

AKADEMIA GÓRNICZO-HUTNICZA  
IM. STANISŁAWA STASZICA W KRAKOWIE

---

WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI, INFORMATYKI I ELEKTRONIKI

mgr inż. Jarosław Kozik

## **ROZPRAWA DOKTORSKA**

**DIAGNOSTYKA MASZYNY SYNCHRONICZNEJ  
Z ZASTOSOWANIEM METOD SZTUCZNEJ INTELIGENCJI**

Promotor:

Dr hab. inż. Zygfryd Głowacz, prof. AGH

Kraków, 2011

Składam serdeczne podziękowania Promotorowi  
dr hab. inż. Zygfrydowi Głowaczowi, prof. nadzw. AGH  
za pomoc przy pisaniu niniejszej pracy.

## SPIS TREŚCI

|                                                                                               |            |
|-----------------------------------------------------------------------------------------------|------------|
| <b>1. WSTĘP, CEL I TEZA PRACY.....</b>                                                        | <b>5</b>   |
| <b>2. MASZYNA SYNCHRONICZNA JAKO OBIEKT DIAGNOSTYCZNY.....</b>                                | <b>10</b>  |
| 2.1. BUDOWA MASZYN SYNCHRONICZNYCH .....                                                      | 10         |
| 2.1. ZASTOSOWANIA MASZYN SYNCHRONICZNYCH .....                                                | 13         |
| 2.3. USZKODZENIA MASZYN SYNCHRONICZNYCH .....                                                 | 14         |
| 2.4. KONSTRUKCJA BADANYCH MASZYN .....                                                        | 14         |
| <b>3. STANOWISKO BADAWCZO-POMIAROWE .....</b>                                                 | <b>17</b>  |
| 3.1. OPIS STANOWISKA POMIAROWEGO.....                                                         | 17         |
| 3.2. URZĄDZENIE DO REJESTRACJI SYGNAŁÓW .....                                                 | 19         |
| 3.2.1. <i>Przetworniki pomiarowe</i> .....                                                    | 21         |
| 3.2.2. <i>Filtry antyaliasingowe</i> .....                                                    | 22         |
| 3.2.3. <i>Układ zasilający</i> .....                                                          | 24         |
| 3.3. REJESTRACJA SYGNAŁÓW .....                                                               | 25         |
| 3.3.1. <i>Karta akwizycji danych</i> .....                                                    | 27         |
| 3.3.2. <i>Środowisko do rejestracji i obróbki danych</i> .....                                | 27         |
| 3.4. SZUMY I ZAKŁÓCENIA W TORZE POMIAROWYM.....                                               | 28         |
| <b>4. WYZNACZANIE SYMPTOMÓW USZKODZEŃ .....</b>                                               | <b>30</b>  |
| 4.1. METODYKA WYZNACZANIA SYMPTOMÓW USZKODZEŃ .....                                           | 30         |
| 4.2. STAN BEZAWARYJNY .....                                                                   | 32         |
| 4.3. ZWARCIE W ZEZWÓJACH TWORNIKA .....                                                       | 39         |
| 4.4. PRZERWA GAŁĘZI RÓWNOLEGŁEJ TWORNIKA.....                                                 | 49         |
| 4.5. ZWARCIE CEWKI OBWODU WZBUDZENIA .....                                                    | 58         |
| 4.6. PRZERWA CEWKI OBWODU WZBUDZENIA.....                                                     | 66         |
| <b>5. AUTOMATYCZNA SELEKCJA CECH.....</b>                                                     | <b>73</b>  |
| 5.1. ALGORYTMY POSZUKIWAŃ .....                                                               | 75         |
| 5.1.1. <i>Algorytmy kompletne</i> .....                                                       | 75         |
| 5.1.2. <i>Algorytmy heurystyczne</i> .....                                                    | 76         |
| 5.1.3. <i>Algorytmy stochastyczne</i> .....                                                   | 77         |
| 5.2. FUNKCJE KRYTERIALNE .....                                                                | 79         |
| 5.2.1. <i>Filtry</i> .....                                                                    | 79         |
| 5.2.2. <i>Metody opakowane</i> .....                                                          | 84         |
| 5.2.3. <i>Metody hybrydowe</i> .....                                                          | 85         |
| 5.2.4. <i>Metody wbudowane</i> .....                                                          | 85         |
| 5.2.5. <i>Metody rankingowe</i> .....                                                         | 86         |
| 5.3. WARUNEK ZATRZYMANIA .....                                                                | 86         |
| 5.4. WERYFIKACJA PODZBIORU CECH .....                                                         | 86         |
| <b>6. SELEKCJA CECH ZA POMOCĄ ALGORYTMU GENETYCZNEGO I MIARY ODLEGŁOŚCI MAHALANOBISA.....</b> | <b>87</b>  |
| 6.1. KODOWANIE CHROMOSOMU .....                                                               | 89         |
| 6.2. POPULACJA POCZĄTKOWA .....                                                               | 90         |
| 6.3. REPRODUKCJA OSOBNIKÓW .....                                                              | 90         |
| 6.4. KRZYŻOWANIE .....                                                                        | 93         |
| 6.5. MUTACJA .....                                                                            | 94         |
| 6.6. FUNKCJA PRZYSTOSOWANIA .....                                                             | 96         |
| 6.7. WYNIKI AUTOMATYCZNEJ SELEKCJI CECH .....                                                 | 97         |
| 6.7.1. <i>Wyniki selekcji dla zwarcia w grupie zezwojów twornika</i> .....                    | 101        |
| 6.7.2. <i>Wyniki selekcji dla przerwy jednej gałęzi równoległej twornika</i> .....            | 109        |
| 6.7.3. <i>Wyniki selekcji dla zwarcia cewki obwodu wzbudzenia</i> .....                       | 115        |
| 6.7.4. <i>Wyniki selekcji dla przerwy jednej cewki obwodu wzbudzenia</i> .....                | 123        |
| 6.8. OCENA SKUTECZNOŚCI AUTOMATYCZNEJ SELEKCJI CECH.....                                      | 129        |
| <b>7. KLASYFIKACJA AUTOMATYCZNA.....</b>                                                      | <b>130</b> |
| 7.1. KLASYFIKACJA NADZOROWANA .....                                                           | 130        |

|                                                                                        |            |
|----------------------------------------------------------------------------------------|------------|
| 7.2. KLASYFIKACJA NIENADZOROWANA .....                                                 | 133        |
| 7.3. NORMALIZACJA DANYCH.....                                                          | 134        |
| 7.4. METODY OCENY SKUTECZNOŚCI KLASYFIKACJI.....                                       | 136        |
| <b>8. NEURONOWY KLASYFIKATOR STANU MASZyny .....</b>                                   | <b>139</b> |
| 8.1. WIADOMOŚCI WSTĘPNE .....                                                          | 139        |
| 8.1.1. <i>Neuron sigmoidalny</i> .....                                                 | 140        |
| 8.1.2. <i>Sieć wielowarstwowa perceptronowa</i> .....                                  | 141        |
| 8.1.3. <i>Metody uczenia sieci perceptronowych</i> .....                               | 142        |
| 8.1.4. <i>Optymalizacja struktury sieci za pomocą algorytmu genetycznego</i> .....     | 150        |
| 8.2. BUDOWA KLASYFIKATORA NEURONOWEGO DO DIAGNOSTYKI MASZyny SYNCHRONICZNEJ .....      | 152        |
| 8.3. WYNIKI KLASYFIKACJI NEURONOWEJ .....                                              | 155        |
| 8.3.1. <i>Wyniki klasyfikacji dla zwarcia w grupie zezwojów twornika</i> .....         | 155        |
| 8.3.2. <i>Wyniki klasyfikacji dla przerwy jednej gałęzi równoległej twornika</i> ..... | 155        |
| 8.3.3. <i>Wyniki klasyfikacji dla zwarcia cewki obwodu wzbudzenia</i> .....            | 156        |
| 8.3.4. <i>Wyniki klasyfikacji dla przerwy cewki obwodu wzbudzenia</i> .....            | 158        |
| 8.3.5. <i>Wyniki klasyfikacji dla wszystkich badanych uszkodzeń</i> .....              | 160        |
| <b>9. ROZMYTY KLASYFIKATOR STANU MASZyny .....</b>                                     | <b>161</b> |
| 9.1. WIADOMOŚCI WSTĘPNE .....                                                          | 161        |
| 9.1.1. <i>Zbiory rozmyte i logika rozmyta</i> .....                                    | 161        |
| 9.1.2. <i>Model wnioskowania rozmytego Mamdaniego-Zadeha</i> .....                     | 162        |
| 9.1.3. <i>Optymalizacja modelu rozmytego za pomocą algorytmu genetycznego</i> .....    | 170        |
| 9.2. BUDOWA KLASYFIKATORA ROZMYTEGO DO DIAGNOSTYKI MASZyny SYNCHRONICZNEJ .....        | 173        |
| 9.3. WYNIKI KLASYFIKACJI ROZMYTEJ.....                                                 | 176        |
| 9.3.1. <i>Wyniki klasyfikacji dla zwarcia w grupie zezwojów twornika</i> .....         | 177        |
| 9.3.2. <i>Wyniki klasyfikacji dla przerwy jednej gałęzi równoległej twornika</i> ..... | 179        |
| 9.3.3. <i>Wyniki klasyfikacji dla zwarcia cewki obwodu wzbudzenia</i> .....            | 181        |
| 9.3.4. <i>Wyniki klasyfikacji dla przerwy cewki obwodu wzbudzenia</i> .....            | 182        |
| <b>10. PODSUMOWANIE I KIERUNKI DALSZYCH PRAC.....</b>                                  | <b>184</b> |
| <b>BIBLIOGRAFIA.....</b>                                                               | <b>187</b> |

# 1. WSTĘP, CEL I TEZA PRACY

Maszyny elektryczne są powszechnie stosowane w praktycznie wszystkich gałęziach przemysłu i często są elementami wykonawczymi w bardzo skomplikowanych procesach technologicznych. W dużych zakładach przemysłowych, jak np. rafinerie lub zakłady chemiczne może być jednocześnie wykorzystywanych kilka tysięcy maszyn elektrycznych. W przeważającej części są to maszyny pracujące jako silniki i wiele z nich wchodzi w skład napędów dużej i bardzo dużej mocy. Wszelkie awarie maszyn prowadzą do bardzo dużych kosztów związanych nie tylko z drogim remontem, ale przede wszystkim z zatrzymaniem procesu technologicznego. Zatem jednym z podstawowych wymagań jakie stawia się maszynom elektrycznym jest niezawodność. Ciągłe kontrolowanie stanu maszyny i szybka reakcja na pierwsze symptomy powstających uszkodzeń są bardzo pożądane. Oceną stanu fizycznego obiektów, w tym również maszyn elektrycznych zajmuje się dziedzina wiedzy zwana diagnostyką. Badania diagnostyczne wykonywane w celu oceny stanu technicznego maszyn oraz stopnia zużycia ich elementów składowych; pozwalają na ustalenie i często zlikwidowanie przyczyn wystąpienia uszkodzeń zanim dojdzie do poważnej w skutkach awarii. Wczesne wykrycie uszkodzenia umożliwia również odpowiednie zaplanowanie harmonogramu remontów i zminimalizowanie przestojów w procesie technologicznym. Metody diagnostyki maszyn elektrycznych podzielić można na dwie zasadnicze grupy. Pierwszą z nich stanowią metody inwazyjne stosowane przez wyspecjalizowane zakłady naprawcze lub produkcyjne i polegają na diagnostyce maszyn po ich demontażu (bardzo często na podstawie wizualnej oceny i pomiarów możliwych do przeprowadzenia po rozmontowaniu maszyny). Tego typu badania wykonuje się najczęściej okresowo, zgodnie z harmonogramem lub na podstawie oznak, mogących świadczyć o postępującym stanie awaryjnym (np. zwiększony pobór energii, wydzielanie większej ilości ciepła, zmiana parametrów emitowanego dźwięku). Metody inwazyjne nie są jednak wystarczająco skuteczne w przypadku dość szybko postępujących uszkodzeń. Drugą, coraz powszechniej stosowaną grupę metod stanowią metody nieinwazyjne, polegające na ocenie stanu maszyny na podstawie symptomów zawartych w sygnałach pomiarowo dostępnych. Diagnostyka maszyn elektrycznych na podstawie sygnałów pomiarowo dostępnych pozwala na ocenę ich stanu fizycznego, bez potrzeby ingerencji w ich strukturę wewnętrzną i co bardzo ważne bez przerywania procesów, w których te maszyny uczestniczą. Może być ona prowadzona w sposób ciągły, dzięki czemu stany awaryjne mogą być wykrywane natychmiast po

przekroczeniu progu detekcji. Jako sygnały diagnostyczne wykorzystuje się prąd, napięcie, drgania i hałas, obraz termowizyjny, strumień elektromagnetyczny. Jednym z najczęściej badanych sygnałów diagnostycznych jest prąd elektryczny, który jest stosunkowo odporny na zakłócenia pochodzące z innych obiektów znajdujących się w pobliżu, nie wymaga dokonywania zmian konstrukcyjnych w budowie maszyny ani instalowania dodatkowych czujników w jej bezpośrednim sąsiedztwie.

Wiele stanów awaryjnych, w szczególności o niskiej intensywności, nie powoduje wyraźnego wzrostu poziomu sygnałów prądowych w miejscach pomiarowo dostępnych (na zewnątrz maszyny), co czyni je trudnymi do wykrycia. Dopiero odpowiednia analiza tych sygnałów (np. analiza spektralna) może pomóc w detekcji uszkodzenia. W związku z tym na całym świecie intensywnie prowadzone są badania mające na celu wyznaczenie symptomów mogących świadczyć o występowaniu stanów awaryjnych w konkretnych rodzajach maszyn. Owocem tych prac są liczne publikacje. Dotyczą one głównie najpowszechniej występujących maszyn elektrycznych - silników indukcyjnych (w szczególności klatkowych). W ostatnim czasie można również zaobserwować zwiększone zainteresowanie diagnostyką maszyn wzbudzanych magnesami trwałymi, w związku z czym powstaje coraz więcej opracowań z tego tematu. Nieco słabiej opisany jest temat maszyn komutatorowych i alternatorów. Natomiast bardzo mało jest publikacji dotyczących maszyn synchronicznych o wzbudzeniu elektromagnetycznym, w szczególności pracujących jako silniki. Wynika to przede wszystkim z faktu, że silniki synchroniczne nie są tak bardzo popularne jak pozostałe wymienione typy maszyn oraz tego, że są to jednostki raczej większej mocy, co utrudnia diagnostykę. Ponadto symptomów uszkodzeń najczęściej poszukuje się poprzez porównywanie sygnałów w maszynie nieuszkodzonej z sygnałami w podobnej maszynie, w której nastąpił stan awaryjny. Zazwyczaj celowo uszkadza się jakiś egzemplarz maszyny lub stosuje się maszyny o konstrukcji specjalnej, która umożliwia taką konfigurację uzwojeń, która odpowiada stanowi awaryjnemu. W przypadku maszyn synchronicznych wymaga to poniesienia znacznie większych nakładów finansowych niż w przypadku pozostałych maszyn. Oprócz diagnostyki na podstawie obiektów rzeczywistych rozwijana jest również diagnostyka na podstawie ich modeli matematycznych. Zaletą takiego rozwiązania jest dużo niższy koszt, brak zakłóceń i błędów pomiarowych oraz możliwość badania skrajnych przypadków awarii (takich które w obiekcie rzeczywistym doprowadziłyby do całkowitego uszkodzenia). Wadą natomiast jest niedokładność odwzorowania wszystkich zjawisk, jakie mogą zajść w rzeczywistej maszynie.

Niezależnie od zastosowanej metody diagnostyki (pomiarowej lub symulacyjnej) występuje problem odnalezienia symptomów związanych z konkretnym uszkodzeniem. W stosowanych

powszechnie metodach diagnostyki rejestruje się (lub generuje, w przypadku diagnostyki na podstawie modeli matematycznych) sygnały w stanie bezawaryjnym oraz w stanie uszkodzenia, a następnie dokonuje się pewnych przekształceń tych sygnałów, takich jak szybka transformacja Fouriera, filtracja lub przekształcenie falkowe. W tak przetworzonych sygnałach poszukuje się charakterystycznych cech, którymi te sygnały się różnią w zależności od stanu maszyny. W tradycyjnych metodach cechy wyznaczane są na ogół na podstawie wizualnej oceny dokonywanej przez eksperta. Coraz częściej jednak stosuje się w tym celu metody zautomatyzowane, w szczególności oparte na sztucznej inteligencji [3], [10], [49], [56]. Sztuczna inteligencja [6], [11], [27] to grupa algorytmów naśladujących swym działaniem procesy zachodzące w świecie organizmów żywych. Wyróżnić wśród nich można sztuczne sieci neuronowe [19], [53], [54], [56], [76], [77], [78], [86], [99], [108], które wzorują się na systemach nerwowych ludzi i zwierząt, algorytmy genetyczne i ewolucyjne [2], [14], [23], [69], [86], [87], które odzwierciedlają dobór naturalny i ewolucję organizmów, logikę rozmytą [65], [81], [86], [103], [104], która naśladuje intuicyjny sposób myślenia i podejmowania decyzji przez ludzi, sztuczne systemy immunologiczne [102], których pierwowzorem jest system immunologiczny człowieka oraz algorytmy mrówkowe [24], które wykorzystują zasady, według których współpracują ze sobą mrówki. Istotną zaletą algorytmów sztucznej inteligencji jest to, że wzorują się na procesach, które sprawdziły się w swoich pierwotnych zastosowaniach. Ponadto są bardzo wydajne i po odpowiednim przystosowaniu mogą być użyte w niemal każdym problemie. Dlatego też zastosowanie technik sztucznej inteligencji w diagnostyce maszyn elektrycznych, w tym również maszyny synchronicznej wydaje się być bardzo dobrym rozwiązaniem.

W rozprawie zostały przedstawione wyniki badań diagnostycznych maszyny synchronicznej dla czterech różnych przypadków uszkodzeń, tj. zwarcia grupy zezwojów w uzwojeniu twornika, przerwy w gałęzi równoległej jednej fazy twornika, a także zwarcie oraz przerwa w uzwojeniu bieguna obwodu wzbudzenia. Dość duży nacisk został położony na wczesne wykrywanie uszkodzeń, dzięki czemu proponowana w rozprawie metodologia diagnostyki ma być konkurencyjna w stosunku do dostępnych na rynku rozwiązań układów zabezpieczających. Wybór symptomów uszkodzeń został dokonany zarówno w sposób tradycyjny – przez eksperta w oparciu o wyniki analizy spektralnej sygnałów prądowych jak również w sposób całkowicie automatyczny poprzez zastosowanie algorytmu genetycznego maksymalizującego odległości między grupami cech w maszynie nieuszkodzonej oraz z występującym stanem awaryjnym. Brak w literaturze wyników takich badań dla maszyny synchronicznej uzasadnia ważność i celowość podejmowanej tematyki rozprawy.

Badania przeprowadzane w niniejszej pracy należą do grupy badań diagnostycznych

nieinwazyjnych mających na celu ocenę stanu uzwojeń w maszynie synchronicznej przy pracy silnikowej. Od typowych badań diagnostycznych odróżnia je jednak to, że są one prowadzone na maszynie będącej w ciągłej eksploatacji, bez konieczności wprowadzania jakichkolwiek zmian w charakterze jej pracy.

W pracy zostanie udowodniona następująca teza:

„Istnieje możliwość wykrycia uszkodzeń maszyny synchronicznej w sposób nieinwazyjny wykorzystując metody sztucznej inteligencji w analizie sygnałów pomiarowo dostępnych.”

Zakres pracy obejmuje wytworzenie aparatury do rejestracji sygnałów prądowych i napięciowych oraz wykonanie pomiarów i analizę ich wyników dla czterech dość powszechnie występujących w maszynie synchronicznej stanów awaryjnych, tj. zwarcia grupy zezwojów twornika, przerwy gałęzi równoległej twornika, zwarcia uzwojenia bieguna wzbudzenia oraz przerwy bieguna wzbudzenia. Poniżej opisano zawartość poszczególnych rozdziałów rozprawy.

W rozdziale drugim zostały przedstawione ogólne wiadomości na temat budowy maszyn synchronicznych, ich zastosowania oraz uszkodzeń, jakie mogą w nich wystąpić, a także bardziej szczegółowo zostały opisane badane maszyny.

W trzecim rozdziale opisano stanowisko pomiarowe do badań maszyn synchronicznych oraz sposób przeprowadzania pomiarów. Ponadto przedstawiono urządzenie, które zostało skonstruowane w celu przeprowadzenia rejestracji sygnałów prądowych i napięciowych podczas badania stanów awaryjnych obu maszyn.

Rozdział czwarty prezentuje wyniki dokonanych pomiarów w postaci sygnałów prądowych twornika i wzbudzenia dla każdego z przypadków uszkodzeń i stanu bezawaryjnego oraz wyniki analizy spektralnej tych sygnałów. Opisano również metodykę wyznaczania symptomów uszkodzeń na podstawie cech zawartych w widmach tych sygnałów dokonaną w sposób klasyczny, tj. przez porównanie przez eksperta składowych w widmach dla stanu uszkodzonego oraz bezawaryjnego. Zaprezentowano także dość popularną w ostatnim czasie metodę bazującą na analizie spektralnej modułu wektora przestrzennego prądu twornika i przedstawiono wyniki zastosowania tej metody dla wszystkich rozpatrywanych stanów awaryjnych.

W rozdziale piątym opisano metody używane w automatycznej selekcji cech. Techniki tego typu stosowane są z powodzeniem w rozpoznawaniu obrazów i dźwięków oraz w diagnostyce medycznej.

Szósty rozdział zawiera opis implementacji oraz wyniki automatycznej selekcji cech z wykorzystaniem algorytmu genetycznego i miary odległości Mahalanobisa. Zawarto w nim też porównanie różnych wariantów algorytmu.

Rozdział siódmy jest opisem technik stosowanych w automatycznej klasyfikacji obiektów na podstawie ich cech charakterystycznych.

W rozdziale ósmy przedstawiono implementacje oraz wyniki automatycznej klasyfikacji z wykorzystaniem sztucznych sieci neuronowych (ANN). Przedstawiono także wyniki optymalizacji struktury i parametrów sieci z wykorzystaniem algorytmu genetycznego.

W dziewiątym rozdziale przedstawiono implementację oraz wyniki automatycznej klasyfikacji z wykorzystaniem modelu wnioskowania rozmytego (FIS). Przedstawiono także wyniki optymalizacji struktury modelu z wykorzystaniem algorytmu genetycznego.

Rozdział dziesiąty stanowi podsumowanie przeprowadzonych badań oraz przedstawia planowane kierunki dalszych prac autora rozprawy.


## 2. MASZYNA SYNCHRONICZNA JAKO OBIEKT DIAGNOSTYCZNY

### 2.1. Budowa maszyn synchronicznych

Maszyny synchroniczne w przeważającej części wykonywane są jako trójfazowe (w przypadku maszyn małych można również spotkać się z wykonaniem jednofazowym) [59], [82], [83]. Uzwojenie twornika umieszczone jest z reguły w stojanie, a uzwojenie wzbudzenia - zasilane prądem stałym poprzez pierścienie ślizgowe - w wirniku (rysunek 2.1.a) [84]. Stojany maszyn synchronicznych, za wyjątkiem maszyn największej mocy, posiadają budowę bardzo zbliżoną lub wręcz identyczną do stojanów maszyn indukcyjnych [91], [92], charakteryzującą się równomiernie rozmieszczonymi na obwodzie zębami i żłobkami, w których umieszczone są uzwojenia. Obwód magnetyczny stojana tworzą pakiety blach o grubości około 0,5mm (w przypadku maszyn o większych mocach pakiety o grubości około 5cm przedzielone są kanałami wentylacyjnymi). Wirniki maszyn synchronicznych mogą być wykonane jako cylindryczne (rysunek 2.2.a) lub jawnobiegunowe (rysunek 2.2.b,c,d,e). W wirnikach cylindrycznych, w celu uzyskania rozkładu indukcji magnetycznej w szczelinie jak najbardziej zbliżonego do sinusoidalnego, uzwojenie wirnika zajmuje tylko część (około 2/3) żłobków. Ze względu na znaczne siły odśrodkowe działające na uzwojenie wzbudzenia w maszynie cylindrycznej, żłobki zamyka się za pomocą klinów. W przypadku maszyn jawnobiegunowych właściwy rozkład indukcji magnetycznej w szczelinie uzyskuje się poprzez nadanie odpowiedniego kształtu nabiegunnikom, tak aby szczelina zwiększała się w miarę oddalania się od osi bieguna. Grubość szczeliny w maszynach synchronicznych jest dość znaczna (np. w porównaniu do maszyn indukcyjnych) i wynosi zazwyczaj  $0,5 \div 5\text{mm}$ . Wzbudzony wirnik nie jest w stanie rozwinąć momentu rozruchowego. Aby umożliwić przeprowadzenie rozruchu niezbędna jest obecność obwodów zwartych o dostatecznie krótkiej stałej czasowej. W maszynach jawnobiegunowych rolę tych obwodów pełni klatka, zwana w silnikach rozruchową (rysunek 2.2.b,c), lub lite elementy obwodu magnetycznego (rysunek 2.2.d,e). W maszynach cylindrycznych na obwody zwarte składa się lity rdzeń wirnika wraz ze wszystkimi nieizolowanymi, metalowymi elementami konstrukcyjnymi w strefie oddziaływania pola głównego (np. kliny zamykające żłobki wirnika) [91]. Obwody zwarte wraz z uzwojeniem wzbudzenia stanowią układ dwufazowy. W celu zrównania przepływów obu tych uzwojeń i uzyskania w przybliżeniu wirującego kołowego przepływu wirnika, w czasie rozruchu obwód wzbudzenia powinien być zwarty poprzez rezystancję około 9- 12 razy większą od jego własnej rezystancji [21]. Klatka rozruchowa pełni jeszcze dodatkowo funkcję tłumiącą oscylacje prędkości obrotowej wirnika, które mogą powstać na skutek skokowych zmian

momentu lub wahań napięcia w sieci zasilającej. Z tego powodu klatka rozruchowa bywa też nazywana klatką tłumiącą. Typowym wykonaniem maszyn szybkobieżnych jest wirnik cylindryczny, a maszyn wolnobieżnych wirnik jawnobiegunowy, przy czym wirniki silników wykonuje się z reguły z biegunami jawnymi [82].

Istnieją również maszyny synchroniczne, w których funkcje stojana i wirnika zostały zamienione poprzez umieszczenie uzwojenia twornika w wirniku, a uzwojenia wzbudzenia w stojanie (rysunek 2.1.b). Jest to rozwiązanie spotykane dość rzadko w maszynach małej i średniej mocy, głównie o przeznaczeniu specjalnym. Zmiana funkcji stojana i wirnika wymaga zmian konstrukcyjnych, nie powoduje natomiast zmiany zasady działania maszyny.




**Rys. 2.1.** Schemat maszyny synchronicznej 3-fazowej o budowie klasycznej (a) oraz odwróconej (b). 1-twornik, 2-obwód wzbudzenia, 3-pierścień ślizgowy, 4-szczotki [82]

Uzwojenie wzbudzenia zasila się z różnych układów, które podzielić można na następujące rodzaje [82]:

- układy wzbudnicowe szczotkowe - zbudowane ze wzbudnicy prądu stałego lub wzbudnicy prądu przemiennego i prostownika,
- układy wzbudnicowe bezszczotkowe - zbudowane ze wzbudnicy prądu przemiennego i wirującego prostownika krzemowego,
- układy bezwzbudnicowe - zbudowane z prostowników sterowanych.

Osobną, bardzo powszechnie rozwijaną w ostatnich latach grupę silników synchronicznych stanowią silniki o wzbudzeniu magnesami trwałymi. Są to z reguły zminiaturyzowane silniki synchroniczne jawnobiegunowe lub cylindryczne [90], choć spotyka się również jednostki o mocy przekraczającej 1 MW [70]. Stojan posiada typowe uzwojenie trójfazowe (lub rzadziej uzwojenie jednofazowe z fazą pomocniczą), natomiast wirnik może być wykonany na wiele sposobów, w zależności od rozmieszczenia magnesów i geometrii wirnika. Do typowych konstrukcji należą wirniki zbudowane z jawnobiegunowych magnesów trwałych

oraz wirniki cylindryczne z magnesami umieszczonymi na powierzchni wirnika lub ukrytymi w jego wnętrzu.



**Rys.2.2.** Przekroje podstawowych typów maszyn synchronicznych: a) maszyna z wirnikiem cylindrycznym, b) maszyna z wirnikiem jawnobiegunowym z klatką tłumiącą poprzeczno-podłużną, c) maszyna z wirnikiem jawnobiegunowym z klatką tłumiącą w osi podłużnej, d) maszyna z wirnikiem jawnobiegunowym z litymi nabiegunnikami, e) maszyna z wirnikiem jawnobiegunowym z litymi nabiegunnikami i pierścieniami zwierającymi, f) . 1-jarżmo stojana z widocznymi zębami i żłobkami, 2-jarżmo wirnika, 3-nabiegunniki, 4-uzwojenie wzbudzenia [91].

Rozruch silników o wzbudzeniu magnesami trwałymi możliwy jest pod wpływem momentu asynchronicznego (dzięki zastosowaniu klatki rozruchowej) lub momentu synchronicznego (rozruch częstotliwościowy). Ze względu na hamujące działanie magnesów podczas rozruchu asynchronicznego, co ogranicza siłę stosowanych magnesów oraz szybki rozwój układów energoelektronicznych, coraz częściej stosuje się rozruch częstotliwościowy.

Silniki o wzbudzeniu magnesami trwałymi mogą być wyposażone w tzw. komutator elektroniczny i wówczas stanowią one odrębną grupę silników – tzw. silniki bezszczotkowe prądu stałego (brushless DC - BLDC). Uzwojenia twornika takiego silnika skojarzone są najczęściej w gwiazdę lub w trójkąt, rzadziej czworokąt [94]. Przełączanie uzwojeń w takim silniku odbywa się w sposób bezstykowy, na podstawie sygnałów pochodzących z układu kontroli położenia magneśnicy względem uzwojeń twornika, składającego się z wirującego nadajnika położenia (zwykle magnes) oraz rozmieszczonych na obwodzie czujników położenia (czujniki hallotronowe, kontaktronowe, indukcyjne, itp.).

W maszynie jawnobiegunowej z uwagi na zmieniającą się grubość szczeliny, a co za tym idzie zmieniającą się reluktancję obwodu magnetycznego, powstaje moment reluktancyjny. Istnieją silniki całkowicie pozbawione obwodu wzbudzenia. Ich zasadniczą wadą jest to, że nie potrafią wytworzyć momentu rozruchowego (konieczne jest zastosowanie dodatkowych elementów tłumiących lub rozruch częstotliwościowy) oraz niska sprawność, która ogranicza ich zastosowania do napędów ułamkowej mocy [82].

## **2.1. Zastosowania maszyn synchronicznych**

Maszyny synchroniczne znajdują zastosowanie jako generatory oraz silniki.

Generatory synchroniczne są typowymi urządzeniami służącymi do wytwarzania energii elektrycznej w elektrowniach obsługujących system energetyczny. Ponadto w wielu dziedzinach stosowane są generatory synchroniczne pracujące na sieci wydzielone lub zasilające pojedyncze urządzenia. W szczególności dotyczy to zastosowań, w których zasilenie z sieci energetycznej jest niepraktyczne lub wręcz niemożliwe. Zatem powszechnie stosowane są na statkach i innych jednostkach pływających, jak również w dużych zakładach przemysłowych.

Ze względu na niezależność prędkości obrotowej wirnika od momentu obciążającego (w pewnym dość dużym zakresie obciążeń) silniki synchroniczne znalazły zastosowanie tam, gdzie pożądana jest stała prędkość. Dodatkowo z uwagi na wyższy koszt wykonania oraz większą sprawność niż w przypadku maszyn indukcyjnych silniki synchroniczne stosuje się raczej w urządzeniach i napędach większej mocy. Silniki synchroniczne stosuje się we wszystkich głównych gałęziach przemysłu, w tym:

- w przemyśle chemicznym i paliwowym do napędu kompresorów i wylączarek,
- w przemyśle hutniczym i surowcowym do napędu walcarek, wciągarek, kruszarek, wentylatorów,
- w przemyśle papierniczym do napędu rozdrabniarek,
- do napędu pomp w przepompowniach wody, oczyszczalniach ścieków,

- w zastosowaniach specjalnych, takich jak tunele aerodynamiczne, układy silnik-generator do zmiany parametrów napięcia (amplituda, częstotliwość, faza).

Maszyny synchroniczne używane bywają także w roli tzw. kompensatorów synchronicznych.


## **2.3. Uszkodzenia maszyn synchronicznych**

Do najbardziej typowych uszkodzeń maszyn elektrycznych, w tym maszyn synchronicznych należą [21], [58], [73]:


- uszkodzenia łożysk na skutek zużycia mechanicznego,
- uszkodzenia łożysk na skutek prądów łożyskowych w przypadku silników zasilanych z falowników,
- uszkodzenia prętów i pierścieni zwierających w klatkach rozruchowych,
- zwarcia w uzwojeniach na skutek zużycia izolacji, przepięć, wyładowań niepełnych, czynników zewnętrznych (zalanie, przegrzanie), przemieszczania się przewodów,
- zwarcia w obwodach wzbudzenia na skutek przebicia izolacji podczas rozruchu asynchronicznego bez włączonego rezystora ograniczającego prąd,
- przerwy w obwodach twornika pod wpływem drgań i naprężeń,
- przerwy w obwodach wzbudzenia pod wpływem drgań i naprężeń,
- ekscentryczność statyczna, dynamiczna i mieszana,
- uszkodzenia izolacji międzyblachowej w rdzeniach prowadzące do zwarć blach,
- deformacje rdzeni na skutek asymetrii wewnętrznych uzwojeń.

## **2.4. Konstrukcja badanych maszyn**

W niniejszej pracy poddawano badaniom dwie maszyny. Pierwsza z nich służyła do badania stanów awaryjnych w uzwojeniach twornika, druga natomiast służyła do badania uszkodzeń w uzwojeniach wzbudzenia. Pierwsza z maszyn jest maszyną jawnobiegunową o konstrukcji klasycznej, w której twornik umieszczony jest w stojanie, a wzbudzenie w wirniku. Maszyna wykonana została na bazie silnika indukcyjnego o mocy znamionowej 30kW, a jej uzwojenia stojana zostały wykonane w specyficzny sposób, umożliwiając dokonywanie uszkodzeń. Końce każdej grupy zezwojów maszyny oraz końce zezwojów w jednej z grup wyprowadzone są na zewnątrz maszyny, przez co możliwa jest ich różna konfiguracja, a co za tym idzie możliwe jest takie łączenie uzwojeń, które odpowiada powszechnie występującym stanom awaryjnym. Uzwojenie to jest uzwojeniem pętlicowym o poskoku równym 10. Schemat rozwinięty uzwojenia stojana maszyny został przedstawiony na rysunku 2.3, a schemat połączeń uzwojeń dla stanu bezawaryjnego na rysunku 2.4.



**Rys. 2.3.** Schemat rozwinięty uzwojenia twornika maszyny o budowie klasycznej



**Rys. 2.4.** Schemat połączeń stojana maszyny do badania uszkodzeń w stojanie dla stanu bezawaryjnego

Wirnik maszyny zawiera cztery bieguny, których uzwojenia zostały skojarzone szeregowo (nie ma możliwości ingerencji w strukturę tych uzwojeń). W wirniku, oprócz uzwojenia wzbudzenia, umieszczone zostało także uzwojenie klatkowe, w którym pręty są mocowane do pierścieni zwierających za pomocą połączeń śrubowych. Dzięki temu możliwe jest poluzowanie tych połączeń, co prowadzi do powiększenia rezystancji styku pierścienia z prętem i odpowiada stanowi uszkodzenia pręta. Dla celów badawczych maszyna została sprzęgnięta z maszyną prądu stałego o mocy 5 kW.


Druga maszyna, jest również jest maszyną jawnobiegunową ale o konstrukcji odwróconej, w której twornik umieszczony jest w wirniku, a wzbudzenie w stojanie. Podobnie jak pierwsza z maszyn, ta również została wykonana na bazie silnika indukcyjnego o mocy znamionowej 30kW. Rdzeń twornika maszyny posiada 36 żłobków, w których umieszczone jest uzwojenie pętlicowe o poskoku równym 7. Uzwojenie to skojarzone jest w gwiazdę i zasilane poprzez pierścienie ślizgowe. Stojan maszyny powstał ze stojana silnika indukcyjnego poprzez wycięcie części zębów i nawinięcie na pozostałych zębach czterech uzwojeń wzbudzających rozmieszczonych równomiernie co  $90^{\circ}$  na obwodzie. Końce tych uzwojeń wyprowadzone zostały na zewnątrz maszyny, przez co możliwa jest ich różna konfiguracja, w tym łącznie ich szeregowo lub równolegle, a także takie ich łączenie, które odpowiada stanom awaryjnym. Nieruchome, umieszczone w stojanie uzwojenie klatkowe składa się z pierścieni i prętów mocowanych ze sobą za pomocą połączeń śrubowych. Jeden z pierścieni zwierających składa się z czterech segmentów skręcanych ze sobą poprzez miedziane płaskowniki i wkręty. Dzięki temu możliwe jest poluzowanie tych połączeń, co prowadzi do powiększenia rezystancji styku fragmentów pierścienia i odpowiada stanowi jego uszkodzenia. Dla celów badawczych poddawana diagnostyce maszyna sprzęgnięta została z maszyną obcowzbudną prądu stałego o mocy 20 kW.

### 3. STANOWISKO BADAWCZO-POMIAROWE


#### 3.1. Opis stanowiska pomiarowego

Z uwagi na konieczność badania dwóch maszyn synchronicznych konieczne było zbudowanie stanowiska pomiarowego w dwóch odmiennych konfiguracjach. Obie maszyny były sprzęgnięte z maszynami prądu stałego, przez co możliwa była zmiana ich obciążenia.


Badano zarówno uszkodzenia w stojanie jak i w wirniku, dlatego w pomiarach używane były dwie maszyny synchroniczne. Schematy stanowiska pomiarowego przedstawiono na rysunkach 3.1 i 3.2, natomiast na rysunku 3.3 znajduje się zdjęcie stanowiska.



Rys. 3.1. Schemat stanowiska pomiarowego z maszyną o budowie klasycznej




**Rys. 3.2.** Schemat stanowiska pomiarowego z maszyną o budowie odwróconej




**Rys. 3.3.** Zdjęcie stanowisk pomiarowych z widocznymi maszynami

### 3.2. Urządzenie do rejestracji sygnałów

Na potrzeby pomiarów wykonane zostało urządzenie do rejestracji sygnałów prądowych i napięciowych maszyn. Głównym założeniem było, by urządzenie posiadało budowę kompaktową, umożliwiającą jego transport i szybki montaż na stanowisku pomiarowym. Dlatego też urządzenie zostało zabudowane w walizce. Urządzenie posiada 12 kanałów pomiarowych, w tym 4 kanały napięciowe i 8 kanałów prądowych. 3 spośród kanałów napięciowych służą do rejestracji napięć fazowych stojana w czterech następujących zakresach (amplitudy): 470 V, 390 V, 330 V i 220 V. Czwarty kanał napięciowy służy do rejestracji napięcia wzbudzenia i posiada następujące zakresy: 50 V, 30 V, 15 V i 10 V. Wszystkie kanały napięciowe chronione są bezpiecznikami o wartości 32 mA. Kanały napięciowe obsługiwane są przez przetworniki napięciowe LEM LV 25-P (więcej informacji na temat przetworników można znaleźć w rozdziale 3.2.1). Spośród ośmiu kanałów prądowych cztery przystosowane są do pomiaru bezpośredniego (maksymalny mierzony prąd wynosi 19.2 A, prąd nominalny 6 A) lub za pomocą przekładników prądowych z wyjściem 5 A. W tych kanałach zastosowano przetworniki prądowe LEM LTS 6-NP (więcej informacji na temat przetworników można znaleźć w rozdziale 3.2.1). Pozostałe cztery kanały przystosowane są do pomiaru z użyciem przetworników cęgowych z wyjściem napięciowym (maksymalnie 10V). Testowano współpracę urządzenia z przetwornikami APPA 32 [30] oraz Chauvin Arnoux MN 39 [32]. Zdjęcie urządzenia pomiarowego przedstawione zostało na rysunku 3.4 a jego schemat na rysunku 3.5. W dalszych podrozdziałach zawarto informacje na temat części składowych urządzenia pomiarowego.



**Rys. 3.4.** Zdjęcie urządzenia do rejestracji sygnałów



**Rys. 3.5.** Schemat urządzenia do rejestracji sygnałów

### 3.2.1. Przetworniki pomiarowe

Do pomiarów prądów stosowane były przetworniki pomiarowe LEM LTS 6-NP, a napięć LEM LV 25-P. Najważniejsze parametry obu przetworników podano w tabelach 3.1 oraz 3.2.

**Tabela 3.1.** *Najważniejsze parametry przetwornika LEM LTS 6-NP (na podstawie [40])*

| Parametr                                                             | wartość                                |
|----------------------------------------------------------------------|----------------------------------------|
| prąd znamionowy strony pierwotnej $I_{PN}$                           | 6 A                                    |
| zakres prądów strony pierwotnej $I_{PM}$                             | 0 ... $\pm 19.2$ A                     |
| przebieżalność prądowa $I_P$                                         | 250 A                                  |
| napięcie wyjściowe $V_{OUT}$                                         | $2.5 \pm (0.625 \cdot I_P / I_{PN})$ V |
| napięcie zasilania $V_C (\pm 5 \%)$                                  | 5 V                                    |
| pobór prądu (przy $V_C = 5 \text{ V} \pm 5 \%$ )                     | $28 + I_P / N_S + V_{OUT} / R_L$ mA    |
| dokładność $X$ (przy $I = I_{PN}$ , $T_A = 25^\circ\text{C}$ )       | $\pm 0,2 \%$                           |
| błąd nieliniowości $\varepsilon_L$                                   | $< 0,1 \%$                             |
| czas reakcji $t_{ra}$ (przy $I = 10\% I_{PN}$ )                      | $< 100$ ns                             |
| czas odpowiedzi $t_r$ (wymuszenie skokowe $I = 90\% \times I_{PN}$ ) | $< 400$ ns                             |
| $di/dt$                                                              | $> 15$ A/ $\mu$ s                      |
| pasmo przenoszenia ( $-0.5 \dots 1$ dB) $BW$                         | DC ... 200 kHz                         |


**Tabela 3.2.** *Najważniejsze parametry przetwornika LEM LV 25-P (na podstawie [41])*

| Parametr                                                                      | wartość            |
|-------------------------------------------------------------------------------|--------------------|
| prąd znamionowy strony pierwotnej $I_{PN}$                                    | 10 mA              |
| zakres prądów strony pierwotnej $I_P$                                         | 0 ... $\pm 14$ mA  |
| prąd znamionowy strony wtórnej $I_{SN}$                                       | 25 mA              |
| przekładnia $K_N$                                                             | 2500 : 1000        |
| napięcie zasilania $V_C (\pm 5 \%)$                                           | $\pm 15$ V         |
| pobór prądu (przy $V_C = 15 \text{ V} \pm 5 \%$ )                             | $I_S + 10$ mA      |
| stopień izolacji                                                              | 4.1 kV             |
| dokładność $X_G$ (przy $I = I_{PN}$ , $T_A = 25^\circ\text{C}$ )              | $\pm 0,8 \%$       |
| błąd nieliniowości $\varepsilon_L$                                            | $< 0,2 \%$         |
| prąd przesunięcia (offset) $I_O$ (przy $I_P = 0$ , $T_A = 25^\circ\text{C}$ ) | $\pm 0,15$ mA      |
| dryft temperaturowy $I_{OT}$ (0 ... $70^\circ\text{C}$ )                      | $\max \pm 0,35$ mA |
| czas odpowiedzi $t_r$ (przy $I = 90\% V_{Pmax}$ )                             | 40 $\mu$ s         |

### 3.2.2. Filtry antyaliasingowe

Zgodnie z twierdzeniem Kotielnikova-Shannona [64], [96], [107] podczas próbkowania z szybkością  $f_s$  próbek/s, jeśli  $k$  jest dowolną liczbą całkowitą, nie jesteśmy w stanie rozróżnić spróbkowanych wartości przebiegu sinusoidalnego o częstotliwości  $f_0$  Hz oraz przebiegu sinusoidalnego o częstotliwości  $(f_0 + k \cdot f_s)$  Hz. Zatem w celu uniknięcia niejednoznaczności podczas odtwarzania sygnału z zarejestrowanych próbek należy ograniczyć pasmo rejestrowanego sygnału tak, aby maksymalna częstotliwość w widmie sygnału była minimum dwa razy mniejsza od częstotliwości próbkowania. Aby osiągnąć ten cel wymagane jest zastosowanie filtra dolnoprzepustowego, nazywanego także filtrem antyaliasingowym.

