena	149
5.4. Neuronowe detektory uszkodzeń łożysk tocznych	155
5.4.1. Badania eksperymentalne łożysk tocznych	155
5.4.2. Perceptronowe detektory uszkodzeń łożysk tocznych	159
5.4.3. Klasyfikator uszkodzeń łożysk oparty na sieci Kohonena	170
5.5. Podsumowanie	171
6. Zastosowanie analizy falkowej do wstępnego przetwarzania sygnałów dla neuronowych detektorów uszkodzeń silników indukcyjnych	173
6.1. Uwagi wstępne	173
6.2. Zastosowanie transformaty falkowej do wykrywania uszkodzeń wirnika	175
6.3. Zastosowanie transformaty falkowej do wykrywania uszkodzeń łożysk tocznych	179
6.4. Neuronowe detektory uszkodzeń wirnika i łożyska	184
6.5. Podsumowanie	187
7. Modele laboratoryjne neurodetektorów uszkodzeń silników indukcyjnych	189
7.1. Uwagi wstępne	189
7.2. Neurodetektor uszkodzeń wirników klatkowych	191
7.3. Neurodetektor uszkodzeń łożysk tocznych	194
7.4. Podsumowanie	195
8. Uwagi i wnioski końcowe	197
Załącznik nr 1	201
Załącznik nr 2	202
Załącznik nr 3	205
Literatura	206
Streszczenie w języku angielskim	222

Contents

List of symbols	4
1. Introduction	6
1.1. Technical diagnosis of industrial plants	6
1.2. Basic problems of the monitoring and diagnosis of induction motors	10
1.2.1. Technical maintenance of electrical machines and drives	10
1.2.2. Diagnosis of the induction motors based on mathematical models	15
1.2.3. Diagnosis of the induction motors based on the measurement signal analysis	18
1.2.4. Diagnosis of the induction motors based on the artificial intelligence methods	19
1.3. Overview of the literature on monitoring and diagnosis of the induction motors	20
1.4. Main goal and topics of the monograph	27
2. The overview of basic faults of the induction motor drives	30
2.1. Fault kinds, causes and statistics	30
2.2. Rotor faults of squirrel-cage rotors	35
2.3. Stator winding faults	37
2.4. Mechanical faults	40
2.5. Summary	43
3. Exploitation methods of monitoring and diagnosis of the induction motor drives	44
3.1. Characteristic of the diagnosis signals	44
3.2. Signal analysis – the basic diagnostic method of the induction motors	48
3.3. Fault detection of squirrel-cage rotors	50
3.3.1. Characteristic of phenomena in the induction motor with faulted rotor	50
3.3.2. Detection of the rotor faults based on the current spectrum analysis	54
3.3.3. Application of space vector analysis method to the rotor fault detection	62
3.4. Stator fault detection	65
3.4.1. General remarks	65
3.4.2. Application of the axial flux to the detection of stator short-circuit turns	66
3.4.3. Application of electromagnetic torque to the detection of stator short-circuit turns	71
3.4.4. Application of symmetrical components to the detection of stator short-circuit turns	72
3.5. Detection of mechanical faults	77
3.5.1. General remarks	77
3.5.2. Application of the current spectrum analysis to mechanical fault detection	79
3.5.2.1. Detection of the rotor eccentricity	79
3.5.2.2. Detection of the rolling bearing faults	82
3.5.3. Application of the mechanical vibration analysis	83
3.6. Summary	90
4. Methodology of neural network application to monitoring and diagnosis of the induction motor drives	94