Podczas wyboru filtra do najważniejszych kryteriów należą: stromość charakterystyki w paśmie przejściowym, płaskość charakterystyki w paśmie przepustowym i zaporowym oraz przesunięcie fazowe [45]. Ponieważ wcześniejsze pomiary wykazały, że analizowanie składowych widma sygnału o częstotliwościach powyżej 2 kHz jest nieuzasadnione ze względu na wpływ czynników zewnętrznych (zakłócenia w napięciu zasilającym, zakłócenia w torze pomiarowym) natomiast ze względu na parametry karty pomiarowej założono próbkowanie sygnału z częstotliwością 25 kHz otrzymano dość szeroki zakres częstotliwości, w którym mogło się mieścić pasmo przejściowe filtra. Zatem stromość charakterystyki w paśmie przejściowym nie była kryterium dominującym przy wyborze rodzaju filtra. Główny nacisk położono na możliwie jak najdokładniejsze przeniesienie amplitud odpowiadających częstotliwościom w paśmie przepustowym. Dlatego też zdecydowano się na wybór filtra Butterwortha. Po dokonaniu symulacji w programach Pspice oraz Multisim zdecydowano się na filtr czwartego rzędu. Schemat takiego filtra został przedstawiony na rysunku 3.6.



**Rys. 3.6.** Schemat filtru Butterwortha 4 rzędu

Na podstawie przeprowadzonych obliczeń dokonano doboru elementów, które zostały wykorzystane w układzie rzeczywistym. Zdecydowano się na zastosowanie rezystorów z typoszeregu E24 oraz kondensatorów z typoszeregu E12. Wartości użytych elementów zestawiono w tabeli 3.3.

**Tabela 3.3.** Wartości elementów zastosowanych w filtrach antyaliasingowych

| Element        | Wartość  | Tolerancja |
|----------------|----------|------------|
| R <sub>1</sub> | 3,90 kΩ  | 1%         |
| R <sub>2</sub> | 3,90 kΩ  | 1%         |
| R <sub>3</sub> | 12,00 kΩ | 1%         |
| R <sub>4</sub> | 6,80 kΩ  | 1%         |
| R <sub>5</sub> | 6,80 kΩ  | 1%         |


| Element        | Wartość  | Tolerancja |
|----------------|----------|------------|
| R <sub>6</sub> | 15,00 kΩ | 1%         |
| C <sub>1</sub> | 10,00 nF | 1%         |
| C <sub>2</sub> | 2,20 nF  | 1%         |
| C <sub>3</sub> | 15,00 nF | 1%         |
| C <sub>4</sub> | 680 pF   | 1%         |

Ze względu na wymóg kompaktowej budowy zdecydowano się na zastosowanie elementów do montażu powierzchniowego (SMD), co pozwoliło na umieszczenie dwunastu filtrów na jednej płytce o niewielkich wymiarach (150mm x 85mm).

Jako wzmacniacze operacyjne zastosowane zostały układy OP07 [28], odznaczające się dobrymi parametrami (niski tzw. offset, niskie szумы, mały dryft temperaturowy).

W celu zabezpieczenia wejść karty pomiarowej przed podaniem zbyt wysokiego napięcia na wyjściu każdego z filtrów zastosowano dwukierunkowe diody zabezpieczające (transile) [31].

Na rysunku 3.7 przedstawiono charakterystykę amplitudową filtru o tak dobranych parametrach. Linia ciągła odpowiada charakterystyce idealnej wykonanej na podstawie symulacji w programie Pspice, natomiast punkty odpowiadają pomiarom w układzie rzeczywistym (wyniki podano w tabeli 3.4). Zieloną pionową linią zaznaczono częstotliwość charakterystyczną filtru (5 kHz).



**Rys. 3.7.** Charakterystyka amplitudowa jednego z filtrów antyaliasingowych, linia ciągła odpowiada symulacji, punkty odpowiadają pomiarom


Przedstawiona charakterystyka rzeczywista dotyczy jednego z filtrów zawartych na płytce z filtrami, charakterystyki pozostałych jedenastu filtrów również zostały wyznaczone i nie odbiegają istotnie od tej przedstawionej na rysunku 3.7. Przesunięcie fazowe sygnału było nieistotne z punktu widzenia prowadzonych analiz.

**Tabela 3.4.** Wyniki pomiarów charakterystyki przejściowej filtru.


| f [Hz] | U <sub>wy</sub> [82] | f [Hz] | U <sub>wy</sub> [82] | f [Hz]  | U <sub>wy</sub> [82] |
|--------|----------------------|--------|----------------------|---------|----------------------|
| 100    | 5,01                 | 2 000  | 4,83                 | 30 000  | 0,008                |
| 200    | 5,00                 | 3 000  | 4,68                 | 40 000  | 0,007                |
| 300    | 5,00                 | 4 000  | 4,12                 | 50 000  | 0,007                |
| 400    | 4,99                 | 5 000  | 2,762                | 60 000  | 0,007                |
| 500    | 4,98                 | 6 000  | 1,62                 | 70 000  | 0,007                |
| 600    | 4,98                 | 7 000  | 0,864                | 80 000  | 0,007                |
| 700    | 4,96                 | 8 000  | 0,472                | 90 000  | 0,007                |
| 800    | 4,95                 | 9 000  | 0,246                | 200 000 | 0,007                |
| 900    | 4,94                 | 10 000 | 0,120                |         |                      |
| 1 000  | 4,925                | 20 000 | 0,008                |         |                      |

### 3.2.3. Układ zasilający

W układzie zasilającym poszczególne bloki urządzenia pomiarowego zastosowano specjalizowane zasilacze KAM 2515D [36] oraz KAM 1005 [33]. Schematy budowy wewnętrznej obu zasilaczy przedstawiono na rysunkach 3.8 i 3.9, a zestawienie ich najważniejszych parametrów w tabeli 3.5. Oba zasilacze zostały dodatkowo zabezpieczone bezpiecznikiem o wartości 630mA.



**Rys. 3.8.** Schemat wewnętrzny zasilacza KAM 2515D [36]




**Rys. 3.9.** Schemat wewnętrzny zasilacza KAM 1005 [33]

**Tabela 3.5.** Zestawienie najważniejszych parametrów zasilaczy KAM 2515D oraz KAM 1005 [36],[33]

|                     | KAM 2515D                 | KAM 1005                  |
|---------------------|---------------------------|---------------------------|
| napięcie wejściowe  | 85-265 VAC<br>120-370 VDC | 85-265 VAC<br>120-370 VDC |
| napięcie wyjściowe  | ±15 V                     | +5V                       |
| prąd wyjściowy      | ±800 mA                   | 2000mA                    |
| moc wyjściowa       | 24 W                      | 10 W                      |
| dokładność          | ±2%                       | ±2%                       |
| sprawność           | 83-85%                    | 70-72%                    |
| izolacja napięciowa | 3000 VAC                  | 3000 VAC                  |

### 3.3. Rejestracja sygnałów

Autorowi zależało na tym, by uniezależnić metodę wykrywania uszkodzeń od zakłóceń występujących w sieci zasilającej. W tym celu rejestracje przeprowadzane były dla różnych warunków zasilania. W części przypadków sygnały prądowe maszyny były rejestrowane gdy maszyna pracowała równolegle z innymi odbiornikami, takimi jak silnik indukcyjny z uszkodzonymi dwoma prętami, silnik indukcyjny z uszkodzonym pierścieniem, falownik zasilający silnik indukcyjny (pracujący z różnymi częstotliwościami) oraz przy różnych kombinacjach tych odbiorników. Na rysunku 3.10.a przedstawiony został przebieg czasowy jednego z napięć zasilających badaną maszynę, natomiast na rysunku 3.10.b zaprezentowano wyniki analizy spektralnej tego przebiegu. Jak widać przebieg ten jest odkształcony, a jego widmo zawiera liczne harmoniczne wyższych rzędów.



**Rys. 3.10.** *Przebieg czasowy napięcia zasilającego oraz jego widmo częstotliwościowe dla maszyny pracującej równolegle z falownikiem zasilającym silnik indukcyjny*

Ponieważ badane przebiegi były rejestrowane w różne dni, ich częstotliwość mogła się nieznacznie różnić. Z punktu widzenia analizy FFT najdokładniejsze odwzorowanie widma mierzonego sygnału ma miejsce wtedy, gdy analizuje się całkowitą liczbę okresów podstawowej składowej sygnału, a ponadto liczba próbek jest potęgą liczby 2. Wymaga to dostosowania częstotliwości próbkowania oraz długości pomiaru (ilości próbek) do aktualnej częstotliwości rejestrowanego przebiegu. W praktyce jest to bardzo trudne do zrealizowania, a wręcz niemożliwe, ponieważ niemożliwe jest dokładne określenie wartości częstotliwości (można ją tylko zmierzyć z pewnym błędem). Niedostosowanie częstotliwości próbkowania i ilości rejestrowanych próbek do częstotliwości mierzonego sygnału skutkuje powstaniem tzw. przecieku FFT [64], który objawia się pojawianiem się w sąsiedztwie rzeczywistych prążków, kolejnych prążków o amplitudach malejących w miarę oddalania się od prążka rzeczywistego. Przeciek można zmniejszać różnymi sposobami, ale nie da się go wyeliminować całkowicie. Dość skutecznym sposobem jest tzw. przepróbkowywanie sygnału polegające na zmianie częstotliwości spróbkowanego sygnału o wymierną ilość razy. Odbywa się to w dwóch krokach – najpierw zwiększa się częstotliwość o całkowitą ilość razy (np.  $k$  razy) przez dodanie odpowiedniej liczby zer pomiędzy istniejące próbki i filtrację dolnoprzepustową, a następnie zmniejsza się częstotliwość o całkowitą liczbę razy (np.  $m$  razy) przez filtrację dolnoprzepustową filtrem o odpowiednio zmniejszonej częstotliwości odcięcia. Częstotliwość sygnału wynikowego różni się  $\frac{k}{m}$  razy od częstotliwości sygnału przed przepróbkowaniem. Operacja ta jest jednak dość czasochłonna i nadal wymaga dość dobrej znajomości częstotliwości mierzonego sygnału. Stosowanie funkcji okien, przez które mnoży się analizowany sygnał (w dziedzinie czasu) również prowadzi do pewnej redukcji przecieku. W wykonywanych w niniejszej pracy analizach stosowano okno Hanninga opisane

wzorem [64],[107]:

$$w(n) = \left[ 0,5 + 0,5 \cos \left( \frac{2\pi n}{N} \right) \right] \quad (3.1)$$

gdzie:

$n$  – numer próbki,

$N$  – długość okna (w próbkach).

Ponadto z sygnału zostały usunięte wszystkie składowe, których amplitudy były na poziomie nieprzekraczającym poziomu szumu (sposób wyznaczania szumu opisany został w dalszej części rozdziału).

### 3.3.1. Karta akwizycji danych

Do rejestracji próbek pomiarowych zastosowano kartę akwizycji danych National Instruments NI-PCI 6034E [29]. W tabeli 3.6 zestawiono najważniejsze parametry karty.

**Tabela 3.6.** Zestawienie najważniejszych parametrów karty akwizycji danych NI-PCI 6034E  
(na podstawie [29])


| Parametr                            | Wartość                                          |
|-------------------------------------|--------------------------------------------------|
| liczba kanałów                      | 16 pojedynczych lub 8 różnicowych                |
| rozdzielczość                       | 16 bit                                           |
| max częstotliwość próbkowania       | 200 kS/s                                         |
| dopuszczalny zakres napięcia        | +/- 10 V                                         |
| zakresy pomiarowe napięcia          | $\pm 10$ V, $\pm 5$ V, $\pm 0,5$ V, $\pm 0,05$ V |
| dokładność pomiaru (odpowiednio dla | 7,560 mV, 1,790 mV, 0,399 mV, 0,0611 mV          |
| jednoczesne próbkowanie             | brak                                             |

### 3.3.2. Środowisko do rejestracji i obróbki danych

Rejestracji dokonywano w środowisku Linux Debian 5.0 Lenny [37], wersja jądra 2.6.28 przy wykorzystaniu dostępnego na licencji GNU GPL sterownika kart akwizycji danych Comedi [34]. Programy do akwizycji danych napisano w języku C++ przy wykorzystaniu funkcji z biblioteki Comedilib (libcomedi0) [35], jak również za pomocą programu KTimeTrace [39]. Obróbka danych pomiarowych, w tym FFT, skalowanie i normalizacja dokonywane były w środowisku Matlab [42].

### 3.4. Szumy i zakłócenia w torze pomiarowym

W rzeczywistych układach pomiarowych występują różnego rodzaju zakłócenia oraz szumy, które dodają się do mierzonego sygnału, zwiększając błąd pomiarowy układu. Z punktu widzenia analiz dokonywanych na podstawie rejestrowanego sygnału dość istotne jest określenie poziomu szumu i zakłóceń zawartych w tym sygnale. W przypadku układu pomiarowego zastosowanego do rejestracji prądów w maszynie synchronicznej zakłócenia mogą pochodzić od samego urządzenia pomiarowego, od karty akwizycji danych i komputera, a także od urządzeń pracujących w pobliżu układu pomiarowego. Zakłócenia generowane przez urządzenie pomiarowe pochodzą głównie od zastosowanych w nim przetworników prądowych i napięciowych, zasilaczy, wzmacniaczy operacyjnych we filtrach antyaliasingowych. Samo urządzenie pomiarowe jest otoczone ekranem elektromagnetycznym i przez to dość odporne na zakłócenia zewnętrzne, natomiast przewody pomiarowe mogą działać jak anteny i przyjmować zakłócenia od urządzeń działających w otoczeniu. W celu zbadania wpływu tych urządzeń, w pobliżu układu pomiarowego uruchomiono falownik zasilający silnik indukcyjny oraz dodatkowo dwa silniki indukcyjne z uszkodzeniami w uzwojeniach klatkowych. Aby zmierzyć zakłócenia i szumy generowane przez układ pomiarowy oraz urządzenia zewnętrzne, uruchomiono rejestrację przebiegów w kanałach prądowych przy niezasilonym stanie maszyny synchronicznej.




**Rys. 3.11.** *Przebieg czasowy oraz widmo częstotliwościowe sygnału szumu i zakłóceń*

Na rysunku 3.11. przedstawiono przykładowy przebieg czasowy sygnału szumu i zakłóceń w

kanale prądowym (po odjęciu składowej stałej dodawanej przez przetworniki LEM LTS 6-NP wynoszącej 2,5V) oraz widmo częstotliwościowe tego sygnału. Porównanie widm wielu zarejestrowanych w ten sposób sygnałów prowadzi do wniosku iż są to zaszumione przebiegi wieloharmoniczne.

Ponieważ analizy prądów dla celów diagnostycznych przeprowadzane były dla częstotliwości nieprzekraczających 2000Hz, analizę szumu zawężono do pasma 0÷2000Hz. Na rysunku 3.12 przedstawiono widmo częstotliwościowe sygnału szumu i zakłóceń dla tego pasma oraz odtworzony za pomocą odwrotnej szybkiej transformacji Fouriera (IFFT) przebieg czasowy sygnału dla zawężonego pasma częstotliwości.



**Rys. 3.12.** *Przebieg czasowy odtworzonego za pomocą odwrotnej transformacji Fouriera sygnału szumu oraz jego widmo częstotliwościowe w zakresie 0 ÷ 2000 Hz*

Z powyższego wykresu widać, że w zakresie częstotliwości 0-2000Hz szумы i zakłócenia są na poziomie nieprzekraczającym jednego miliwolta, co w stosunku do wartości napięć podawanych na kartę akwizycji danych podczas rejestracji sygnałów prądowych dla celów diagnostycznych, będących na poziomie kilku woltów, jest dość małym błędem.

## 4. WYZNACZANIE SYMPTOMÓW USZKODZEŃ

W pracy analizowano cztery dość powszechnie występujące w maszynie synchronicznej uszkodzenia. Dwa pierwsze uszkodzenia dotyczyły uzwojenia twornika i były to: zwarcie jednej grupy zezwojów twornika oraz przerwa jednej gałęzi równoległej. Pomiarów dla obu tych uszkodzeń prowadzone były na maszynie o budowie klasycznej. Dwa pozostałe uszkodzenia dotyczyły uzwojenia wzbudzenia i były to odpowiednio zwarcie oraz przerwa cewki bieguna wzbudzenia i prowadzone były na maszynie o budowie odwróconej. Ponieważ przez większość czasu swojego działania maszyna synchroniczna pracuje w stanie synchronizmu, a opracowana metodologia diagnostyki ma umożliwiać ciągłe kontrolowanie stanu maszyny, pomiary wszystkich stanów awaryjnych dokonywane były podczas pracy synchronicznej.

### 4.1. Metodyka wyznaczania symptomów uszkodzeń

Typowe metody wyznaczania symptomów uszkodzeń w maszynach elektrycznych opierają się na obserwacji i porównywaniu ze sobą sygnałów maszyny (prądy, drgania, hałas) zarejestrowanych w różnych stanach jej pracy (stan bezawaryjny i różnego typu uszkodzenia). Porównywać można różne parametry tych sygnałów. Zamiast sygnałów mogą być również użyte ich transformaty.

Dość powszechnie stosowaną metodą diagnostyki (głównie w silnikach indukcyjnych) jest MCSA (Motor Current Signature Analysis) [16], [55], [74], [85] polegająca na analizie widm częstotliwościowych prądów (zwykle twornika) i badaniu wpływu różnych uszkodzeń na składowe tych widm. W niniejszej pracy również zastosowano tę metodę, zarówno do analizy prądów twornika, jak i prądu wzbudzenia. Z uwagi na fakt, że składowe charakterystyczne widma dla wielu rodzajów uszkodzeń zależą od prędkości obrotowej (poślizgu), metoda ta jest bardzo dobrze rozwinięta w przypadku maszyn indukcyjnych, których prędkość obrotowa zmienia się wraz z obciążeniem. Ponadto powszechność występowania i niski koszt zakupu tego typu maszyn również przyczynia się do znacznej liczby prowadzonych badań diagnostycznych i publikacji na ten temat. Natomiast dla maszyn synchronicznych niewiele jest wzmianek w literaturze dotyczących zastosowania MCSA w wykrywaniu uszkodzeń.

Stosowaną ostatnio i dającą dobre rezultaty metodą jest analizowanie prądów twornika nie wprost, ale po transformowaniu ich do tzw. wektora przestrzennego prądu twornika, nazywanego inaczej wektorem Parka (Park's vector). Metoda ta daje dobre wyniki w szczególności dla stanów awaryjnych wywołanych asymetriami uzwojeń twornika, a więc

dla dwóch z poddawanych w niniejszej pracy przypadków.

Wektor Parka posiada dwie ortogonalne składowe  $I_D$ ,  $I_Q$ , które związane są z prądami fazowymi  $I_R$ ,  $I_S$ ,  $I_T$  poprzez następujące zależności [12], [13], [15], [22]:

$$\mathbf{i} = I_D + jI_Q = \sqrt{\frac{2}{3}}(I_R + \mathbf{a} \cdot I_S + \mathbf{a}^2 \cdot I_T) \quad (4.1)$$

gdzie:

$$\mathbf{a} = -\frac{1}{2} + j\frac{\sqrt{3}}{2}, \quad j = \sqrt{-1},$$

$I_R, I_S, I_T$  - wartości chwilowe prądów fazowych,

Składowe ortogonalne wektora Parka mają postać:

$$I_D = \sqrt{\frac{2}{3}}I_R - \frac{1}{\sqrt{6}}I_S - \frac{1}{\sqrt{6}}I_T \quad (4.2)$$

$$I_Q = \frac{1}{\sqrt{2}}I_S - \frac{1}{\sqrt{2}}I_T \quad (4.3)$$

Moduł wektora Parka wyraża się następującym wzorem:

$$I = \sqrt{I_D^2 + I_Q^2} \quad (4.4)$$

W widmie modułu wektora przestrzennego prądu twornika zawarta jest dobra informacja diagnostyczna, w postaci składowych typowych dla różnych stanów awaryjnych.

W pracach [13],[57] podano, że zwarcie w uzwojeniu twornika prowadzi do wzrostu składowej o częstotliwości:

$$f_w = 2f_s \quad (4.5)$$

gdzie:

$f_s$  - częstotliwość napięcia zasilającego.


Składowa ta jest wyraźnie widoczna zarówno w przypadku maszyny pracującej w stanie synchronicznym przy poślizgu równym zero, jak i w stanie asynchronicznym [13]. Jak stwierdzono w [80] za wzrost tej harmonicznej może być także odpowiedzialna asymetria napięcia zasilającego silnik. Dlatego w trakcie badań rejestrowane były napięcia zasilające i kontrolowany stopień ich asymetrii.

W niniejszej pracy do wyznaczania symptomów uszkodzeń na podstawie prądów twornika zastosowano metodę MCSA, oraz analizę widma modułu wektora przestrzennego prądu twornika. Ponadto w dalszej części użyta została zautomatyzowana metoda oparta na technice zwanej selekcją cech, wykorzystująca algorytm genetyczny.


## **4.2. Stan bezawaryjny**

Jednym z celów rozprawy jest zbadanie wpływu uszkodzeń na widma prądów maszyny, dlatego istotne jest dokonanie pomiarów dla stanu bezawaryjnego, które stanowią punkt odniesienia dla dalszych rozważań. Poddawane badaniom maszyny, podobnie jak wszystkie maszyny rzeczywiste, posiadają pewien stopień asymetrii już w stanie bezawaryjnym. Oprócz tego sposób ich wykonania, przystosowujący je do badań diagnostycznych, wprowadza dodatkowe asymetrie. W szczególności wynika to ze sposobu wykonania klatek rozruchowych, które posiadają pręty przykręcane do pierścieni, a więc o powiększonej rezystancji, która może różnić się dla poszczególnych prętów, a także ze sposobu wykonania uzwojenia twornika w maszynie o budowie klasycznej, w którym końce każdej grupy zezwojów wyprowadzone są na zewnątrz obudowy (różne długości tych wyprowadzeń) i są łączone z końcami innych grup za pomocą przewodów (różne rezystancje przewodów łączących, różne rezystancje styku przewodów z zaciskami). Również sposób wykonania uzwojenia wzbudzenia maszyny o budowie odwróconej może prowadzić do dodatkowych niesymetrii. Ponadto maszyny znajdują się w eksploatacji od pewnego, dłuższego już czasu, a więc mogą w nich postępować procesy starzeniowe (np. izolacji) oraz zużycia mechanicznego (np. łożysk). Maszyny są sprzęgnięte z maszynami prądu stałego, przez co możliwe są asymetrie wynikające z niedokładności wykonania tych połączeń (niewspółosiowość, skoszenie osi wałów). Zatem dla dalszych analiz ważne jest zarejestrowanie przebiegów w stanie nieuszkodzonym. Detekcja symptomów uszkodzeń odbywać się będzie na zasadzie porównania widm sygnałów prądowych zarejestrowanych w maszynach z uszkodzeniami z widmami prądów tych maszyn w stanach bezawaryjnych.

Na rysunkach 4.1 oraz 4.2 przedstawiono przebiegi czasowe oraz widma częstotliwościowe sygnałów prądowych odpowiednio twornika i wzbudzenia maszyny o budowie klasycznej w stanie bezawaryjnym. Przebiegi te zarejestrowane zostały podczas pracy w stanie synchronizmu. Na podstawie sygnałów prądowych twornika w każdej z faz wygenerowano sygnał wektora przestrzennego prądu twornika, którego przebieg zaprezentowany został na rysunku 4.3.




**Rys. 4.1.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w jednej z faz twornika maszyny o budowie klasycznej dla stanu bezawaryjnego




**Rys. 4.2.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny o budowie klasycznej dla stanu bezawaryjnego

Analiza zarejestrowanych przebiegów wykazała, że w widmach prądów twornika oraz wzbudzenia podczas pracy maszyny z prędkością synchroniczną największe amplitudy występują dla częstotliwości będących całkowitymi wielokrotnościami 25 Hz ( $f = k \cdot 25\text{Hz}$ ,  $k = 1, 2, \dots, 80$ ), które związane są z prędkością obrotową maszyny, wynoszącą 1500 obr/min. Jest to wyraźnie widoczne na rysunkach 4.1 i 4.2 oraz pozostałych rysunkach przedstawiających widma sygnałów w różnych stanach maszyny znajdujących się w dalszej części rozdziału. Podobne obserwacje zostały opisane również w pozycji [101].




**Rys. 4.3.** *Widmo częstotliwościowe modułu wektora przestrzennego prądu twornika maszyny o budowie klasycznej dla stanu bezawaryjnego*


Zestawienie przebiegów czasowych prądów twornika oraz wzbudzenia dla maszyny o budowie odwróconej zaprezentowano na rysunkach 4.4, 4.5 oraz 4.6. W przypadku tej maszyny pomiarów dokonano przy dwóch różnych sposobach połączenia cewek obwodu wzbudzającego - szeregowym oraz równoległym, prąd wzbudzenia dla obu tych przypadków przedstawiony został odpowiednio na rysunkach 4.5 i 4.6. Przebieg czasowy sygnału wektora przestrzennego prądu twornika dla tej maszyny przedstawiony został na rysunku 4.7.




**Rys. 4.4.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w jednej z faz twornika maszyny o budowie odwróconej dla stanu bezawaryjnego



**Rys. 4.5.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny o budowie odwróconej przy szeregowym połączeniu cewek tego obwodu dla stanu bezawaryjnego



**Rys. 4.6.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny o budowie odwróconej przy równoległym połączeniu cewek tego obwodu dla stanu bezawaryjnego



**Rys. 4.7.** *Widmo częstotliwościowe modułu wektora przestrzennego prądu twornika maszyny o budowie odwróconej dla stanu bezawaryjnego*

Jak wcześniej wspomniano, obie maszyny posiadają pewien stopień asymetrii już w stanie przyjmowanym jako bezawaryjny. W celu właściwej kontroli stanu maszyny pomiary stanu bezawaryjnego powinny być dokonywane jak najwcześniej, gdy stan maszyny jest potwierdzony, zatem dla nowej maszyny, przed wprowadzeniem jej do eksploatacji lub po remoncie, w czasie którego stan maszyny został określony. Następnie w trakcie eksploatacji maszyny powinno się regularnie dokonywać badań diagnostycznych i oceniać stan maszyny. Takie podejście pozwala wykrywać pojawiające się nieprawidłowości we wczesnym ich stadium i kontrolować tempo ich postępowania.

### 4.3. Zwarcie w zezwojach twornika.

Pierwszym spośród rozpatrywanych stanów awaryjnych było zwarcie w jednej z grup zezwojów twornika. Zwarcia w obwodzie twornika, powstałe na skutek degradacji izolacji są dość powszechnie występującymi uszkodzeniami w maszynach elektrycznych [1]. Początkowo zwarcie obejmuje najczęściej pojedyncze zwoje powodując wzrost ich temperatury na skutek przepływu prądu o dużej wartości, dochodzącej nawet do kilkudziesięciokrotności prądu znamionowego [57] (prąd fazowy w tym czasie nie ulega znacznemu zwiększeniu). Pod wpływem zwiększonej temperatury dochodzi w bardzo krótkim czasie do uszkodzenia izolacji sąsiednich zwojów i zwarcie bardzo szybko rozprzestrzenia się obejmując w niedługim czasie całe uzwojenie. Zatem bardzo ważne jest, aby tego typu uszkodzenie wykryć w jego początkowym stadium. Niestety stosowane obecnie

układy zabezpieczeń są niewrażliwe na zwarcia niewielkiej liczby zwojów, gdyż powodują one zbyt małe zmiany ilościowe w prądach fazowych. Prądy fazowe zaczynają wzrastać do poziomu, na który mogą zareagować zabezpieczenia dopiero wtedy, gdy zwarcie obejmuje już znaczną część uzwojenia. Dlatego istnieje potrzeba badań tego typu uszkodzeń.

Pomiary przeprowadzane były podczas pracy maszyny w stanie ustalonym. Zwierana była jedna grupa zezwojów w jednej z faz (faza S) twornika (grupa zezwojów  $V_1 Y_1$  na rysunku 4.8). Wprowadzenie stopniowania miało na celu określenie możliwości wykrycia tego typu uszkodzenia w jego wczesnym stadium. Pomiar był dokonywany w układzie pomiarowym według schematu z rysunki 3.1 z użyciem maszyny o budowie klasycznej. Maszyna pracowała w stanie synchronicznym (poślizg równy zero). Liczba zarejestrowanych próbek wynosiła 1200 i składało się na nią po 200 rejestracji dla sześciu następujących przypadków:

- brak uszkodzenia,
- zwarcie w jednej grupie zezwojów za pomocą rezystancji zwierającej o wartości  $3.45\Omega$ ,
- zwarcie w jednej grupie zezwojów za pomocą rezystancji zwierającej o wartości  $2.47\Omega$ ,
- zwarcie w jednej grupie zezwojów za pomocą rezystancji zwierającej o wartości  $2.00\Omega$ ,
- zwarcie w jednej grupie zezwojów za pomocą rezystancji zwierającej o wartości  $1.54\Omega$ ,
- zwarcie w jednej grupie zezwojów za pomocą rezystancji zwierającej o wartości  $1.30\Omega$ .

Spośród 200 próbek dla każdego z przypadków 50 było rejestrowanych gdy maszyna pracowała równolegle z dwoma uszkodzonymi silnikami indukcyjnymi, 50 gdy pracowała równolegle z falownikiem, 50 gdy pracowała równolegle z dwoma uszkodzonymi silnikami indukcyjnymi i falownikiem oraz 50 gdy pracowała bez odbiorników podłączonych równolegle.

Wartości prądu w zwartym zezwoju dla każdego z wymienionych przypadków wynosiły (wartości skuteczne):

12.8A dla przypadku, gdy  $R_{zw} = 3.45\Omega$ ,

19.0A dla przypadku, gdy  $R_{zw} = 2.47\Omega$ ,


23.3A dla przypadku, gdy  $R_{zw} = 2.00\Omega$ ,

30.6A dla przypadku, gdy  $R_{zw} = 1.54\Omega$ ,

37.6A dla przypadku, gdy  $R_{zw} = 1.30\Omega$ .

Jak widać prąd w zwartym zezwoju silnie wzrastał wraz ze spadkiem wartości rezystancji zwierającej. Prądy fazowe, zarówno dla faz wolnych od uszkodzenia jak i dla fazy w której zwarto grupę zezwojów nie różniły się znacząco pomiędzy sobą i były zbliżone do wartości prądów dla stanu bezawaryjnego (około 18A). Z uwagi na wymóg nieuszkodzenia maszyny w trakcie pomiarów nie stosowano rezystancji zwierających o wartościach niższych niż  $1.30\Omega$ . Zatem jest to diagnostyka w bardzo wczesnym stadium uszkodzenia.


Sposób podłączenia rezystancji zwierającej do obwodów twornika został przedstawiony na rysunku 4.8.




**Rys. 4.8.** Sposób podłączenia rezystancji zwierającej podczas badania zwarcia w uzwojeniach twornika

Na rysunku 4.9 przedstawiono przykładowy przebieg czasowy oraz widmo częstotliwościowe prądu w fazie, w której nastąpiło zwarcie jednej grupy zezwojów za pomocą rezystancji o wartości  $1.3 \Omega$ , natomiast na rysunku 4.10 zaprezentowano przebieg czasowy oraz widmo częstotliwościowe prądu wzbudzenia podczas zwarcia jednej grupy zezwojów twornika rezystancją o wartości  $1.3 \Omega$ .


W celu wyciągnięcia prawidłowych wniosków odnośnie tendencji wzrostowych lub spadkowych w amplitudach poszczególnych harmonicznych pod wpływem zwarcia należy porównać wszystkie zarejestrowane próbki dla danego przypadku ze wszystkimi zarejestrowanymi próbkami dla stanu bezawaryjnego. Jak już wcześniej wspomniano, w przypadku maszyny pracującej w stanie synchronicznym w widmie prądów twornika pojawiają się składowe, które są całkowitymi wielokrotnościami  $25\text{Hz}$ . Na rysunku 4.11 przedstawiono zestawienie amplitud harmonicznych (całkowitych wielokrotności  $25\text{Hz}$ ) prądów fazowych maszyny ze zwartą grupą zezwojów w fazie S ( $R_{zw}=1.3 \Omega$ ) oraz prądów fazowych w tej samej maszynie w przypadku braku uszkodzenia (po 200 rejestracji dla każdego z przypadków).



**Rys. 4.9.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w jednej z faz twornika maszyny, w której nastąpiło zwarcie jednej grupy zezwojów za pomocą rezystancji zwierającej o wartości 1.3  $\Omega$




**Rys. 4.10.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny, w której nastąpiło zwarcie jednej grupy zezwojów za pomocą rezystancji zwierającej o wartości 1.3  $\Omega$




**Rys. 4.11.** Amplitudy składowych prądów twornika o częstotliwościach będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej (kolor czarny) oraz dla maszyny, w której nastąpiło zwarcie jednej grupy zezwojów w fazie S poprzez rezystancję o wartości 1.3  $\Omega$  (kolor czerwony)

Na podstawie rysunku 4.11 można stwierdzić, że wśród harmoniczných prądów twornika, zarówno w uszkodzonej fazie jak i dwóch sąsiednich, tylko harmoniczna o częstotliwości 150Hz pozwala na odróżnienie stanu zwarcia od stanu bezawaryjnego. Amplitudy tej harmonicznej dla wszystkich zarejestrowanych próbek dla stanu bezawaryjnego oraz stanu zwarcia w jednej grupie zezwojów tworzą dwa skupiska, które po odrzuceniu pewnej liczby próbek dają się odseparować. Trudno natomiast jest wskazać, w której fazie nastąpiło uszkodzenie, ponieważ nie ma wyraźnej różnicy pomiędzy prądami w fazie uszkodzonej i w fazach wolnych od uszkodzenia. Zależność wartości amplitudy harmonicznej 150Hz prądu twornika od wartości rezystancji zwierającej podczas stopniowanego zwarcia została przedstawiona na rysunku 4.12. Jak można zauważyć istnieje tendencja do wzrostu wartości amplitudy wraz ze spadkiem wartości rezystancji zwierającej, jednak rozrzut wartości amplitud, dla każdego z przypadków jest tak duży, że wnioskowanie o stanie maszyny na podstawie wartości amplitudy tej harmonicznej obarczone jest bardzo dużym błędem.




**Rys. 4.12.** Amplitudy harmonicznej 150Hz prądu twornika w fazie ze zwartą grupą zezwojów dla różnych wartości rezystancji zwierającej

Na rysunku 4.13 przedstawiono zestawienie amplitud harmoniczných (całkowitych wielokrotności 25Hz) prądu wzbudzenia dla stanu bezawaryjnego oraz podczas zwarcia jednej grupy zezwojów rezystancją o wartości 1.3  $\Omega$ .




**Rys. 4.13.** Amplitudy składowych prądu wzbudzenia o częstotliwościach będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej (kolor czarny) oraz dla maszyny, w której nastąpiło zwarcie jednej grupy zezwojów w fazie S poprzez rezystancję o wartości  $1.3 \Omega$  (kolor czerwony)


Analiza rysunku 4.13 prowadzi do obserwacji, iż w sygnale prądowym w obwodzie wzbudzenia znajduje się kilka harmonicznnych dla których amplitudy tworzą separowalne skupiska odpowiadające stanom bezawaryjnemu oraz zwarcia grupy zezwojów twornika. Ponadto stopień separowalności jest wyższy niż w przypadku analizowanego wcześniej prądu twornika (odległość środków obu skupisk jest większa, a ich rozproszenie w poszczególnych grupach mniejsze). Zatem sygnał prądu w obwodzie wzbudzenia wydaje się być lepszym do diagnostyki zwarć zezwojów w obwodach twornika. Do celów diagnostycznych dobrze nadają się częstotliwości 100Hz i 200Hz, które dają w pełni separowalne skupiska oraz częstotliwość 125Hz, dla której stopień separowalności jest już nieco gorszy. W pracy [101] autorzy na podstawie badań na innej maszynie synchronicznej doszli do podobnych wniosków i jako częstotliwości charakterystyczne dla tego typu niesymetrii podają: 100Hz, 125Hz i 225Hz, co pozwala na postawienie hipotezy, że obserwacje te można uogólnić dla większej liczby maszyn synchronicznych. Na rysunkach 4.14 - 4.16 przedstawiono zależności wartości amplitud harmonicznnych odpowiednio 100Hz, 125Hz i 200Hz prądu wzbudzenia od wartości rezystancji zwierającej podczas stopniowanego zwarcia. Jak można zauważyć, dla harmonicznnych 100Hz i 200Hz istnieje silniejsza tendencja wzrostowa wartości amplitud wraz ze spadkiem wartości rezystancji zwierającej oraz mniejszy rozrzut danych niż w przypadku harmonicznnej 150Hz prądu twornika. Dla pozostałej harmonicznnej prądu wzbudzenia (125Hz) wzrost wartości amplitudy pod wpływem spadku wartości rezystancji zwierającej jest już mniejszy, a rozrzut wartości amplitud, dla każdego z przypadków jest znacznie większy, przez co użycie amplitudy tej harmonicznnej jako danej wejściowej klasyfikatora może prowadzić do błędów klasyfikacji.



**Rys. 4.14.** Amplitudy harmonicznej 100Hz prądu wzbudzenia dla różnych wartości rezystancji zwierającej jedną grupę zezwojów twornika




**Rys. 4.15.** Amplitudy harmonicznej 125Hz prądu wzbudzenia dla różnych wartości rezystancji zwierającej jedną grupę zezwojów twornika



**Rys. 4.16.** Amplitudy harmonicznej 200Hz prądu wzbudzenia dla różnych wartości rezystancji zwierającej jedną grupę zezwojów twornika


Analizę widmową prądów twornika, która okazała się stosunkowo mało przydatna dla diagnostyki zwarć w obwodach twornika, można zastąpić analizą widmową modułu wektora przestrzennego prądu twornika. Widmo wektora przestrzennego prądu twornika maszyny, zarejestrowanego podczas zwarcia jednej grupy zezwojów przez rezystancję o wartości 1.3  $\Omega$  zostało przedstawione na rysunku 4.17.



**Rys. 4.17.** Widmo wektora przestrzennego prądu twornika maszyny, w której nastąpiło zwarcie jednej grupy zezwojów poprzez rezystancję zwierającą o wartości 1.3  $\Omega$

Jak widać, amplituda składowej o częstotliwości 100Hz osiąga wyraźnie większą wartość w stosunku do amplitudy tej składowej dla stanu bezawaryjnego (rysunek 4.3).

Na rysunku 4.19 przedstawiono zestawienie amplitud harmonicznej 100Hz modułu wektora przestrzennego prądu twornika dla różnych wartości rezystancji zwierającej jedną grupę zezwojów twornika oraz stanu bezawaryjnego. Na podstawie tego rysunku zaobserwować można stałą tendencję wzrostową wartości amplitudy składowej 100Hz w miarę pogłębiania się stanu awaryjnego (w miarę spadku wartości rezystancji zwierającej).




**Rys. 4.19.** Amplitudy harmonicznej 100Hz modułu wektora przestrzennego prądu twornika dla różnych wartości rezystancji zwierającej jedną grupę zezwojów twornika

Z porównania rysunków 4.11 i 4.18 wynika, że do wykrywania zwarć zwojowych w tworniku lepiej nadaje się widmo modułu wektora przestrzennego prądu twornika (składowa 100Hz), aniżeli widma prądów fazowych. Stopień separowalności amplitud składowej 100Hz modułu wektora przestrzennego prądu twornika dla wszystkich zarejestrowanych próbek pomiarowych jest znacznie większy niż w przypadku składowej 150Hz w prądzie twornika, a rozrzut amplitud dla określonego stanu maszyny znacznie mniejszy.

#### 4.4. Przerwa gałęzi równoległej twornika.

Kolejnym rozpatrywanym stanem awaryjnym była przerwa jednej gałęzi równoległej uzwojenia twornika. Jest to dość powszechnie występujący w maszynach synchronicznych stan awaryjny. Zezwoje twornika zazwyczaj łączone są ze sobą poprzez połączenia lutowane, które mogą ulec uszkodzeniom na skutek drgań maszyny lub deformacji połączeń czołowych


pod wpływem przepływu prądów o dużej wartości. Prowadzi to do powstania przerwy na połączeniu zezwojów a co za tym idzie przerwy w całej gałęzi równoległej. Maszyna w takim stanie może nadal pracować, jednak praca w takich warunkach powoduje zwiększenie wartości prądu w pozostałych gałęziach równoległych należących do tej samej fazy, co w efekcie prowadzi do powstania kolejnych uszkodzeń na skutek nadmiernych ilości ciepła wydzielanego w tych gałęziach. Z uwagi na charakter uszkodzenia (przerwanie połączenia lutowanego) nie ma potrzeby dokonywać stopniowania wartości rezystancji wpiętej szeregowo w przerywany obwód. Pomiar tego stanu został wykonany przy całkowitym usunięciu połączenia pomiędzy dwiema grupami zezwojów stanowiących jedną z dwóch gałęzi równoległych w fazie S maszyny rysunek 4.19). Pomiar przeprowadzany był podczas pracy maszyny z prędkością synchroniczną.




**Rys. 4.19.** Sposób połączenia uzwojeń podczas badania przerwy w gałęzi równoległej twornika

Na rysunku 4.20 przedstawiono przykładowy przebieg czasowy oraz widmo częstotliwościowe prądu w fazie, w której nastąpiła przerwa w jednej z dwóch gałęzi równoległych, natomiast na rysunku 4.21 zaprezentowano przebieg czasowy oraz widmo częstotliwościowe prądu wzbudzenia dla tego samego przypadku uszkodzenia.


W celu wyciągnięcia prawidłowych wniosków odnośnie tendencji wzrostowych lub spadkowych w harmonicznych pod wpływem uszkodzenia polegającego na przerywaniu gałęzi równoległej w jednej z faz twornika należy porównać wszystkie zarejestrowane próbki dla tego przypadku ze wszystkimi zarejestrowanymi próbkami dla stanu bezawaryjnego. Na rysunku 4.22 przedstawiono zestawienie amplitud harmonicznych (całkowitych wielokrotności 25Hz) prądów fazowych w maszynie z przerwaną jedną gałęzią równoległą twornika i prądów fazowych w przypadku braku uszkodzenia, dla 200 rejestracji dla każdego z przypadków.