4.1. Basic information on neural networks	94
4.2. Neural networks in diagnostics	101
4.3. Learning and testing methods of neural fault detectors	104
4.4. Preprocessing of measurement signals for neural fault detectors	110
4.4.1. General remarks	110
4.4.2. Nonparametric methods of determination of the diagnostic signatures	112
4.4.2.1. Fourier transformation	112
4.4.2.2. Wavelet transformation	115
4.4.3. Preparation and processing of testing sets	120
4.5. Summary	123
5. Neural fault detectors of the induction motors	125
5.1. Introduction	125
5.2. Neural fault detectors of squirrel-cage rotor	126
5.2.1. Characteristics of experimental tests of faulted rotors	126
5.2.2. Perceptron-type fault detector of squirrel-cage rotors	130
5.3. Neural detectors of stator faults	137
5.3.1. Characteristics of experimental tests of the stator short-circuit turns	137
5.3.2. Perceptron-type detector of inter-turn short circuits	143
5.3.3. Classifier of inter-turn short circuits based on the Kohonen network	149
5.4. Neural detectors of the rolling bearing faults	155
5.4.1. Characteristics of experimental tests of the faulted rolling bearings	155
5.4.2. Perceptron-type detectors of rolling bearing faults	159
5.4.3. Classifier of rolling bearing faults based on the Kohonen network	170
5.5. Summary	171
6. Application of the wavelet analysis in signal pre-processing for neural fault detectors of the induction motor	173
6.1. General remarks	173
6.2. Application of wavelet transformation to the rotor fault detection	175
6.3. Application of wavelet transformation to the rolling bearing fault detection	179
6.4. Neural detector of rolling bearing fault	184
6.5. Summary	187
7. Laboratory models of neural fault detectors of induction motors	189
7.1. General remarks	189
7.2. Neural detector of the squirrel-cage rotor faults	191
7.3. Neural detector of the rolling bearing faults	194
7.4. Summary	195
8. Final summary and conclusions	197
Appendix 1	201
Appendix 2	202
Appendix 3	205
Bibliography	206
Summary in English	222



PRACE NAUKOWE INSTYTUTU MASZYN,
NAPĘDÓW I POMIARÓW ELEKTRYCZNYCH
(wydane w latach 1999–2005)

- Nr 46, Monografie nr 12, P. Zieliński, K. Schoepp, *Prądnice synchroniczne o magnesach trwałych z rozszczepionymi biegunami*, Wrocław 1999
- Nr 47, Monografie nr 13, L. Antal, *Obliczenia elektromagnetyczne bezżłobkowych maszyn synchronicznych z nadprzewodzącym uzwojeniem wzbudzenia*, Wrocław 1999
- Nr 48, Studia i Materiały nr 20, SME 2000, *Badania maszyn elektrycznych*, Wrocław 2000
- Nr 49, Studia i Materiały nr 21, SME 2000, *Diagnostyka maszyn elektrycznych*, Wrocław 2000
- Nr 50, Studia i Materiały nr 22, SME 2000, *Modelowanie maszyn elektrycznych*, Wrocław 2000
- Nr 51, Monografie nr 14, K. Makowski, *Jednofazowe silniki indukcyjne z pomocniczym uzwojeniem zwartym w ujęciu obwodowo-polowym*, Wrocław 2000
- Nr 52, Monografie nr 15, K. Pieńkowski, *Analiza układów hamowania elektrycznego silników indukcyjnych klatkowych z przekształtnikami energoelektronicznymi*, Wrocław 2000
- Nr 53, Monografie nr 16, B. Ślusarek, *Dielektromagnesy Nd-Fe-B*, Wrocław 2001
- Nr 54, Studia i Materiały nr 23, *Zagadnienia maszyn, napędów i pomiarów elektrycznych*, Wrocław 2003
- Nr 55, Monografie nr 17, Z. Kłós, *Problematyka wzorcowania aparatury elektrometrycznej*, Wrocław 2004
- Nr 56, Studia i Materiały nr 24, *Zagadnienia maszyn, napędów i pomiarów elektrycznych*, Wrocław 2004



BIBLIOTEKA GŁÓWNA

324153L/1

Wydawnictwa Politechniki Wrocławskiej
są do nabycia w księgarni
„Tech”

Wybrzeże Wyspiańskiego 27, 50-370 Wrocław
budynek A-1 PWr., tel. (0-71) 321 32 52
Prowadzimy sprzedaż wysyłkową

ISSN 1733-0696