**Rys. 4.20.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w jednej z faz twornika maszyny, w której nastąpiła przerwa w jednej gałęzi równoległej w jednej z faz twornika




**Rys. 4.21.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny, w której nastąpiła przerwa w jednej gałęzi równoległej w jednej z faz twornika



**Rys. 4.22.** Amplitudy harmonicznych będących całkowitymi wielokrotnościami 25Hz prądu w fazie, w której nastąpiła przerwa w jednej gałęzi równoległej (kolor czerwony) oraz prądu w tej samej fazie w przypadku braku uszkodzenia (kolor czarny)


Na podstawie rysunku 4.22 można stwierdzić, że wśród harmoniczných prądów twornika, zarówno w uszkodzonej fazie jak i dwóch pozostałych, tylko harmoniczna o częstotliwości 150Hz pozwala na rozróżnienie pomiędzy stanem bezawaryjnym a stanem przerwy w jednej gałęzi równoległej. Natomiast analiza widma prądów fazowych nie pozwala jednoznacznie określić, w której fazie wystąpiło to uszkodzenie. W pracy [89] autor doszedł do podobnych wniosków na podstawie obliczeń numerycznych bazujących na modelu matematycznym silnika synchronicznego..

Zależność wartości amplitudy harmonicznój 150Hz prądu twornika od wartości rezystancji zwierającej podczas stopniowanego zwarcia została przedstawiona na rysunku 4.23.




**Rys. 4.23.** Amplitudy harmonicznój 150Hz prądu twornika w fazie nieuszkodzonej oraz z przerwą w gałęzi równoległej twornika


Na rysunku 4.24 przedstawiono zestawienie amplitud harmoniczných (całkowitych wielokrotności 25Hz) prądu wzbudzenia dla stanu bezawaryjnego oraz podczas pracy z przerwą w jednej gałęzi równoległej twornika. Analiza tego rysunku prowadzi do obserwacji, iż w sygnale prądowym w obwodzie wzbudzenia znajduje się kilka harmoniczných dla których amplitudy tworzą separowalne skupiska odpowiadające stanom bezawaryjnemu oraz przerwy w jednej gałęzi równoległej twornika. Są to składowe: 100Hz, 200Hz i 225Hz. Zestawienie wartości amplitud dla tych składowych dla stanu bezawaryjnego oraz dla przerwy w jednej gałęzi równoległej twornika zostało przedstawione na rysunkach 4.25, 4.26 i 4.27.




**Rys. 4.24.** Amplitudy prądu wzbudzenia dla częstotliwości będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej oraz dla maszyny, w której nastąpiło zwarcie jednej grupy zezwojów za pomocą rezystancji zwierającej o wartości  $1.3 \Omega$



**Rys. 4.25.** Amplitudy harmonicznego 100Hz prądu wzbudzenia w fazie nieuszkodzonej oraz z przerwą w gałęzi równoległej twornika




**Rys. 4.26.** Amplitudy harmonicznej 200Hz prądu wzbudzenia w fazie nieuszkodzonej oraz z przerwą w gałęzi równoległej twornika




**Rys. 4.27.** Amplitudy harmonicznej 225Hz prądu wzbudzenia w fazie nieuszkodzonej oraz z przerwą w gałęzi równoległej twornika

Podobnie jak w przypadku zwarcia grupy zezwojów twornika również i w tym przypadku widma prądów fazowych nie niosą zbyt bogatej informacji diagnostycznej. Prądy fazowe zostały transformowane do wektora przestrzennego prądu twornika i widmo modułu tego wektora poddano analizie. Przerwa gałęzi równoległej prowadzi do silnego wzrostu amplitudy składowej 100Hz, co można zaobserwować na rysunku 4.28.



**Rys. 4.28.** *Widmo wektora przestrzennego prądu twornika maszyny, w której nastąpiła przerwa jednej gałęzi równoległej twornika*

Na kolejnym rysunku, 4.29, przedstawiono zestawienie amplitud harmonicznej 100Hz modułu wektora przestrzennego prądu twornika dla przerwy gałęzi równoległej oraz dla stanu bezawaryjnego. Jak widać wystąpienie uszkodzenia spowodowało znaczny wzrost amplitudy tej składowej dla wszystkich analizowanych próbek.




**Rys. 4.29.** *Amplitudy harmonicznej 100Hz modułu wektora przestrzennego prądu twornika dla różnych wartości rezystancji zawierającej jedną grupę zewojów twornika*

Z porównania rysunków 4.23 i 4.29 wynika, że do wykrywania przerw w gałęziach równoległych twornika lepiej jest wykorzystać widmo modułu wektora przestrzennego prądu twornika (składowa 100Hz), niż widma prądów fazowych. W przypadku składowej 100Hz modułu wektora przestrzennego uzyskano lepszą separowalność i mniejszy rozrzut amplitud dla wszystkich zarejestrowanych próbek pomiarowych.

#### 4.5. Zwarcie cewki obwodu wzbudzenia.

Do tego typu uszkodzenia może dojść na skutek przebicia izolacji, np. podczas rozruchu asynchronicznego bez włączonej równoległe z obwodem wzbudzenia tzw. rezystancji rozruchowej (z otwartym podczas rozruchu obwodem wzbudzenia), kiedy poślizg wirnika jest bliski 1, a siła elektromotoryczna indukowana w uzwojeniu wzbudzenia osiąga duże, znacznie przewyższające znamionowe, wartości. Maszyna z tego typu uszkodzeniem może mieć problemy z rozruchem asynchronicznym.

Pomiarów dla stanu zwarcia uzwojenia bieguna dokonano z wykorzystaniem maszyny o budowie odwróconej pracującej w stanie synchronicznym. Uzwojenia wzbudzenia skojarzone były szeregowo. Równoległe z uzwojeniem jednego bieguna włączona została opornica o regulowanej wartości (rysunek 4.30).



**Rys. 4.30.** *Sposób skojarzenia uzwojeń oraz włączenia opornicy zwierającej podczas badania zwarcie w uzwojeniach wzbudzenia*

Wprowadzenie stopniowania, podobnie jak w przypadku pomiarów uszkodzeń w obwodzie twornika, miało na celu określenie możliwości wykrycia tego typu uszkodzenia w jego wczesnym stadium. Pomiar był dokonywany w układzie pomiarowym według schematu z rysunki 3.2 z użyciem maszyny o budowie odwróconej.

Liczba zarejestrowanych próbek wynosiła 1200 i składało się na nią po 200 rejestracji dla sześciu następujących przypadków:

- brak uszkodzeń,
- zwarcie jednej cewki obwodu wzbudzenia poprzez rezystancję o wartości  $3.45\Omega$ ,
- zwarcie jednej cewki obwodu wzbudzenia poprzez rezystancję o wartości  $2.47\Omega$ ,
- zwarcie jednej cewki obwodu wzbudzenia poprzez rezystancję o wartości  $2.00\Omega$ ,
- zwarcie jednej cewki obwodu wzbudzenia poprzez rezystancję o wartości  $1.54\Omega$ ,
- zwarcie jednej cewki obwodu wzbudzenia poprzez rezystancję o wartości  $1.30\Omega$ .

Spośród 200 próbek dla każdego z przypadków 50 było rejestrowanych gdy maszyna pracowała równolegle z dwoma uszkodzonymi silnikami indukcyjnymi, 50 gdy pracowała równolegle z falownikiem, 50 gdy pracowała równolegle z dwoma uszkodzonymi silnikami indukcyjnymi oraz falownikiem i 50 gdy pracowała bez odbiorników podłączonych równolegle. Wartości prądu w zwartej cewce dla każdego z wymienionych przypadków wynosiły:

0.98A dla przypadku, gdy  $R_{zw} = 3.45\Omega$ ,

1.38A dla przypadku, gdy  $R_{zw} = 2.47\Omega$ ,

1.61A dla przypadku, gdy  $R_{zw} = 2.00\Omega$ ,


1.92A dla przypadku, gdy  $R_{zw} = 1.54\Omega$ ,

2.26A dla przypadku, gdy  $R_{zw} = 1.30\Omega$ .


Jak widać prąd w zwartej cewce wzrastał wraz ze spadkiem wartości rezystancji zwierającej. Z uwagi na wymóg nieuszkodzenia maszyny w trakcie pomiarów nie stosowano rezystancji zwierających o wartościach niższych niż  $1.30\Omega$ . Zatem jest to diagnostyka w bardzo wczesnym stadium uszkodzenia.

Na rysunkach 4.31 i 4.32 przedstawiono przykładowe przebiegi czasowe oraz widma częstotliwościowe odpowiednio prądów twornika oraz wzbudzenia w maszynie, w której nastąpiło zwarcie cewki obwodu wzbudzenia poprzez rezystancję o wartości  $1.3\Omega$ .


Ponieważ maszyna pracowała z prędkością synchroniczną wynoszącą 1500 obr/min w widmach prądów twornika oraz wzbudzenia pojawiają się składowe, które są całkowitymi wielokrotnościami 25Hz. Na rysunku 4.33 przedstawiono zestawienie amplitud harmonicznych (całkowitych wielokrotności 25Hz) prądów fazowych maszyny ze zwartą cewką uzwojenia wzbudzenia ( $R_{zw}=1.3\Omega$ ) oraz maszyny nieuszkodzonej (po 200 rejestracji dla każdego z przypadków), natomiast na rysunku 4.34 przedstawiono podobne zestawienie dla prądu wzbudzenia.




**Rys. 4.31.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w jednej z faz twornika maszyny, w której nastąpiło zwarcie cewki obwodu wzbudzenia za pomocą rezystancji zwierającej o wartości 1.3  $\Omega$



**Rys. 4.32.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny, w której nastąpiło zwarcie cewki obwodu wzbudzenia za pomocą rezystancji zwierającej o wartości 1.3  $\Omega$



**Rys. 4.33.** Amplitudy składowych prądów twornika o częstotliwościach będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej oraz dla maszyny, w której nastąpiło zwarcie cewki obwodu wzbudzenia za pomocą rezystancji zawierającej o wartości  $1.3 \Omega$




**Rys. 4.34.** *Amplitudy składowych prądu wzbudzenia o częstotliwościach będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej oraz dla maszyny, w której nastąpiło zwarcie cewki obwodu wzbudzenia za pomocą rezystancji zwierającej o wartości  $1.3 \Omega$*

Analiza rysunku 4.33 prowadzi do wniosku, iż w sygnale prądowym w obwodzie twornika brak jest harmonicznych, które rozpatrywane samodzielnie pozwalałyby w sposób jednoznaczny stwierdzić o wystąpieniu tego typu zwarcia. Natomiast na podstawie rysunku 4.34 można stwierdzić, że w sygnale prądowym w obwodzie wzbudzenia znajduje się jedna harmoniczna (25Hz), którą należy brać pod uwagę w diagnostyce zwarć cewki obwodu wzbudzenia. Tworzy ona separowalne skupiska odpowiadające stanom bezawaryjnemu oraz zwarcia uzwojenia bieguna obwodu wzbudzenia. Na rysunku 4.35 przedstawiono zależność wartości amplitudy harmonicznej 25Hz prądu wzbudzenia od wartości rezystancji zwierającej podczas stopniowanego zwarcia. Jak można zauważyć istnieje tendencja wzrostowa wartości amplitud wraz ze spadkiem wartości rezystancji zwierającej, przy czym największa różnica w wartości amplitud występuje pomiędzy stanem bezawaryjnym, a zwarcie poprzez rezystancję o wartości  $3.45 \Omega$ . Tendencja ta ulega znacznemu osłabieniu przy dalszym zmniejszaniu wartości rezystancji zwierającej, co przy zastosowanych wartościach rezystancji uniemożliwia wnioskowanie o stopniu zwarcia. Rozrzut danych w obrębie danej klasy może sugerować, iż wartość tej harmonicznej jest silnie uzależniona od czynników zewnętrznych, w tym od stopnia nagrzania uzwojenia (zmiana rezystancji pod wpływem temperatury), a także w pewnym stopniu, z uwagi na dość małe wartości tych amplitud, niewiele przekraczające poziom szumów, na zakłócenia (choć biorąc pod uwagę fakt, że dla niższych wartości, rozrzut jest mniejszy, wpływ ten nie jest bardzo silny).


W pracy [89] zamieszczono wyniki badań na podstawie modelu matematycznego oraz pomiarów (przeprowadzonych na tej samej maszynie, na której prowadzone były badania w ramach niniejszej rozprawy) dla podobnego przypadku uszkodzenia, ale przy zwarcu

bezpośrednim obwodu wzbudzenia (bez włączania rezystancji) i przy pracy generatorowej. Jako częstotliwość charakterystyczną podano 150Hz w prądzie wzbudzenia. Ponadto pomiary wykazały, że w prądzie wzbudzenia zwiększeniu pod wpływem zwarcia ulega amplituda składowej 25Hz, natomiast obliczenia nie sugerują jej wzrostu. Autor tłumaczy to zjawisko niesymetrią obwodu magnetycznego (co jest wykazane w pracy [93]) i odrzuca składową 25Hz jako objaw związany ze zwarcie cewki obwodu wzbudzenia.




**Rys. 4.35.** Amplitudy harmonicznej 25Hz prądu wzbudzenia dla różnych wartości rezystancji zawierającej cewkę obwodu wzbudzenia

Również i dla tego przypadku uszkodzenia dokonano analizy widmowej modułu wektora przestrzennego prądu twornika. Przykładowy przebieg tego sygnału dla jednej z zarejestrowanych próbek przedstawiony został na rysunku 4.36. Porównanie tego przebiegu z przebiegiem z rysunku 4.7 prowadzi do wniosku, że zwarcie cewki obwodu wzbudzenia nie ma znacznego wpływu na sygnał modułu wektora przestrzennego prądu twornika.



**Rys. 4.36.** Widmo wektora przestrzennego prądu twornika maszyny, w której nastąpiło zwarcie cewki obwodu wzbudzenia poprzez rezystancję zwierającą o wartości 1.3  $\Omega$


Porównanie amplitud składowej 100Hz modułu wektora przestrzennego prądu twornika, widoczne na rysunku 4.37, prowadzi do wniosku, że zwarcie cewki obwodu wzbudzenia nie powoduje trwałej ilościowej zmiany wartości amplitudy tej składowej.



**Rys. 4.37.** Amplitudy harmonicznej 100Hz modułu wektora przestrzennego prądu twornika dla różnych wartości rezystancji zwierającej jedną grupę zezwojów twornika


## 4.6. Przerwa cewki obwodu wzbudzenia.

W maszynach o znacznych rozmiarach promieniowych (np. sprężarki gazu) spotyka się wirniki o dużej liczbie biegunów (np. 16). Uzwojenia biegunów zazwyczaj łączone są ze sobą równolegle poprzez połączenia lutowane, które mogą ulec uszkodzeniom na skutek drgań. Prowadzi to do powstania przerwy na połączeniu zezwojów a co za tym idzie przerwy w cewce obwodu wzbudzenia. Przy dużej liczbie równolegle połączonych uzwojeń biegunów przerwa w jednym z nich jest dość trudna do wykrycia przy użyciu tradycyjnych zabezpieczeń. Maszyna w takim stanie może nadal pracować, jednak obniża to jej sprawność oraz moment elektromagnetyczny. Ponadto odlutowane fragmenty uzwojenia mogą pod wpływem siły odśrodkowej przemieszczać się, co może prowadzić do nadmiernych drgań, pod których wpływem może dochodzić do uszkodzania się kolejnych połączeń. Ponadto przemieszczające się części uzwojeń mogą doprowadzić do uszkodzeń mechanicznych maszyny na skutek tarcia o wewnętrzne struktury stojana. Z uwagi na charakter uszkodzenia (przerwanie połączenia lutowanego) nie ma potrzeby dokonywać stopniowania wartości rezystancji wpiętej szeregowo w przerywany obwód. Pomiar tego stanu został wykonany przy całkowitym usunięciu połączenia pomiędzy końcem jednej z cewek obwodu wzbudzenia oraz końcami pozostałych, równolegle połączonych cewek. Schemat połączeń obwodu wzbudzenia dla tego stanu pracy przedstawiony został na rysunku 4.38. Pomiar przeprowadzany był podczas pracy maszyny z prędkością synchroniczną.




**Rys. 4.38.** Sposób połączenia uzwojeń biegunów podczas badania przerwy w obwodzie wzbudzenia


Na rysunku 4.39 przedstawiono przykładowy przebieg czasowy oraz widmo częstotliwościowe prądu fazowego w maszynie, w której nastąpiła przerwa w jednej z równolegle połączonych cewek obwodu wzbudzenia, natomiast na rysunku 4.40 zaprezentowano przebieg czasowy oraz widmo częstotliwościowe prądu wzbudzenia (od strony zasilania) dla tego samego przypadku uszkodzenia.



**Rys. 4.39.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w jednej z faz twornika maszyny, w której nastąpiła przerwa w jednej cewce obwodu wzbudzenia




**Rys. 4.40.** Przebieg czasowy oraz widmo częstotliwościowe sygnału prądowego w obwodzie wzbudzenia maszyny, w której nastąpiła przerwa w jednej cewce obwodu wzbudzenia



**Rys. 4.41.** Amplitudy składowych prądów twornika o częstotliwościach będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej oraz dla maszyny, w której wystąpiła przerwa jednej cewki obwodu wzbudzenia


Rysunek 4.41 jest zestawieniem amplitud harmonicznych (całkowitych wielokrotności 25Hz) prądów fazowych w maszynie pracującej z przerwą jedną cewką obwodu wzbudzenia i prądów fazowych w przypadku braku uszkodzenia, dla 200 rejestracji dla każdego z przypadków. Na rysunku 4.42 przedstawiono podobne zestawienie dla prądu wzbudzenia.



**Rys. 4.42.** Amplitudy składowych prądu wzbudzenia o częstotliwościach będących całkowitymi wielokrotnościami 25Hz dla maszyny nieuszkodzonej oraz dla maszyny, w której wystąpiła przerwa jednej cewki obwodu wzbudzenia

Analiza obu rysunków prowadzi do wniosku, że zarówno w prądach fazowych, jak i w prądzie wzbudzenia brak jest składowych (wielokrotności 25Hz), które pozwalałyby jednoznacznie stwierdzić o wystąpieniu przerwy cewki obwodu wzbudzenia. Jedyną składową, która mogłaby być źródłem informacji diagnostycznej jest składowa 25Hz w prądzie wzbudzenia. Amplitudy tej składowej co prawda nie tworzą separowanych skupisk, jednak w przypadku wystąpienia uszkodzenia wartości amplitud są w większości nieznacznie wyższe niż dla stanu bezawaryjnego. Dalsza analiza tej składowej pokazuje jednak, że składowa ta nie jest zbyt użyteczna dla wnioskowania o wystąpieniu uszkodzenia. Porównanie wartości amplitud harmonicznej 25Hz dla stanu bez uszkodzenia i przerwy jednej cewki obwodu wzbudzenia przedstawiono na rysunku 4.43. Ponadto na podstawie informacji zawartych w [89], [93] można przypuszczać, że składowa 25Hz może mieć związek z niesymetrią obwodu magnetycznego.


Jedyną składową, która powodowała powstanie separalnych skupisk dla stanu bezawaryjnego oraz przerwy była składowa stała (składowa o częstotliwości 0Hz). Jest to dość oczywiste, ponieważ przerwa powoduje istotną zmianę impedancji równoległego połączenia uzwojeń. Jednak amplituda składowej stałej może ulegać zmianie pod wpływem wielu innych czynników i stosowanie jej jako symptom świadczący o wystąpieniu przerwy nie jest wskazane.




**Rys. 4.43.** Amplitudy harmonicznej 25Hz prądu wzbudzenia dla stanu bezawaryjnego oraz przerwy w jednej cewce obwodu wzbudzenia

Analiza widmowa modułu wektora przestrzennego prądu twornika również nie daje dobrych rezultatów. Wystąpienie przerwy jednej cewki obwodu wzbudzenia nie powoduje istotnych zmian w amplitudach składowych tego sygnału. Przykładowy przebieg modułu wektora przestrzennego prądu twornika dla jednej z zarejestrowanych próbek przedstawiony został na rysunku 4.44, a porównanie amplitud składowej 100Hz w tym sygnale dla stanu bezawaryjnego oraz dla zwarcia cewki wzbudzenia widoczne jest na rysunku 4.47. Jak można zaobserwować zwarcie cewki obwodu wzbudzenia nie powoduje znaczących zmian wartości amplitudy tej składowej.

Na podstawie analizy wszystkich czterech przypadków uszkodzeń można stwierdzić, że wektor przestrzenny prądu twornika daje bardzo dobrą informację diagnostyczną w przypadku asymetrii w obwodach twornika, natomiast dla asymetrii w skupionych uzwojeniach wzbudzenia informacja ta jest niewystarczająca do wnioskowania o wystąpieniu tych uszkodzeń.




**Rys. 4.44.** *Widmo wektora przestrzennego prądu twornika maszyny, w której nastąpiła przerwa w jednej cewce obwodu wzbudzenia*



**Rys. 4.45.** *Amplitudy harmonicznej 100Hz modułu wektora przestrzennego prądu twornika dla stanu bezawaryjnego oraz przerwy w jednej cewce obwodu wzbudzenia*

## 5. AUTOMATYCZNA SELEKCJA CECH

Wybór symptomów uszkodzeń polegający na rozpatrywaniu każdej z harmonicznych osobno i wybieraniu tych spośród nich, które tworzą separowalne skupiska dla różnych stanów maszyny (uszkodzenie lub jego brak), nie zawsze musi prowadzić do dobrych efektów późniejszej klasyfikacji. Istnieje bowiem możliwość, że pozostałe harmoniczne, choć samodzielnie nie tworzą separowanych skupisk, to rozpatrywane razem, jako współrzędne punktów w przestrzeniach o większej wymiarowości, będą dawać skupiska o wysokim stopniu separowalności. Tego typu sytuacja została zilustrowana na rysunku 6.1, na którym zbiory dwóch cech  $x$  i  $y$ , rozpatrywane indywidualnie nie dają separowanych skupisk, natomiast gdy zostaną użyte jako współrzędne wektorów cech w przestrzeni dwuwymiarowej, tworzą dwie liniowo separowalne grupy.



**Rys. 5.1.** Przykład wektorów cech, które w przestrzeni dwuwymiarowej tworzą dwa liniowo separowalne skupiska

Ponadto branie pod uwagę kilku częstotliwości, które rozpatrywane samodzielnie dają dość dobrze separowalne skupiska może być czasem nieefektywne, ponieważ harmoniczne te mogą być ze sobą silnie skorelowane, przez co wzrasta redundancja i obniża się jakość klasyfikacji. Dlatego też dobrze jest podczas wyboru cech brać pod uwagę wszystkie harmoniczne jednocześnie i poszukiwać takiego ich podzbioru, który w sensie przyjętego kryterium dawałby największą separowalność. Do tego celu służy procedura nazywana selekcją cech.

Selekcja cech jest procesem polegającym na wyborze spośród zbioru wszystkich cech takiego podzbioru, który optymalizowałby pewną funkcję kryterialną. [95].

Jeśli  $\{x_1, x_2, \dots, x_D\}$  jest D-elementowym zbiorem cech, to zbiór  $\{x_{i1}, x_{i2}, \dots, x_{id}\}$  jest jego d-elementowym podzbiorem ( $d < D$ ) spełniającym warunek:


$$\{x_{i1}, x_{i2}, \dots, x_{id}\} = \arg \max_{d, i_d} [J(\{x_i, i = 1, 2, \dots, D\})] \quad (5.1)$$

Selekcja prowadzi do zredukowania ilości cech poprzez wybór cech najistotniejszych i odrzucenie cech nieistotnych, nadmiarowych (gdy pewne cechy są liniową kombinacją innych cech) i zaszumionych [48], [98]. Dzięki temu zwiększa się poprawność późniejszej klasyfikacji oraz zmniejsza czas potrzebny do jej przeprowadzenia.

Proces selekcji cech składa się z czterech podstawowych elementów [18]:

1. algorytmu przeszukiwania przestrzeni wejściowej, służącego do generacji kolejnych podzbiorów cech,
2. funkcji kryterialnej służącej do oceny podzbiorów w kolejnych krokach działania algorytmu przeszukiwania,
3. warunku zatrzymania, którego spełnienie prowadzi do zakończenia działania procesu selekcji,
4. procedury weryfikacyjnej (walidacyjnej) służącej do oceny jakości podzbiorów, które zostały uznane za najlepsze.

Algorytm selekcji rozpoczyna działanie od wygenerowania podzbioru cech, dla którego następnie obliczana jest wartość funkcji kryterialnej. Jeśli wartość ta nie spełnia warunku zatrzymania, generowany jest kolejny podzbiór i warunek zatrzymania jest sprawdzany ponownie. Czynności te są powtarzane aż do momentu, kiedy warunek zatrzymania zostanie spełniony. Wtedy algorytm selekcji kończy swoje działanie i wykonywana jest walidacja podzbioru, dla którego został spełniony warunek zatrzymania. Proces walidacji nie jest częścią algorytmu selekcji cech, ale musi być zawsze przeprowadzany po jego zakończeniu [18]. Diagram działania algorytmu selekcji cech został przedstawiony na rysunku 5.2.



**Rys. 5.2.** Diagram algorytmu selekcji cech i walidacji

## 5.1. Algorytmy poszukiwań

Wybór odpowiedniego algorytmu przeszukiwania przestrzeni wejściowej cech ma kluczowe znaczenie w procesie selekcji. Ze względu na rodzaj strategii poszukiwania wyróżnia się trzy podstawowe grupy algorytmów przeszukiwań: algorytmy kompletne, heurystyczne oraz stochastyczne [18],[51],[95].

### 5.1.1. Algorytmy kompletne

Algorytmy kompletne (inna spotykana w literaturze nazwa to algorytmy wykładnicze) dają w wyniku swojego działania rozwiązania optymalne. Podstawowym algorytmem kompletnym jest algorytm przeszukiwania wyczerpującego (exhaustive search), który analizuje wszystkie dostępne kombinacje cech. Dla  $n$ -elementowego wektora cech istnieje  $\binom{n}{k}$   $k$ -elementowych kombinacji cech. Jeśli liczba cech, które należy brać pod uwagę ( $k$ ) nie jest z góry ustalona, przestrzeń poszukiwań osiąga rozmiar  $2^n$  (zatem przestrzeń poszukiwań rośnie wykładniczo wraz ze wzrostem ilości cech) [63]. W przypadku wektorów o większej liczbie cech sprawdzenie tak dużej liczby możliwych kombinacji jest często praktycznie nie do zrealizowania.

W pracy [18] stwierdzono, że „to, że algorytm przeszukiwania jest kompletny, wcale nie musi oznaczać, że jest on wyczerpujący”. Opracowano zatem inne algorytmy o takim samym rozmiarze przestrzeni poszukiwań ( $2^n$ ), ale o mniejszej liczbie kroków działania algorytmu. Jednym z takich algorytmów jest algorytm branch&bound [88], [72], [62], który redukuje ilość kroków poprzez stosowanie warunku monotoniczności w postaci:

$$\mathbf{F}_1 \supset \mathbf{F}_2 \supset \dots \supset \mathbf{F}_j \Rightarrow J(\mathbf{F}_1) \geq J(\mathbf{F}_2) \geq \dots \geq J(\mathbf{F}_j) \quad (5.2)$$

gdzie:

$\mathbf{F}_1, \mathbf{F}_2, \mathbf{F}_j$  – podzbiory cech,

$J(\mathbf{F}_1), J(\mathbf{F}_2), J(\mathbf{F}_j)$  – wartość funkcji kryterialnej dla podzbiorów  $\mathbf{F}_1, \mathbf{F}_2, \mathbf{F}_j$ .

Algorytm tworzy drzewo decyzyjne, którego korzeniem jest pełny zbiór cech, a liśćmi są jego poszczególne podzbiory. Liście powstają przez pojedyncze usuwanie cech; na pierwszym poziomie drzewa znajdują się podzbiory z usuniętą jedną cechą, na drugim poziomie z dwiema, itd. Dla każdego z podzbiorów na danym poziomie obliczana jest wartość funkcji kryterialnej, a najlepszy dotychczasowy podzbiór wraz z wartością jego funkcji kryterialnej jest zapamiętywany. Jeżeli na którymś etapie wartość funkcji kryterialnej aktualnie sprawdzanego liścia nie spełnia warunku monotoniczności w stosunku do najlepszej zapamiętanej wartości na wyższym poziomie, to poddrzewo tego liścia nie jest już dalej przeszukiwane.

Innym algorytmem kompletnym jest algorytm best first search [88]. Również ten algorytm tworzy strukturę drzewa, którego poszczególnymi liśćmi są podzbiory pełnego zbioru cech.

Algorytm sprawdza i zapamiętuje wartość funkcji kryterialnej dla każdego z liści na danym poziomie ( $n$ ), a dla najlepszego podzbioru rozwija jego liście na niższym poziomie ( $n+1$ ) i sprawdza wartości ich funkcji kryterialnych. Jeżeli największa wartość funkcji kryterialnej (dla problemu maksymalizacyjnego) na tym poziomie ( $n+1$ ) jest większa od drugiej w kolejności najlepszej wartości na poziomie  $n$ , to algorytm kontynuuje rozwijanie liści najlepszego podzbioru na kolejnym, niższym poziomie ( $n+2$ ). W przeciwnym wypadku algorytm przechodzi do sprawdzania drugiego pod względem wartości funkcji kryterialnej elementu na poziomie  $n$  i rozwija jego liście. Procedura ta powtarzana jest wielokrotnie aż do spełnienia warunku zatrzymania lub do osiągnięcia stanu, gdy w rozwijanym poddrzewie osiągnięty został ostatni element i brak jest lepszych podzbiorów na wyższych poziomach. Kolejnym algorytmem kompletnym jest algorytm beam search. Jego działanie polega na rozwijaniu tylko ustalonej liczby najlepszych liści na danym poziomie. Algorytmy best first search i beam search prowadzą do rozwiązania suboptymalnego, natomiast algorytmy wyczerpujący oraz branch&bound dają w efekcie swojego działania rozwiązanie optymalne [88].

### 5.1.2. Algorytmy heurystyczne

W algorytmach heurystycznych (zwanych też sekwencyjnymi) cechy dodawane lub usuwane są w sposób sekwencyjny. W grupie tej wyróżnić można takie algorytmy jak: sequential forward selection (SFS), sequential floating forward selection (SFFS) oraz sequential backward selection (SBS). Algorytm SFS generuje na początku zbiór pusty, do którego w kolejnych krokach dodaje kolejne elementy. Elementami tymi są cechy, których dołączenie powoduje największy przyrost wartości funkcji kryterialnej. Wadą tego algorytmu jest brak możliwości usunięcia cech uprzednio dodanych. Często bowiem zdarza się, że po dodaniu nowych cech, obecność w zbiorze niektórych dołączonych wcześniej cech powoduje zmniejszenie wartości funkcji kryterialnej. Niedogodność ta została zlikwidowana w algorytmie SFFS, który po dodaniu nowej cechy dodatkowo dokonuje szeregu warunkowych usunięć, jeśli wpływa to na wzrost wartości funkcji kryterialnej. Trzeci z algorytmów sekwencyjnych - algorytm SBS ma działanie odwrotne. Startuje on z pełnego zbioru cech i sekwencyjnie usuwa te spośród nich, których eliminacja powoduje największy przyrost funkcji kryterialnej. Algorytmy SFS są wydajniejsze obliczeniowo od algorytmów SBS, ale jednocześnie prowadzą one do gorszych rozwiązań [25].

Algorytmy sekwencyjne należą do łatwych w implementacji i szybkich metod poszukiwań, a ich złożoność obliczeniowa wynosi  $n^2$ , natomiast ich zasadniczą wadą jest tendencja do zbieżności do minimów lokalnych.

### 5.1.3. Algorytmy stochastyczne

W kolejnym typie algorytmów przeszukiwania przestrzeni cech – algorytmach stochastycznych problem zbieżności do minimum lokalnego został przezwyciężony poprzez wprowadzenie elementu losowości przy wyborze cech. Chociaż rozmiar przestrzeni poszukiwań w algorytmach stochastycznych jest taki sam jak w algorytmach kompletnych ( $2^n$ ), to ilość iteracji algorytmów jest znacznie mniejsza [18]. Do najpopularniejszych algorytmów stochastycznych należą algorytmy genetyczne, strategie ewolucyjne, a także symulowane wyżarzanie.

Algorytmy genetyczne oparte są na mechanizmach doboru naturalnego oraz dziedziczności [23]. Operują one na populacjach osobników (sztucznych organizmach), z których każdy reprezentowany jest przez ciąg bitowy zwany chromosomem. W chromosomie zakodowane jest położenie osobnika w przestrzeni poszukiwań. Na podstawie położenia osobnika obliczane jest jego przystosowanie. Na podstawowy (klasyczny, elementarny, prosty) algorytm genetyczny składają się następujące kroki [87]:

1. inicjacja, czyli wybór początkowej populacji chromosomów,
2. ocena przystosowania chromosomów w populacji,
3. sprawdzenie warunku zatrzymania,
4. selekcja chromosomów do populacji tymczasowej,
5. zastosowanie operatorów genetycznych,
6. utworzenie nowej populacji,
7. sprawdzenie warunku zatrzymania, jeśli jest on spełniony to dokonywane jest wyprowadzenie najlepiej przystosowanego chromosomu, jeśli nie to dokonywany jest powrót do punktu czwartego algorytmu.

Algorytmy genetyczne z powodzeniem stosowane są w wielu problemach optymalizacyjnych (np. w optymalizacji konstrukcji [66], [67]), zastępując powszechnie stosowane metody gradientowe. Więcej informacji na temat działania algorytmów genetycznych zostało zawartych w kolejnym rozdziale.

Strategie ewolucyjne w swoim działaniu przypominają nieco algorytmy genetyczne, ale posiadają w stosunku do nich pewne różnice. Główne podobieństwo polega na tym, że w obu metodach występuje populacja potencjalnych rozwiązań, a zasada selekcji polega na przeżyciu bardziej dopasowanych osobników [2], [69]. Jednak osobniki kodowane są za pomocą wektorów zmiennopozycyjnych, podczas gdy w algorytmach genetycznych do kodowania osobników stosowane są wektory binarne. Również inna jest kolejność stosowania operatorów selekcji, mutacji i krzyżowania. W strategiach ewolucyjnych najpierw dokonywana jest mutacja i krzyżowanie, a dopiero po nich dochodzi do selekcji. Prawdopodobieństwa krzyżowania i mutacji zmieniają się w poszczególnych krokach działania strategii wraz ze zmianą wektora rozwiązań. Osobnikiem jest trójka  $(x, \sigma, \Theta)$ ,

w której  $x$  oznacza wektor rozwiązań,  $\sigma$  prawdopodobieństwo krzyżowania, a  $\theta$  prawdopodobieństwo mutacji. Cała trójka poddawana jest procesowi ewolucji. W pojedynczym pokoleniu strategii ewolucyjnej  $\mu$  rodziców tworzy pośrednią populację składającą się z  $\lambda$  potomków utworzonych za pomocą operatorów krzyżowania i mutacji (dla strategii  $(\mu, \lambda)$ ) i ewentualnie, dodatkowo, z  $\mu$  rodziców (dla strategii  $(\mu + \lambda)$ ). Następnie w procesie selekcji redukuje się liczebność populacji pośredniej do  $\mu$  osobników, poprzez wyrzucenie z niej osobników najgorzej przystosowanych i w ten sposób tworzy się nowe pokolenie. Selekcja w strategiach ewolucyjnych polega na deterministycznym wyborze, a nie jak w algorytmach genetycznych na losowaniu ze zwracaniem, dzięki czemu najsłabsze osobniki nie mają żadnych szans na przejście do kolejnego pokolenia.

Symulowane wyżarzanie jest metodą opierającą się na analogii do procesu krzepnięcia ciał fizycznych podczas ich wyżarzania przy temperaturze stopniowo zmniejszanej do zera [38], [78]. Materiały ogrzane do wysokich temperatur i stopniowo schładzane krystalizują w stanach o najniższych energiach. Zbyt szybkie chłodzenie spowodować może powstanie defektów i naprężeń, przez co stan energetyczny materiału po zakończeniu procesu będzie na poziomie wyższym niż podczas schładzania powolnego. Jeśli przyjąć za funkcję celu energię ciała, a absolutne minimum tej energii za minimum globalne, naprężenia powstałe wskutek zbyt szybkiego chłodzenia odpowiadają utknięciu procesu w minimum lokalnym. Wyjście procesu z minimum lokalnego możliwe jest poprzez dopuszczenie chwilowego wzrostu energii. Prawdopodobieństwo wystąpienia konfiguracji o energii wyższej o  $\Delta E$  od absolutnego minimum dane jest przez rozkład Boltzmanna:

$$p(\Delta E) = \exp\left(-\frac{\Delta E}{kT}\right) \quad (5.3)$$

gdzie:

$k$  – stała Boltzmanna,

$T$  – temperatura.

Zgodnie ze wzorem (5.3) prawdopodobieństwo pojawienia się stanów o wyższej energii maleje wraz ze spadkiem temperatury. Zatem opuszczenie minimum lokalnego łatwiejsze jest przy temperaturach wyższych i w początkowej fazie procesu schładzanie powinno być bardzo powolne, co prowadzi do nieznacznego spadku energii. W środkowej fazie procesu schładzania dokonują się największe zmiany energii, natomiast w końcowej jego fazie, przy temperaturze zbliżającej się do zera absolutnego zmiany temperatury są nieznaczne. Jeśli temperatura zmierzać będzie do zera nieskończenie wolno to układ zmierzać będzie do konfiguracji odpowiadającej absolutnemu minimum ( $\Delta E=0$ ).

Metoda symulowanego wyżarzania jest algorytmicznym odpowiednikiem fizycznego procesu wyżarzania i przebiega według następującego schematu:

1. Wybierz stan początkowy w przy założonej temperaturze początkowej  $T$ .
2. Dopóki  $T > 0$  wykonaj następujące czynności:
  - a. wybierz nowe rozwiązanie  $w'$  z sąsiedztwa  $w$ ,


- b. oblicz różnicę funkcji celu  $\Delta E = E(w') - E(w)$ ,
- c. jeśli  $\Delta E \leq 0$ , przyjmij  $w = w'$  (obniżenie energii), w przeciwnym wypadku ( $\Delta E > 0$ ) załóż, że  $w = w'$  z prawdopodobieństwem  $\exp(-\Delta E/T)$ , co oznacza generację liczby losowej  $R$  z zakresu  $(0,1)$  i porównanie jej z wartością  $\exp(-\Delta E/T)$ ; jeśli  $\exp(-\Delta E/T) > R$  zaakceptuj nowe rozwiązanie  $w = w'$ , w przeciwnym wypadku nie akceptuj.
3. Zredukuj temperaturę  $T_{i+1} = r \cdot T_i$  przy współczynniku redukcji z zakresu  $(0,1)$  i wróć do punktu 2 algorytmu.
4. Po zredukowaniu temperatury do wartości zerowej wyprowadź aktualne rozwiązanie.

## 5.2. Funkcje kryterialne

Wybór optymalnego podzbioru cech jest zawsze zależny od zastosowanej funkcji kryterialnej (zastosowanie w tym samym algorytmie selekcji cech dwóch różnych funkcji kryterialnych może prowadzić do otrzymania różnych rozwiązań) [18]. W zależności od zastosowanej funkcji kryterialnej wyróżnia się dwie podstawowe grupy metody selekcji cech: filtry oraz metody opakowane, a także ich kombinacje – metody hybrydowe oraz metody wbudowane i metody rankingowe.

### 5.2.1. Filtry

Filtry są grupą metod, w których selekcja optymalnego podzbioru cech odbywa się niezależnie od późniejszego procesu klasyfikacji [25],[98]. Funkcja kryterialna ocenia stopień separowalności klas, korzystając z pewnej miary. Wyróżnia się pięć rodzajów miar stosowanych w filtrach: miary odległościowe, miary informacyjne, miary korelacyjne, miary jednoznaczności oraz miary błędu odpowiedzi klasyfikatora. Diagram działania algorytmu typu filtr został przedstawiony na rysunku 5.3.



**Rys. 5.3.** Diagram działania algorytmu selekcji cech typu filtr

Do zalet filtrów należą: mniejsza złożoność obliczeniowa niż pozostałych metod, dzięki czemu ich czas wykonania jest krótszy, uniwersalność – wynik selekcji jest niezależny od

klasyfikatora (przez co można zastosować dowolny klasyfikator) oraz możliwość zastosowania w praktycznie dowolnym problemie klasyfikacyjnym. Wadą jest konieczność estymacji wielowymiarowych rozkładów prawdopodobieństwa.

### Miary odległościowe

Określane są również jako miary separowalności, dywergencyjne lub dyskryminacyjne. Miary odległościowe w problemach dwuklasowych preferują te podzbiory cech, które generują większą różnicę pomiędzy klasami; różnica ta określana jest za pomocą odległości.

Odległość powinna spełniać trzy aksjomaty:

$$d(\mathbf{x}, \mathbf{y}) = 0 \Leftrightarrow \mathbf{x} = \mathbf{y} \quad (5.4)$$

$$d(\mathbf{x}, \mathbf{y}) = d(\mathbf{y}, \mathbf{x}) \quad (5.5)$$

$$d(\mathbf{x}, \mathbf{y}) + d(\mathbf{y}, \mathbf{z}) \geq d(\mathbf{x}, \mathbf{z}) \quad (5.6)$$

gdzie:

$\mathbf{x}, \mathbf{y}, \mathbf{z}$  -wektory,

$d(\mathbf{x}, \mathbf{y})$  – odległość pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

Istnieje wiele miar odległościowych, spośród których najczęściej stosowane zostały przedstawione poniżej.

Uogólnioną miarą odległości jest ważona odległość Minkowskiego, która wyraża się wzorem [95]:

$$d_w^M(\mathbf{x}, \mathbf{y}) = (\sum_{i=1}^n w_i \cdot |x_i - y_i|^p)^{\frac{1}{p}} \quad (5.7)$$

$$\sum_{i=1}^n w_i = 1$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$w_i$  – waga i-tej cechy,

$p$  – dodatnia liczba całkowita,

$d_w^M(\mathbf{x}, \mathbf{y})$  – ważona odległość Minkowskiego pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

Jeśli wszystkim współrzędnym wektorów nada się wagę równą 1 ( $w_i = 1$ ), otrzymuje się nieważoną odległość Minkowskiego, daną wzorem:

$$d^M(\mathbf{x}, \mathbf{y}) = (\sum_{i=1}^n |x_i - y_i|^p)^{\frac{1}{p}} \quad (5.8)$$

Do szczególnych przypadków nieważonej odległości Minkowskiego, w zależności od wartości  $p$  należą odległość euklidesowa ( $p = 2$ ) oraz odległość według normy  $L_1$  ( $p = 1$ ) dane wzorami:

$$d^E(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5.9)$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$d^E(\mathbf{x}, \mathbf{y})$  – odległość euklidesowa pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

$$d^{L_1}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n |x_i - y_i| \quad (5.10)$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$d^{L_1}(\mathbf{x}, \mathbf{y})$  – odległość według normy  $L_1$  pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

Często stosowana jest także ważona odległość euklidesowa wyrażająca się zależnością:

$$d_w^E(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n w_i (x_i - y_i)^2} \quad (5.11)$$

$$\sum_{i=1}^n w_i = 1$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$w_i$  – waga  $i$ -tej cechy,

$d_w^E(\mathbf{x}, \mathbf{y})$  – ważona odległość euklidesowa pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

Odległość według normy  $L_\infty$  (zwana także odległością iniektywną, Czebyszewa, szachową):

$$d^\infty(\mathbf{x}, \mathbf{y}) = \max_{i=1:n} |x_i - y_i| \quad (5.12)$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$d^\infty(\mathbf{x}, \mathbf{y})$  – odległość według normy  $L_\infty$  pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

Odległość Canberra:

$$d^{Can}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n \frac{|x_i - y_i|}{x_i + y_i} \quad (5.13)$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$d^{Can}(\mathbf{x}, \mathbf{y})$  – odległość Canberry pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ .

Odległość  $\chi^2$ :

$$d^{\chi^2}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n \frac{1}{sum_i} \left( \frac{x_i}{size_x} - \frac{y_i}{size_y} \right)^2 \quad (5.14)$$

gdzie:

$\mathbf{x}, \mathbf{y}$  -wektory,

$d^{\chi^2}(\mathbf{x}, \mathbf{y})$  – odległość  $\chi^2$  pomiędzy wektorami  $\mathbf{x}$  i  $\mathbf{y}$ ,

$sum_i$  – suma wszystkich wartości cechy  $i$ -tej ze zbioru trenującego,

$size_x, size_y$  – suma wartości wszystkich elementów wektorów  $\mathbf{x}$  i  $\mathbf{y}$ .

## Miary informacyjne

Miary te zazwyczaj określają przyrost informacji po uwzględnieniu danej cechy. Przyrost informacji jest definiowany jako różnica pomiędzy niepewnością bez uwzględnienia cechy oraz niepewnością po jej uwzględnieniu. Z dwóch różnych cech preferowana jest ta, która powoduje większy przyrost informacji [5], [68]. Powszechnie stosowaną miarą informacyjną jest entropia Shannona. Zadanie selekcji polega na znalezieniu takiego podzbioru cech, który maksymalizowałby przyrost informacji.

Dla obiektu  $o$  opisanego wektorem cech  $\mathbf{x}$  entropia warunkowa klas ma postać:

$$H(C|\mathbf{x}) = -\sum_i p(C_i|\mathbf{x}) \ln(p(C_i|\mathbf{x})) \quad (5.15)$$

gdzie:

$p(C_i|\mathbf{x})$  – funkcja gęstości prawdopodobieństwa zdarzenia, że wektor  $\mathbf{x}$  zostanie zakwalifikowany do klasy  $C_i$ .

Średnia entropia warunkowa dla wszystkich możliwych obiektów wyraża się wzorem:

$$H(C|X) = -\sum_{\mathbf{x} \in X} \sum_i p(C_i|\mathbf{x}) \ln(p(C_i|\mathbf{x})) \quad (5.16)$$

gdzie:

$X$  – zbiór wektorów cech  $\mathbf{x}$  wszystkich możliwych obiektów.

Entropia warunkowa klas, w przypadku gdy zbiór wektorów cech nie jest znany ma postać:

$$H(C) = -\sum_i p(C_i) \ln(p(C_i)) \quad (5.17)$$

gdzie:

$p(C_i)$  – prawdopodobieństwo a priori klasy  $i$ -tej.

Przyrost informacji jest różnicą entropii warunkowych bez uwzględnienia zbioru wektorów cech oraz po jego uwzględnieniu:

$$I(C, X) = H(C) - H(C|X) \quad (5.18)$$

## Miary korelacyjne

Miary korelacyjne określają możliwość predykcji wartości jednej zmiennej na podstawie wartości innej zmiennej. Mogą być wykorzystywane na dwa sposoby: badany jest stopień skorelowania poszczególnych cech z daną klasą. Spośród dwóch cech wybierana jest ta, której stopień skorelowania z klasą jest wyższy. Drugi sposób polega na badaniu stopnia korelacji pomiędzy cechami. Pozwala to na usunięcie cech nadmiarowych, które są silnie skorelowane z innymi cechami.

W zasadzie funkcje kryterialne oparte na miarach korelacyjnych zaliczyć można do jednej z dwóch poprzednich grup: metod opartych na miarach odległościowych lub metod opartych na miarach informacyjnych, ale z uwagi na sposób podejścia do problemu klasyfikacji traktowane są jako odrębna grupa.

Powszechnie stosowaną miarą korelacyjną jest współczynnik korelacji Pearsona opisany zależnością [4]:

$$\mathcal{R}(i) = \frac{cov(X_i, Y)}{\sqrt{var(X_i) \cdot var(Y)}} \quad (5.19)$$

gdzie:

- $X_i$  – i-ty współczynnik wektora cech (i-ta cecha),
- $\mathcal{R}(i)$  – współczynnik korelacji Pearsona pomiędzy cechą  $X_i$  oraz klasą  $Y$ ,
- $var()$ ,  $cov()$  – wariancja oraz kowariancja.

W przypadku, gdy wektory cech są częścią pewnego zbioru (zbioru uczącego) współczynnik korelacji zastępuje się jego estymatą, która dana jest wzorem:

$$R(i) = \frac{\sum_{k=1}^m (x_{k,i} - \bar{x}_i)(y_k - \bar{y})}{\sqrt{\sum_{k=1}^m (x_{k,i} - \bar{x}_i)^2 \cdot \sum_{k=1}^m (y_k - \bar{y})^2}} \quad (5.20)$$

gdzie:

- $x_{k,i}$  – i-ty współczynnik k-tego wektora cech,
- $y_k$  – klasa, do której należy k-ty wektor cech,
- $\bar{x}_i$ ,  $\bar{y}$  – wartości średnie odpowiednio i-tej cechy współczynnik k-tego wektora cech,
- $R(i)$  – estymata współczynnika korelacji Pearsona pomiędzy cechą  $x_i$  oraz klasą  $y$ .

### Miary jednoznaczności

W pracach [17], [106] jako miary jednoznaczności autorzy proponują używanie wskaźnika niejednoznaczności, który obliczany jest w następujący sposób:

- (1) Wzorzec uznawany jest za niejednoznaczny, jeśli w zbiorze uczącym istnieją co najmniej dwa przypadki wzorca, zaliczone do różnych klas (dwa przypadki wzorca mają takie same wartości za wyjątkiem ich przynależności do klas).
- (2) Licznik niejednoznaczności (inconsistency count) wzorca podzbioru jest równy liczbie jego wystąpień w zbiorze uczącym pomniejszonej o liczbę przypadków należących do najliczniejszej klasy. Na przykład, jeśli dla podzbioru  $S$  wzorzec  $p$  pojawia się w  $n_p$  przypadkach, z których  $c_1$  należy do pierwszej klasy,  $c_2$  do klasy drugiej, a  $c_3$  do klasy trzeciej ( $c_1 + c_2 + c_3 = n_p$ ) oraz klasa trzecia jest klasą najliczniejszą, to licznik niejednoznaczności ma wartość  $n_p - c_3$ .
- (3) Wskaźnik niejednoznaczności  $I_R(S)$  podzbioru cech  $S$  jest równy sumie wszystkich liczników niejednoznaczności dla wszystkich wzorców podzbioru  $S$  podzielonej przez liczbę wszystkich przypadków w zbiorze uczącym.

Występujące w powyższej definicji pojęcie wzorca (ang. pattern) rozumiane jest jako jeden z możliwych przypadków (spośród zbioru uczącego), jakie może osiągnąć podzbiór cech. Na przykład jeśli liczba możliwych wartości jakie mogą przyjmować cechy: pierwsza, druga, ..., n-ta wynosi odpowiednio  $n_1, n_2, \dots, n_n$ , to istnieje co najwyżej  $n_1 \cdot n_2 \cdot \dots \cdot n_n$  wzorców takiego podzbioru cech.

Według pierwotnej definicji podzbiór cech jest uważany za jednoznaczny, jeśli jego wskaźnik niejednoznaczności jest równy zero. Aby uodpornić algorytmy korzystające z miar jednoznaczności na dane zaszumione przyjmuje się założenie, że podzbiór jest jednoznaczny, gdy jego wskaźnik niejednoznaczności jest nie większy od pewnej wartości progowej  $\delta$  ( $I_R(S) \leq \delta$ ).

Do głównych zalet algorytmów opartych na miarach jednoznaczności należą: monotoniczność (wraz ze wzrostem ilości cech podzbioru jego wskaźnik niejednoznaczności maleje), szybkość działania (złożoność obliczeniowa wynosi  $P$ , gdzie  $P$  to liczba przypadków w zbiorze uczącym), zdolność do usuwania nadmiarowych lub nieistotnych cech, odporność na zakłócenia w zbiorze uczącym.

### **Miary błędu odpowiedzi klasyfikatora**


Miary te są głównie używane w metodach typu opakowanego, ale również we filtrach znalazły zastosowanie. W pracy [20] autor proponuje następującą metodę selekcji cech: sztuczna sieć neuronowa o liczbie neuronów w warstwie wejściowej równej liczbie wszystkich cech jest trenowana pełnym ich zestawem. Po osiągnięciu zakładanego poziomu wytrenowania wagi są zamrażane. Następnie za pomocą algorytmu genetycznego wybierane są podzbiory zbioru wszystkich cech i są one podawane na wejście sieci. Funkcją przystosowania chromosomów jest błąd odpowiedzi sieci, który jest minimalizowany przez algorytm genetyczny. Zatem w przeciwieństwie do techniki typu opakowanego nie są tworzone osobne sieci dla każdego z zestawów cech i proces trenowania odbywa się tylko raz, na początku działania algorytmu, pełnym zestawem cech.

### **5.2.2. Metody opakowane**

W metodach opakowanych (ang. wrapper) generacja podzbiorów cech odbywa się na podstawie ich oceny dokonywanej przez klasyfikator [61]. Dla każdego wygenerowanego podzbioru cech przeprowadzana jest klasyfikacja poprzedzona trenowaniem klasyfikatora. Podzbiory oceniane są na podstawie jakości klasyfikacji mierzonej za pomocą współczynnika błędu odpowiedzi klasyfikatora. Schemat działania algorytmów typu wrapper przedstawiono na rysunku 5.4 [51], [98].

Podstawową zaletą metod opakowanych jest generowanie lepszych rozwiązań w stosunku do metod typu filtr, co spowodowane jest tym że proces selekcji dostosowany jest do konkretnego klasyfikatora i prowadzony jest tak, aby minimalizować błąd klasyfikacji. Oczywiście zastosowanie w procesie klasyfikacji innego klasyfikatora niż był używany w procesie selekcji mija się z celem. Dotyczy to nie tylko rodzaju klasyfikatora, ale też jego parametrów, dostrajanych w procesie uczenia. Ponieważ ocena podzbiorów jest ściśle związana z algorytmem uczącym klasyfikatora, algorytmy typu opakowanego muszą być uruchamiane od nowa za każdym razem, gdy zmienia się algorytm uczący. Metody opakowane są też bardziej uniwersalnie i mogą być zastosowane do praktycznie każdego

problemu klasyfikacyjnego. Zasadniczą wadą metod opakowanych jest duża złożoność obliczeniowa, co ogranicza ich zastosowanie w przypadku dużych przestrzeni poszukiwań. Ponadto czas wykonania selekcji z użyciem metod opakowanych jest dłuższy niż czas wykonania z użyciem metod typu filtr w tym samym problemie klasyfikacyjnym. Metody wbudowane są też bardziej podatne na przetrenowanie.



**Rys. 5.4.** Diagram działania algorytmu selekcji cech typu opakowanego

### 5.2.3. Metody hybrydowe

Metody hybrydowe zwane także frapperami (ang. frapper = filter+wrapper) łączą w sobie sposób działania dwóch poprzednich metod. Selekcja cech odbywa się za pomocą filtra, ale parametry filtra dostosowuje się za pomocą metody typu opakowanego [100]. Frappery, podobnie jak filtry są metodami uniwersalnymi (możliwość zastosowania do dowolnego problemu klasyfikacyjnego i z dowolnym klasyfikatorem), są nieco wolniejsze od filtrów, ale szybsze od metod opakowanych, natomiast ich dokładność jest większa od filtrów, a mniejsza od metod opakowanych.

### 5.2.4. Metody wbudowane

W metodach wbudowanych (ang. embedded) selekcja cech jest wbudowana w klasyfikator i jest częścią procesu jego trenowania. Metody te są podobne do metod opakowanych, ale podczas gdy w opakowanych metodach selekcja i trenowanie klasyfikatora zachodzą oddzielnie, to w metodach wbudowanych stanowią one jeden proces.

Z uwagi na fakt, że metody wbudowane nie tworzą wielu instancji klasyfikatora, które należy oddzielnie trenować (jak w metodach opakowanych), są one mniej złożone obliczeniowo niż metody opakowane. Metody te odznaczają się również dużą dokładnością, ponieważ są dostosowane do konkretnego rodzaju klasyfikatora. Przeprowadzenie selekcji z użyciem określonego klasyfikatora prowadzi jednak do małej uniwersalności metod wbudowanych, która jest ich zasadniczą wadą.

### 5.2.5. Metody rankingowe

Metody rankingowe dokonują selekcji cech w oparciu o ich rankingi. Mogą być używane jako filtry lub metody opakowane. Ustalenie pozycji w rankingu najczęściej zachodzi na podstawie statystyk [71], miar informacyjnych lub błędów odpowiedzi klasyfikatora. Na podstawie pozycji w rankingu tworzone są zbiory istotnych cech, które są wykorzystywane do budowy klasyfikatora. W porównaniu do pozostałych sposobów selekcji, metody rankingowe są atrakcyjne z uwagi na ich prostotę implementacji i stosunkowo dobrą dokładność. Ich złożoność obliczeniowa nie jest zbyt wysoka, ponieważ wymagają jedynie obliczania określonej ilości wag i sortowania tych wag w rosnącej lub malejącej kolejności.

## 5.3. Warunek zatrzymania

Warunek zatrzymania jest spełniony wtedy gdy ma miejsce jedno z poniższych zdarzeń [18]:

- przeszukiwanie zostało zakończone (cała przestrzeń wejściowa została sprawdzona),
- zakładana ilość elementów podzbioru cech została osiągnięta,
- zakładana liczba iteracji algorytmu poszukiwań została osiągnięta,
- wartość funkcji kryterialnej osiągnęła zakładaną wartość,
- jeśli dodanie lub usunięcie kolejnej cechy nie powoduje wzrostu wartości funkcji kryterialnej.


## 5.4. Weryfikacja podzbioru cech

Walidacja podzbioru cech przeprowadzana jest po zakończeniu algorytmu selekcji i polega na ocenie jakości otrzymanego w procesie selekcji podzbioru cech. Istnieją dwie podstawowe procedury walidacyjne. Pierwsza opiera się na znajomości istotnych cech i polega na wygenerowaniu sztucznego zbioru testującego (artificial dataset), złożonego z wektorów cech zawierającego różne przypadki (różne wartości istotnych oraz nieistotnych cech, różny poziom szumów itp.), a następnie przeprowadzeniu procesu selekcji dla tego zbioru i porównaniu wyników ze znanym zestawem istotnych cech. Druga procedura walidacyjna wykorzystuje klasyfikator oraz zbiór danych pochodzących z obiektu rzeczywistego (real-world dataset). Zbiór ten zawiera wektory, z których tworzy się podzbiory testujące zawierające tylko wybrane w procesie selekcji cechy. Podzbiory te są podawane na wejście klasyfikatora, a następnie oceniany jest błąd klasyfikacji.

## 6. SELEKCJA CECH ZA POMOCĄ ALGORYTMU GENETYCZNEGO I MIARY ODLEGŁOŚCI MAHALANOBISA

Do wyboru symptomów uszkodzeń maszyny synchronicznej została zastosowana technika selekcji cech typu filtr. Jako algorytm przeszukiwania przestrzeni cech wykorzystano klasyczny algorytm genetyczny [23], a jako funkcja kryterialna została wykorzystana odległość Mahalanobisa pomiędzy środkami dwóch klas. Problem sprowadzał się do poszukiwania takiego podzbioru cech, dla którego odległość ta byłaby jak największa.

Zadanie selekcji opierało się na porównywaniu ze sobą wielu próbek, które mogły się między sobą różnić częstotliwością składowej podstawowej. Występowanie takich różnic skutkuje przesunięciem widm (ta sama składowa widma (np. 50Hz) znajduje się w różnych punktach, zależnie od różnicy w częstotliwości składowej podstawowej sygnału). Ponadto niedostosowanie częstotliwości próbkowania oraz liczby punktów pomiarowych do aktualnej częstotliwości rejestrowanego sygnału prowadzi do powstawania przecieku FFT i pojawiania się dodatkowych składowych w widmie. Przeprowadzanie selekcji wprost na widmie sygnału prowadziłoby do sytuacji, w których porównywane byłyby rzeczywiste składowe sygnału z prążkami bocznymi, które wynikają ze specyfiki FFT, a których w sygnale tak naprawdę nie ma. Dlatego wprowadzono dodatkową procedurę, która sprawdzała, czy dany punkt widma jest składnikiem rzeczywistego sygnału, czy też powstał skutek przecieku. W tym celu analizowany przedział widma podzielony został na podprzedziały, z których każdy składał się z czterech punktów (rysunek 6.1).




**Rys. 6.1.** Ilustracja sposobu podziału przestrzeni poszukiwań zapewniającego porównywanie rzeczywistych prążków widma sygnału.

Czteropunktowe podprzedziały były wystarczające do uodpornienia analizy na zmiany częstotliwości w granicach około 1,5 Hz. Jest to zakres większy niż wahania możliwe do wystąpienia w układzie rzeczywistym. W każdym podprzedziale wyznaczane było maksimum i porównywane z punktami sąsiadującymi bezpośrednio z przedziałem. Gdy wartość maksymalna amplitudy w przedziale była większa od amplitud punktów w sąsiedztwie przedziału to oznaczało, że w przedziale znajduje się rzeczywisty prążek i za wartość amplitudy w tym przedziale brano wartość maksymalną. Natomiast jeśli wartość w którymś z sąsiadujących z przedziałem punktów była wyższa niż maksymalna wartość w przedziale, znaczyło to, że przedział znajduje się na zboczu wynikającym z przecieku. W tej sytuacji wartość amplitudy dla tego przedziału przyjmowana była jako zero. Dzięki temu rzeczywiste prążki powinny znajdować się zawsze w tych samych przedziałach, i porównywane powinny być zawsze ich prawdziwe wartości.

Zdecydowano się na rozpatrywanie 1024 podprzedziałów, co przy częstotliwości próbkowania  $f_p=25000\text{Hz}$  i liczbie rejestrowanych w każdym pomiarze próbek  $N=65536$  daje zakres częstotliwości  $0\div1562,5\text{ Hz}$ . Rozpatrywanie większego zakresu było bezcelowe, ponieważ składowe o wyższych częstotliwościach posiadały bardzo małe amplitudy. Każda z cech rozważana była jako jeden z wymiarów w wielowymiarowej (1024-wymiarowej) przestrzeni cech.

Algorytm zaczyna swoje działanie od wygenerowania populacji początkowej, składającej się ze sztucznych organizmów (osobników) reprezentowanych przez ciągi kodowe zwane chromosomami. Wszystkie osobniki z populacji początkowej podlegają ocenie na podstawie ich funkcji przystosowań. Następnie sprawdzany jest warunek zatrzymania algorytmu, którym może być osiągnięcie zakładanej wartości przez funkcję przystosowania najlepszego osobnika, ale w stosowanym algorytmie jest nim osiągnięcie zakładanej liczby iteracji (nazywanej liczbą pokoleń). W przypadku spełnienia warunku zatrzymania algorytm kończy swoje działanie i wyprowadzany jest najlepiej przystosowany osobnik, w przeciwnym wypadku następuje selekcja osobników i utworzenie puli rodzicielskiej. Następnie osobniki z puli rodzicielskiej poddawane są działaniu operatorów genetycznych – krzyżowaniu oraz mutacji, w wyniku czego powstaje nowe pokolenie osobników, które zastępuje pokolenie bieżące. Następuje ponowna ocena osobników i sprawdzenie warunku zatrzymania i algorytm kontynuuje swoje działanie aż do momentu, gdy warunek zatrzymania zostanie spełniony. Diagram działania algorytmu genetycznego został przedstawiony na rysunku 6.2.




**Rys. 6.2.** Diagram działania algorytmu genetycznego

W kolejnych podrozdziałach omówione zostały poszczególne elementy algorytmu.

## 6.1. Kodowanie chromosomu

Poszczególne wektory cech zostały przedstawione w postaci chromosomów, będących ciągami zer i jedynek (rysunek 6.3). W problemach selekcji cech można się spotkać z kodowaniem chromosomów poprzez przyporządkowanie każdej ze współrzędnych wektorów cech (a więc w tym przypadku każdemu podprzedziałowi z rozpatrywanego przedziału) jednego genu w chromosomie. Wartość genu danej cechy (allel) oznacza odpowiednio: 0 – cecha nie została wybrana, 1 – cecha została wybrana. Jednak w rozpatrywanym problemie prowadziłoby do powstania chromosomów o dużej ilości genów równej 1024, co znacznie wydłuża czas obliczeń. Zdecydowano się zatem na kodowanie binarne cech zapisanych w sposób dziesiętny. Wadą takiego podejścia jest to, że wymusza ono odgórne określenie liczby cech (czyli rozmiaru wektora cech w przestrzeni poszukiwań) i prowadzi do znacznie dłuższych chromosomów w przypadku rozpatrywania wektorów o dużych liczbach cech. Z uwagi na fakt, że selekcja cech przeprowadzana jest w celu znalezienia wektorów, które poddane zostaną następnie klasyfikacji z użyciem klasyfikatorów, w których korzystniej jest stosować niedużą liczbę wejść (np. klasyfikatory rozmyte), w procesie selekcji preferowane są wektory o małych wymiarach (maksymalnie 4). Zatem odgórne założenie ilości cech w studiowanym problemie jest jak najbardziej do przyjęcia i nie jest wadą. Każda z cech kodowana była za pomocą 10 genów (bitów), co daje 1024 kombinacji. Sprawdzano kombinacje dwu-, trzy- i czterocechowe, co dawało chromosomy o liczbach genów odpowiednio 20, 30 i 40, a więc znacznie mniejszej od 1024. Przykładowy sposób generacji chromosomu dla 3-cechowego wektora został przedstawiony na rysunku 6.3.



Rys. 6.3. Sposób kodowania chromosomu dla wektora 3-cechowego

## 6.2. Populacja początkowa

Algorytmy genetyczne przeszukują przestrzeń rozwiązań startując równolegle z kilku punktów, przez co są dość odporne na utknięcie w minimum lokalnym. Jednak dość istotne jest, aby punkty startowe w miarę równomiernie pokrywały przestrzeń poszukiwań, dzięki czemu zwiększa się szansa, że któryś z nich znajdzie się w pobliżu punktu optymalnego. Populacja początkowa tworzona jest poprzez losowanie ze zwracaniem z pełnego zbioru cech i stanowi tylko niewielką próbę losową osobników z całej przestrzeni poszukiwań.

## 6.3. Reprodukacja osobników

Operacja reprodukcji polega na wyborze z całej populacji osobników, których chromosomy wykorzystane zostaną do utworzenia kolejnego pokolenia, przy czym preferowane są osobniki o wyższym stopniu przystosowania (wyższej wartości funkcji przystosowania) [14]. Wybrane w ten sposób osobniki tworzą tzw. pulę rodzicielską i poddawane są następnie operacjom krzyżowania i mutacji. Proces reprodukcji powtarzany jest wielokrotnie aż do uzyskania populacji potomnej o zakładanym rozmiarze (najczęściej stosuje się taką samą liczbę osobników w populacji w każdym kroku działania algorytmu). Najpopularniejszymi metodami reprodukcji są tzw. metoda ruletki, metoda rankingowa oraz metoda turniejowa. W metodzie ruletki (roulette wheel method) osobniki z populacji losowane są z prawdopodobieństwem proporcjonalnym do ich funkcji przystosowania. Nazwa metody bierze się z jej analogii do losowania za pomocą koła ruletki, którego wycinki reprezentują poszczególne chromosomy, a szerokość wycinków jest proporcjonalna do wartości funkcji przystosowania chromosomów i określona jest wzorem:

$$v(ch_i) = p_s(ch_i) \cdot 100\% \quad (6.1)$$

w którym  $p_s(ch_i)$  jest prawdopodobieństwem selekcji chromosomu  $ch_i$  danym wzorem:


$$p_s(ch_i) = \frac{F(ch_i)}{\sum_{j=1}^n F(ch_j)} \quad (6.2)$$

gdzie:

$F(ch_i)$  –wartość funkcji przystosowania i-tego chromosomu,

$n$  – rozmiar puli rodzicielskiej (liczba chromosomów wybieranych w trakcie selekcji).

Przykładowy sposób podziału koła ruletki został przedstawiony na rysunku 6.4.



**Rys. 6.4.** Ilustracja reprodukcji metodą „koła ruletki”

Kręcąc utworzonym w ten sposób kołem ruletki dokonuje się wyboru w sposób losowy, ale prawdopodobieństwo wylosowania lepiej przystosowanych chromosomów jest większe niż tych o gorszym przystosowaniu, dzięki czemu zapewniona jest zbieżność algorytmu. Zasadniczą wadą tego sposobu reprodukcji jest to, że może on być stosowany tylko w problemach maksymalizacyjnych, w przypadku poszukiwania minimum należy odpowiednio przekształcić funkcję przystosowania, tak aby problem stał się problemem poszukiwania maksimum. Kolejną wadą jest to, że osobniki o bardzo małej wartości funkcji przystosowania mogą być zbyt wcześnie eliminowane z populacji, natomiast licznie występujące osobniki o średnim przystosowaniu mogą zdominować populację, co prowadzi do przedwczesnej zbieżności algorytmu genetycznego.


W metodzie rankingowej (ranking selection) chromosomy w populacji sortowane są według malejących wartości funkcji przystosowania. Pozycja w posortowanej liście jest nazywana rangą chromosomu. Liczba kopii każdego z chromosomów, która wejdzie w skład puli rodzicielskiej, ustalana jest z wykorzystaniem funkcji, której zmienną jest ranga chromosomu ( $M(r)$ ). Najczęściej stosuje się funkcje liniowe (rysunek 6.5) Do puli rodzicielskiej wybieranych jest  $k$  pierwszych chromosomów spełniających warunek:

$$\sum_{i=1}^k M_i(r_i) \leq n \quad (6.3)$$

gdzie:

$M_i(r_i)$  –wartość funkcji określającej ilość kopii w zależności od rangi  $i$ -tego chromosomu,  
 $n$  – rozmiar puli rodzicielskiej.


Metoda rankingowa może być stosowana zarówno w problemach maksymalizacji, jak i minimalizacji (funkcja rankingowa może być rosnąca lub malejąca) i jest odporniejsza na przedwczesną zbieżność niż metoda ruletki.



**Rys. 6.5.** Przykład funkcji określającej liczbę osobników w reprodukcji rankingowej

Możliwe jest też połączenie metod rankingowej i ruletki w ten sposób, że wielkość wycinka na kole ruletki jest proporcjonalna do rangi chromosomu. Dzięki temu zbieżność algorytmu ulega znacznemu spowolnieniu w stosunku do metody ruletki.

W selekcji turniejowej (tournament selection) chromosomy w populacji dzielone są na pewną ilość (najczęściej dwie) podgrup, a następnie w każdej z podgrup chromosom o najlepszym przystosowaniu wybierany jest do puli rodzicielskiej. Proces ten jest powtarzany aż do osiągnięcia zakładanej liczby osobników. Kopie wybranych do puli rodzicielskiej osobników są zazwyczaj zwracane do puli turniejowej, przez co możliwy jest ich ponowny wybór. Ilustracją sposobu działania reprodukcji turniejowej jest rysunek 6.6.




**Rys. 6.6.** Ilustracja sposobu działania mechanizmu reprodukcji turniejowej

Możliwy jest też sposób selekcji będący połączeniem metod turniejowej i ruletki, w którym zamiast w każdej z podgrup wybierać chromosomy o najwyższym przystosowaniu dokonuje się losowania z użyciem metody ruletki.


## 6.4. Krzyżowanie

Krzyżowanie polega na wymianie między sobą części ciągów kodowych poszczególnych chromosomów. Najbardziej klasycznym rodzajem krzyżowania jest krzyżowanie jednopunktowe. W celu jego przeprowadzenia z puli rodzicielskiej z prawdopodobieństwem krzyżowania  $p_k$  (zazwyczaj  $p_k$  jest liczbą z przedziału  $[0.5,1]$ ) losuje się dwa osobniki, a następnie w sposób losowy wybiera się punkt krzyżowania  $l_k$ , który jest liczbą z przedziału  $[1, L - 1]$ , gdzie  $L$  jest liczbą genów w chromosomie. Następnie tworzy się dwa osobniki potomne, z których pierwszy składa się z genów na pozycjach 1 do  $l_k$  rodzica pierwszego oraz genów na pozycjach  $l_k + 1$  do  $L$  rodzica drugiego. Drugi z potomków zbudowany jest z pozostałych części, a więc genów na pozycjach 1 do  $l_k$  rodzica drugiego oraz genów na pozycjach  $l_k + 1$  do  $L$  rodzica pierwszego. Sposób przebiegu krzyżowania jednopunktowego dla dwóch przykładowych chromosomów przedstawiono na rysunku 6.7.



Rys. 6.7. Krzyżowanie jednopunktowe

Krzyżowanie wielopunktowe jest uogólnieniem krzyżowania jednopunktowego, w którym losowanych jest kilka punktów krzyżowania i osobniki potomne otrzymują naprzemiennie fragmenty kodowe pierwszego i drugiego rodzica. Ilustruje to rysunek 6.8, na którym przedstawiono krzyżowanie czteropunktowe.




**Rys. 6.8.** Krzyżowanie czteropunktowe

Innym sposobem krzyżowania jest krzyżowanie równomierne, w którym potomkowie otrzymują geny rodziców zgodnie z wylosowanym wzorcem, który jest ciągiem zer i jedynek o długości równej liczbie genów w chromosomach rodziców. W przypadku wystąpienia zera na danej pozycji geny są przepisywane, a w przypadku jedynki zamieniane na geny drugiego z rodziców.

## 6.5. Mutacja


Mutacja polega na wymianie wartości pojedynczych genów na wartości przeciwne (z 0 na 1 lub z 1 na 0) i zachodzi z prawdopodobieństwem  $p_m$  będącym zazwyczaj liczbą z przedziału  $[0,0.1]$ , a więc dużo mniejszym niż prawdopodobieństwo krzyżowania, co sprawia, że mutacja pełni drugorzędną rolę w stosunku do operacji krzyżowania. Dla każdego genu dokonuje się losowania z założonym wcześniej prawdopodobieństwem, zatem istnieje możliwość, że w danym chromosomie więcej niż jeden gen będzie poddany mutacji. Może się również zdarzyć sytuacja, że żaden z genów nie ulegnie mutacji. Na rysunku 6.9 przedstawiono mutację dwóch genów w chromosomie.



**Rys. 6.9.** *Mutacja chromosomu*

Współczynnik mutacji może mieć ustaloną, jednakową w każdym pokoleniu wartość jak również można zastosować technikę zmniejszającą jego wartość w kolejnych generacjach (zwykle w sposób liniowy). Zastosowanie zmiennego współczynnika mutacji jest korzystne, dlatego że w początkowej fazie działania algorytmu genetycznego duża wartość tego współczynnika zapewnia dużą różnorodność osobników (zmniejsza zbyt szybką dominację osobników lepiej przystosowanych), natomiast pod koniec działania algorytmu, w celu zapewnienia jego zbieżności, wskazane jest niskie prawdopodobieństwo mutacji.

Zastosowanie operatorów reprodukcji i krzyżowania powoduje stopniowe podążanie w kierunku najbliższego maksimum, natomiast mutacja powoduje pewne zaburzenie mogące prowadzić do przeniesienia aktualnego rozwiązania w inne miejsce przestrzeni poszukiwań. Ilustruje to rysunek 6.10, na którym widać, że operacja mutacji doprowadziła do przeniesienia aktualnego, zbieżnego do maksimum lokalnego rozwiązania do takiego miejsca przestrzeni poszukiwań, w którym operacje reprodukcji i krzyżowania zapewniają zbieżność do maksimum globalnego.



**Rys. 6.10.** *Ilustracja wpływu reprodukcji, krzyżowania i mutacji w procesie poszukiwania rozwiązania optymalnego*

Oczywiście może zdarzyć się sytuacja odwrotna, w której zbieżne do maksimum globalnego rozwiązanie zostanie przeniesione w miejsce, w którym ta zbieżność nie jest zapewniona, ale z uwagi na fakt, że algorytmy genetyczne operują na całej populacji osobników, przez co przeszukiwanie przestrzeni rozwiązań odbywa się w sposób równoległy, oraz to, że

reprodukcja i krzyżowanie prowadzą do powiększania się liczby dobrze przystosowanych osobników kosztem osobników o słabszym przystosowaniu, w skali globalnej mutacja zwiększa szanse na znalezienie rozwiązania optymalnego.

## 6.6. Funkcja przystosowania

Funkcja przystosowania stanowi miarę jakości poszczególnych chromosomów w populacji, przez co możliwa jest ich ocena. Jest ona odpowiednikiem funkcji celu w algorytmach optymalizacyjnych, przy czym w klasycznym algorytmie genetycznym może przyjmować tylko wartości nieujemne i powinna być tak skonstruowana, by rozwiązywany problem był problemem poszukiwania maksimum (w problemach minimalizacyjnych należy odpowiednio przekształcić funkcję celu np. poprzez zastosowanie jej odwrotności) [87]. Osobniki o lepszym przystosowaniu będą rozprzestrzeniały swoje schematy w populacji.

W analizowanym problemie funkcja dopasowania powinna preferować takie podzbiory cech, które dają jak największą odległość pomiędzy środkami obu klas, przy jednoczesnym małym rozrzucie wewnątrzklasowym wektorów cech. Tego typu właściwości posiada miara odległości Mahalanobisa, która dana jest wzorem:

$$d^M(\bar{\mathbf{x}}_i, \bar{\mathbf{x}}_j) = \sqrt{(\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j)^T C_{ij}^{-1} (\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j)} \quad (6.4)$$

gdzie:

$\bar{\mathbf{x}}_i, \bar{\mathbf{x}}_j$  – wektory środków grup i-tej oraz j-tej,

$C_{ij}$  – macierz kowariancji ważonej.

Macierz kowariancji ważonej wyraża się wzorem:

$$C_{ij} = \frac{1}{n_i n_j} (n_i C_i + n_j C_j) \quad (6.5)$$

gdzie:

$n_i, n_j$  – liczby wektorów należących do poszczególnych grup (odpowiednio i-tej oraz j-tej),

$C_i, C_j$  – macierze kowariancji wektorów w poszczególnych grupach.

W celu poprawy działania algorytmu genetycznego stosuje się technikę zwaną skalowaniem funkcji przystosowania. W początkowej fazie działania algorytmu skalowanie zapobiega przedwczesnej zbieżności (do minimum lokalnego) objawiającej się tym, że nieoptymalne, ale najlepiej przystosowane osobniki zaczynają silnie dominować i wypierać inne osobniki. Natomiast w końcowej fazie działania algorytmu genetycznego skalowanie zapobiega sytuacji, w której populacja zachowuje znaczną różnorodność, ale średnia wartość przystosowania niewiele odbiega od wartości maksymalnej, a osobniki przeciętne otrzymują podobną liczbę potomków co osobniki najlepiej przystosowane. Istnieją trzy podstawowe metody skalowania: skalowanie liniowe, obcinanie typu sigma oraz skalowanie potęgowe.

Skalowanie liniowe polega na przekształceniu funkcji przystosowania według następującej zależności:

$$F' = a \cdot F + b \quad (6.6)$$

gdzie:

$F, F'$  – wartości funkcji przystosowania przed i po skalowaniu,

$a, b$  – stałe.

Wartości stałych  $a$  i  $b$  należy dobrać w taki sposób, aby średnia wartość funkcji przystosowania przed i po skalowaniu była taka sama (dzięki temu osobniki o przeciętnym przystosowaniu będą miały średnio jednego potomka w następnym pokoleniu), a maksymalna wartość funkcji przystosowania po skalowaniu była proporcjonalna (zwykle 1,2÷2 razy większa) od średniej wartości funkcji przystosowania. Ponadto należy zastosować mechanizm zapobiegający osiągnięciu przez funkcję  $F'$  wartości ujemnych.

Obcinanie typu sigma przekształca funkcję przystosowania zgodnie z zależnością:

$$F' = F + (\bar{F} - c \cdot \sigma) \quad (6.7)$$

gdzie:

$F, F'$  – wartości funkcji przystosowania przed i po skalowaniu,

$\bar{F}$  – średnia wartości funkcji przystosowania w populacji,

$\sigma$  – odchylenie standardowe w populacji.

Skalowanie potęgowe prowadzi do przekształcenia funkcji przystosowania według wzoru:

$$F' = F^k \quad (6.8)$$

gdzie:

$F, F'$  – wartości funkcji przystosowania przed i po skalowaniu,


$k$  – liczba o wartości bliskiej 1 (np. 1,005).

## 6.7. Wyniki automatycznej selekcji cech

Algorytm działający według opisanego wcześniej sposobu został zaimplementowany w środowisku Matlab na podstawie elementarnego algorytmu genetycznego (SGA) Davida E. Goldberga [23] oraz z wprowadzonymi modyfikacjami (według własnego pomysłu) dodającymi nowe funkcjonalności takie jak: selekcja rankingowa i turniejowa, zmienne prawdopodobieństwo mutacji, skalowanie funkcji przystosowania. Ponadto wprowadzono zabezpieczenie przed możliwością wielokrotnego wyboru tych samych cech.

Dla każdego ze stanów awaryjnych wykonano 15 różnych wariantów obliczeń, które były kombinacjami trzech różnych ilości wybieranych w procesie selekcji cech (2, 3 i 4 cechy) oraz pięciu różnych wariantów algorytmu (klasyczny algorytm genetyczny z selekcją metodą ruletki, klasyczny algorytm genetyczny z selekcją metodą ruletki i skalowaniem liniowym


funkcji przystosowania, klasyczny algorytm genetyczny z selekcją metodą ruletki i skalowaniem potęgowym funkcji przystosowania, algorytm genetyczny z selekcją rankingową oraz algorytm genetyczny z selekcją turniejową). Ponadto dla każdego z wariantów zaimplementowano malejący liniowo współczynnik mutacji. W pierwszym pokoleniu wynosił on 0.1 a w ostatnim 0.005. Liczba pokoleń działania algorytmu wynosiła 100. Liczba osobników w populacji była utrzymywana na stałym poziomie i wynosiła 200. W każdym wariancie algorytm uruchamiany był 50 razy i za każdym razem wynik uruchomienia był zapisywany. Badane były widma zarówno prądów twornika, jak i wzbudzenia. Z uwagi na dużą liczbę uruchomień algorytmu wynoszącą 6000 (50 uruchomień x 5 wariantów algorytmu x 3 ilości wybieranych cech x 2 prądy x 4 stany awaryjne) napisany został zewnętrzny program, który w pełni automatyzował uruchamianie kolejnych wersji algorytmu i zapisywał wyniki do plików). W celu porównania wyników działania każdego z wariantów algorytmu dla konkretnego przypadku uszkodzenia wykonano zbiorcze wykresy odległości Mahalanobisa najlepiej przystosowanych osobników w funkcji numeru uruchomienia danego wariantu algorytmu. W celu zwiększenia czytelności zostały one posortowane w kolejności rosnącej. Cechy najlepiej przystosowanych osobników wraz z odpowiadającymi im odległościami Mahalanobisa zostały zestawione w tabelach. Ponadto aby porównać zbieżność poszczególnych wariantów algorytmu w tym samym problemie selekcyjnym wykonane zostały wykresy maksymalnego oraz średniego przystosowania, które przedstawione są na rysunkach 6.11 – 6.15.



**Rys. 6.11.** *Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu genetycznego z reprodukcją osobników metodą ruletki.*


W algorytmie genetycznym z selekcją metodą ruletki przystosowanie najlepszego osobnika w danej epoce posiada trend wzrostowy w początku działania algorytmu, następnie trend ten słabnie i ostatnich epokach przechodzi w lekko spadkowy (rysunek 6.11). Ponadto widoczne są dość duże oscylacje funkcji przystosowania, świadczące o wpływie losowości procesu selekcji obniżającej zbieżność algorytmu. Średnie przystosowanie wszystkich osobników w danej epoce posiada stały wzrostowy trend, który podlega dość dużym oscylacjom.

Po zastosowaniu skalowania liniowego funkcji przystosowania dopasowanie najlepszego w danej epoce osobnika podlega bardzo dużym wahaniom, co jest wynikiem tego, że dominacja najlepiej dopasowanych osobników jest tłumiona, zapobiegając przedwczesnej zbieżności algorytmu (rysunek 6.12). Średnie przystosowanie w tym zakresie utrzymuje się na stałym poziomie. W końcowej fazie działania algorytmu oscylacje dopasowania najlepiej przystosowanego osobnika ulegają znacznemu osłabieniu, a średnie przystosowanie osobników gwałtownie rośnie.



**Rys. 6.12.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu genetycznego z reprodukcją osobników metodą ruletki i skalowaniem liniowym funkcji przystosowania.


W przypadku zastosowania potęgowego skalowania funkcji przystosowania (rysunek 6.13) dopasowanie najlepszego osobnika również podlega dość znacznym (lecz mniejszym niż w przypadku skalowania liniowego) oscylacjom, a trend tego dopasowania jest wzrostowy. Trend średniego przystosowania rośnie w sposób potęgowy wraz z numerem epoki działania algorytmu a oscylacje są dużo mniejsze niż w algorytmie bez skalowania.



**Rys. 6.13.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu genetycznego z reprodukcją osobników metodą ruletki i skalowaniem potęgowym funkcji przystosowania.


Żaden z algorytmów opartych na selekcji metodą ruletki nie uzyskał pełnej zbieżności (maksymalne przystosowanie cały czas oscyluje).

W algorytmie z reprodukcją rankingową (rysunek 6.14) występują dość niskie oscylacje funkcji przystosowania najlepszego osobnika, które dość szybko zanikają i dość szybko osiągnięty jest ostateczny wynik (algorytm jest zbieżny). Średnie przystosowanie osobników w populacji posiada trend wzrostowy i stosunkowo małe oscylacje.



**Rys. 6.14.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu genetycznego z rankingową reprodukcją.

W algorytmie z reprodukcją turniejową (rysunek 6.15) praktycznie brak jest oscylacji funkcji przystosowania najlepszego osobnika i występuje szybka zbieżność aktualnego rozwiązania do rozwiązania optymalnego (lub suboptymalnego). Średnie przystosowanie posiada stały wzrostowy trend. Algorytm w tej postaci można uznać za najlepszy spośród wszystkich pięciu algorytmów w analizowanym problemie selekcyjnym.



**Rys. 6.15.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu genetycznego z turniejową reprodukcją osobników.

### 6.7.1. Wyniki selekcji dla zwarcia w grupie zezwojów twornika

#### Wyniki selekcji na podstawie widma prądu twornika.

Wyniki selekcji cech dla zwarcia grupy zezwojów twornika na podstawie widma prądu twornika dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.1, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.16-6.19.


**Tabela 6.1.** Wyniki selekcji najlepszych osobników na podstawie widma prądu twornika dla diagnostyki zwarcia w grupie zezwojów twornika

| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 150             | 250             | -               | -               | 6.2788                    |
| 3                                      | 150             | 250             | 350             | -               | 6.5818                    |
| 4                                      | 150             | 250             | 350             | 1350            | 6.7594                    |


Dla porównania odległość Mahalanobisa w przypadku składowej 100Hz wektora przestrzennego prądu twornika dla tego stanu awaryjnego wynosi 25,7292, zatem dużo lepiej nadaje się ona do identyfikacji zwarć w uzwojeniach twornika niż wyznaczone zestawy cech w widmach prądów twornika.

Na podstawie rysunku 6.16 można stwierdzić, że rozpatrywanie dwóch cech jednocześnie prowadzi do powstania dwóch liniowo separowalnych skupisk, jednak odległość pomiędzy punktami najbardziej wysuniętymi w stronę przeciwnej grupy jest minimalna. Na separowalność obu grup decydujący wpływ ma cecha pierwsza odpowiadająca częstotliwości 150 Hz, jednak rozpatrywanie jej samodzielnie prowadziło do powstania skupisk nieseparowalnych (co można zaobserwować rzutując punkty na oś związaną z tą cechą) i do błędów w późniejszej klasyfikacji.

Z rysunku 6.17 wynika, że dla pośrednich wartości rezystancji zwierającej odpowiadające im punkty lokują się mniej więcej pomiędzy punktami dla stanu bezawaryjnego oraz stanu zwarcia poprzez rezystancję o wartości 1.3  $\Omega$ , jednak ich rozrzut jest na tyle duży, że ciężko jest dokładnie wnioskować o stopniu zwarcia.




**Rys. 6.16.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej grupy zewzwojów twornika poprzez rezystancję zwierającą o wartości  $1.3 \Omega$




**Rys. 6.17.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w dwucechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  –niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  –fioletowy, zwarcie  $1.3 \Omega$  – czerwony.

Analiza rysunków 6.18 i 6.19 prowadzi do wniosku, że uwzględnianie trzeciej cechy, odpowiadającej częstotliwości 350 Hz nie podnosi w znacznym stopniu separowalności poszczególnych klas.




**Rys. 6.18.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor niebieski odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej grupy zezwojów twornika poprzez rezystancję zwierającą o wartości  $1.3 \Omega$




**Rys. 6.19.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w trzycechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  –niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  –fioletowy, zwarcie  $1.3 \Omega$  – czerwony.


Na rysunkach, 6.20, 6.21 i 6.22 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu zwarcia grupy zezwojów twornika spośród wszystkich cech zawartych w widmie prądu twornika.



**Rys. 6.20.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 2 cech charakterystycznych dla zwarcia w jednej grupie zezwojów twornika.



**Rys. 6.21.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 3 cech charakterystycznych dla zwarcia w jednej grupie zezwojów twornika.



**Rys. 6.22.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 4 cech charakterystycznych dla zwarcia w jednej grupie zezwojów twornika.

## Wyniki selekcji na podstawie widma prądu wzbudzenia.


Wyniki selekcji cech dla zwarcia grupy zezwojów twornika na podstawie widma prądu wzbudzenia dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.2, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.23-6.26.

**Tabela 6.2.** Wyniki selekcji najlepszych osobników na podstawie widma prądu wzbudzenia dla diagnostyki zwarcia w grupie zezwojów twornika


| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 100             | 200             | -               | -               | 18.2472                   |
| 3                                      | 100             | 125             | 200             | -               | 20.0908                   |
| 4                                      | 100             | 125             | 200             | 1500            | 20.5327                   |

Uzyskane rezultaty w przypadku prądu wzbudzenia są porównywalne, z wynikami dla składowej 100Hz wektora przestrzennego prądu twornika (dla której odległość Mahalanobisa wynosi 25.7292). Zatem prąd wzbudzenia może zostać uznany jako sygnał o bardzo dobrej informacji diagnostycznej dla wykrywania zwarc w uzwojeniach twornika.


Na podstawie rysunku 6.23 można stwierdzić, że rozpatrywanie dwóch cech jednocześnie prowadzi do powstania dwóch liniowo separowanych skupisk z bardzo dużym marginesem pomiędzy skrajnymi przypadkami z obu klas. Rozpatrywanie każdej z cech osobno także prowadziło do powstania liniowo separowalnych grup punktów (co można zaobserwować rzutując punkty na poszczególne osie), jednak margines pomiędzy grupami byłby mniejszy. Z rysunku 6.24 wynika, że dla pośrednich wartości rezystancji zwierającej odpowiadające im punkty lokują się pomiędzy punktami dla stanu bezawaryjnego oraz stanu zwarcia poprzez rezystancję o wartości  $1.3 \Omega$ , i poza nielicznymi wyjątkami, tworzą separowalne skupiska dla każdej z badanych klas (odpowiadającej różnym wartościom rezystancji zwierającej). Analiza rysunków 6.25 i 6.26 prowadzi do wniosku, że uwzględnianie trzeciej cechy, odpowiadającej częstotliwości 125 Hz, tylko nieznacznie podnosi separowalność poszczególnych klas. Zatem składowe o częstotliwościach 100 Hz i 200 Hz uznać należy za najbardziej miarodajne w przypadku diagnostyki zwarc w uzwojeniach twornika maszyny synchronicznej.




**Rys. 6.23.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej grupy zezwojów twornika poprzez rezystancję zwierającą o wartości  $1.3 \Omega$



**Rys. 6.24.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w dwucechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  – niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  – fioletowy, zwarcie  $1.3 \Omega$  – czerwony.




**Rys. 6.25.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej grupy zezwojów twornika poprzez rezystancję zwierającą o wartości  $1.3 \Omega$




**Rys. 6.26.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w trzycechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  – niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  – fioletowy, zwarcie  $1.3 \Omega$  – czerwony.


Na kolejnych rysunkach, 6.27, 6.28 i 6.29 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu zwarcia grupy zezwojów twornika spośród wszystkich cech zawartych w widmie prądu wzbudzenia.



**Rys. 6.27.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 2 cech charakterystycznych dla zwarcia w jednej grupie zezwojów twornika.



**Rys. 6.28.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 3 cech charakterystycznych dla zwarcia w jednej grupie zezwojów twornika.



**Rys. 6.29.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 4 cech charakterystycznych dla zwarcia w jednej grupie zezwojów twornika.

### 6.7.2. Wyniki selekcji dla przerwy jednej gałęzi równoległej twornika

#### Wyniki selekcji na podstawie widma prądu twornika.

Wyniki selekcji cech dla przerwy gałęzi równoległej twornika na podstawie widma prądu twornika dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.3, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.30 i 6.31.


**Tabela 6.3.** Wyniki selekcji najlepszych osobników na podstawie widma prądu twornika dla diagnostyki przerwy w gałęzi równoległej twornika

| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 25              | 150             | -               | -               | 12.5284                   |
| 3                                      | 25              | 30              | 150             | -               | 14.9119                   |
| 4                                      | 25              | 30              | 50              | 150             | 16.7851                   |


Odległość Mahalanobisa dla składowej 100Hz wektora przestrzennego prądu twornika dla tego stanu awaryjnego wynosi 16.3226, zatem rozpatrywanie wektorów czterocechowych powinno dać lepsze rezultaty w procesie klasyfikacji.

Analiza rysunku 6.30 prowadzi do stwierdzenia, że rozpatrywanie samej składowej 150Hz prowadziłoby do powstania separowalnych skupisk punktów odpowiadających stanowi bezawaryjnemu oraz przerwy w gałęzi równoległej twornika. Dla większości próbek pomiarowych można wyciągnąć podobne wnioski także odnośnie składowej 25Hz. Istnieje jednak kilka punktów które w przestrzeni jednowymiarowej związanej z częstotliwością 25Hz znajdują się bliżej środka przeciwnej klasy. Spowodowane to może być tym, że na amplitudę tej składowej wpływ mają także inne czynniki, jak np. zakłócenia napięcia zasilającego podczas wykonywania pomiarów. Jednakże istnienie dość wyraźnie oddzielonych od siebie grup sugeruje, że obecność tego typu uszkodzenia ma istotny wpływ na wartość amplitudy składowej o częstotliwości 25Hz, powodując jej wzrost. W przypadku drugiej składowej istnieje pełna separowalność i do tego z dużym marginesem. Jednak i na tą składową wpływ mają także inne czynniki, co można wywnioskować po tym, że dla maszyny uszkodzonej tworzą się dwa odrębne skupiska. Uwzględnienie obu cech jednocześnie powinno poprawić jakość późniejszej klasyfikacji.

Analiza rysunku 6.31 prowadzi do wniosku, że uwzględnienie trzeciej cechy, choć przesuwając środek grupy związanej ze stanem bezawaryjnym, nie powinno dać lepszych wyników klasyfikacji.




**Rys. 6.30.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej gałęzi równoległej twornika




**Rys. 6.31.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej gałęzi równoległej twornika


Na kolejnych rysunkach, 6.32, 6.33 i 6.34 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu przerwy gałęzi równoległej twornika spośród wszystkich cech zawartych w widmie prądu twornika.



**Rys. 6.32.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 2 cech charakterystycznych dla przerwy jednej gałęzi równoległej twornika.



**Rys. 6.33.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 3 cech charakterystycznych dla przerwy jednej gałęzi równoległej twornika.



**Rys. 6.34.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 4 cech charakterystycznych dla przerwy jednej gałęzi równoległej twornika.


## Wyniki selekcji na podstawie widma prądu wzbudzenia.

Wyniki selekcji cech dla przerwy gałęzi równoległej twornika na podstawie widma prądu wzbudzenia dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.4, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.35 i 6.36.

**Tabela 6.4.** Wyniki selekcji najlepszych osobników na podstawie widma prądu wzbudzenia dla diagnostyki przerwy w gałęzi równoległej twornika

| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 50              | 100             | -               | -               | 15.5490                   |
| 3                                      | 50              | 100             | 200             | -               | 19.0791                   |
| 4                                      | 50              | 100             | 200             | 150             | 20.2042                   |


Z rysunku 6.35 wynika, że na dużą separowalność grup dla tego uszkodzenia wpływ ma składowa o częstotliwości 100Hz. Druga ze składowych – 50Hz przy samodzielnym rozpatrywaniu nie zapewnia separowalności. Wyraźny podział każdej z grup na dwie podgrupy, o którym decyduje przede wszystkim składowa 50Hz, sugeruje, że także inne czynniki mają wpływ na wartości amplitud tych składowych.



**Rys. 6.35.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej gałęzi równoległej twornika

Jednak znaczna różnica w amplitudach składowej 100Hz w przypadku maszyny nieuszkodzonej i maszyny z przerwą w gałęzi równoległej twornika nie pozostawia wątpliwości, że występowanie uszkodzenia ma wpływ na tę amplitudę.


Dość istotną poprawę separowalności daje uwzględnienie trzeciej składowej o częstotliwości 200Hz, co jest widoczne na rysunku 6.36.




**Rys. 6.36.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej gałęzi równoległej twornika

Dobry rezultat daje również rozpatrywanie składowych 100Hz oraz 200Hz, jednak odległość Mahalanobisa dla tego przypadku jest nieco mniejsza i wynosi 13.1400..


Na rysunkach, 6.37, 6.38 i 6.39 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu przerwy gałęzi równoległej twornika spośród wszystkich cech zawartych w widmie prądu twornika.



**Rys. 6.37.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 2 cech charakterystycznych dla przerwy jednej gałęzi równoległej twornika.



**Rys. 6.38.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 3 cech charakterystycznych dla przerwy jednej gałęzi równoległej twornika.



**Rys. 6.39.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 4 cech charakterystycznych dla przerwy jednej gałęzi równoległej twornika.

### 6.7.3. Wyniki selekcji dla zwarcia cewki obwodu wzbudzenia


#### Wyniki selekcji na podstawie widma prądu twornika.

Wyniki selekcji cech dla zwarcia cewki obwodu wzbudzenia na podstawie widma prądu twornika dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.5, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.40 - 6.43.

**Tabela 6.5.** Wyniki selekcji najlepszych osobników na podstawie widma prądu twornika dla diagnostyki zwarcia cewki obwodu wzbudzenia


| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 50              | 75              | -               | -               | 2.2542                    |
| 3                                      | 25              | 50              | 75              | -               | 2.4933                    |
| 4                                      | 25              | 50              | 75              | 150             | 2.6936                    |

Dla porównania odległość Mahalanobisa w przypadku składowej 100Hz wektora przestrzennego prądu twornika dla tego stanu awaryjnego wynosi 0.0128 i składowa ta nie nadaje się do diagnostyki tego rodzaju uszkodzeń. Z rozmieszczenia punktów pomiarowych na rysunku 6.40 można wnioskować, że składowe 50Hz i 75Hz nie tworzą separowalnych skupisk. Można doszukiwać się istnienia dwóch różnych grup, jednak nie są one rozłączne. Dodatkowo amplituda składowej 50Hz w prądzie twornika jest silnie uzależniona od obciążenia mechanicznego silnika i stosowanie jej do celów diagnostycznych byłoby ryzykowne. Uwzględnienie trzeciej składowej – o częstotliwości 25Hz, widoczne na rysunku 6.42, nie powoduje poprawy sytuacji.




**Rys. 6.40.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej cewki obwodu wzbudzenia poprzez rezystancję zwierającą o wartości  $1.3 \Omega$


W tej sytuacji rozpatrywanie stanów pośrednich uszkodzenia, widoczne na rysunkach 6.42 i 6.43 również nie daje dobrej informacji o występowaniu, a tym bardziej o stopniu zaawansowania uszkodzenia.



**Rys. 6.41.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w dwucechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  –niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  – fioletowy, zwarcie  $1.3 \Omega$  – czerwony.




**Rys. 6.42.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej cewki obwodu wzbudzenia poprzez rezystancję zwierającą o wartości  $1.3 \Omega$




**Rys. 6.43.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w trzycechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  –niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  – fioletowy, zwarcie  $1.3 \Omega$  – czerwony.


Na rysunkach, 6.44, 6.45 i 6.46 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu zwarcia cewki obwodu wzbudzenia spośród wszystkich cech zawartych w widmie prądu twornika.



**Rys. 6.44.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 2 cech charakterystycznych dla zwarcia cewki obwodu wzbudzenia.



**Rys. 6.45.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 3 cech charakterystycznych dla zwarcia cewki obwodu wzbudzenia.



**Rys. 6.46.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 4 cech charakterystycznych dla zwarcia cewki obwodu wzbudzenia.


## Wyniki selekcji na podstawie widma prądu wzbudzenia.

Wyniki selekcji cech dla przerwy gałęzi równoległej twornika na podstawie widma prądu wzbudzenia dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.6, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.47-6.50.

**Tabela 6.6.** Wyniki selekcji najlepszych osobników na podstawie widma prądu wzbudzenia dla diagnostyki zwarcia cewki obwodu wzbudzenia

| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 25              | 600             | -               | -               | 8.5423                    |
| 3                                      | 25              | 600             | 100             | -               | 8.5448                    |
| 4                                      | 25              | 100             | 200             | 600             | 9.1400                    |


Powstanie dwóch liniowo separowalnych grup widoczne na rysunku 6.47 sugeruje, że zwarcie w uzwojeniu wzbudzenia ma istotny wpływ na składową o częstotliwości 25Hz i powoduje jej wzrost. Druga ze składowych, o częstotliwości 600Hz nie posiada tej własności, ale uwzględnienie jej zwiększa nieco margines separowalności. Uwzględnienie trzeciej składowej - o częstotliwości 100Hz (rysunek 6.49) minimalnie poprawia separowalność.




**Rys. 6.47.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej cewki obwodu wzbudzenia poprzez rezystancję zwierającą o wartości 1.3  $\Omega$

Widoczne oddzielenie się niektórych punktów od pozostałej części grupy dla stanu bezawaryjnego i przyjmowanie przez te punkty wartości 0 wynika z wcześniejszego odcięcia wszystkich składników widma, których amplitudy znajdowały się na poziomie szumu pomiarowego. Stany uszkodzenia o mniejszej intensywności, widoczne na rysunkach 6.48 i 6.50 również dają się odseparować od stanu bezawaryjnego, jednak nie jest możliwe określenie stopnia zaawansowania uszkodzenia.


Jak stwierdzono w [89] i [93], wzrost wartości amplitudy składowej 25Hz wynika z niesymetrii obwodu magnetycznego, która może być wywołana przez zwarcie, ale także przez inne uszkodzenia. Po usunięciu z widma składowej 25Hz algorytm jako najlepsze wybierał zestawy zawierające składową stałą, dla których odległość Mahalanobisa była na poziomie 5. Składowa ta również nie powinna być uznawana jako symptom uszkodzenia, ponieważ jej wartość zależy od wielu różnych czynników (np. temperatury uzwojeń, rezystancji elementów stykowych, szczotek, napięcia zasilającego obwód wzbudzenia). Dlatego też stosowanie składowej stałej jako kryterium uszkodzenia jest dość kłopotliwe, choć przy zapewnieniu stałych warunków w jakich dokonywany jest pomiar stosowanie tej składowej może posłużyć jak wskaźnik świadczący o ewentualnym wystąpieniu uszkodzenia, a potwierdzeniem tego przypuszczenia może być pomiar rezystancji uzwojeń dokonany w warunkach normatywnych. Usunięcie z widma dodatkowo składowej stałej powoduje, że wybierane zestawy częstotliwości tworzą skupiska, dla których odległość Mahalanobisa wynosi około 1,5, i wydają się one być nieprzydatne dla celów diagnostyki.



**Rys. 6.48.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w dwucechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie 3.45  $\Omega$  – niebieski, zwarcie 2.47  $\Omega$  – błękitny, zwarcie 2.00  $\Omega$  – zielony, zwarcie 1.54  $\Omega$  – fioletowy, zwarcie 1.3  $\Omega$  – czerwony.




**Rys. 6.49.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony zwarcia jednej cewki obwodu wzbudzenia poprzez rezystancję zwierającą o wartości  $1.3 \Omega$




**Rys. 6.50.** Rozkład punktów pomiarowych odpowiadających różnym stanom maszyny w trzycechowej przestrzeni, kolorami oznaczono odpowiednio: stan bezawaryjny –czarny, zwarcie  $3.45 \Omega$  – niebieski, zwarcie  $2.47 \Omega$  – błękitny, zwarcie  $2.00 \Omega$  – zielony, zwarcie  $1.54 \Omega$  – fioletowy, zwarcie  $1.3 \Omega$  – czerwony.


Na rysunkach, 6.51, 6.52 i 6.53 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu zwarcia cewki obwodu wzbudzenia spośród wszystkich cech zawartych w widmie prądu wzbudzenia.



**Rys. 6.51.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 2 cech charakterystycznych dla zwarcia cewki obwodu wzbudzenia.



**Rys. 6.52.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 3 cech charakterystycznych dla zwarcia cewki obwodu wzbudzenia.



**Rys. 6.53.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 4 cech charakterystycznych dla zwarcia cewki obwodu wzbudzenia.

#### 6.7.4. Wyniki selekcji dla przerwy jednej cewki obwodu wzbudzenia


##### Wyniki selekcji na podstawie widma prądu twornika.

Wyniki selekcji cech dla przerwy cewki obwodu wzbudzenia na podstawie widma prądu twornika dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.7, a rozkład punktów pomiarowych w dwu- i trzycieczowej przestrzeni zaprezentowany został na rysunkach 6.54 i 6.55.

**Tabela 6.7.** Wyniki selekcji najlepszych osobników na podstawie widma prądu twornika dla diagnostyki przerwy w cewce obwodu wzbudzenia

| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 25              | 100             | -               | -               | 1.4715                    |
| 3                                      | 25              | 300             | 950             | -               | 1.8046                    |
| 4                                      | 25              | 100             | 125             | 950             | 2.0951                    |


Dla porównania odległość Mahalanobisa w przypadku składowej 100Hz wektora przestrzennego prądu twornika dla tego stanu awaryjnego wynosi 0,5239.



**Rys. 6.54.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej cewce obwodu wzbudzenia


W przypadku analizy prądu twornika dla tego uszkodzenia sytuacja wygląda podobnie jak dla zwarcia cewki obwodu wzbudzenia. Informacja diagnostyczna zawarta w widmie prądu twornika jest bardzo uboga i nie jest możliwe wnioskowanie o występowaniu uszkodzenia na podstawie składników widma tego prądu. Jest to dobrze widoczne na rysunkach 6.54 i 6.55.

Żadna ze składowych nie tworzy separowalnych skupisk ani samodzielnie ani w połączeniu z innymi składowymi, co odbija się również na niskich wartościach odległości Mahalanobisa.




**Rys. 6.55.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej cewce obwodu wzbudzenia


Na rysunkach, 6.56, 6.57 i 6.58 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu przerwy cewki obwodu wzbudzenia spośród wszystkich cech zawartych w widmie prądu twornika.



**Rys. 6.56.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 2 cech charakterystycznych dla przerwy jednej cewki obwodu wzbudzenia.



**Rys. 6.57.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 3 cech charakterystycznych dla przerwy jednej cewki obwodu wzbudzenia.



**Rys. 6.58.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu twornika 4 cech charakterystycznych dla przerwy jednej cewki obwodu wzbudzenia.

## Wyniki selekcji na podstawie widma prądu wzbudzenia.


Wyniki selekcji cech dla przerwy cewki obwodu wzbudzenia na podstawie widma prądu wzbudzenia dla wektorów dwu-, trzy- i czterocechowych przedstawione zostały w tabeli 6.7, a rozkład punktów pomiarowych w dwu- i trzycechowej przestrzeni zaprezentowany został na rysunkach 6.59 i 6.60.

**Tabela 6.8.** Wyniki selekcji najlepszych osobników na podstawie widma prądu wzbudzenia dla diagnostyki przerwy w cewce obwodu wzbudzenia


| liczba cech<br>poddawanych<br>selekcji | cecha 1<br>[Hz] | cecha 2<br>[Hz] | cecha 3<br>[Hz] | cecha 4<br>[Hz] | odległość<br>Mahalanobisa |
|----------------------------------------|-----------------|-----------------|-----------------|-----------------|---------------------------|
| 2                                      | 0               | 150             | -               | -               | 16.4666                   |
| 3                                      | 0               | 73              | 150             | -               | 19.0119                   |
| 4                                      | 0               | 73              | 100             | 250             | 21.5536                   |

Analiza rysunku 6.59 prowadzi do wniosku, że wystąpienie przerwy w cewce obwodu wzbudzenia skutkuje obniżeniem wartości składowej stałej tego przebiegu (składowej o częstotliwości 0 Hz), co jest logiczne biorąc pod uwagę fakt, że zmienia się impedancja tego obwodu. Jednak wartość tej składowej może również zależeć od wielu innych czynników, zmieniających impedancję obwodu wzbudzenia (np. temperatury uzwojeń, rezystancji elementów stykowych, szczotek, itp.), jak również od napięcia zasilającego ten obwód. Dlatego też stosowanie tej składowej jako kryterium uszkodzenia jest dość kłopotliwe, choć przy zapewnieniu stałych warunków w jakich dokonywany jest pomiar stosowanie tej składowej może posłużyć jak wskaźnik świadczący o ewentualnym wystąpieniu uszkodzenia, a potwierdzeniem wydanej na tej podstawie diagnozy może być pomiar rezystancji uzwojeń dokonany w warunkach normatywnych.

Niestety pozostałe składniki widma nie dają tak dobrych rezultatów jak składowa stała. Zostało to udowodnione po przeprowadzeniu procedury selekcyjnej z wyłączeniem składowej 0Hz. Odległość Mahalanobisa najlepszej dwucechowej kombinacji składowych widma (25Hz i 125Hz) po zabiegu wycięcia składowej stałej wynosiła 2.2982, a punkty nie tworzyły separowalnych skupisk. Ponadto jak już wcześniej wspomniano pojawienie się składowej 25Hz w dużej mierze wynika z niesymetrii obwodu magnetycznego i nie pozwala ona jednoznacznie stwierdzić, czym ta niesymetria została wywołana. Wycięcie składowej 25Hz spowodowało, że rezultaty selekcji były jeszcze gorsze. Odległość Mahalanobisa na poziomie około 1.




**Rys. 6.59.** Rozkład punktów pomiarowych w dwucechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej cewce obwodu wzbudzenia




**Rys. 6.60.** Rozkład punktów pomiarowych w trzycechowej przestrzeni, kolor czarny odpowiada stanowi bezawaryjnemu, kolor czerwony przerwie w jednej cewce obwodu wzbudzenia


Na rysunkach, 6.61, 6.62 i 6.63 zaprezentowano efektywność działania poszczególnych algorytmów w problemie selekcji odpowiednio, dwóch, trzech i czterech cech charakterystycznych dla stanu przerwy cewki obwodu wzbudzenia spośród wszystkich cech zawartych w widmie prądu wzbudzenia.



**Rys. 6.61.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 2 cech charakterystycznych dla przerwy jednej cewki obwodu wzbudzenia.



**Rys. 6.62.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 3 cech charakterystycznych dla przerwy jednej cewki obwodu wzbudzenia.



**Rys. 6.63.** Porównanie działania różnych wariantów algorytmu genetycznego w problemie selekcji z widma prądu wzbudzenia 4 cech charakterystycznych przerwy jednej cewki obwodu wzbudzenia.

## 6.8. Ocena skuteczności automatycznej selekcji cech

Uzyskane wyniki potwierdzają tezę, że selekcja cech jest bardzo skutecznym mechanizmem wyszukiwania symptomów towarzyszących uszkodzeniom w maszynach synchronicznych.

W przypadku detekcji zwarcia w grupie zezwojów twornika za symptomy należy uznać składową 150Hz (oraz w mniejszym stopniu składowe 250Hz i 350Hz) w prądzie twornika oraz składowe 100Hz, 125Hz i 200Hz w prądzie wzbudzenia. Diagnostyka na podstawie prądu wzbudzenia umożliwia nawet określenie stopnia intensywności uszkodzenia.

Selekcja cech charakterystycznych dla przerwy gałęzi równoległej twornika wykazała, że jako symptomy tego uszkodzenia można uznać składową 150Hz (oraz w mniejszym stopniu 25Hz) w prądzie twornika oraz 50Hz, 100Hz i 200Hz w prądzie wzbudzenia.

Dla obu przypadków uszkodzeń w uzwojeniach wzbudzenia poszukiwanie cech w widmie prądu twornika nie doprowadziło do znalezienia symptomów tworzących liniowo separowalne skupiska punktów odpowiadających stanowi bezawaryjnemu oraz uszkodzonemu. Wyniki selekcji na podstawie prądu wzbudzenia dały dość dobre rezultaty w postaci separowalnych grup punktów, jednak składowe widma odpowiedzialne za tę separowalność (tj. 25Hz w przypadku zwarcia cewki obwodu wzbudzenia oraz 0Hz w przypadku jej przerwy) samodzielnie nie powinny być uznawane jako symptomy tych uszkodzeń, ponieważ wartości ich amplitud mogą zależeć także od innych czynników. Można ich jedynie używać jako wskaźników, które mogą świadczyć o podejrzeniu uszkodzenia, ale potwierdzenie wystąpienia konkretnego stanu awaryjnego wymaga dalszych pomiarów i analiz. Po usunięciu tych składowych z widm sygnałów pozostałe składowe nie powodują powstawania separowanych grup. Zatem wykrywanie uszkodzeń w obwodach wirnika można uznać za problem trudny wymagający przeprowadzenia dodatkowych analiz, innych niż analiza spektralna sygnałów prądowych. Jednakże brak liniowej separowalności wcale nie musi oznaczać, że uszkodzenia w uzwojeniach wzbudzenia nie mogą być poprawnie klasyfikowane. Istnieją bowiem klasyfikatory (np. neuronowe), których powierzchnie decyzyjne (powierzchnie oddzielające grupy punktów należących do różnych klas) mają bardziej skomplikowane kształty.

Wyniki selekcji prowadzą do wniosku, że prąd wzbudzenia jest sygnałem zawierającym lepszą informację diagnostyczną niż prąd wzbudzenia i nieznacznie gorszą niż wektor przestrzenny prądu twornika.

Z porównania wyników działania poszczególnych wariantów algorytmu genetycznego dla wszystkich przypadków uszkodzeń wynika, że w problemach selekcji mniejszej ilości cech (dwóch) algorytmy oparte na selekcji metodą ruletki działają zazwyczaj lepiej od algorytmów opartych na selekcji rankingowej oraz turniejowej, co można stwierdzić na podstawie wartości funkcji dopasowania najlepszych osobników w populacji. Dla problemów selekcji większej liczby cech (trzy i cztery) lepsze rezultaty osiągają algorytmy z selekcją rankingową oraz turniejową. Zwłaszcza ten ostatni wariant algorytmu okazał się skuteczny.

## 7. KLASYFIKACJA AUTOMATYCZNA

Klasyfikacja polega na przydzielaniu obiektów do klas stanowiących zbiory elementów podobnych do siebie względem przyjętych kryteriów. Klasyfikacja może być dokonywana przez eksperta w danej dziedzinie (np. w diagnostyce maszyn elektrycznych przez osobę potrafiącą oceniać stan maszyny na podstawie dostępnych symptomów) lub też być w pełni automatyczna. Klasyfikacja automatyczna może być nadzorowana, gdy klasy do których kwalifikowane są poddawane klasyfikacji obiekty są z góry znane lub nienadzorowana (tzw. grupowanie) gdy nie ma żadnych informacji na temat klas, a obiekty są klasyfikowane na podstawie podobieństwa do innych obiektów (obiekty podobne do siebie zaliczane są do tej samej klasy).

### 7.1. Klasyfikacja nadzorowana

W klasyfikacji nadzorowanej zakłada się, że na całej populacji obiektów  $O$  jest określona pewna (nieznana) funkcja  $\Phi$  przypisująca każdemu obiektowi etykietę jednej z  $c$  rozłącznych klas  $O_1, O_2, \dots, O_c$  [95]:

$$\Phi: O \rightarrow I = \{1, 2, \dots, c\} \quad (7.1)$$

gdzie:

$O$  – zbiór obiektów,

$I$  – zbiór etykiet klas.

System klasyfikujący powinien znaleźć jak najlepsze w sensie przyjętego kryterium przybliżenie funkcji  $\Phi$  korzystając z tzw. zbioru uczącego  $U$ :

$$U = \{\langle opis(o_i), t_i \rangle = \Phi(o_i)\}_{i=1}^N \quad (7.2)$$

gdzie:

$o_i$  – obiekt  $i$ -tej klasy,

$t_i$  – etykieta  $i$ -tej klasy.

Zbiór uczący zawiera tzw. przykłady będące parami składającymi się z opisu obiektu oraz etykiety klasy, do której obiekt należy. Opis obiektu jest zwykle reprezentowany poprzez wektor cech tego obiektu. W zbiorze uczącym znajduje się jedynie niewielka część obiektów z całej populacji możliwych do wystąpienia przypadków. W miarę możliwości należy tak konstruować zbiór uczący, aby zawierał jak najszerszą reprezentację populacji obiektów, w szczególności, by znajdowały się w nim obiekty ze wszystkich możliwych klas.

Przybliżenie funkcji  $\Phi$  jest odwzorowaniem zbioru obiektów  $O$  (populacji) na zbiór decyzji  $Z_c$ :

$$\phi: O \ni o \rightarrow z \in Z_c \quad (7.3)$$

gdzie:

$\phi$  – przybliżenie funkcji  $\Phi$ ,

$O$  – zbiór obiektów,

$Z_c$  – zbiór decyzji.

Zbiór decyzji zawiera decyzje o przyporządkowaniu obiektu do poszczególnych klas oraz dodatkowy element 0, który oznacza brak decyzji (w sytuacji, gdy zakwalifikowanie obiektu do którejś z dostępnych klas jest obarczone zbyt dużym ryzykiem):

$$Z_c = \{0, 1, 2, \dots, c\} \quad (7.4)$$

W systemie automatycznej klasyfikacji odwzorowanie  $\phi$  jest realizowane za pośrednictwem złożenia trzech odwzorowań składowych [97]:

$$\phi = \phi_3 \phi_2 \phi_1 \quad (7.5)$$

Odwzorowanie  $\phi_1$  każdemu obiektowi  $o$  ze zbioru  $O$  przyporządkowuje jego reprezentację  $x$  z wybranej przestrzeni reprezentacji  $X$ :

$$\phi_1: O \ni o \rightarrow x \in X \quad (7.6)$$

Odwzorowanie  $\phi_2$  każdej reprezentacji  $x$  obiektu  $o$  przyporządkowuje wektor wartości funkcji dyskryminacyjnych:

$$\phi_2: X \ni x \rightarrow [g_1(x), g_2(x), \dots, g_c(x)] \in R^c \quad (7.7)$$

gdzie:

$g_i(x)$  – funkcja dyskryminacyjna dla  $i$ -tej klasy,

$R^c$  –  $c$ -wymiarowa przestrzeń o elementach rzeczywistych.

Funkcje dyskryminacyjne dla każdej z klas powinny być tak zdefiniowane, aby każda z nich posiadała największą wartość dla reprezentacji obiektu własnej klasy.

Odwzorowanie  $\phi_3$  każdemu wektorowi wartości funkcji dyskryminacyjnych przyporządkowuje decyzję ze zbioru decyzji:

$$\phi_3: R^c \ni [g_1(x), g_2(x), \dots, g_c(x)] \rightarrow z \in Z_c \quad (7.8)$$

Funkcja  $\psi$ , będąca złożeniem funkcji  $\phi_2$  i  $\phi_3$  nazywana jest algorytmem klasyfikacji, regułą decyzyjną lub klasyfikatorem:

$$\psi = \phi_3 \phi_2: X \ni x \rightarrow z \in Z_c \quad (7.9)$$

W przypadku podejścia strukturalnego klasa reprezentowana jest przez tzw. prototyp, który jest zbiorem cech obiektu.

Klasyfikator  $\psi$  dzieli przestrzeń cech obiektu na  $c$  rozłącznych obszarów decyzyjnych, z których każdy odpowiada jednej z klas:

$$ObDec_i = \{x \in E : \psi(x) = t_i\}, t_i \in I \quad (7.10)$$

gdzie:

$ObDec_i$  – i-ty obszar decyzyjny klasyfikatora,

$E$  – przestrzeń cech,

$t_i$  – etykieta i-tej klasy.

Obszary decyzyjne oddzielone są od siebie powierzchniami decyzyjnymi. Równanie powierzchni decyzyjnej  $g_{ij}$  oddzielającej klasę i-tą od klasy j-tej dane jest wzorem:

$$g_{ij}(x) : g_i(x) - g_j(x) = 0 \quad (7.11)$$

Zadanie klasyfikacji nadzorowanej składa się z dwóch trybów: trybu uczenia i walidacji oraz trybu testowania i eksploatacji.

Tryb uczenia i walidacji służy do określenia funkcji dyskryminacyjnych klasyfikatora, jego parametrów oraz ewentualnie prototypów klas. Składa się z czterech następujących etapów:

- wstępnego przetwarzania danych, który ma na celu dostosowanie danych do konkretnego problemu klasyfikacyjnego,
- typowania i obliczania reprezentacji obiektu, polegającego na znalezieniu dziedziny odwzorowania  $\phi_1$  oraz określeniu cech obiektu (utworzeniu wektora cech), a następnie obliczeniu reprezentacji dla wszystkich obiektów i utworzeniu zbioru uczącego,
- ekstrakcji i selekcji cech, polegającego na wyeliminowaniu cech nadmiarowych, mało istotnych i silnie zaszumionych, a pozostawieniu tylko tych cech, które są istotne z punktu widzenia przyjętego kryterium klasyfikacji,
- uczenia i walidacji, którego celem jest wyznaczenie funkcji dyskryminacyjnych (w niektórych przypadkach również prototypów klas), a także dostrojenie parametrów zastosowanego klasyfikatora.

Tryb testowania i eksploatacji służy do oceny jakości klasyfikatora (jego zdolności dyskryminacyjnych na podstawie przykładów nie wchodzących do zbioru uczącego) oraz do klasyfikowania nowych przypadków. Tryb ten składa się z czterech następujących etapów:

- wstępnego przetwarzania danych,
- obliczania reprezentacji obiektu ( $x = \phi_1(o)$ ),
- obliczania wartości funkcji dyskryminacyjnych ( $\phi_2(x) = [g_1(x), g_2(x), \dots, g_c(x)]$ ),
- podejmowania decyzji ( $i = \phi_3(g_1(x), g_2(x), \dots, g_c(x))$ ).

## 7.2. Klasyfikacja nienadzorowana

W klasyfikacji nienadzorowanej, zwanej również grupowaniem, klasy obiektów oraz ich liczba nie są z góry znane. Zbiór uczący składa się z przykładów, z których każdy jest d-wymiarowym wektorem cech [95]:

$$U = \{x_i = (x_{i1}, x_{i2}, \dots, x_{id}) \mid i = 1, 2, \dots, N\} \quad (7.12)$$

gdzie:

$x_i$  – i-ty przykład,

$U$  – zbiór uczący.

Celem klasyfikacji nienadzorowanej jest podział zbioru uczącego na grupy  $G_1, G_2, \dots, G_c$  będące podzbiorami podobnych do siebie wektorów. Wektory zaklasyfikowane do tej samej grupy powinny być bardziej podobne (według przyjętej miary podobieństwa) do siebie nawzajem niż do jakichkolwiek innych wektorów z pozostałych grup.

Liczba przypadków zawartych w zbiorze uczącym musi być na tyle duża, aby możliwe było odzwierciedlenie pełnej różnorodności zjawisk występujących w danym problemie.

W wyniku grupowania może dojść do podziału twardego (hard), rozmytego (fuzzy) lub posybilistycznego (possibilistic) zbioru uczącego.

W przypadku podziału twardego każdy element zbioru uczącego może przynależeć tylko do jednej grupy, zatem stopień przynależności każdego z elementów wynosi 1 dla grupy do której element został zakwalifikowany oraz 0 dla pozostałych grup.

Każda z grup spełnia następujące warunki:

$$G_i \neq \emptyset, \quad i = 1, 2, \dots, c \quad (7.13)$$

$$G_i \cap G_j = \emptyset, \quad i \neq j, \quad i = 1, 2, \dots, c \quad (7.14)$$

$$\bigcup_{i=1}^c G_i = U \quad (7.15)$$

gdzie:

$G_i$  – i-ta grupa,

$U$  – zbiór uczący.

W przypadku podziału rozmytego każdy element zbioru uczącego może przynależeć jednocześnie do kilku grup. Stopień przynależności do poszczególnych grup dla każdego z elementów osiąga wartość z przedziału  $[0; 1]$  i im wartość ta jest wyższa, tym element jest bardziej podobny do pozostałych elementów w danej grupie.

W przypadku podziału posybilistycznego stopień przynależności wektora do danej grupy zastąpiony jest stopniem kompatybilności wektora z tą grupą, spełniającym warunek:

$$\max_{i=1,2,\dots,c} u_{ik} > 0, \quad k = 1, 2, \dots, N \quad (7.16)$$

gdzie:

$U_{ik}$  – stopień kompatybilności  $k$ -tego wektora z  $i$ -tą grupą.

Procedura grupowania składa się z sześciu następujących etapów:

- utworzenia reprezentacji obiektu, obejmującego ustalenie liczebności zbioru uczącego, wybór cech reprezentujących obiekty oraz ewentualnie ekstrakcję i selekcję cech, wstępną obróbkę danych wejściowych (normalizację), a w niektórych algorytmach również ustalenie liczby grup,
- wyboru miary podobieństwa, która w sposób ilościowy określa stopień podobieństwa pomiędzy wektorami,
- ustalenia tendencji grupującej, czyli sprawdzenia na podstawie hipotez statystycznych czy zbiór uczący wykazuje istnienie struktury wewnętrznej, która miała by być rozpoznana poprzez grupowanie,
- grupowania, czyli podziału zbioru uczącego na grupy przy wykorzystaniu jednego z wielu algorytmów grupujących,
- walidacji wyniku, mającego na celu sprawdzenie poprawności uzyskanego podziału
- abstrakcji danych, polegającego na opisie uzyskanych grup w postaci reprezentujących je prototypów.

Jeśli dany wektor ze zbioru uczącego nie pasuje do żadnej z istniejących już grup, tworzona jest nowa grupa, do której wektor ten jest zaliczany.

### 7.3. Normalizacja danych

W problemach klasyfikacyjnych większość metod zakłada zazwyczaj podobny rozrzut danych w poszczególnych wymiarach przestrzeni wejściowej [47]. Dlatego też często wskazana jest pewna transformacja danych, która doprowadzi do zmniejszenia dysproporcji pomiędzy wartościami w poszczególnych wymiarach. Najprostszą stosowaną transformacją danych jest normalizacja, która dostosowuje wartości tak, aby mieściły się w określonym przedziale (np.  $[0,1]$ ,  $[-1,1]$ ). Istnieje kilka metod normalizacji, z których najpopularniejszą jest metoda min-max [47],[95],[46]:

$$x'_{ij} = \frac{(x_{ij} - \min_j\{x_{ij}\})(b-a)}{\max_j\{x_{ij}\} - \min_j\{x_{ij}\}} + a, \quad i = 1, 2, \dots, n, \quad j = 1, 2, \dots, d \quad (7.17)$$

gdzie:

$x_{ij}, x'_{ij}$  - wartość  $i$ -tej współrzędnej  $j$ -tego wektora cech przed i po znormalizowaniu,

$\min_j\{x_{ij}\}, \max_j\{x_{ij}\}$  – wartości minimalna oraz maksymalna  $i$ -tej współrzędnej  $j$ -tego wektora cech,

$a, b$  – granice przedziału, w którym mają mieścić się dane po znormalizowaniu.

Podstawową wadą powyższej transformacji jest to, że w przypadku wystąpienia błędnych wartości, leżących daleko poza typowym zakresem wartości danej cechy, dochodzi do nadmiernego ściśnięcia wartości dla pozostałych danych. W celu wyeliminowania powyższej wady wartości  $x_{min}$  i  $x_{max}$  wybiera się nie spośród całego zbioru  $\{x_1, x_2, \dots, x_n\}$ , ale po odrzuceniu z niego  $k\%$  najmniejszych i największych wartości (zwykle  $k = 5 \div 10$ ). Tego typu normalizacja nazywana jest normalizacją min-max z obcięciem [47].

W przypadku, gdy zakres danych wejściowych (wartości  $\min_j\{x_{ij}\}$  i  $\max_j\{x_{ij}\}$ ) nie jest znany, stosuje się normalizację Z-score (zwaną także Zero-Mean lub standaryzacją) [46] , [47],[95]:

$$x'_{ij} = \frac{x_{ij} - \bar{x}_i}{\sigma_{xi}} \quad (7.18)$$

gdzie:

$x_{ij}, x'_{ij}$  - wartość i-tej współrzędnej j-tego wektora cech przed i po znormalizowaniu,

$\bar{x}_i$  - wartość średnia i-tej współrzędnej wektora  $x$ ,

$\sigma_{xi}$  - odchylenie standardowe i-tej współrzędnej wektora  $x$ .

Tak znormalizowane cechy posiadają zerową wartość średnią i jednostkową wariancję [95].

Gdy zakresy wartości dla poszczególnych cech różnią się znacznie między sobą (różnice sięgają rzędów wielkości) stosuje się normalizację poprzez skalowanie decymalne [46]:

$$x'_{ij} = \frac{x_{ij}}{10^k} \quad (7.19)$$

gdzie:

$x_{ij}, x'_{ij}$  - wartość i-tej współrzędnej j-tego wektora cech przed i po znormalizowaniu,

$k$  - najmniejsza liczba całkowita taka, że  $x'_{ij}$  spełnia nierówność:

$$\max_j\{|x'_{ij}|\} < 1 \quad (7.20)$$

W przypadku gdy wartości poszczególnych cech dla kolejnych pomiarów mają rozkład normalny można stosować poniższą normalizację [46]:

$$x'_{ij} = \frac{x_{ij} - \text{median}\{x_{ij}\}}{MAD} \quad (7.21)$$

$$MAD = \text{median}\{|x_{ij} - \text{median}\{x_{ij}\}|\} \quad (7.22)$$

gdzie:

$x_{ij}, x'_{ij}$  - wartość j-tej współrzędnej i-tego wektora cech przed i po znormalizowaniu,

$\bar{x}_j$  - wartość średnia j-tej współrzędnej wektora  $x$  dla  $i$  próbek,

$MAD$  – mediana wartości bezwzględnej odchylenia (median absolute deviation).

Powyższa metoda jest dość odporna na występowanie wartości nietypowych, jednak gdy rozkład wartości poszczególnych cech nie jest typu Gaussowskiego jest nieefektywna.

Gdy rozkład wartości poszczególnych cech nie jest normalny lub liniowy i zależy nam na zachowaniu relacji pomiędzy poszczególnymi cechami a nie odległości jakie one wyznaczają,

można skorzystać z następującego przekształcenia:

$$x'_{ij} = 2|\{x: x < x_{ij}\}| + |\{x: x = x_{ij}\}| \quad (7.23)$$

gdzie:

$x_{ij}, x'_{ij}$  - wartość j-tej współrzędnej i-tego wektora cech przed i po znormalizowaniu,  
 $|\{x\}|$  – moc zbioru  $\{x\}$ .

Istnieje jeszcze wiele innych typów normalizacji takich jak np. normalizacja za pomocą funkcji typu podwójna sigmoida (double sigmoid function) [8] lub estymatora tangens hiperboliczny (tanh-estimators) [26],[46].

## 7.4. Metody oceny skuteczności klasyfikacji

Błąd klasyfikacji klasyfikatora to prawdopodobieństwo poprawnej klasyfikacji losowo wybranego przypadku [50]:

$$accuracy = P(\Phi(o_i) = t_i) \quad (7.24)$$

gdzie:

$\Phi$  – funkcja klasyfikująca,  
 $o_i$  – obiekt i-tej klasy,  
 $t_i$  – etykieta i-tej klasy.

Ponieważ klasyfikator jest uczony i testowany jedynie na małym fragmencie zbioru możliwych przypadków, przy określaniu skuteczności klasyfikacji korzysta się estymacji tego prawdopodobieństwa.

Ocena skuteczności klasyfikacji dokonywana jest z wykorzystaniem tzw. zbioru testowego, w którym każdy przypadek reprezentowany jest poprzez wektor cech oraz etykietę klasy, do której ten wektor przynależy. Poprawność klasyfikacji oceniana jest poprzez porównanie odpowiedzi klasyfikatora na dany wektor cech ze zbioru testującego z jego etykietą z tego zbioru i wykonywane jest dla wszystkich elementów tego zbioru. Na podstawie porównania można określić tzw. błąd klasyfikacji, który definiowany może być w różny sposób. Najczęściej stosuje się tzw. łączny błąd klasyfikacji, opisany następującą zależnością [95]:

$$e = \frac{n_{false}}{n_{test}} \quad (7.25)$$

gdzie:

$n_{false}$  – liczba błędnie sklasyfikowanych przypadków ze zbioru testującego,  
 $n_{test}$  – liczba wszystkich przypadków w zbiorze testującym.

Dopełnienie błędu klasyfikacji do jedności to tzw. sprawność klasyfikacji, która wyraża się wzorem:

$$s = 1 - e = \frac{n_{correct}}{n_{test}} \quad (7.26)$$

gdzie:

$n_{correct}$  – liczba poprawnie sklasyfikowanych przypadków ze zbioru testującego,

$n_{test}$  – liczba wszystkich przypadków w zbiorze testującym.

Innymi miarami poprawności klasyfikacji, stosowanymi w problemach dwuklasowych, są wrażliwość (ang. sensitivity) oraz specyficzność (ang. specificity) zdefiniowane następująco:

$$sensitivity = \frac{TP}{TP+FN} \quad (7.27)$$

$$specificity = \frac{TN}{FP+TN} \quad (7.28)$$

gdzie:

$TP$  – liczba poprawnie sklasyfikowanych przypadków z pierwszej klasy (true positive),

$TN$  – liczba poprawnie sklasyfikowanych przypadków z drugiej klasy (true negative),

$FN$  – liczba błędnie sklasyfikowanych przypadków z pierwszej klasy (false negative),

$FP$  – liczba błędnie sklasyfikowanych przypadków z drugiej klasy (false positive),

W celu dokładniejszej estymacji skuteczności klasyfikacji przeprowadza się tzw. proces walidacji klasyfikatora, w którym zbiór uczący dzieli się na zbiory: treningowy i testujący i przeprowadza się na nich procesy trenowania i testowania według przyjętej metody. Rozróżnia się kilka metod walidacji modeli klasyfikatorów, różniących się od siebie sposobem wyznaczania zbiorów treningowego i testującego.

### **Metoda redystrybucji [52]**

Metoda ta polega na trenowaniu i testowaniu klasyfikatora za pomocą wszystkich danych ze zbioru uczącego (zatem testowanie odbywa się z użyciem tych samych przypadków, które były używane podczas trenowania).

### **Metoda holdout [50][52]**

W metodzie tej zbiór uczący  $U$  dzielony jest na dwa wzajemnie rozłączne podzbiory: treningowy  $U_t$  i testujący  $U_h$ . Powszechnie stosowany jest podział w stosunku 2/3 przypadków - zbiór treningowy, 1/3 przypadków - zbiór testujący. Jeśli w zbiorze testującym znajduje się  $h$  przypadków, to estymowana sprawność w tej metodzie wyraża się wzorem:

$$acc_h = \frac{1}{h} \sum_{\langle x_i, t_i \rangle \in U_h} \delta(\Phi(o_i), t_i) \quad (7.29)$$

gdzie:

$h$  – liczba przypadków w zbiorze testującym,

$\langle x_i, t_i \rangle$  – para złożona z  $i$ -tego wektora cech i etykiety klasy, do której ten wektor przynależy,

$\Phi(o_i)$  – wartości odpowiedź klasyfikatora na  $i$ -ty obiekt,

$\delta(i, j)$  – błąd klasyfikacji równy 1 gdy  $i = j$  oraz 0 gdy  $i \neq j$ .

Ponieważ użycie całego zbioru przypadków do trenowania klasyfikatora daje z reguły lepsze rezultaty rozpoznawania, metoda holdout ma tendencję do przeszacowywania błędu klasyfikacji. W celu poprawy skuteczności oceny i uniezależnienia jej od sposobu podziału, stosuje się wielokrotny losowy podział zbioru próbek, a następnie uśrednienie błędu rozpoznawania po wszystkich podziałach. Często stosowana jest też technika stratified holdout, polegająca na takim losowaniu próbek, aby poszczególne klasy posiadały w obu zbiorach taki sam lub zbliżony rozkład próbek.

### **Metoda leave-one-out [50]**

W metodzie tej  $N$ -elementowy zbiór uczący również dzielony jest na dwa wzajemnie rozłączne podzbiory: treningowy  $U_t$  i testujący  $U_h$ , przy czym zbiór testujący zawiera tylko jeden element, a zbiór treningowy pozostałe  $N-1$  elementów. Uczenie i testowanie przeprowadzane jest  $N$ -krotnie, a wyniki klasyfikacji są następnie uśredniane. Metoda leave-one-out z uwagi na większą liczbę przypadków znajdujących się w zbiorze treningowym daje lepsze rezultaty niż metoda holdout.

### **Metoda leave-k-out (metoda rotacji) [50], [52]**

Metoda ta jest uogólnieniem metody leave-one-out, w której liczba przypadków w zbiorze testującym wynosi  $k$ , a w zbiorze treningowym  $N-k$ . Uczenie i testowanie przeprowadzane jest  $m$ -krotnie ( $m=N/k$ ), a wynik podobnie jak poprzednio jest uśredniany. Metoda ta w przypadku  $k=1$  staje się metodą leave-one-out, natomiast w przypadku  $k$  zbliżonego do  $N/2$  (np.  $k=N/3$ ) przechodzi w metodę holdout. Metoda rotacji daje lepsze wyniki niż metoda holdout (większa liczebność zbioru treningowego) oraz jest mniej kosztowna obliczeniowo od metody leave-one-out (mniejsza liczba powtórzeń trenowania i testowania). W metodzie tej podobnie jak w metodzie holdout może być stosowana technika zwana stratification, prowadząca do zbliżonego rozkład próbek w poszczególnych klasach.

### **Metody bootstrappingu [50], [52]**

W metodach tych eksperyment klasyfikacji przeprowadzany jest wielokrotnie i na podstawie dużej ilości eksperymentów szacowane jest obciążenie klasyfikatora [52]. Każdy eksperyment jest wykonywany na podstawie zbioru uczącego uzyskanego w wyniku losowania ze zwracaniem w zbiorze danych.

## 8. NEURONOWY KLASYFIKATOR STANU MASZYNY

### 8.1. Wiadomości wstępne

Sztuczne sieci neuronowe powstały na podstawie obserwacji działania systemu nerwowego w organizmach żywych i szybko znalazły zastosowanie w wielu dziedzinach nauki i techniki z uwagi na fakt, iż sposób przetwarzania informacji w systemie nerwowym jest bardzo efektywny [19], [54]. Podstawowym elementem sieci neuronowej, podobnie jak układu nerwowego, jest neuron. Pierwszy model sztucznego neuronu został zaprezentowany w 1943 roku i od nazwisk jego twórców nosi nazwę modelu McCullocha-Pittsa [78]. W modelu tym sygnały wejściowe są sumowane z odpowiednimi wagami, a następnie, w zależności od znaku sumy na wyjście neuronu podawana jest wartość 0 lub 1. Funkcja aktywacji takiego neuronu ma postać:

$$f(u) = \begin{cases} 1 & \text{gdy } u > 0 \\ 0 & \text{gdy } u \leq 0 \end{cases} \quad (8.1)$$

gdzie:

$u$  – suma iloczynów sygnałów wejściowych i odpowiadających im wag.

Sumowanie odbywa się według następującej zależności:

$$u(t) = \sum_{j=1}^N w_j x_j(t) + w_0 \quad (8.2)$$

gdzie:

$x_j(t)$  –  $j$ -ty sygnał wejściowy,  
 $w_j$  – waga  $j$ -tego sygnału wejściowego,  
 $w_0$  – próg aktywacji,  
 $N$  – liczba wejść neuronu.


Na bazie modelu McCullocha-Pittsa utworzono wiele innych modeli neuronów, z których najpopularniejszym jest tzw. perceptron. Perceptron jest zwykłym modelem McCullocha-Pittsa o odpowiednio przyjętej strategii uczenia – tzw. regule perceptronu. Zgodnie z tą regułą dobór wag odbywa się następująco: na wejścia neuronu podawany jest wektor uczący  $x$  i obliczana jest wartość sygnału wyjściowego  $y$ , który porównywany jest z wartościąadaną  $d$ ; w zależności od wyniku tego porównania wagi uaktualniane są w następujący sposób:

- jeśli  $y=d$  to wagi pozostają bez zmian,
- jeśli  $y=0$  a  $d=1$  to  $w_j(k+1) = w_j(k) + x_j$  ( $k$  oznacza numer cyklu poprzedniego, a  $k+1$  bieżącego),
- jeśli  $y=1$  a  $d=0$  to  $w_j(k+1) = w_j(k) - x_j$ .

Zasadniczym postępowaniem w stosunku do perceptronu było zastosowanie w miejsce dwustanowej skokowej funkcji aktywacji funkcji nieliniowej ciągłej. Spełnienie postulatu ciągłości umożliwia zastosowanie gradientowych metod uczenia (dzięki różniczkowalności). Modelem neuronu posiadającym ciągłą funkcję aktywacji jest tzw. neuron sigmoidalny.

### 8.1.1. Neuron sigmoidalny

W neuronie sigmoidalnym sygnały wejściowe są mnożone przez odpowiadające im wagi, a następnie iloczyny te są sumowane ze sobą oraz z dodatkowym składnikiem  $w_{i0}$  zwanym progiem [77], [78], [99] (tak jak w modelu McCullocha-Pittsa). Wynik sumowania to tzw. sygnał aktywacji, będący argumentem tzw. funkcji aktywacji, która w przypadku neuronu sigmoidalnego ma kształt sigmoidy. Schemat budowy neuronu sigmoidalnego został przedstawiony na rysunku 9.1.



**Rys. 8.1.** Schemat neuronu sigmoidalnego

Wykorzystuje się dwa rodzaje funkcji sigmoidalnych, unipolarne dane wzorem:

$$f(u) = \frac{1}{1+e^{-\beta u}} \quad (8.3)$$


oraz bipolarne opisane zależnością:

$$f(u) = \tanh(\beta u) \quad (8.4)$$

gdzie:

- $\beta$  – parametr dobierany indywidualnie, mający wpływ na kształt funkcji (jej stromość),
- $u$  – sygnał aktywacji.

Wykresy obu funkcji zostały przedstawione na rysunku 9.2.



**Rys. 8.2.** Wykresy funkcji sigmoidalnych: unipolarnej i bipolarnej dla różnych wartości parametru  $\beta$

W wyniku różniczkowania powyższych funkcji otrzymuje się:

$$\frac{df(u)}{du} = \beta f(u)(1 - f(u)) \quad (8.5)$$

oraz


$$\frac{df(u)}{du} = \beta(1 - f^2(u)) \quad (8.6)$$

odpowiednio dla funkcji unipolarnej i bipolarnej.

Wykresy obu funkcji pochodnych mają krzywej dzwonowej z maksimum w  $u = 0$ .

### 8.1.2. Sieć wielowarstwowa perceptronowa

Neurony można łączyć ze sobą tworząc w ten sposób tzw. sieci neuronowe. Istnieją różne sposoby łączenia neuronów przez co można otrzymać różne rodzaje sieci, jednak najpopularniejszym typem jest sieć wielowarstwowa, jednokierunkowa o neuronach typu sigmoidalnego zwana również perceptronem wielowarstwowym lub w skrócie MLP (Multi Layer Perceptron) [78], [86], [99], [108]. W sieci MLP neurony ułożone są w warstwach, z których pierwsza nazywana jest warstwą wejściową, ostatnia warstwą wyjściową, a pozostałe, znajdujące się pomiędzy nimi warstwy noszą nazwę warstw ukrytych. Ilość warstw ukrytych może być praktycznie dowolna, jednak zostało udowodnione, że sieć o jednej lub co najwyżej dwóch warstwach ukrytych, jest wystarczająca do dowolnie dokładnego odwzorowania sygnału wejściowego w sygnał wyjściowy. Neurony w poszczególnych warstwach łączą się z neuronami w warstwach sąsiednich, natomiast nie mają połączeń z neuronami we własnej warstwie. Schemat sieci MLP posiadającej jedną warstwę ukrytą został przedstawiony na rysunku 9.3.



Rys. 8.3. Schemat sieci MLP o jednej warstwie ukrytej

### 8.1.3. Metody uczenia sieci perceptronowych

Uczenie wielowarstwowej sieci perceptronowej odbywa się zwykle w tzw. trybie nadzorowanym, który polega na podawaniu na wejście sieci wektorów ze zbioru treningowego, który zawiera przypadki składające się z par: (wektor wejściowy, zadany wektor odpowiedzi) i wyznaczanie błędu odpowiedzi sieci. Uczenie sieci polega na takim doborze wag, aby uzyskać minimum wartości funkcji błędu na zadanym zbiorze uczącym [19], [76], [79], [108]. Uaktualnienie wag może odbywać się po każdorazowej prezentacji próbki uczącej (pary  $(\mathbf{x}, \mathbf{d})$ ) – tzw. uczenie typu on-line lub jednorazowo, po prezentacji wszystkich próbek – tzw. tryb off-line. Jako funkcję błędu najczęściej przyjmuje się połowę sumy kwadratów różnic pomiędzy poszczególnymi elementami wektorów odpowiedzi  $\mathbf{y}$  i  $\mathbf{d}$ :

$$E(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^M (y_k - d_k)^2 \quad (8.7)$$

gdzie:

$\mathbf{w}$  – wektor wszystkich wag sieci,

$y_k$  – k-ty element wektora odpowiedzi sieci  $\mathbf{y}$  na wektor wejściowy  $\mathbf{x}$ ,

$d_k$  – k-ty element zadanego wektora odpowiedzi  $\mathbf{d}$  sieci,

$M$  – liczba wyjść sieci.

W przypadku, gdy zbiór uczący zawiera  $p$  próbek, funkcja celu będzie sumą funkcji błędów po wszystkich próbkach:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^M (y_k^{(j)} - d_k^{(j)})^2 \quad (8.8)$$

Powszechnie stosowanymi metodami uczenia sieci są tzw. metody gradientowe, wykorzystujące rozwinięcie funkcji błędu w szereg Taylora w najbliższym sąsiedztwie znanego aktualnego rozwiązania  $\mathbf{w}$  w kierunku  $\mathbf{p}$ :

$$E(\mathbf{w} + \mathbf{p}) = E(\mathbf{w}) + [\mathbf{g}(\mathbf{w})]^T \mathbf{p} + \frac{1}{2} \mathbf{p}^T \mathbf{H}(\mathbf{w}) \mathbf{p} + \dots \quad (8.9)$$

gdzie:

$\mathbf{p}$  – wektor kierunkowy uzależniony od aktualnych wartości wag,

$\mathbf{g}(\mathbf{w})$  – wektor gradientu,

$\mathbf{H}(\mathbf{w})$  – macierz drugich pochodnych (macierz Hessego, hesjan).

$$\mathbf{g}(\mathbf{w}) = \nabla E = \frac{\partial E}{\partial \mathbf{w}} = \left[ \frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_n} \right]^T \quad (8.10)$$

$$\mathbf{H}(\mathbf{w}) = \nabla^2 E = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1 \partial w_1} & \dots & \frac{\partial^2 E}{\partial w_1 \partial w_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 E}{\partial w_n \partial w_1} & \dots & \frac{\partial^2 E}{\partial w_n \partial w_n} \end{bmatrix} \quad (8.11)$$

W praktyce wykorzystuje się dwa lub co najwyżej trzy pierwsze składniki rozwinięcia w szereg Taylora funkcji błędu.

Jeśli w pewnym punkcie przestrzeni poszukiwań  $\mathbf{w}_k$  wartość gradientu  $\mathbf{g}(\mathbf{w}_k)$  jest równa zero, a macierz hesjanu  $\mathbf{H}(\mathbf{w}_k)$  jest dodatnio określona, to w punkcie tym występuje minimum funkcji błędu.

Aktualizacja wag odbywa się według zależności:

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \eta_k \mathbf{p}_k \quad (8.12)$$

gdzie:

$\eta_k$  – współczynnik uczenia w  $k$ -tym kroku działania algorytmu,

$\mathbf{p}_k$  – wektor kierunkowy w  $k$ -tym kroku działania algorytmu.

Kierunek poszukiwań oraz wartość współczynnika uczenia należy dobierać w taki sposób, aby spełniona była zależność:

$$E(\mathbf{w}_{k+1}) < E(\mathbf{w}_k) \quad (8.13)$$

Do najpopularniejszych algorytmów wyznaczających właściwy kierunek poszukiwań minimum funkcji błędu i zaliczanych do metod gradientowych należą [53], [78]:

- algorytm wstecznej propagacji błędów,
- algorytm największego spadku,
- algorytm zmiennej metryki,
- algorytm Levenberga-Marquardta,
- algorytm gradientów sprzężonych.

Ponadto w oparciu o metody gradientowe utworzone zostały dwie szybkie i dość popularne metody heurystyczne: Quickprop i Rprop.

### Algorytm wstecznej propagacji błędów

Algorytm ten rozpoczyna swoje działanie od podania na wejście próbki ze zbioru uczącego, a następnie obliczenie odpowiedzi neuronów w kolejnych warstwach sieci, kończąc na warstwie wyjściowej. Na podstawie odpowiedzi neuronów w warstwie wyjściowej obliczana jest wartość funkcji celu  $E(\mathbf{w})$  (wzór 8.7). Funkcję tę poddaje się następnie minimalizacji względem wag warstwy wyjściowej. Odpowiednio przekształcając wzór 8.7 otrzymuje się następującą postać funkcji celu:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{k=1}^M \left[ f\left(\sum_{i=0}^K w_{ki}^{(L)} y_i^{(L-1)}\right) - d_k \right]^2 \quad (8.14)$$

gdzie:

- $w_{ki}^{(L)}$  –  $i$ -ta waga  $k$ -tego neuronu warstwy  $L$ -tej (wyjściowej),
- $y_i^{(L-1)}$  – odpowiedź  $i$ -tego neuronu warstwy  $(L-1)$ -szej,
- $d_k$  – odpowiedź wzorcowa  $k$ -tego neuronu warstwy  $(n-1)$ -szej,
- $M$  – liczba neuronów w warstwie  $n$ -tej,
- $K$  – liczba neuronów w warstwie  $(L-1)$ -szej.

Poszczególnymi składnikami gradientu dla neuronów warstwy wyjściowej są pochodne cząstkowe po poszczególnych wagach w tej warstwie:

$$\frac{\partial E}{\partial w_{ij}^{(L)}} = \left( y_i^{(n)} - d_i \right) \frac{df\left(\sum_{j=0}^K w_{ij}^{(L)} y_j^{(L-1)}\right)}{d\left(\sum_{j=0}^K w_{ij}^{(L)} y_j^{(L-1)}\right)} y_i^{(L-1)} \quad (8.15)$$

Po oznaczeniu sygnału aktywacji  $i$ -tego neuronu warstwy wyjściowej przez  $u_i^{(L)}$  wzór 8.15 przyjmuje postać:

$$\frac{\partial E}{\partial w_{ij}^{(L)}} = \left( y_i^{(n)} - d_i \right) \frac{df(u_i^{(L)})}{d(u_i^{(L)})} y_i^{(L-1)} \quad (8.16)$$

Składniki gradientu dla warstw ukrytych oraz warstwy wejściowej oblicza się w podobny sposób, jednak mają one nieco bardziej skomplikowaną postać z uwagi na konieczność obliczania pochodnych funkcji złożonych. Dla dowolnej  $n$ -tej warstwy ( $n = 1, 2, \dots, L-1$ ) składniki gradientu można wyznaczyć ze wzoru:

$$\frac{\partial E}{\partial w_{ij}^{(n)}} = \sum_{k=1}^M \left( y_k^{(n+1)} - d_k \right) \frac{df(u_k^{(n+1)})}{d(u_k^{(n+1)})} w_{ki}^{(n+1)} \frac{df(u_i^{(n)})}{d(u_i^{(n)})} x_j^{(n)} \quad (8.17)$$

Wagi uaktualniane są wg wzoru:

$$w_{ij}^{(n)}(k+1) = w_{ij}^{(n)}(k) - \eta_k \frac{\partial E}{\partial w_{ij}^{(n)}}(k) \quad (8.18)$$

gdzie:

$k, k+1$  – krok  $k$ -ty i  $(k+1)$ -szy działania algorytmu.

## Algorytm największego spadku

Algorytm największego spadku ogranicza się do dwóch pierwszych składników rozwinięcia w szereg Taylora. Aby zapewnić spadek wartości funkcji błędu w kolejnych krokach spełniony musi być warunek:

$$[\mathbf{g}(\mathbf{w}_k)]^T \mathbf{p}_k < 0 \quad (8.19)$$

a zatem wektor kierunkowy powinien być równy:

$$\mathbf{p}_k = -\mathbf{g}(\mathbf{w}_k) \quad (8.20)$$

Nieuwzględnienie trzeciego składnika rozwinięcia (hesjanu) powoduje niewykorzystanie informacji o krzywiznie funkcji celu, co sprawia, że metoda największego spadku jest wolnozbieżna. Ponadto metoda charakteryzuje się brakiem postępów optymalizacyjnych w okolicach punktu optymalnego, gdzie wartości gradientu osiągają bardzo małe wartości. Niewątpliwą zaletą metody jest jej prostota i mała złożoność obliczeniowa. Cechy te sprawiają, że stosowana jest raczej do dużych (wielowarstwowych) sieci, w których zastosowanie innych metod jest niemożliwe z uwagi na posiadaną moc obliczeniową.

Efektywność działania metody największego spadku można poprawić poprzez wprowadzenie modyfikacji polegającej na zastosowaniu tzw. uczenia z momentem. W zmodyfikowanym w ten sposób algorytmie aktualizacja wag odbywa się zgodnie z zależnością:

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \Delta \mathbf{w}_k \quad (8.21)$$

$$\Delta \mathbf{w}_k = \eta_k \mathbf{p}_k + \alpha (\mathbf{w}_k - \mathbf{w}_{k-1}) \quad (8.22)$$

gdzie:

$\alpha$  – współczynnik momentu (przyjmowany z zakresu  $[0,1]$ ).

Współczynnik momentu nie jest uzależniony od wartości gradientu, dzięki czemu w pobliżu minimum lokalnego, gdy zmiany gradientu są minimalne, może on prowadzić do przeniesienia aktualnego rozwiązania poza strefę przyciągania tego minimum. Stałe utrzymywanie dużej wartości współczynnika momentu prowadzi do niestabilności algorytmu uczenia, dlatego najczęściej współczynniki temu nadaje się duże wartości na początku i zmniejsza się je w miarę postępowania procesu uczenia.

## Algorytm zmiennej metryki

W algorytmie tym wykorzystuje się trzy pierwsze składniki rozwinięcia w szereg Taylora (8.9). Osiągnięcie minimum funkcji błędu w kroku  $k$  wymaga, aby spełniony był warunek:

$$\frac{\partial E(\mathbf{w}_k + \mathbf{p}_k)}{\partial \mathbf{p}_k} = 0 \quad (8.23)$$

który jest spełniony dla następującego kierunku:

$$\mathbf{p}_k = -[\mathbf{H}(\mathbf{w}_k)]^{-1} \mathbf{g}(\mathbf{w}_k) \quad (8.24)$$

Zatem w każdym kroku należy wyznaczyć wartość gradientu i hesjanu, co jest dość kłopotliwe. W metodzie zmiennej metryki rezygnuje się z dokładnego wyznaczenia hesjanu i zastępuje się go jego przybliżeniem  $\mathbf{G}(\mathbf{w}_k)$ , które powstaje poprzez dodanie pewnej poprawki na wartość tej macierzy z poprzedniego kroku. W praktyce modyfikuje się odwrotność przybliżonej macierzy hesjanu  $\mathbf{V}(\mathbf{w}_k)$  ( $\mathbf{V}(\mathbf{w}_k) = [\mathbf{G}(\mathbf{w}_k)]^{-1}$ ), dzięki czemu nie ma potrzeby dodatkowego odwracania tej macierzy w celu wyliczenia kierunku. Dwie najpopularniejsze formuły wyznaczania przyrostu to formuła Broydena-Fletcher-Goldfarba-Shanno (BFGS) oraz formuła Davidona-Fletcher-Powella (DFP), zgodnie z którymi przybliżona wartość macierzy odwrotnej hesjanu w  $k$ -tym kroku dana jest kolejno wzorami:

$$\mathbf{V}_k = \mathbf{V}_{k-1} + \left[ 1 + \frac{\mathbf{r}_k^T \mathbf{V}_{k-1} \mathbf{r}_k}{\mathbf{s}_k^T \mathbf{r}_k} \right] \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{r}_k} - \frac{\mathbf{s}_k \mathbf{r}_k^T \mathbf{V}_{k-1} + \mathbf{V}_{k-1} \mathbf{r}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{r}_k} \quad (8.25)$$

$$\mathbf{V}_k = \mathbf{V}_{k-1} + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{s}_k^T \mathbf{r}_k} - \frac{\mathbf{V}_{k-1} \mathbf{r}_k \mathbf{r}_k^T \mathbf{V}_{k-1}}{\mathbf{r}_k^T \mathbf{V}_{k-1} \mathbf{r}_k} \quad (8.26)$$

gdzie:

$\mathbf{s}_k$  – przyrost wektora wag ( $\mathbf{s}_k = \mathbf{w}_k - \mathbf{w}_{k-1}$ ),

$\mathbf{r}_k$  – przyrost wektora gradientu ( $\mathbf{r}_k = \mathbf{g}(\mathbf{w}_k) - \mathbf{g}(\mathbf{w}_{k-1})$ ).

Jako pierwszą wartość macierzy  $\mathbf{V}$  przyjmuje się macierz jednostkową, a kolejne wartości oblicza się już według zależności (8.25) i (8.26). Algorytm zmiennej metryki charakteryzuje się szybką zbieżnością (superliniową) i jest uważany za jedną z najlepszych technik optymalizacji funkcji wielu zmiennych. Jej największą wadą jest duża złożoność obliczeniowa oraz duża ilość potrzebnej pamięci, co sprawia, że jest stosowana w uczeniu sieci o niezbyt dużej ilości wag.

### Algorytm Levenberga-Marquardta

W algorytmie tym, podobnie jak w algorytmie zmiennej metryki, wykorzystuje się trzy pierwsze składniki rozwinięcia w szereg Taylora a macierz Hessego zastępuje się jej przybliżeniem  $\mathbf{G}(\mathbf{w})$ . Wektor gradientu przedstawiany jest jako:

$$\mathbf{g}(\mathbf{w}) = [\mathbf{J}(\mathbf{w})]^T \mathbf{e}(\mathbf{w}) \quad (8.27)$$

gdzie:

$\mathbf{J}(\mathbf{w})$  – macierz Jacobiego (jakobian),

$\mathbf{e}(\mathbf{w})$  – wektor błędów odpowiedzi.

Macierz Jacobiego dana jest wzorem:

$$\mathbf{J}(\mathbf{w}) = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \dots & \frac{\partial e_1}{\partial w_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial e_M}{\partial w_1} & \dots & \frac{\partial e_M}{\partial w_n} \end{bmatrix} \quad (8.28)$$

natomiast wektor błędów odpowiedzi:

$$\mathbf{e}(\mathbf{w}) = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_M \end{bmatrix} = \begin{bmatrix} y_1(\mathbf{w}) - d_1 \\ y_2(\mathbf{w}) - d_2 \\ \vdots \\ y_M(\mathbf{w}) - d_M \end{bmatrix} \quad (8.29)$$

Aproksymowana macierz hesjanu opisana jest zależnością:

$$\mathbf{G}(\mathbf{w}) = [\mathbf{J}(\mathbf{w})]^T \mathbf{J}(\mathbf{w}) + \mathbf{R}(\mathbf{w}) \quad (8.30)$$

w której macierz  $\mathbf{R}(\mathbf{w})$  odpowiada składnikom rozwinięcia hesjanu zawierającym wyższe pochodne względem wektora wag ( $\mathbf{w}$ ) i dana jest wzorem:

$$\mathbf{R}(\mathbf{w}) = v\mathbf{I} \quad (8.31)$$

gdzie:

$v$  – parametr Levenberga-Marquardta,

$\mathbf{I}$  – macierz jednostkowa.

Dla  $k$ -tego kroku działania algorytmu aproksymowana macierz hesjanu przyjmuje postać:

$$\mathbf{G}(\mathbf{w}_k) = [\mathbf{J}(\mathbf{w}_k)]^T \mathbf{J}(\mathbf{w}_k) + v_k \mathbf{I} \quad (8.32)$$

Na początku procesu uczenia, gdy aktualna wartości składowych wektora wag są dalekie od rozwiązania optymalnego, przyjmuje się dużą wartość parametru  $v_k$  w stosunku do największej wartości własnej macierzy  $[\mathbf{J}(\mathbf{w}_k)]^T \mathbf{J}(\mathbf{w}_k)$ . W takiej sytuacji hesjan jest reprezentowany przede wszystkim przez czynnik regularyzacyjny ( $\mathbf{G}(\mathbf{w}_k) \cong v_k \mathbf{I}$ ), a poszukiwanie kierunku odbywa się zgodnie z metodą największego spadku. W miarę zmniejszania się wartości składowych wektora błędu zmniejsza się również wartość parametru  $v_k$ , przez co pierwszy składnik aproksymowanego hesjanu zaczyna odgrywać coraz większą rolę. W pobliżu rozwiązania optymalnego wartość parametru Levenberga-Marquardta zmierza do zera.

### Algorytm gradientów sprzężonych

W algorytmie tym kierunek poszukiwań wybierany jest tak, aby był on ortogonalny i sprzężony ze wszystkimi poprzednimi kierunkami poszukiwań. Wektor kierunkowy, który spełnia te założenia ma postać:

$$\mathbf{p}_k = -\mathbf{g}(\mathbf{w}_k) + \beta_{k-1} \mathbf{p}_{k-1} \quad (8.33)$$

gdzie:

$\beta_{k-1}$  – współczynnik sprzężenia.

Zatem aktualny kierunek poszukiwań zależny jest tylko od wartości gradientu w aktualnym punkcie poszukiwań oraz od poprzedniego kierunku i współczynnika sprzężenia. Istnieje

wiele sposobów wyznaczania współczynnika  $\beta_{k-1}$ , z których dwie najbardziej znane to:

$$\beta_{k-1} = \frac{[\mathbf{g}(\mathbf{w}_k)]^T \mathbf{g}(\mathbf{w}_k) - \mathbf{g}(\mathbf{w}_{k-1})}{[\mathbf{g}(\mathbf{w}_{k-1})]^T (\mathbf{g}(\mathbf{w}_{k-1}))} \quad (8.34)$$

$$\beta_{k-1} = \frac{[\mathbf{g}(\mathbf{w}_k)]^T \mathbf{g}(\mathbf{w}_k) - \mathbf{g}(\mathbf{w}_{k-1})}{-\mathbf{p}_{k-1} \mathbf{g}(\mathbf{w}_{k-1})} \quad (8.35)$$

W obliczeniach numerycznych, po wykonaniu pewnej liczby cykli obliczeniowych metoda zatracą ortogonalność między wektorami kierunków (spowodowane jest to kumulacją błędów zaokrąglania w kolejnych cyklach) i powinna być uruchamiana od początku, startując z punktu będącego aktualnym rozwiązaniem w ostatnim cyklu poprzedniego uruchomienia, a kierunek minimalizacyjny powinien być określony zgodnie z algorytmem największego spadku. Metoda gradientów sprzężonych dzięki stosunkowo niewielkiej złożoności obliczeniowej stosowana jest głównie z problemami optymalizacyjnymi z dużą ilością zmiennych.

### Algorytm Quickprop

Algorytm ten zaliczany jest do grupy algorytmów heurystycznych, bazujących na metodach gradientowych. Zmiana wagi w  $k$ -tym kroku działania algorytmu dokonywana jest zgodnie z zależnością:

$$\Delta w_{ij}(k) = -\eta_k \left[ \frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}} + \gamma w_{ij}(k) \right] + \alpha_{ij}(k) \Delta w_{ij}(k-1) \quad (8.36)$$

gdzie:

- $-\eta_k$  - współczynnik uczenia,
- $\Delta w_{ij}(k), \Delta w_{ij}(k-1)$  - zmiana wagi w kroku  $k$ -tym,  $(k-1)$  - szym,
- $\gamma$  - czynnik redukujący wartości wag (zwykle  $\gamma = 10^{-4}$ ),
- $\alpha_{ij}(k)$  - współczynnik momentu w  $k$ -tym kroku.

Częściej stosowana jest uproszczona wersja algorytmu, której skuteczność porównywalna jest ze skutecznością wersji oryginalnej. W wersji tej wagi uaktualniane są według wzoru:

$$\Delta w_{ij}(k) = \begin{cases} \alpha_{ij}(k) \Delta w_{ij}(k-1), & \text{gdy } \Delta w_{ij}(k-1) \neq 0 \\ \eta_0 \frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}}, & \text{w przeciwnym przypadku} \end{cases} \quad (8.37)$$

gdzie:

- $-\eta_k$  - współczynnik uczenia o stałej wartości (zwykle z przedziału  $[0.01 \ 0.6]$ ).

Współczynnik momentu określany jest z zależności:

$$\alpha_{ij}(k) = \min \left\{ \frac{\frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}}}{\frac{\partial E(\mathbf{w}(k-1))}{\partial w_{ij}} - \frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}}}, \alpha_{max} \right\} \quad (8.38)$$

gdzie:

$\eta_0$  - współczynnik uczenia o stałej wartości (zwykle z przedziału [0.01 0.6]).

$\alpha_{\max}$  - maksymalna dopuszczalna wartość współczynnika momentu (np.  $\alpha_{\max} = 1.75$ )

Algorytm Quickprop znacznie przyspiesza proces uczenia i zapobiega utknięciu w płytkim minimum lokalnym wynikającym z punktu pracy neuronu w nasyceniu krzywej sigmoidalnej.

### Algorytm Rprop

Podobnie jak Quickprop, również i algorytm Rprop zaliczany jest do grupy algorytmów heurystycznych. Algorytm aktualizuje wagi w oparciu jedynie o znak składowej gradientu ignorując jej wartość. Zmiana wagi w k-tym kroku działania algorytmu opisana jest zależnością:

$$\Delta w_{ij}(k) = -\eta_{ij}(k) \operatorname{sgn}\left(\frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}}\right) \quad (8.39)$$

gdzie:

$\eta_{ij}(k)$  - współczynnik uczenia w k-tym kroku,

$\operatorname{sgn}\left(\frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}}\right)$  - znak gradientu.

Współczynnik uczenia dobierany jest adaptacyjnie zgodnie z zależnością:

$$\eta_{ij}(k) = \begin{cases} \min(a \eta_{ij}(k-1), \eta_{\max}) & \text{gdy } \frac{\partial E(\mathbf{w}(k-1))}{\partial w_{ij}} \cdot \frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}} > 0 \\ \max(b \eta_{ij}(k-1), \eta_{\min}) & \text{gdy } \frac{\partial E(\mathbf{w}(k-1))}{\partial w_{ij}} \cdot \frac{\partial E(\mathbf{w}(k))}{\partial w_{ij}} < 0 \\ \eta_{ij}(k-1), & \text{w przeciwnym przypadku} \end{cases} \quad (8.40)$$

gdzie:

$a, b$  - stałe,  $a = 1.2$ ,  $b = 50$ .

$\eta_{\min}$ ,  $\eta_{\max}$  - minimalna i maksymalna wartość współczynnika uczenia,  $\eta_{\min}=10^{-6}$ ,  $\eta_{\max}=50$ .

### Określanie współczynnika uczenia.

Podczas gdy kierunek poszukiwań powoduje zmierzanie aktualnego rozwiązania w kierunku minimum lokalnego funkcji błędu, współczynnik uczenia decyduje o szybkości, z jaką osiągnięcie minimum nastąpi. Wartość tego współczynnika zmienia się w każdym kroku działania algorytmu (stosowanie stałej wartości współczynnika uczenia jest bardzo nieefektywne i rzadko spotykane) i powinna być dobierana w odpowiedni sposób [78]. Zbyt mała wartość współczynnika uczenia powoduje niewykorzystanie możliwości zminimalizowania funkcji celu w danym kroku i konieczność jego powtórzenia w kroku następnym. Natomiast zbyt duża jego wartość powoduje „przeskoczenie” minimum i konieczność zmiany kierunku na przeciwny w następnym kroku. Może to prowadzić do oscylacji aktualnego rozwiązania wokół wartości minimalnej. Dobór współczynnika uczenia

odbywa się na ogół oddzielnie dla każdej z warstw sieci. Istnieje wiele metod wyznaczania wartości współczynnika  $\eta$ . Jedną z najprostszych metod jest szacowanie wartości współczynnika błędu zgodnie z zależnością:

$$\eta \leq \min\left(\frac{1}{n_i}\right) \quad (8.41)$$

gdzie:

$n_i$  – liczba wejść  $i$ -tego neuronu w warstwie.

Bardziej skuteczną metodą jest adaptacyjna zmiana wartości współczynnika uczenia uzależniona od aktualnych zmian wartości funkcji celu w trakcie uczenia. W metodzie tej zwiększa się wartość współczynnika  $\eta$  sprawdzając jednocześnie, czy błąd średniokwadratowy (pierwiastek sumy kwadratów różnic odpowiedzi sieci i oczekiwanej odpowiedzi) nie rośnie w stosunku do błędu przy poprzedniej wartości  $\eta$ . Przy aktualizacji współczynnika błędu korzysta się z następujących zależności:

$$\varepsilon_i > k_w \varepsilon_{i-1} \Rightarrow \eta_{i+1} = \eta_i \rho_d \quad (8.42)$$

$$\varepsilon_i \leq k_w \varepsilon_{i-1} \Rightarrow \eta_{i+1} = \eta_i \rho_i \quad (8.43)$$

gdzie:

$\varepsilon_i, \varepsilon_{i-1}$  – błąd średniokwadratowy w  $i$ -tym oraz  $i-1$  kroku,

$k_w$  – dopuszczalny współczynnik wzrostu błędu,

$\rho_d, \rho_i$  – współczynniki odpowiedni zmniejszania oraz zwiększania  $\eta$ .

Najefektywniejszym sposobem doboru współczynnika uczenia jest minimalizacja funkcji celu na wyznaczonym kierunku  $\mathbf{p}_k$ . Funkcję celu wzdłuż danego kierunku względem zmiennej  $\eta$  aproksymuje się wielomianem trzeciego stopnia:

$$W(\eta) = a_3 \eta^3 + a_2 \eta^2 + a_1 \eta + a_0 \quad (8.44)$$


Współczynniki wielomianu wyznacza się korzystając z informacji o wartości funkcji oraz jej pochodnej w dwóch punktach. Poszukiwaną wartość współczynnika uczenia wyznacza się przyrównując do zera pochodną wielomianu i posiada ona postać:

$$\eta_{min} = \frac{-a_2 + \sqrt{a_2^2 - 3a_3 a_1}}{3a_3} \quad (8.45)$$

#### 8.1.4. Optymalizacja struktury sieci za pomocą algorytmu genetycznego

Algorytmy genetyczne mogą zostać wykorzystane do określania architektury sieci, a nawet, jako algorytm uczący, do określania jej wag. Przebieg działania algorytmu wygląda podobnie jak opisany we wcześniejszym rozdziale, a zasadniczą różnicą jest sposób kodowania chromosomów oraz postać funkcji celu. Sposoby kodowania można podzielić na bezpośrednie oraz pośrednie.

W kodowaniu bezpośrednim koduje się pełną informację o architekturze sieci tak, że każdy neuron i każde połączenie znajduje swoje odzwierciedlenie w genach chromosomu [19],[87]. W przypadku kodowania bezpośredniego bazującego na połączeniach chromosom jest ciągiem wartości wag lub informacji o występowaniu połączeń. Do określenia struktury sieci stosuje się najczęściej macierz połączeń, w której każdy wiersz oraz każda kolumna reprezentują pojedynczy neuron w sieci, a elementy macierzy informują o istnieniu bądź braku połączenia. Element znajdujący się na przecięciu i-tego wiersza i j-tej kolumny macierzy stanowi informacje na temat połączenia pomiędzy neuronem i-tym i neuronem j-tym. Wartość jeden oznacza istnienie połączenia a zero jego brak. W przypadku sieci jednokierunkowych macierz połączeń jest macierzą górnortrójkątną, z zerami na głównej przekątnej. Chromosom tworzy się poprzez przepisanie macierzy wiersz po wierszu (lub rzadziej kolumna po kolumnie). Jeśli dodatkowo koduje się wartości wag, to po każdym bicie chromosomu informującym o połączeniu następuje kilka bitów stanowiących zakodowaną wartość wagi tego połączenia. W przypadku, gdy bit informujący o połączeniu ma wartość zero, to dana waga nie jest brana pod uwagę. Można również wprost zastąpić bity informujące o połączeniach ciągami bitów z zakodowanymi wagami i wówczas połączenie istnieje, gdy odpowiadająca mu waga posiada niezerową wartość. Sposób określania macierzy połączeń oraz chromosomu (bez wag) dla przykładowej sieci został przedstawiony na rysunku 8.4.



**Rys. 8.4.** Sposób tworzenia macierzy połączeń oraz chromosomu

W przypadku sieci rekurencyjnych kodować można również ścieżki prowadzące od wejść do wyjść poszczególnych neuronów. Bezpośredni sposób kodowania jest efektywny w przypadku sieci o niewielkiej liczbie neuronów, natomiast w przypadku sieci o większych rozmiarach chromosomy osiągną znaczną długość, co znacznie spowalnia działanie algorytmu genetycznego.

W metodach kodowania pośredniego [75], w których koduje się nie połączenia a parametry

sieci, takie jak liczba warstw ukrytych, liczba neuronów w tych warstwach, funkcje aktywacji neuronów, itp. Kodować można nie tylko strukturę sieci, ale również parametry procesu uczenia, jak np. rodzaj algorytmu uczącego, współczynnik uczenia, wartość momentu (w algorytmach z momentem), zakładaną dokładność, maksymalną liczbę iteracji. Schemat kodowania pośredniego ma uzasadnienie biologiczne, gdyż zgodnie z odkryciami neurologii nie jest możliwe, aby informacja genetyczna zakodowana w chromosomach określała w sposób bezpośredni cały układ nerwowy organizmu (choćby z uwagi na fakt, że liczba genów w genotypie jest znacznie mniejsza niż liczba neuronów w mózgu) [19].

Funkcja celu powinna uwzględniać błąd odpowiedzi sieci (minimalizować go) oraz jej złożoność (liczbę warstw, neuronów i połączeń).

## **8.2. Budowa klasyfikatora neuronowego do diagnostyki maszyny synchronicznej**


W badaniach zastosowano sieć MLP o jednej warstwie ukrytej. Warstwa wejściowa sieci zawierała tyle neuronów ukrytych ile częstotliwości było brane pod uwagę w konkretnym zadaniu klasyfikacyjnym. Badano klasyfikatory neuronowe przystosowane do rozpoznawania jednego typu uszkodzenia (zwarcia grupy zezwojów twornika, przerwy gałęzi równoległej twornika, zwarcia cewki obwodu wzbudzenia, przerwy cewki obwodu wzbudzenia) stosując wektory wejściowe dwu-, trzy- i czterocechowe, jak również klasyfikator, który miał za zadanie rozpoznawać każdy ze stanów awaryjnych. Dlatego też w poszczególnych klasyfikatorach neuronowych liczba neuronów w warstwie wejściowej wynosiła: 2, 3, 4 lub 7. Liczba neuronów w warstwie wyjściowej wynosiła 1 dla problemów dwuklasowych dotyczących jednego uszkodzenia. W przypadku barku uszkodzenia odpowiedź sieci powinna wynosić 0, a po jego wystąpieniu 1. W przypadku problemu pięcioklasowego zastosowano sieć o pięciu neuronach w warstwie wyjściowej. Odpowiedź sieci dla stanu bezawaryjnego miała wynosić  $[a1\ 0\ 0\ 0\ 0]$ , dla zwarcia grupy zezwojów twornika  $[0\ 1\ 0\ 0\ 0]$ , dla przerwy gałęzi równoległej twornika  $[0\ 0\ 1\ 0\ 0]$ , dla zwarcia cewki obwodu wzbudzenia  $[0\ 0\ 0\ 1\ 0]$ , a dla przerwy cewki obwodu wzbudzenia  $[0\ 0\ 0\ 0\ 1]$ . Liczba neuronów w warstwie ukrytej nie była z góry ustalona i optymalizowana była z wykorzystaniem algorytmu genetycznego, przy czym przyjęto, że maksymalnie mogła ona wynosić 32. Algorytm uczenia sieci również nie był z góry ustalony i wybierany był za pomocą algorytmu genetycznego.

Do określenia parametrów sieci wykorzystano algorytm genetyczny, który poszukiwał sieci generującej możliwie najmniejszy błąd odpowiedzi na zbiór testowy. Dla każdego chromosomu w populacji generowana była osobna sieć na której przeprowadzany był trening i walidacja. Do generacji i testowania sieci wykorzystano pakiet Neural Network Toolbox programu Matlab [44].

Ponieważ w procesie selekcji cech najbardziej efektywnym algorytmem genetycznym okazał

się algorytm z turniejową selekcją cech, a jego wyższość w innych problemach optymalizacyjnych podkreślana jest także w literaturze, został on wykorzystany w problemie doboru architektury i parametrów sieci do rozpoznawania uszkodzeń w maszynie synchronicznej.

Sposób kodowania chromosomów przedstawiony został na rysunku 8.5.



**Rys. 8.5.** Sposób kodowania chromosomów

Pięć pierwszych genów w chromosomie służyło do zakodowania liczby neuronów w warstwie ukrytej. Ponieważ nie rozpatrywano sieci o zerowej liczbie neuronów ukrytych liczba ta dekodowana była według zależności:

$$n = (ch_i(1:5))_{10} + 1 \quad (8.46)$$

gdzie:

$(ch_i(1:5))_{10}$  – dziesiętna reprezentacja genów 1 do 5 i-tego chromosomu.


Daje to liczbę neuronów z przedziału  $1 \div 32$ .

Kolejne trzy geny odpowiadały za zakodowanie metody trenowania sieci. Możliwa przy takiej ilości genów liczba metod wynosi 8. Wzięto pod uwagę następujące metody:

- Levenberga-Marquardta,
- największego spadku,
- największego spadku z momentem,
- największego spadku z adaptacyjnym współczynnikiem uczenia,
- gradientów sprzężonych,
- BFGS,
- Quickprop,
- Rprop,

Geny na pozycjach 9-14 służyły do zakodowania funkcji transferu neuronów w warstwach odpowiednio wejściowej (neurony 9 i 10), ukrytej (neurony 11 i 12) i wyjściowej (neurony 13 i 14). Zastosowanie dwóch neuronów daje możliwość zakodowania czterech różnych funkcji. Rozważane były następujące funkcje:

- sigmoidalna unipolarna (rysunek 8.2),
- sigmoidalna bipolarna (rysunek 8.2),
- unipolarna funkcja liniowa z nasyceniem (rysunek 8.6a),
- bipolarna funkcja liniowa z nasyceniem (rysunek 8.6b).



**Rys. 8.6.** Wykres funkcji liniowej z nasyceniem

Jako kryterium jakości poszczególnych sieci przyjęto średniokwadratowy błąd odpowiedzi sieci, wyrażony wzorem:

$$MSE = \frac{1}{p} \sum_{j=1}^p \frac{1}{M} \sum_{k=1}^M (y_k - d_k)^2 \quad (8.47)$$

gdzie:

$p$  – liczba przypadków w zbiorze testującym,

$M$  – liczba wyjść sieci,

$y_k$  –  $k$ -ty element wektora odpowiedzi sieci na wektor wejściowy,

$d_k$  –  $k$ -ty element zadanego wektora odpowiedzi sieci.

Funkcja przystosowania powinna preferować architektury sieci generujące jak najmniejszy błąd średniokwadratowy odpowiedzi sieci na zbiór testujący oraz o niskiej ilości neuronów w warstwie ukrytej. Na podstawie analizy błędów generowanych przez sieci o różnych liczbach neuronów warstwie ukrytej wyznaczony (empirycznie) został następujący wzór:

$$fitness = \sqrt[3]{\frac{n_{max}-n+1}{n}} \left( \ln \frac{1}{MSE} \right)^3 \quad (8.48)$$

gdzie:

$n$  – liczba neuronów w warstwie ukrytej,

$n_{max}$  – dopuszczalna liczba neuronów w warstwie ukrytej,

$MSE$  – błąd średniokwadratowy odpowiedzi sieci na zbiór testujący.

### **8.3. Wyniki klasyfikacji neuronowej**

Dla wszystkich przypadków, w których występowała liniowa separowalność punktów odpowiadających stanowi bezawaryjnemu i uszkodzonemu, do klasyfikacji wystarczyły sieci o jednym neuronie w warstwie ukrytej. Dotyczyło to rozpoznawania obu przypadków uszkodzeń w tworniku zarówno na podstawie składowych prądu twornika jak i wzbudzenia. Średniokwadratowy błąd odpowiedzi sieci, po przeprowadzeniu trenowania, wynosił dla wszystkich tych przypadków 0 i optymalizacja była bezcelowa. Podobnie sytuacja wyglądała w przypadku detekcji zwarcia oraz przerwy cewki obwodu wzbudzenia na podstawie zestawu składowych prądu wzbudzenia zawierających 0Hz i 25Hz. Jednak jak już wcześniej zostało wspomniane obie te składowe mogą służyć jedynie jako wskaźniki mogące świadczyć o podejrzeniu wystąpienia uszkodzenia i nie powinny być traktowane jako symptomy.

Dla kolejnych czterech analizowanych przypadków, tj. wykrywania zwarcia oraz przerwy cewki obwodu wzbudzenia na podstawie prądu twornika, a także detekcji obu tych uszkodzeń na podstawie prądu wzbudzenia z usuniętymi składowymi: 0Hz oraz 25Hz, w których to przypadkach nie było liniowej separowalności, sieci o jednym neuronie w warstwie ukrytej nie funkcjonowały dostatecznie dobrze i istniała potrzeba zastosowania sieci o większej liczbie neuronów oraz optymalizacji ich struktury.

Zbudowano i zoptymalizowano również klasyfikator do rozpoznawania wszystkich uszkodzeń na podstawie składników widma prądu wzbudzenia, które były charakterystyczne dla poszczególnych uszkodzeń.

#### **8.3.1. Wyniki klasyfikacji dla zwarcia w grupie zezwojów twornika**

Zarówno dla klasyfikacji na podstawie prądu twornika, jak i prądu wzbudzenia skuteczność rozpoznawania na poziomie 100% zapewniała sieć o jednym neuronie w warstwie ukrytej. Nie było potrzeby przeprowadzania procedury optymalizacyjnej.

#### **8.3.2. Wyniki klasyfikacji dla przerwy jednej gałęzi równoległej twornika**

Zarówno dla klasyfikacji na podstawie prądu twornika, jak i prądu wzbudzenia skuteczność rozpoznawania na poziomie 100% zapewniała sieć o jednym neuronie w warstwie ukrytej. Nie było potrzeby przeprowadzania procedury optymalizacyjnej.


### 8.3.3. Wyniki klasyfikacji dla zwarcia cewki obwodu wzbudzenia

#### Wyniki klasyfikacji na podstawie widma prądu twornika.

Dla tego przypadku klasyfikacyjnego zastosowana została sieć o czterech neuronach w warstwie wejściowej, na które podawane były amplitudy następujących składowych prądu twornika: 25Hz, 50Hz, 75Hz i 150Hz. Wyniki klasyfikacji oraz procesu optymalizacji klasyfikatora zestawiono w tabeli 8.1, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 8.7.

**Tabela 8.1.** Wyniki optymalizacji parametrów klasyfikatora neuronowego do diagnostyki zwarcia cewki obwodu wzbudzenia na podstawie widma prądu twornika

| Parametr                                            | Wartość                         |
|-----------------------------------------------------|---------------------------------|
| liczba neuronów w warstwie ukrytej                  | 3                               |
| metoda treningowa                                   | Rprop                           |
| funkcje aktywacji warstwy wejściowej                | unipolarna liniowa z nasyceniem |
| funkcje aktywacji warstwy ukrytej                   | sigmoidalna bipolarna           |
| funkcje aktywacji warstwy wyjściowej                | unipolarna liniowa z nasyceniem |
| średniokwadratowy błąd odpowiedzi                   | 0.1762                          |
| wartość funkcji przystosowania najlepszego osobnika | 132.9085                        |




**Rys. 8.7.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

## Wyniki klasyfikacji na podstawie widma prądu wzbudzenia.

W przypadku uwzględnienia pełnego widma skuteczność rozpoznawania na poziomie 100% zapewniała sieć o jednym neuronie w warstwie ukrytej i nie było potrzeby przeprowadzania procedury optymalizacyjnej. Po wycięciu składowych 0Hz i 25Hz najlepszym zestawem składowych były częstotliwości: 75Hz, 100Hz i 200Hz (dla których odległość Mahalanobisa była jednak niska i wynosiła 1,5). Dla tych składowych został zbudowany i zoptymalizowany klasyfikator o trzech wejściach. Wyniki klasyfikacji oraz procesu optymalizacji klasyfikatora zestawiono w tabeli 8.2, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 8.8.

**Tabela 8.2.** Wyniki optymalizacji parametrów klasyfikatora neuronowego do diagnostyki zwarcia cewki obwodu wzbudzenia na podstawie widma prądu wzbudzenia

| Parametr                                            | Wartość                         |
|-----------------------------------------------------|---------------------------------|
| liczba neuronów w warstwie ukrytej                  | 2                               |
| metoda treningowa                                   | Levenberga-Marquardta           |
| funkcje aktywacji warstwy wejściowej                | sigmoidalna bipolarna           |
| funkcje aktywacji warstwy ukrytej                   | sigmoidalna bipolarna           |
| funkcje aktywacji warstwy wyjściowej                | unipolarna liniowa z nasyceniem |
| średniokwadratowy błąd odpowiedzi                   | 0.1267                          |
| wartość funkcji przystosowania najlepszego osobnika | 224.0241                        |



**Rys. 8.8.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu


### 8.3.4. Wyniki klasyfikacji dla przerwy cewki obwodu wzbudzenia

#### Wyniki klasyfikacji na podstawie widma prądu twornika.

Dla tego przypadku klasyfikacyjnego zastosowana została sieć o czterech neuronach w warstwie wejściowej, na które podawane były amplitudy następujących składowych prądu twornika: 25Hz, 100Hz, 125Hz i 950Hz. Wyniki klasyfikacji oraz procesu optymalizacji klasyfikatora zestawiono w tabeli 8.3, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 8.9.

**Tabela 8.3.** Wyniki optymalizacji parametrów klasyfikatora neuronowego do diagnostyki przerwy cewki obwodu wzbudzenia na podstawie widma prądu twornika

| Parametr                                            | Wartość                         |
|-----------------------------------------------------|---------------------------------|
| liczba neuronów w warstwie ukrytej                  | 2                               |
| metoda treningowa                                   | Levenberga-Marquardta           |
| funkcje aktywacji warstwy wejściowej                | sigmoidalna bipolarna           |
| funkcje aktywacji warstwy ukrytej                   | unipolarna liniowa z nasyceniem |
| funkcje aktywacji warstwy wyjściowej                | sigmoidalna unipolarna          |
| średniokwadratowy błąd odpowiedzi                   | 0.039944                        |
| wartość funkcji przystosowania najlepszego osobnika | 848.1779                        |




**Rys. 8.9.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

## Wyniki klasyfikacji na podstawie widma prądu wzbudzenia.

W przypadku uwzględnienia pełnego widma skuteczność rozpoznawania na poziomie 100% zapewniała sieć o jednym neuronie w warstwie ukrytej i nie było potrzeby przeprowadzania procedury optymalizacyjnej. Po wycięciu składowych 0Hz i 25Hz najlepszym zestawem składowych były częstotliwości: 50Hz, 175Hz i 250Hz. Dla tych składowych został zbudowany i zoptymalizowany klasyfikator o trzech wejściach. Wyniki klasyfikacji oraz procesu optymalizacji klasyfikatora zestawiono w tabeli 8.4. Przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 8.10.

**Tabela 8.4.** Wyniki optymalizacji parametrów klasyfikatora neuronowego do diagnostyki przerwy cewki obwodu wzbudzenia na podstawie widma prądu wzbudzenia

| Parametr                                            | Wartość                         |
|-----------------------------------------------------|---------------------------------|
| liczba neuronów w warstwie ukrytej                  | 2                               |
| metoda treningowa                                   | gradientów sprzężonych          |
| funkcje aktywacji warstwy wejściowej                | sigmoidalna bipolarna           |
| funkcje aktywacji warstwy ukrytej                   | unipolarna liniowa z nasyceniem |
| funkcje aktywacji warstwy wyjściowej                | sigmoidalna unipolarna          |
| średniokwadratowy błąd odpowiedzi                   | 0.18731                         |
| wartość funkcji przystosowania najlepszego osobnika | 119.3562                        |




**Rys. 8.10.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

### 8.3.5. Wyniki klasyfikacji dla wszystkich badanych uszkodzeń

Na podstawie wyników selekcji na podstawie prądu wzbudzenia wytypowane zostały składowe widma, które dawały największe odległości Mahalanobisa dla poszczególnych uszkodzeń. Wybrane zostały następujące składowe: 0Hz, 25Hz, 50Hz, 100Hz, 150Hz, 200Hz i 600Hz. Dla powyższych składowych utworzony został klasyfikator neuronowy o siedmiu wejściach oraz pięciu wyjściach, które odpowiadały poszczególnym stanom awaryjnym oraz stanowi bezawaryjnemu. Dla tak zbudowanego klasyfikatora przeprowadzono optymalizację struktury, której wyniki zestawiono w tabeli 8.5. Przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 8.11. Klasyfikator bezbłędnie radził sobie z wykrywaniem uszkodzeń w uzwojeniach twornika, natomiast popełniał błędy w przypadku rozpoznawania uszkodzeń w obwodzie wzbudzenia. Należy przy tym zaznaczyć, że składowe 0Hz i 25Hz nie mogą być w pełni uznane za miarodajne i stwierdzenie wystąpienia uszkodzenia w obwodzie wzbudzenia przez klasyfikator nie zawsze musi świadczyć o tym, że rzeczywiście takie uszkodzenie miało miejsce.

**Tabela 8.5.** Wyniki optymalizacji parametrów klasyfikatora neuronowego do diagnostyki przerwy cewki obwodu wzbudzenia na podstawie widma prądu wzbudzenia

| Parametr                                            | Wartość                |
|-----------------------------------------------------|------------------------|
| liczba neuronów w warstwie ukrytej                  | 3                      |
| metoda treningowa                                   | Levenberga-Marquardta  |
| funkcje aktywacji warstwy wejściowej                | sigmoidalna unipolarna |
| funkcje aktywacji warstwy ukrytej                   | sigmoidalna bipolarna  |
| funkcje aktywacji warstwy wyjściowej                | sigmoidalna unipolarna |
| średniokwadratowy błąd odpowiedzi                   | 0.11445                |
| wartość funkcji przystosowania najlepszego osobnika | 258.664                |



**Rys. 8.11.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

## 9. ROZMYTY KLASYFIKATOR STANU MASZYN

### 9.1. Wiadomości wstępne

Teoria zbiorów rozmytych została opracowana w 1965 roku przez L. Zadeha jako uogólnienie klasycznej teorii zbiorów [60], [65], [103], [104], [105]. W 1973 roku ten sam naukowiec stworzył podstawy logiki operującej na zbiorach rozmytych – tzw. logiki rozmytej, która następnie rozwijana była przez wiele ośrodków naukowych. Ze względu na swój olbrzymi potencjał, szybko znalazła zastosowanie w wielu dziedzinach nauki i techniki, w szczególności w modelowaniu obiektów, sterowaniu, diagnostyce, prognozowaniu. Zaletą modeli rozmytych jest to, że funkcjonują one prawidłowo nawet w przypadku niepełnej wiedzy o modelowanym problemie.

#### 9.1.1. Zbiory rozmyte i logika rozmyta

Zbiorem rozmytym  $A$  w pewnej niepustej przestrzeni  $X$  (uniwersum) jest zbiór par [87]:

$$A = \{(x, \mu_A(x)); x \in X\} \quad (9.1)$$

gdzie:

$x$  – element przestrzeni rozważań  $X$ ,


$\mu_A: X \rightarrow [0,1]$  – funkcja przynależności,

$\mu_A(x) \in [0,1]$  – stopień przynależności elementu  $x$  do zbioru rozmytego  $A$ .

W klasycznej teorii zbiorów funkcja przynależności może osiągać tylko dwie wartości: 1 – gdy element należy do zbioru oraz 0 – gdy element do zbioru nie należy, a więc jest odwzorowaniem przestrzeni na zbiór dwuelementowy  $X \rightarrow \{0,1\}$ . W zbiorach rozmytych oprócz pełnej przynależności lub jej braku dopuszcza się również częściową przynależność do zbioru (gdy  $\mu_A(x) \in (0,1)$ ).

Wprowadzenie częściowej przynależności rozszerzyło stosowalność teorii zbiorów na problemy, w których nie da się jednoznacznie zakwalifikować elementu do konkretnego zbioru nierozmytego. W szczególności dotyczy to sytuacji, gdy element jest opisywany przy pomocy zmiennych lingwistycznych (np. duży, szybki, tani, bardzo ładna), lub jego przynależność do konkretnego zbioru określana jest na podstawie subiektywnej oceny. Dany element może przynależeć (w stopniu niezerowym) do pewnego zbioru i jednocześnie do jego dopełnienia, co dla zbiorów klasycznych jest niemożliwe do spełnienia. Na ogół dana

zmienna przynależy naraz do kilku zbiorów, co zostało zilustrowane na rysunku 9.1 przedstawiającym funkcje przynależności zmiennej wzrost do pięciu zbiorów rozmytych. Np. osoba o wzroście 185cm według subiektywnych ocen może być zaliczona jednocześnie do trzech różnych zbiorów osób: średniego wzrostu, wysokich oraz bardzo wysokich.



**Rys. 9.1.** Przykładowe funkcje przynależności do pięciu zbiorów rozmytych

Funkcje przynależności mogą przybierać różne kształty, z których najpopularniejsze to trójkątny, trapezoidalny, sigmoidalny, gaussowski.

Rozróżnia się dwa rodzaje zbiorów rozmytych: zbiory rozmyte typu pierwszego, w których stopnie przynależności są liczbami, oraz zbiory rozmyte typu drugiego, w których stopnie przynależności są również rozmyte [86], [87].

Zmienna rozmyta (lub tzw. rozmyta zmienna lingwistyczna) jest czwórką danych [7]:

$$\{X, L, \chi, M_X\} \quad (9.2)$$

gdzie:

$X$  – nazwa zmiennej (np. wzrost),


$L$  – zbiór etykiet zmiennej  $X$  (np.  $\{\text{bardzo niski}, \text{niski}, \text{średni}, \text{wysoki}, \text{bardzo wysoki}\}$ ),

$\chi$  – podprzestrzeń uniwersum, na której zdefiniowana jest zmienna  $L$  (np.  $[140, 230]$ ),

$M_X$  – funkcja semantyczna przyporządkowująca etykietom zmiennej wartości funkcji przynależności.

### 9.1.2. Model wnioskowania rozmytego Mamdaniego-Zadeha


Model wnioskowania rozmytego Mamdaniego-Zadeha składa się z trzech zasadniczych bloków: fuzyfikacji, inferencji oraz defuzyfikacji, z których każdy pełni odpowiednie funkcje [81]. Schemat blokowy typowego modelu Mamdaniego-Zadeha przedstawiony został na rysunku 9.2.



**Rys. 9.2.** Model wnioskowania rozmytego Mamdaniego-Zadeha

## Fuzyfikacja

W bloku fuzyfikacja przeprowadzana jest operacja rozmywania, czyli obliczania stopnia przynależności każdego z wejść do poszczególnych zbiorów rozmytych odpowiadających tym wejściom. Odbywa się to poprzez wyznaczenie wartości funkcji przynależności w punktach będących chwilowymi wartościami sygnałów wejściowych. Sposób określania wartości funkcji przynależności do poszczególnych zbiorów rozmytych został zilustrowany na rysunku 10.3. Takie postępowanie należy przeprowadzić dla wszystkich wejść systemu.



**Rys. 9.3.** Sposób określania wartości stopnia przynależności wejścia do zbiorów rozmytych

Poszczególne wejścia mogą mieć różne liczby odpowiadających im funkcji przynależności, ale może też się zdarzyć, że każdemu z wejść odpowiada ta sama liczba zbiorów rozmytych. Jeśli system posiada  $n$  wejść, z których każdemu odpowiada  $m$  zbiorów rozmytych, wówczas istnieje  $m^n$  funkcji przynależności. Zatem całkowita liczba funkcji przynależności (a co za tym idzie liczba reguł wnioskowania i złożoność modelu) rośnie wykładniczo wraz ze wzrostem liczby wejść (tzw. eksplozja kombinatoryczna). Dlatego też korzystnie jest tworzyć modele rozmyte o możliwie jak najmniejszej liczbie wejść i jak najmniejszej liczbie zbiorów rozmytych odpowiadających tym wejściom, co niestety odbija się na dokładności modelu.

## Inferencja

Blok inferencja na podstawie wejściowych stopni przynależności oblicza wynikową funkcję przynależności wyjścia modelu. Obliczanie tej funkcji odbywa się poprzez wnioskowanie na podstawie tzw. bazy reguł. Baza reguł zawiera reguły logiczne określające zależności przyczynowo-skutkowe pomiędzy zbiorami rozmytymi wejść i wyjść systemu.

Każda z reguł składa się z przesłanki oraz z konkluzji, w związku z czym można ją zapisać:

$$JEŚLI \text{ przesłanka } TO \text{ konkluzja}$$

Przesłanka jest przesłanką prostą, gdy ma postać:

$$x_i = A_{ji} \quad (9.3)$$

gdzie:

$x_i$  –  $i$ -te wejście systemu rozmytego,  
 $A_{ji}$  –  $j$ -ty zbiór rozmyty  $i$ -tego wejścia.

Najczęściej jednak występują przesłanki złożone, zbudowane z przesłanek prostych przy użyciu operatorów  $I$ . W tym przypadku każda z reguł przyjmuje następującą postać:

$$R_i: JEŚLI (x_1 = A_{1i}) I (x_2 = A_{2i}) I \dots I (x_n = A_{ni}) TO (y = B_i) \quad (9.4)$$

gdzie:

$x_1, x_2, \dots, x_n$  – wejścia systemu rozmytego,  
 $A_{1i}, A_{2i}, \dots, A_{ni}$  –  $i$ -te zbiory rozmyte  $(1, 2, \dots, n)$ -ego wejścia,  
 $y$  – wyjście systemu rozmytego,  
 $B_i$  –  $i$ -ty zbiór rozmyty wyjścia.

Jeśli dwie lub więcej przesłanek prostych zawiera tę samą konkluzję, to przesłanki takie można połączyć w jedną przesłankę złożoną przy użyciu operatora  $LUB$ .

Dla każdej z reguł należy określić stopień spełnienia jej przesłanek  $h$ . W przypadku przesłanek prostych stopniem spełnienia przesłanki jest jej stopień przynależności. W przypadku przesłanek złożonych z kilku przesłanek prostych stopień spełnienia przesłanki wyznacza się w następujący sposób:

- dla koniunkcji przesłanek prostych  $(x_1 = A_{11}) I (x_2 = A_{21})$ :

$$h(x_1^*, x_2^*) = \mu_{A_{11} \cap A_{21}}(x_1^*, x_2^*) = T(\mu_{A_{11}}(x_1^*), \mu_{A_{21}}(x_2^*)) \quad (9.5)$$

- dla dysjunkcji przesłanek prostych  $(x_1 = A_{11}) LUB (x_2 = A_{21})$ :

$$h(x_1^*, x_2^*) = \mu_{A_{11} \cup A_{21}}(x_1^*, x_2^*) = S(\mu_{A_{11}}(x_1^*), \mu_{A_{21}}(x_2^*)) \quad (9.6)$$

gdzie:

$x_1^*, x_2^*$  – chwilowe wartości wejść systemu rozmytego,  
 $T(\ )$  – operator T-normy,  
 $S(\ )$  – operator S-normy.

Gdy przesłanka jest złożona z większej liczby przesłanek prostych połączonych przez operatory  $I / LUB$  operatory T-normy / S-normy stosuje się wielokrotnie.

Jeśli przesłanka jest złożona z przesłanek prostych połączonych zarówno spójnikiem logicznym  $I$  jak i spójnikiem  $LUB$  (przesłanka koniunkcyjno-dysjunkcyjna) najpierw wykonuje się operacje przecięcia zbiorów  $I$  (z wykorzystaniem operatora T-normy), a następnie operacje połączenia zbiorów  $LUB$  (z wykorzystaniem operatora S-normy).

Do najczęściej stosowanych operatorów T-normy należą:

Minimum (MIN):

$$\mu_{A \cap B}(x) = MIN(\mu_A(x), \mu_B(x)) \quad (9.7)$$

Iloczyn (PROD):

$$\mu_{A \cap B}(x) = \mu_A(x) \cdot \mu_B(x) \quad (9.8)$$

Iloczyn Hamachera:

$$\mu_{A \cap B}(x) = \frac{\mu_A(x) \cdot \mu_B(x)}{\mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x)} \quad (9.9)$$

Iloczyn Einsteina:

$$\mu_{A \cap B}(x) = \frac{\mu_A(x) \cdot \mu_B(x)}{2 - (\mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x))} \quad (9.10)$$

Iloczyn drastyczny:

$$\mu_{A \cap B}(x) = \begin{cases} MIN(\mu_A(x), \mu_B(x)) & \text{dla } MAX(\mu_A(x), \mu_B(x)) = 1 \\ 0 & \text{w przeciwnym przypadku} \end{cases} \quad (9.11)$$

Ograniczona różnica:

$$\mu_{A \cap B}(x) = MAX(0, \mu_A(x) + \mu_B(x) - 1) \quad (9.12)$$

soft MIN:

$$\mu_{A \cap B}(x) = \frac{\mu_A(x) + \mu_B(x) + \delta^2 - \sqrt{(\mu_A(x) - \mu_B(x))^2 + \delta^2}}{2} \quad (9.13)$$

gdzie:

$\delta$  – współczynnik zmiękczenia o wartości dodatniej bliskiej zero (np. 0,05).

Do najczęściej stosowanych operatorów S-normy należą:

Maksimum (MAX):

$$\mu_{A \cup B}(x) = MAX(\mu_A(x), \mu_B(x)) \quad (9.14)$$

Suma algebraiczna:

$$\mu_{A \cup B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x) \quad (9.15)$$

Suma Hamachera:

$$\mu_{A \cup B}(x) = \frac{\mu_A(x) + \mu_B(x) - 2\mu_A(x) \cdot \mu_B(x)}{1 - \mu_A(x) \cdot \mu_B(x)} \quad (9.16)$$

Suma Einsteina:

$$\mu_{A \cup B}(x) = \frac{\mu_A(x) + \mu_B(x)}{1 + \mu_A(x) \cdot \mu_B(x)} \quad (9.17)$$

Suma drastyczna:

$$\mu_{A \cap B}(x) = \begin{cases} \max(\mu_A(x), \mu_B(x)) & \text{dla } \min(\mu_A(x), \mu_B(x)) = 0 \\ 1 & \text{w przeciwnym przypadku} \end{cases} \quad (9.18)$$

Suma ograniczona:

$$\mu_{A \cap B}(x) = \min(1, \mu_A(x) + \mu_B(x)) \quad (9.19)$$

Dla wszystkich zaktywizowanych reguł (reguł, których stopień spełnienia przesłanek jest większy od zera ( $h > 0$ )) określa się zmodyfikowane funkcje przynależności do reguł. Proces ten nosi nazwę inferencji w regułach i polega na dokonaniu implikacji rozmytej  $h \Rightarrow \mu_B(y)$ . Jako operator implikacji rozmytej najczęściej stosowane są operatory T-normy, w związku z czym inferencja w poszczególnych regułach ma postać:

$$\mu_{B_j}^*(y) = T(h_j, \mu_{B_j}(y)) \quad (9.20)$$

Na podstawie zmodyfikowanych funkcji przynależności dokonuje się procesu akumulacji, przez co otrzymuje się wynikową funkcję przynależności; wykorzystuje się w tym celu operatory S-normy:

$$\mu_{wyn}(y) = \mu_{B^*}(y) = S(\mu_{B_1}^*(y), \mu_{B_2}^*(y), \dots, \mu_{B_m}^*(y)) \quad (9.21)$$

Wynikowa funkcja przynależności jest wartością wyjściową bloku inferencji.


## Defuzyfikacja

Blok defuzyfikacja oblicza ostrą wartość wyjścia systemu na podstawie wynikowej funkcji przynależności wyjścia, obliczonej w bloku inferencyjnym. Do najczęściej używanych metod defuzyfikacji należą [81]:

- metoda środka maksimum,
- metoda pierwszego maksimum,
- metoda ostatniego maksimum,
- metoda środka ciężkości,
- metoda środka sum,
- metoda wysokości.


### Metoda środka maksimum

W metodzie tej jako ostrą wartość wyjściową przyjmuje się tę wartość rozmytą, dla której stopień aktywacji jest najwyższy. W przypadku, gdy najwyższy stopień aktywacji występuje dla więcej niż jednej wartości rozmytej sygnału wyjściowego (rysunek 9.4), wynikiem defuzyfikacji jest średnia arytmetyczna wartości wyjściowych o najwyższym stopniu aktywacji.



Rys. 9.4. Defuzyfikacja metodą środka maksimum


Wadą tej metody defuzyfikacji jest jej nieciągłość, co zostało zilustrowane na rysunku 9.5, na którym niewielka zmiana aktywizacji zbiorów  $B_1$  i  $B_2$  powoduje skokową zmianę wartości wyjściowej.



Rys. 9.5. Ilustracja nieciągłości metody środka maksimum

### Metoda pierwszego maksimum


W metodzie pierwszego maksimum za ostrą wartość wyjściową konkluzji wynikowej przyjmuje się najmniejszą wartość rozmytą wyjścia, dla której stopień przynależności jest najwyższy (rysunek 9.6). Zaletą tej metody jest bardzo mały nakład obliczeniowy, a wadami nieciągłość oraz uwzględnianie tylko jednego, najbardziej zaktywizowanego zbioru  $B_i$ .




Rys. 9.6. Defuzyfikacja metodą pierwszego maksimum

### Metoda ostatniego maksimum

W metodzie ostatniego maksimum za ostrą wartość wyjściową konkluzji wynikowej przyjmuje się największą wartość rozmytą wyjścia, dla której stopień przynależności jest najwyższy (rysunek 9.7). Zalety i wady tej metody są takie same jak w przypadku metody pierwszego maksimum oraz dodatkowo występuje jeszcze jedna wada, zilustrowana na rysunku 9.8 - w przypadku gdy stopień aktywizacji zbioru  $B_1$  rośnie, a  $B_2$  maleje ostra wartość wyjściowa powinna przesuwać się w stronę środka zbioru zbiorów  $B_1$ , natomiast w metodzie ostatniego maksimum jest dokładnie odwrotnie.



Rys. 9.7. Defuzyfikacja metodą ostatniego maksimum




Rys. 9.8. Ilustracja wady metody ostatniego maksimum

### Metoda środka ciężkości


W metodzie tej jako ostrą wartość wyjściową przyjmuje się środek powierzchni pod wykresem funkcji  $\mu(y)$  (rysunek 9.9). Obliczenia tej wartości dokonuje się według wzoru:

$$y^* = \frac{\int y \cdot \mu_{wyn}(y) dy}{\int \mu_{wyn}(y) dy} \quad (9.22)$$




Rys. 9.9. Defuzyfikacja metodą środka ciężkości

Zaletą tej metody jest branie pod uwagę wszystkich zaktywizowanych reguł, dzięki czemu czułość metody środka ciężkości jest większa niż w przypadku metod opisywanych wcześniej. Zasadniczą wadą jest duża złożoność obliczeniowa wynikająca z konieczności całkowania nieregularnych powierzchni. Kolejną wadą jest nieczułość metody na zmianę stopnia aktywizacji w przypadku, gdy zaktywizowany jest jedynie jeden zbiór rozmyty, co zostało zilustrowane na rysunku 9.10.



**Rys. 9.10.** Ilustracja nieczułości metody środka ciężkości przy zaktywizowanym jednym zbiorze rozmytym wyjścia

Następną wadą jest bardzo niska czułość w przypadku, gdy nośniki poszczególnych zbiorów rozmytych wyjścia znacznie różnią się między sobą (rysunek 9.11). W tej sytuacji duża zmiana zaktywizowania zbiorów prowadzi do nieznacznej zmiany środka ciężkości.



**Rys. 9.11.** Ilustracja niskiej czułości metody środka ciężkości w przypadku dużych różnic nośników poszczególnych zbiorów rozmytych wyjścia

### Metoda środka sum


W metodzie tej ostrą wartością wyjściową jest środek ciężkości sumy funkcji przynależności poszczególnych zbiorów rozmytych wyjścia. Wynikową funkcję wyjścia uzyskuje się przez zsumowanie w procesie akumulacji funkcji przynależności do zbiorów wyjściowych dla wszystkich reguł:

$$\mu_{wyn} = \sum_{j=1}^m \mu_{Bj*}(y) \quad (9.23)$$

Następnie obliczany jest środek ciężkości otrzymanej w ten sposób funkcji wynikowej:

$$y^* = \frac{\int y \cdot \mu_{wyn}(y) dy}{\int \mu_{wyn}(y) dy} = \frac{\int y_i \sum_{j=1}^m \mu_{Bj*}(y_i)}{\int \sum_{j=1}^m \mu_{Bj*}(y_i)} \quad (9.24)$$


Sposób defuzyfikacji metodą środka sum został zilustrowany na rysunku 9.12.



**Rys. 9.12.** Defuzyfikacja metodą środka sum

### Metoda wysokości

Metoda ta, zwana również metodą singletonów, jest uproszczoną, dyskretną wersją metody środka sum. W metodzie tej każdy ze zbiorów rozmytych wyjścia zastępuje się singletonem umiejscowionym w wartości modalnej tego zbioru (rysunek 9.13).



**Rys. 9.13.** Defuzyfikacja metodą wysokości

Do obliczenia wartości wyjścia modelu stosuje się dyskretną wersję wzoru 9.24:

$$y^* = \frac{\sum_{j=1}^m y_j \cdot \mu_{B_j^*}}{\sum_{j=1}^m \mu_{B_j^*}} \quad (9.25)$$


Do zalet metody wysokości należą mniejsza złożoność obliczeniowa niż metod środka ciężkości oraz środka sum, ciągłość, duża czułość, niezależność wyniku defuzyfikacji od długości nośników poszczególnych zbiorów. Duża liczba zalet i mała liczba wad sprawiają, że metoda wysokości jest najczęściej stosowaną metodą defuzyfikacji.

### 9.1.3. Optymalizacja modelu rozmytego za pomocą algorytmu genetycznego

Parametry modeli rozmytych, takie jak kształty funkcji przynależności, postaci reguł w bazie, zastosowane operatory T- oraz S-normy mogą być określane z wykorzystaniem algorytmu genetycznego. Działanie algorytmu jest podobne do tego, jakie zostało opisane w poprzednich rozdziałach, zaś zasadniczą różnicą jest sposób zakodowania problemu.


W przypadku gdy algorytm genetyczny używany jest do określania parametrów funkcji przynależności wejść i/lub wyjścia modelu najczęściej stosuje się technikę, w której

przestrzeń rozważań poszczególnych zmiennych wejściowych i/lub zmiennej wyjściowej dzieli się na skończoną liczbę przedziałów (rysunek 9.14) [81]. Każdemu z tych przedziałów odpowiada jeden gen w chromosomie. Jeżeli w danym przedziale znajduje się wierzchołek funkcji przystosowania to gen taki otrzymuje wartość 1, w przeciwnym przypadku 0. Większa ilość przedziałów prowadzi do zwiększenia rozdzielczości wejść i dokładności modelu rozmytego, jednak również powoduje większą złożoność obliczeniową.



**Rys. 9.14.** Kodowanie funkcji przynależności w postaci chromosomu

Kodować można również współrzędne punktów charakterystycznych funkcji przystosowania, którymi są np. wierzchołki w przypadku funkcji o kształcie trójkątnym i trapezowym lub środek oraz szerokość w przypadku funkcji o kształcie gaussowskim (rysunek 9.15).



**Rys. 9.15.** Współrzędne charakterystyczne różnych funkcji przynależności

Algorytmy genetyczne mogą także służyć do generacji bazy reguł. Istnieją trzy podejścia do tego problemu: Michigan, Pittsburgh i uczenie iteracyjne [69],[87].

W podejściu Michigan każdy chromosom koduje jedną regułę, a poszukiwaną bazę reguł stanowią wszystkie lub część spośród chromosomów w populacji. Funkcja przystosowania obliczana jest dla całej populacji i jest reprezentowana przez błąd odpowiedzi modelu rozmytego o danej bazie reguł na zbiór testujący. Na przykład, jeżeli układ składa się z czterech wejść i jednego wyjścia, które mogą być opisane poprzez następujące zmienne lingwistyczne: bardzo niski, niski, średni, wysoki, bardzo wysoki, to po przyporządkowaniu każdej ze zmiennych numeru, np.  $1 \div 5$  (1- bardzo niski, 5-bardzo wysoki) oraz wprowadzeniu

znaku # oznaczającego brak odpowiedniej zmiennej lingwistycznej dla danego wejścia, to baza reguł o następującej postaci:

*R1: Jeżeli x1 jest średni i x3 jest bardzo niski to y jest niski*

*R2: Jeżeli x2 jest wysoki i x3 jest bardzo wysoki to y jest wysoki*

może być zakodowana w następującej postaci:

*R1: 3#1#2*

*R2: #45#4*

Tak zakodowane reguły są następnie poddawane operatorom genetycznym operującym na liczbach rzeczywistych. Mogą być też przekształcone do postaci binarnej poprzez przyporządkowanie każdemu wejściu odpowiedniej liczby bitów i zakodowanie liczb całkowitych w sposób dwójkowy. Znak # może być zakodowany poprzez wartość 0. Np. przy reprezentacji każdego wejścia przez trzy bity powyższe reguły przyjmą postać:

*R1: 011 000 001 000 010*

*R2: 000 100 101 000 100*

Do reguł zakodowanych w sposób binarny stosuje się klasyczne operatory genetyczne.

W podejściu Pittsburgh w każdym chromosomie zakodowana jest cała baza reguł. Działanie algorytmu nie odbiega od klasycznego algorytmu genetycznego i polega na poszukiwaniu najlepiej przystosowanych osobników, które po zdekodowaniu ich chromosomów dawałyby bazy reguł generujące najmniejszy błąd odpowiedzi modelu na zbiór testujący. Dla bazy o dwóch podanych wcześniej za przykład regułach, chromosom byłby konkatencją dwóch chromosomów kodujących te reguły, a więc dla kodowania rzeczywistego miałby postać: 3#1#2#45#4, a dla kodowania binarnego: 011 000 001 000 010 000 100 101 000 100.

Wadą podejścia Pittsburgh jest to, że chromosomy osiągają większe długości niż przypadku podejścia Michigan. W przypadku systemów o dużej liczbie wejść i dużej ilości zbiorów rozmytych chromosomy mogą posiadać dość znaczne rozmiary, co znacząco zwiększa czas obliczeń.

Uczenie iteracyjne łączy w sobie cechy podejść Michigan oraz Pittsburgh i cechuje się tym, że każdy chromosom koduje pojedynczą regułę, ale w każdym uruchomieniu algorytmu wybierany jest tylko jeden osobnik, a zatem i jedna reguła. Aby uzyskać pełną bazę reguł należy algorytm uruchamiać wielokrotnie. Ponieważ w utworzonej w ten sposób bazie mogą występować powtarzające się reguły oraz reguły ze sobą sprzeczne, należy po zakończeniu działania algorytmu zastosować procedury modyfikujące bazę. Można również kontrolować działanie kolejnych uruchomień algorytmu poprzez usuwanie ze zbioru uczącego tych danych, które odpowiedzialne były za wybranie konkretnej reguły tak, aby przy następnym uruchomieniu model rozmyty uczony był bez tych danych.

## 9.2. Budowa klasyfikatora rozmytego do diagnostyki maszyny synchronicznej

Do klasyfikacji z użyciem modelu rozmytego zastosowano, podobnie jak w przypadku sieci neuronowych, zbiór uczący składający się z amplitud poszczególnych harmonicznych widma prądu wzbudzenia. Klasyfikację przeprowadzono dla wszystkich czterech badanych stanów awaryjnych. Do generacji modelu rozmytego zastosowano zestaw narzędzi Fuzzy Logic Toolbox pakietu Matlab [43]. Procedura generacji i ewaluacji modelu osadzona została w zaimplementowanym algorytmie genetycznym. Dla każdego z osobników populacji w danym pokoleniu algorytmu generowany był osobny model, który następnie był testowany, a odwrotność jego błędu odpowiedzi przyjmowana była jako wartość funkcji dopasowania chromosomu. Ponadto modele różniły się między sobą liczbą wejść (rozpatrywano modele o  $n$  wejściach, gdzie  $n \in \{2,3,4\}$ ). Liczba wyjść była równa jeden. Wejścia odpowiadały poszczególnym cechom wybranym podczas selekcji, które reprezentowane były poprzez amplitudy poszczególnych składowych widma. Każdemu z wejść odpowiadały dwa zbiory rozmyte, z których jeden dotyczył amplitud dla stanu bezawaryjnego (zbiór o nazwie *dobra*), a drugi uszkodzonego (zbiór o nazwie *uszkodzona*).

Funkcje przynależności do poszczególnych zbiorów rozmytych wejść były kształtu gaussowskiego i dostosowane były do rozkładu danych według poniższej zależności [9]:


$$A_{ik}(x_i) = \exp\left(-\frac{(x_i - \bar{x}_{ik})^2}{2\sigma_{ik}^2}\right) \quad (9.26)$$

gdzie:

$x_i$  – wartość i-tej cechy,

$\bar{x}_{ik}$  – wartość średnia i-tej cechy w k-tej klasie,

$\sigma_{ik}$  – odchylenie standardowe i-tej cechy w k-tej klasie.



**Rys. 9.16.** Ilustracja sposobu tworzenia funkcji przynależności dwóch cech do dwóch klas uwzględniająca środki klas i odchylenie standardowe cech w obrębie danej klasy

Rysunek 9.14 przedstawia przykładowe kształty wyznaczonych według wzoru 9.26 funkcji przynależności dla dwóch cech oraz dwóch klas.

Dla  $n$  wejść, z których każde posiada po dwa zbiory rozmyte oraz jednego wyjścia, które również może przynależać do dwóch zbiorów rozmytych możliwe jest wygenerowanie  $2^{n+1}$  reguł koniunkcyjnych. Na przykład przy dwóch wejściach będzie to 8 reguł o następującej postaci:

*R1: JEŚLI w1 jest dobra I w2 jest dobra TO wyjście jest dobra*

*R2: JEŚLI w1 jest dobra I w2 jest uszkodzona TO wyjście jest dobra*

*R3: JEŚLI w1 jest uszkodzona I w2 jest dobra TO wyjście jest dobra*

*R4: JEŚLI w1 jest uszkodzona I w2 jest uszkodzona TO wyjście jest dobra*

*R5: JEŚLI w1 jest dobra I w2 jest dobra TO wyjście jest uszkodzona*

*R6: JEŚLI w1 jest dobra I w2 jest uszkodzona TO wyjście jest uszkodzona*

*R7: JEŚLI w1 jest uszkodzona I w2 jest dobra TO wyjście jest uszkodzona*

*R8: JEŚLI w1 jest uszkodzona I w2 jest uszkodzona TO wyjście jest uszkodzona*

Poszczególne reguły są parami sprzeczne, ponieważ przy tych samych przesłankach mają różne konkluzje. Dotyczy to reguł: *R1* i *R5*, *R2* i *R6*, *R3* i *R7* oraz *R4* i *R8*, które nie powinny występować jednocześnie. Dlatego w bazie reguł mogą się znajdować co najwyżej 4 reguły, lub ogólnie  $2^n$  reguł. O tym, które to będą reguły decydować ma algorytm genetyczny, jednak należy wprowadzić mechanizm, który będzie uniemożliwiał budowanie modeli o sprzecznych regułach. Ponadto w bazie może znajdować się mniej niż  $2^n$  reguł. Jeśli z punktu widzenia dokładności modelu (mierzonej błędem jego odpowiedzi na zbiór testowy) któreś z reguł są zbędne lub wręcz pogarszają działanie klasyfikatora, to takie reguły należy z bazy usunąć.

Każdą z reguł można zakodować za pomocą  $n + 1$  genów (dla podanego tutaj przykładu o dwóch wejściach będą to trzy geny). Pierwszy z genów opisuje wejście pierwsze, drugi gen wejście drugie, itd. Ostatni z genów opisuje wyjście systemu. Jeśli któryś z tych genów przyjmuje wartość 0 to zgodnie z przyjętą zasadą wejście mu odpowiadające należy do zbioru *dobra*, natomiast w przypadku przyjmowania wartości 1 wejście takie należy do zbioru *uszkodzona*. Do zakodowania pełnej bazy reguł należy zarezerwować w chromosomie  $(n + 1) \cdot 2^n$  genów. Stosując powyższy sposób kodowania poszczególne reguły z przykładu można zapisać następująco: *R1: 000*, *R2: 010*, *R3: 100*, *R4: 110*, *R5: 001*, *R6: 011*, *R7: 101*, *R8: 111*.

Optymalizacji podlegały również stosowane w modelu operatory T- oraz S- normy.

Dla połączenia reguł prostych w reguły złożone (operator *I*) możliwe do wybrania były operatory MIN i PROD. Ponieważ wybór dotyczył jednego z dwóch wariantów do


zakodowania tych operatorów wystarczył jeden gen w chromosomie.

Do przeprowadzenia implikacji również przewidziano dwa możliwe do wybrania operatory (MIN i PROD) i także kodowano je przy pomocy jednego genu.

Dwa operatory (MAX i SUM) brano pod uwagę podczas procesu agregacji i również odpowiadał im jeden gen w chromosomie.

Dwa geny w chromosomie użyte zostały do zakodowania metody defuzyfikacji, ponieważ brano pod uwagę cztery metody: singletonową, pierwszego maksimum, środka maksimum oraz ostatniego maksimum.

Funkcje przynależności do zbiorów rozmytych wyjścia nie były z góry ustalone, a ich kształt i parametry optymalizował algorytm genetyczny. Dla każdego ze zbiorów możliwe było wygenerowanie funkcji przynależności o czterech różnych kształtach, stąd liczba genów niezbędna do zakodowania ich wynosi 4 (po 2 geny dla każdego ze zbiorów). Pierwszy ze zbiorów rozmytych wyjścia mógł posiadać funkcję o jednym z czterech następujących kształtów: z-shape, sigmoidalny lewy, trójkątny lewy, trapezowy lewy, natomiast drugi ze zbiorów: s-shape, sigmoidalny prawy, trójkątny prawy, trapezowy prawy. Poszczególne kształty przedstawione zostały na rysunku 9.15.



**Rys. 9.17.** Kształty funkcji przynależności do zbiorów rozmytych wyjść

Każda z tych funkcji wymaga podania dwóch, trzech lub czterech parametrów. Aby zapewnić odpowiednią rozdzielczość przestrzeni wyjściową podzielono na 1024 punkty i każdy z parametrów funkcji przynależności kodowano za pomocą 10 genów ( $2^{10} = 1024$ ). W sumie na cztery parametry funkcji przynależności dla obu zbiorów zarezerwowano 80 genów. W przypadku funkcji, które wymagają podania jedynie dwóch lub trzech parametrów pozostałe wyznaczone parametry były ignorowane.

Sposób podziału chromosomu przedstawiony został na rysunku 9.16. Jego całkowita długość wynosiła  $89 + (n + 1) \cdot 2^n$ .

| 1 | 2          | 3         | 4-5           | 6-7                   | 8-9                   | 10-19                   | 20-29                   | 30-39                   | 40-49                   | 50-59                   | 60-69                   | 70-79                   | 80-89                   | 89-[89+(n+1) 2 <sup>n</sup> ] |
|---|------------|-----------|---------------|-----------------------|-----------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------|-------------------------------|
| I | implikacja | agregacja | defuzyfikacja | f. przyst. 1 - rodzaj | f. przyst. 2 - rodzaj | f. przyst. 1 - param. 1 | f. przyst. 1 - param. 2 | f. przyst. 1 - param. 3 | f. przyst. 1 - param. 4 | f. przyst. 2 - param. 1 | f. przyst. 2 - param. 2 | f. przyst. 2 - param. 3 | f. przyst. 2 - param. 4 | baza reguł                    |

**Rys. 9.18.** *Sposób kodowania chromosomu*

### 9.3. Wyniki klasyfikacji rozmytej

Zastosowanie modeli rozmytych o jedynie dwóch wejściach zmniejszyło złożoność obliczeniową (jak również długość chromosomów), ale równocześnie pogorszyło jakość klasyfikacji. Próby zwiększenia liczby wejść nie przyniosły dużej poprawy w jakości klasyfikacji więc pozostano przy modelach o liczbie wejść wynoszącej dwa.

Dla wszystkich przypadków, w których występowała liniowa separowalność punktów odpowiadających stanowi bezawaryjnemu i uszkodzonemu, klasyfikatory rozmyte dawały poprawne odpowiedzi na zbiór testujący. W pozostałych przypadkach błędy odpowiedzi były na tyle duże, że nie można było uznać wyników ich działania za poprawne.

Słabe wyniki klasyfikacji uszkodzeń w obwodach wzbudzenia nie dawały podstaw do budowy klasyfikatora do rozpoznawania wszystkich uszkodzeń

### 9.3.1. Wyniki klasyfikacji dla zwarcia w grupie zezwojów twornika

#### Wyniki klasyfikacji na podstawie widma prądu twornika.

Klasyfikacja przeprowadzona została dla dwuelementowego wektora odpowiadającego częstotliwościom 150Hz i 250Hz. Średniokwadratowy błąd odpowiedzi zoptymalizowanego klasyfikatora na zbiór testujący wynosił 1545.8323. Wyniki optymalizacji klasyfikatora zestawiono w tabeli 9.1, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 9.19.


**Tabela 9.1.** Wyniki optymalizacji parametrów klasyfikatora rozmytego do diagnostyki zwarcia w grupie zezwojów twornika na podstawie widma prądu twornika

| Parametr                                     | Wartość                 |
|----------------------------------------------|-------------------------|
| operator połączenia                          | PROD                    |
| operator implikacji                          | PROD                    |
| operator agregacji                           | MAX                     |
| metoda defuzyfikacji                         | singleton               |
| funkcja przyn. wyjścia do zbioru bezawaryjny | z-shape, a=11, b=37     |
| funkcja przyn. wyjścia do zbioru uszkodzony  | s-shape, a=1015, b=1017 |
| dopasowanie                                  | 0.6469                  |

Baza reguł zoptymalizowanego klasyfikatora miała postać:

JEŚLI wejście1 jest dobra I wejście2 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest uszkodzona I wejście2 jest uszkodzona TO stan jest uszkodzony



**Rys. 9.19.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

## Wyniki klasyfikacji na podstawie widma prądu wzbudzenia.

Klasyfikacja przeprowadzona została dla dwuelementowego wektora odpowiadającego częstotliwościom 100Hz i 200Hz. Średniokwadratowy błąd odpowiedzi zoptymalizowanego klasyfikatora na zbiór testujący wynosił  $2.1341e-148$ . Wyniki optymalizacji klasyfikatora zestawiono w tabeli 9.2, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 9.20.

**Tabela 9.2.** Wyniki optymalizacji parametrów klasyfikatora rozmytego do diagnostyki zwarcia w grupie zezwojów twornika na podstawie widma prądu wzbudzenia

| Parametr                                     | Wartość                 |
|----------------------------------------------|-------------------------|
| operator połączenia                          | PROD                    |
| operator implikacji                          | PROD                    |
| operator agregacji                           | SUM                     |
| metoda defuzyfikacji                         | singleton               |
| funkcja przyn. wyjścia do zbioru bezawaryjny | z-shape, a=3, b=5       |
| funkcja przyn. wyjścia do zbioru uszkodzony  | s-shape, a=1021, b=1023 |
| dopasowanie                                  | 1340.0246               |


Baza reguł zoptymalizowanego klasyfikatora miała postać:

JEŚLI wejście1 jest dobra I wejście2 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest dobra I wejście2 jest uszkodzona TO stan jest bezawaryjny

JEŚLI wejście1 jest uszkodzona I wejście2 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest uszkodzona I wejście2 jest uszkodzona TO stan jest uszkodzony



**Rys. 9.20.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

### 9.3.2. Wyniki klasyfikacji dla przerwy jednej gałęzi równoległej twornika

#### Wyniki klasyfikacji na podstawie widma prądu twornika.

Klasyfikacja przeprowadzona została dla dwuelementowego wektora odpowiadającego częstotliwościom 25Hz i 150Hz. Średniokwadratowy błąd odpowiedzi zoptymalizowanego klasyfikatora na zbiór testujący wynosił  $3.0698e-006$ . Wyniki optymalizacji klasyfikatora zestawiono w tabeli 9.3, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 9.21.

**Tabela 9.3.** Wyniki optymalizacji parametrów klasyfikatora rozmytego do diagnostyki przerwy w gałęzi równoległej twornika na podstawie widma prądu twornika


| Parametr                                     | Wartość                 |
|----------------------------------------------|-------------------------|
| operator połączenia                          | PROD                    |
| operator implikacji                          | PROD                    |
| operator agregacji                           | SUM                     |
| metoda defuzyfikacji                         | singleton               |
| funkcja przyn. wyjścia do zbioru bezawaryjny | z-shape, a=1, b=6       |
| funkcja przyn. wyjścia do zbioru uszkodzony  | s-shape, a=1014, b=1015 |
| dopasowanie                                  | 1012.6939               |

Baza reguł zoptymalizowanego klasyfikatora miała postać:

JEŚLI wejście1 jest dobra I wejście2 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest dobra I wejście2 jest uszkodzona TO stan jest uszkodzony

JEŚLI wejście1 jest uszkodzona I wejście2 jest dobra TO stan jest bezawaryjny



**Rys. 9.21.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

## Wyniki klasyfikacji na podstawie widma prądu wzbudzenia.

Klasyfikacja przeprowadzona została dla trzejelementowego wektora odpowiadającego częstotliwościom 50Hz, 100Hz i 200Hz. Średniokwadratowy błąd odpowiedzi zoptymalizowanego klasyfikatora na zbiór testujący wynosił  $1.4368e-018$ . Wyniki optymalizacji klasyfikatora zestawiono w tabeli 9.4, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 9.22.

**Tabela 9.4.** Wyniki optymalizacji parametrów klasyfikatora rozmytego do diagnostyki przerwy w gałęzi równoległej twornika na podstawie widma prądu wzbudzenia


| Parametr                                     | Wartość                 |
|----------------------------------------------|-------------------------|
| operator połączenia                          | PROD                    |
| operator implikacji                          | PROD                    |
| operator agregacji                           | SUM                     |
| metoda defuzyfikacji                         | singleton               |
| funkcja przyn. wyjścia do zbioru bezawaryjny | z-shape, a=2, b=10      |
| funkcja przyn. wyjścia do zbioru uszkodzony  | s-shape, a=1015, b=1015 |
| dopasowanie                                  | 1041.0841               |

Baza reguł zoptymalizowanego klasyfikatora miała postać:

JEŚLI wejście1 jest dobra I wejście2 jest dobra I wejście3 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest dobra I wejście2 jest uszkodzona I wejście3 jest uszkodzona TO stan jest uszkodzony

JEŚLI wejście1 jest uszkodzona I wejście2 jest dobra I wejście3 jest dobra TO stan jest bezawaryjny



**Rys. 9.22.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

### 9.3.3. Wyniki klasyfikacji dla zwarcia cewki obwodu wzbudzenia

#### Wyniki klasyfikacji na podstawie widma prądu twornika.

Dla tego rodzaju uszkodzenia klasyfikacja rozmyta bazująca na prądzie twornika nie dawała dobrych rezultatów.

#### Wyniki klasyfikacji na podstawie widma prądu wzbudzenia.

Klasyfikacja przeprowadzona została dla dwuelementowego wektora odpowiadającego częstotliwościom 25Hz, i 600Hz. Średniokwadratowy błąd odpowiedzi zoptymalizowanego klasyfikatora na zbiór testujący wynosił  $4.3162e-007$ . Wyniki optymalizacji klasyfikatora zestawiono w tabeli 9.5, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 9.23. Przy nieuwzględnieniu składowych 0Hz i 25Hz wyniki rozpoznawania były bardzo słabe.

**Tabela 9.5.** Wyniki optymalizacji parametrów klasyfikatora rozmytego do diagnostyki zwarcia cewki obwodu wzbudzenia na podstawie widma prądu wzbudzenia


| Parametr                                     | Wartość                 |
|----------------------------------------------|-------------------------|
| operator połączenia                          | PROD                    |
| operator implikacji                          | PROD                    |
| operator agregacji                           | MAX                     |
| metoda defuzyfikacji                         | singleton               |
| funkcja przyn. wyjścia do zbioru bezawaryjny | z-shape, a=1, b=2       |
| funkcja przyn. wyjścia do zbioru uszkodzony  | s-shape, b=1015, b=1015 |
| dopasowanie                                  | 1014.6557               |

Baza reguł zoptymalizowanego klasyfikatora miała postać:

JEŚLI wejście1 jest dobra I wejście2 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest uszkodzona I wejście2 jest dobra TO stan jest uszkodzony

JEŚLI wejście1 jest uszkodzona I wejście2 jest uszkodzona TO stan jest uszkodzony



**Rys. 9.23.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

### 9.3.4. Wyniki klasyfikacji dla przerwy cewki obwodu wzbudzenia

#### Wyniki klasyfikacji na podstawie widma prądu twornika.

Dla tego rodzaju uszkodzenia klasyfikacja rozmyta bazująca na prądzie twornika nie dawała dobrych rezultatów.

#### Wyniki klasyfikacji na podstawie widma prądu wzbudzenia.

Klasyfikacja przeprowadzona została dla dwuelementowego wektora odpowiadającego częstotliwościom 0Hz, i 150Hz. Średniokwadratowy błąd odpowiedzi zoptymalizowanego klasyfikatora na zbiór testujący wynosił  $8.6624e-076$ . Wyniki optymalizacji klasyfikatora zestawiono w tabeli 9.6, a przebieg procesu optymalizacji w postaci zależności maksymalnej oraz średniej funkcji przystosowania od numeru pokolenia zaprezentowano na rysunku 9.24. Przy nieuwzględnieniu składowych 0Hz i 25Hz wyniki rozpoznawania były bardzo słabe.

**Tabela 9.6.** Wyniki optymalizacji parametrów klasyfikatora rozmytego do diagnostyki przerwy cewki obwodu wzbudzenia na podstawie widma prądu wzbudzenia


| Parametr                                     | Wartość                 |
|----------------------------------------------|-------------------------|
| operator połączenia                          | PROD                    |
| operator implikacji                          | PROD                    |
| operator agregacji                           | MAX                     |
| metoda defuzyfikacji                         | singleton               |
| funkcja przyn. wyjścia do zbioru bezawaryjny | z-shape, a=1, b=3       |
| funkcja przyn. wyjścia do zbioru uszkodzony  | s-shape, a=1014, b=1017 |
| dopasowanie                                  | 1172.8375               |

Baza reguł zoptymalizowanego klasyfikatora miała postać:

JEŚLI wejście1 jest dobra I wejście2 jest dobra TO stan jest bezawaryjny

JEŚLI wejście1 jest dobra I wejście2 jest uszkodzona TO stan jest bezawaryjny

JEŚLI wejście1 jest uszkodzona I wejście2 jest uszkodzona TO stan jest uszkodzony



**Rys. 9.24.** Zależność maksymalnej (kolor niebieski) oraz średniej (kolor czerwony) wartości funkcji dopasowania osobników w populacji od numeru epoki działania algorytmu

## 10. PODSUMOWANIE I KIERUNKI DAJSZYCH PRAC

W rozprawie przedstawione zostały wyniki badań diagnostycznych maszyny synchronicznej dla czterech różnych przypadków uszkodzeń: zwarcia grupy zezwojów w uzwojeniu twornika, przerwy w gałęzi równoległej jednej fazy twornika, a także zwarcia oraz przerwy w uzwojeniu bieguna obwodu wzbudzenia. W badaniach wykorzystano dwie maszyny synchroniczne o konstrukcjach specjalnych, które umożliwiały konfigurowanie uzwojeń, a w szczególności takie ich połączenia, które odpowiadały badanym stanom awaryjnym.

W celu umożliwienia wykonania badań zbudowane zostało stanowisko pomiarowe. Przeprowadzenie pomiarów poprzedzone zostało wytworzeniem aparatury pomiarowej służącej do rejestracji sygnałów prądowych i napięciowych. Ponieważ istnieje wiele czynników mających wpływ na wartości amplitud poszczególnych harmonicznych w widmie sygnału, pomiary przeprowadzone zostały w zmiennych warunkach zasilania, co miało na celu jak największe uniezależnienie prowadzonych analiz od wpływu tych czynników. W szczególności dotyczyło to wyższych harmonicznych w napięciu zasilającym, dlatego też równoległe z badanymi maszynami uruchamiano inne odbiorniki, uznawane powszechnie za źródła wyższych harmonicznych. W celu podniesienia konkurencyjności prowadzonych analiz duży nacisk położony był na diagnostykę we wczesnych stadiach uszkodzeń, dlatego w stanach awaryjnych obejmujących zwarcia zastosowano stopniowanie intensywności tych uszkodzeń.

Na podstawie zarejestrowanych przebiegów dokonano analizy spektralnej i wyboru składowych widm sygnałów prądowych mogących potencjalnie świadczyć o obecności stanu awaryjnego. Dokonano również transformacji sygnału do wektora przestrzennego prądu twornika i zbadano wpływ poszczególnych uszkodzeń na wartość składowej 100Hz tego sygnału.

Następnie dokonano wyboru symptomów uszkodzeń w sposób w pełni automatyczny. W tym celu zastosowano nowy rodzaj podejścia do problemu diagnostyki maszyn elektrycznych polegający na określaniu wpływu stanu awaryjnego na kombinacje składowych widm sygnału, podczas gdy dotychczas wykorzystywane metody bazowały na badaniu wpływu uszkodzenia na pojedyncze składowe. Autor użył do tego celu techniki, która stosowana jest w diagnostyce medycznej i rozpoznawaniu obrazów, zwanej selekcją cech. Problem diagnostyki został przedstawiony jako poszukiwanie w wielowymiarowej przestrzeni cech takiej jej podprzestrzeni (reprezentowanej przez zestaw składowych widm sygnału), która powodowałaby powstawanie największych różnic pomiędzy stanem bezawaryjnym a stanem uszkodzonym. Jako kryterium spełnienia tego warunku zastosowana została odległość Mahalanobisa, która uwzględnia odległości między środkami grup punktów, a także ich rozrzut wewnątrz klas, do których przynależą. Dzięki temu udało się odnaleźć takie zestawy

składowych, które tworzyły liniowo separowalne skupiska w wielowymiarowych podprzestrzeniach i to nawet w sytuacjach, gdy żadna z tych składowych rozpatrywana osobno (w jednowymiarowej podprzestrzeni) tej separowalności nie zapewniała. Z uwagi na dość duży rozmiar przestrzeni poszukiwań konieczne było zastosowanie wydajnego i dobrego jakościowo algorytmu przeszukiwania. W tym celu zaadaptowano klasyczny algorytm genetyczny, dodając do niego kilka ulepszeń.

Przeprowadzone badania dowiodły, że prąd wzbudzenia maszyny synchronicznej jest sygnałem w którym zawarta jest dobra informacja diagnostyczna. Dotyczy to głównie uszkodzeń w tworniku maszyny. Wyniki analiz na podstawie widma tego prądu posiadają jakość porównywalną z jakością diagnostyki na podstawie składowej 100Hz wektora przestrzennego prądu twornika, która powszechnie uznawana jest za bardzo dobry wskaźnik świadczący o asymetriach w uzwojeniach twornika. W przypadku diagnostyki uszkodzeń w obwodach wzbudzenia składowa 100 Hz wektora przestrzennego prądu twornika nie pozwala na wnioskowanie o wystąpieniu tych uszkodzeń, podobnie jak kombinacje składowych widma prądu twornika. Analiza prądu wzbudzenia dla tych przypadków daje umiarkowanie dobre rezultaty.

Dokonane w sposób w pełni automatyczny poszukiwania optymalnych zestawów cech w większości przypadków doprowadziły do podobnych rezultatów co wybór symptomów przeprowadzony przez eksperta. W przypadku uszkodzeń w obwodzie wzbudzenia algorytm był w stanie wskazać składowe, które potencjalnie mogłyby być użyte w procesie klasyfikacji, podczas gdy wyniki wizualnej oceny przez eksperta nie wskazywały na obecność takich składowych. Można ocenić, że zaprezentowany sposób wyboru symptomów towarzyszących uszkodzeniom maszyny synchronicznej jest bardzo skutecznym narzędziem diagnostycznym. W przypadku selekcji uszkodzeń w tworniku wyniki uznać można za bardzo dobre, a brak podobnej klasy rezultatów dla uszkodzeń w obwodach wzbudzenia wynika z braku obecności w widmach sygnałów prądowych składowych, które jednoznacznie mogłyby charakteryzować te uszkodzenia. Należy również dodać, że algorytm selekcji cech dawał również bardzo dobre wyniki w przypadku operowania na danych zaszumionych.

Algorytm genetyczny, po odpowiednim dostosowaniu zastosowany został również do optymalizacji parametrów zastosowanych klasyfikatorów. Jako klasyfikatory wykorzystane zostały sieci neuronowe typu MLP oraz model wnioskowania rozmytego Mamdaniego-Zadeha.

Klasyfikatory oparte na sieciach neuronowych bardzo dobrze poradziły sobie z problemem rozpoznawania stanów awaryjnych. Dla wszystkich przypadków, w których istniała liniowa separowalność do prawidłowej klasyfikacji wystarczyły sieci o jednym neuronie w warstwie ukrytej, które były w stanie bezbłędnie klasyfikować te stany awaryjne. Dla pozostałych przypadków liczba neuronów wymaganych do prawidłowego rozpoznania była również niska, jakość klasyfikacji mierzona średniokwadratowym błędem odpowiedzi sieci na zbiór testujący była bardzo wysoka.

Klasyfikatory oparte na modelu rozmytym Mamdaniego-Zadeha, których parametry także

dostrajane były z użyciem algorytmu genetycznego okazały się gorsze od klasyfikatorów neuronowych. Główną przyczyną tego faktu było założenie małej liczby wejść modelu. Ich działanie można uznać za dobre dla wszystkich przypadków, w których istniała liniowa separowalność pomiędzy punktami odpowiadającymi stanowi bezawaryjnemu oraz stanowi uszkodzonemu, a więc w przypadku klasyfikacji uszkodzeń w tworniku oraz uszkodzeń we wzbudzeniu na podstawie pełnego spektrum prądu wzbudzenia. . Wyjątek stanowiła klasyfikacja przerwy gałęzi równoległej na podstawie prądu twornika dla której średniokwadratowy błąd odpowiedzi klasyfikatora był dość znaczny. We wszystkich pozostałych przypadkach klasyka tor rozmyty popełniał wiele błędów, przez co średniokwadratowy błąd odpowiedzi osiągał duże wartości. Zwiększenie dokładności modelu rozmytego poprzez zastosowanie większej liczby wejść nie spowodowałoby jednak takiego wzrostu jakości klasyfikacji, że mogłaby ona być porównywalna z jakością klasyfikacji neuronowej. Porównanie obu rodzajów klasyfikatorów wypada zdecydowanie na korzyść sieci neuronowych.

Elementami nowości w rozprawie są: propozycja metody diagnostyki bazującej na analizie spektralnej pomiarowo dostępnych sygnałów, zbudowanie urządzenia do rejestracji sygnałów, zbudowanie stanowiska pomiarowego, wykonanie pomiarów i analiz spektralnych, analiza sygnałów na podstawie wektora przestrzennego prądu twornika, wyznaczenie symptomów uszkodzeń z zastosowaniem selekcji cech, wykonanie klasyfikatorów neuronowych oraz rozmytych do diagnostyki maszyny synchronicznej, optymalizacja parametrów klasyfikatorów z wykorzystaniem algorytmu genetycznego dostosowująca je do konkretnych zadań klasyfikacyjnych.

W przyszłości planowane jest przeprowadzenie podobnych badań dla innych egzemplarzy maszyn synchronicznych w celu weryfikacji zastosowanych technik. Ponadto brana jest pod uwagę możliwość zastosowania procedury selekcji cech z wykorzystaniem algorytmów genetycznych i odległości Mahalanobisa również do innych rodzajów maszyn elektrycznych. Autor zamierza także stosować w problemie selekcji pozostałe techniki sztucznej inteligencji, w szczególności sztuczne systemy immunologiczne i algorytmy mrówkowe.

## Bibliografia

- [1] Antal M., Antal L., Zawilak J., Badania uszkodzeń uzwojenia stojana klatkowego silnika indukcyjnego, Zeszyty Problemowe BOBRME Komel, nr. 76/2007, str. 83-88.
- [2] Arabas J., Wykłady z algorytmów ewolucyjnych, WNT, Warszawa 2001.
- [3] Awadallah M. A., Morcos M. M., Application of AI tools in fault diagnosis of electrical machines and drives, IEEE Transactions on Energy Conversion, Vol. EC-18, No. 2, 2003, pp. 245-251.
- [4] Biesiada J., Duch W., A Kolmogorov-Smirnov correlation-based filter solution for microarray gene expressions data, Springer Lecture Notes in Computer Science volume 4985 (2008), pp. 285-294.
- [5] Biesiada J., Duch W., Feature Selection for High-Dimensional Data - A Pearson Redundancy Based Filter, Computer Recognition Systems 2/2008, pp. 242-249.
- [6] Bolc L., Zaremba J., Wprowadzenie do uczenia się maszyn, Akademicka Oficyna Wydawnicza RM, Warszawa 1992.
- [7] Brown M., An introduction to fuzzy and neurofuzzy systems, 1996.
- [8] Cappelli R., Maio D., Maltoni D., Combining fingerprint classifiers, Proceedings of First International Workshop on Multiple Classifier Systems, 2000, pp. 351-361.
- [9] Chiu S., An efficient method for extracting fuzzy classification rules from high dimensional data, Journal of Advanced Computational Intelligence, Volume 1, no. 1, 1997, pp. 1-7.
- [10] Chow M. Y., Sharpe R. N., Hung J. C., On the application and design of artificial neural networks for motor fault detection, IEEE Transactions on Industrial Electronics, Volume 40, No. 2, 1993, pp. 181-196.
- [11] Cichosz P., Systemy uczące się, Wydanie drugie, WNT, Warszawa 2007.
- [12] Cruz S. M. A., Cardoso, A. J. M., Rotor cage fault diagnosis in three-phase induction motors, by Extended Park's Vector Approach, Electric Machines and Power Systems, Vol. 28, No. 4, pp. 289 - 299.
- [13] Cruz S.M.A., Cardoso A.J.M., Stator winding fault diagnosis in three phase synchronous and asynchronous motors, by the Extended Park's Vector Approach, IEEE Transactions on Industry applications, Volume 37, No5, 2001, pp. 1227-1233.
- [14] Cytowski J., Algorytmy genetyczne. Podstawy i zastosowania. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1996.
- [15] Das S., Purkait P., Chakravorti S., Space-Vector characterization of induction motor operating conditions, Proceedings of 15th NPSC, Mumbai, 2008, pp. 512-517.

- [16] Drozdowski P., Petryna J., Weinreb K., Ocena skuteczności diagnozowania silników indukcyjnych poprzez analizę spektralną prądu stojana, materiały konferencyjne Międzynarodowego Sympozjum Maszyn Elektrycznych SME'96, Kraków, s. 31-36.
- [17] Dash M., Liu H., Consistency-based search in feature selection, *Artificial Intelligence* 151(1-2), December 2003, pp. 155-176.
- [18] Dash, M., Liu, H., Feature selection for classification. *International Journal of Intelligent Data Analysis*, 1(3), 1997, pp. 131-156.
- [19] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R., *Biocybernetyka i Inżynieria Biomedyczna*, t. 6 – Sieci neuronowe, Akademicka Oficyna Wydawnicza Exit, 2000.
- [20] El Alami M. E., A filter model for feature subset selection based on genetic algorithm, *Journal of Knowledge-Based Systems*, Volume 22 (2009) pp. 356–362.
- [21] Glinka T., *Badania diagnostyczne maszyn elektrycznych w przemyśle*, Komel, Katowice 2000.
- [22] Głowacz Z., Kozik J., Detection of synchronous motor inter-turn faults based on spectral analysis of Park's vector. *Archives of Metallurgy and Materials*, (przyjęty do druku w tomie 56/2011).
- [23] Goldberg D.E., *Algorytmy genetyczne i ich zastosowania*, WNT, Warszawa 2003.
- [24] Grzymkowski R., Kaczmarek K., Kiełtyka S., Nowak I., *Wybrane algorytmy optymalizacji. Algorytmy genetyczne. Algorytmy mrówkowe*, Pracownia Komputerowa Jacka Skalmierskiego, 2009.
- [25] Guyon I., Elisseeff A., An Introduction to Variable and Feature Selection, *Journal of Machine Learning Research* 3 (2003), pp. 1157-1182.
- [26] Hampel et al., *Robust Statistics: The Approach Based on Influence Functions*, Wiley Series in Probability and Statistics, 1986 (przedruk 2005).
- [27] Hawkins J., Blakeslee S., *Istota inteligencji*, Wydawnictwo HELION 2005.
- [28] <http://focus.ti.com/lit/ds/symlink/op07c.pdf>
- [29] <http://sine.ni.com/nips/cds/view/p/lang/en/nid/11916>
- [30] <http://www.appatech.com/upload/download/file12541997634139.pdf>
- [31] [http://www.centalsemi.com/PDFs/products/P6SMB6.8CA\\_200CA.PDF](http://www.centalsemi.com/PDFs/products/P6SMB6.8CA_200CA.PDF)
- [32] [http://www.chauvin-arnoux.com.cn/menu2/minipincemn\\_a.pdf](http://www.chauvin-arnoux.com.cn/menu2/minipincemn_a.pdf)
- [33] <http://www.chinfa.com.tw/04product/download/pdf/ACDC/kam10.pdf>
- [34] <http://www.comedi.org>
- [35] <http://www.comedi.org/download/>
- [36] <http://www.datasheetdir.com/KAM2512+download>
- [37] <http://www.debian.org>

- [38] <http://www.fizyka.umk.pl/~duch/cog-book/AI>
- [39] <http://www.ktimetrace.sourceforge.net>
- [40] <http://www.lem.com/docs/products/lts%206-np%20e.pdf>
- [41] <http://www.lem.com/docs/products/lv%2025-p%20sp2%20e.pdf>
- [42] <http://www.mathworks.com>
- [43] <http://www.mathworks.com/help/toolbox/fuzzy/>
- [44] <http://www.mathworks.com/help/toolbox/nnet/>
- [45] Izydorczyk J., Konopacki J., Filtry analogowe i cyfrowe, Wydawnictwo Pracowni Komputerowej Jacka Skalmierskiego, 2003.
- [46] Jain, A., Nandakumar, K., Ross, A., Score normalization in multimodal biometric systems, *Pattern Recognition* (38), No. 12, December 2005, pp. 2270-2285.
- [47] Jankowski N., Ontogeniczne sieci neuronowe. O sieciach zmieniających swoją strukturę, Akademicka Oficyna Wydawnicza Exit, 2003. silnika indukcyjnego, *Zeszyty Problemowe BOBRME Komel*, nr. 76/2007, str. 83-88.
- [48] John G.H., Kohavi R., Pfleger K., Irrelevant Features and the Subset Selection Problem, *Proceedings of the Eleventh International Conference on Machine Learning* (1994), pp. 121-129.
- [49] Kasperski M.J., *Sztuczna inteligencja*, Helion 2003.
- [50] Kohavi R., A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *IJCAI-95*.
- [51] Kohavi R., John. G. H., Wrappers for feature subset selection. *Artificial Intelligence*, 97(1-2), pp. 273–324.
- [52] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., *Diagnostyka procesów. Modele, metody sztucznej inteligencji, zastosowania*, WNT, Warszawa 2002.
- [53] Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe – podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [54] Kosiński R. A., *Sztuczne sieci neuronowe*, WNT, 2002.
- [55] Kowalski C. T., Mikrokomputerowy system monitorowania i diagnostyki napędów elektrycznych z silnikami indukcyjnymi, *Prace Nauk. IMNE*, 1996, seria *Studia i Materiały* Nr 45, Nr 19, str. 69-77.
- [56] Kowalski C. T., Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych, *Wyd. Pol. Wrocławskiej, Monografie*, t. 57, nr 18, Wrocław 2005.
- [57] Kowalski C. T., Wolkiewicz M., Ewert P., Analiza uszkodzeń stojana silnika indukcyjnego zasilanego z przemiennika częstotliwości, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej*, Nr 62, 2008.

- [58] Latek W., Badania maszyn elektrycznych w przemyśle, WNT, Warszawa 1979.
- [59] Latek W., Teoria maszyn elektrycznych, WNT, Warszawa 1987.
- [60] Lejewski C., Jan Łukasiewicz. Encyclopedia of Philosophy, Vol. 5, MacMillan, NY: 1967, pp. 104-107.
- [61] Li-Xin Z., Jia-Xin W., Yan-Nan Z., Ze-Hong Y., A novel hybrid feature selection algorithm: using ReliefF estimation for GA-Wrapper search, Proceedings of the Second International Conference on Machine Learning and Cybernetics, Xi'an, 2-5 November 2003, pp. 380-384.
- [62] Liu H., Motoda H., Dash M., A Monotonic Measure for Optimal Feature Selection, Lecture Notes In Computer Science; Vol. 1398, Proceedings of the 10th European Conference on Machine Learning, 1998, pp. 101-106.
- [63] Liu H., Setiono R., A probabilistic approach to feature selection - a filter solution, Proceedings of the 13th International Conference in Machine Learning, Bari, Italy, July 1996, pp. 319-327.
- [64] Lyons R.G., Wprowadzenie do cyfrowego przetwarzania sygnałów, WKiŁ, Warszawa 2000.
- [65] Łachwa A., Rozmyty świat zbiorów, liczb, relacji, faktów, reguł i decyzji, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
- [66] Łukaniszyn M., Jagieła M., Wróbel R., Numerical Optimization of Electrical Converteres Using Evolutionary Algorithms, Przegląd Elektrotechniczny, R LXXIX, 2003, No 10.
- [67] Łukaniszyn M., Jagieła M., Wróbel R., Optymalne projektowanie transformatora przy użyciu algorytmu ewolucyjnego, XXVI Międzynarodowa Konferencja z Podstaw Elektrotechniki i Teorii Obwodów IC-SPETO, Niedzica 2003, s. 56-58.
- [68] Mahfoud S. W., Niching Methods for Genetic Algorithms, Rozprawa Doktorska 1995.
- [69] Michalewicz Z., Algorytmy genetyczne + struktury danych = programy ewolucyjne, WNT, Warszawa 2003.
- [70] Mizia W. (red), Maszyny synchroniczne. Badania i pomiary, Wyd. Politechniki Śląskiej, 1999.
- [71] Mucciardi A.N., Gose E.E., A comparison of seven techniques for choosing subsets of pattern recognition, IEEE Transactions on Computers, C-20, September 1971, pp. 1023-1031.
- [72] Narendra P.M., Fukunaga K., A branch and bound algorithm for feature subset selection. IEEE Trans. on Computer, C-26(9), 1977, pp. 917-922.
- [73] Noga M., Rams W., Rusek J., Skwarczyński J., Badania pomiarowe deformacji stojana maszyny synchronicznej wywołanych wewnętrzną niesymetrią uzwojeń, Zeszyty Naukowe AGH nr 1190, Elektrotechnika, Zeszyt 12, 1988, s. 261-271.

- [74] Noga M., Rams W., Rusek J., Skwarczyński J., Metody i przyrządy do diagnostyki obwodów maszyn elektrycznych indukcyjnych i synchronicznych, Zeszyty problemowe: Maszyny Elektryczne Nr 46, 1993, Wydawnictwo BOBRME Katowice.
- [75] Obuchowicz A., Evolutionary search with soft selection in training a network of dynamic neurons, Proceedings of 8<sup>th</sup> International Symposium on Intelligent Information Systems, Ustroń/Wisła, Poland, 1999, pp. 214-223.
- [76] Osowski S., Sieci neuronowe, Oficyna Wydawnicza PW, 1994.
- [77] Osowski S., Sieci neuronowe w ujęciu algorytmicznym, WNT, 1996.
- [78] Osowski S., Sieci neuronowe do przetwarzania informacji, OW PW, Warszawa 2000.
- [79] Osowski S., Cichocki A., Siwek K., Matlab w zastosowaniu do obliczeń obwodowych i przetwarzania sygnałów, OW PW, Warszawa 2006.
- [80] Pawlak M., Arczyński Z., Przenośny system pomiarowy do diagnostyki silników indukcyjnych, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Nr 62, 2008.
- [81] Piegat A., Modelowanie i sterowanie rozmyte, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2003.
- [82] Plamitzer A.M., Maszyny elektryczne, Wydanie szóste, WNT, Warszawa 1976.
- [83] PN-88/E-06701 (IEC 34-1): Maszyny elektryczne wirujące. Ogólne wymagania i badania.
- [84] Rusek J., Elektrotechnika z elementami napędów, Wydawnictwa AGH, Kraków 1996.
- [85] Rusek J., Komputerowa analiza maszyny indukcyjnej z wykorzystaniem bilansu harmonicznego, Wydawnictwa AGH, Kraków 2000.
- [86] Rutkowska D., Piliński M., Rutkowski L., Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, PWN, Warszawa 1999.
- [87] Rutkowski L., Metody i techniki sztucznej inteligencji, Wydawnictwo Naukowe PWN, Warszawa 2006.
- [88] Siedlecki W. Sklansky J., On automatic feature selection. International Journal of Pattern Recognition and Artificial Intelligence, 2/1988, pp. 197–220.
- [89] Skwarczyński J., Asymetrie wewnętrzne jawnobiegunowych maszyn synchronicznych, Zeszyty Naukowe Elektrotechnika, Wydawnictwo AGH, Kraków 1990.
- [90] Skwarczyński J., Tertil Z., Elektromechaniczne przetwarzanie energii, Wydawnictwo AGH, Kraków 2000.
- [91] Skwarczyński J., Tertil Z., Maszyny elektryczne. Cz. II. Teoria, Wydawnictwo AGH, Kraków 1989.
- [92] Skwarczyński J., Tertil Z., Maszyny elektryczne, część IV. Podstawowe pomiary

laboratoryjne, Wydawnictwa AGH, Kraków 1994.

- [93] Skwarczyński J., Weinreb K., Model matematyczny maszyny synchronicznej jawnobiegunowej dla analizy harmonicznej ustalonych wielkości elektrycznych, Kwartalnik Elektrotechnika, tom 8, zeszyt 2, 1989, Wydawnictwo AGH, s. 175-203.
- [94] Sochocki R., Mikromaszyny elektryczne, wyd. Politechniki Warszawskiej, 1996.
- [95] Stapor K., Automatyczna klasyfikacja obiektów, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2005.
- [96] Szabatin J., Podstawy teorii sygnałów, WKiŁ, Warszawa 2003.
- [97] Szczepaniak P. S., Obliczenia inteligentne, szybkie przekształcenia i klasyfikatory, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2004.
- [98] Tan F., Improving Feature Selection Techniques For Machine Learning, Rozprawa Doktorska 2007.
- [99] Tadeusiewicz R., Sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
- [100] Yuan H., Tseng S.S., Ganshan W., Fuyan Z., A Two-phase Feature Selection Method Using both Filter and Wrapper, IEEE SMC '99 Conference on Systems, Man, and Cybernetics, vol. 2, pp. 132 - 136.
- [101] Weinreb K., Sułowicz M.: Nieinwazyjna diagnostyka wewnętrznych niesymetrii uzwojeń maszyny synchronicznej, Zeszyty Problemowe – Maszyny Elektryczne Nr 77/2007, s. 59-64.
- [102] Wierzchoń S. T., Sztuczne systemy immunologiczne. Teoria i zastosowania. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
- [103] Zadeh L.A., Fuzzy Sets, Information and Control, 1965.
- [104] Zadeh L.A., Outline of a new approach to the analysis of complex systems and decision processes, 1973.
- [105] Zadeh L.A., Fuzzy algorithms, Information and Control, Vol. 12, 1968, pp. 94-102.
- [106] Zhao Z., Liu H., Searching for Interacting Features, Proceedings of International Joint Conference on Artificial Intelligence (IJCAI), January, 2007, pp. 1156-1161.
- [107] Zieliński T., P., Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań, WKiŁ, Warszawa 2005.
- [108] Żurada J., Barski M., Jędruch W., Sztuczne sieci neuronowe, PWN, Warszawa 1996.