

AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA W KRAKOWIE

WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI, INFORMATYKI I
INŻYNIERII BIOMEDYCZNEJ



AGH

mgr inż. Adam Głowacz

PRACA DOKTORSKA

**KOMPUTEROWE TECHNIKI ANALIZY
INFORMACJI ZAWARTEJ W SYGNAŁACH
AKUSTYCZNYCH
MASZYN ELEKTRYCZNYCH
DLA CELÓW DIAGNOSTYKI STANÓW
PRZEDAWARYJNYCH**

Promotor:

Dr hab. inż. Grzegorz Dobrowolski, prof. nz. AGH

Kraków, 2013

AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA W KRAKOWIE

WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI, INFORMATYKI I
INŻYNIERII BIOMEDYCZNEJ



AGH

mgr inż. Witold Głowacz

PRACA DOKTORSKA

**METODY ANALIZY I ROZPOZNAWANIA
INFORMACJI ZAWARTEJ W SYGNAŁACH
PRĄDOWYCH I NAPIĘCIOWYCH
SILNIKÓW ELEKTRYCZNYCH
DLA DIAGNOSTYKI STANÓW PRZEDAWARYJNYCH**

Promotor:

Prof. zw. dr hab. inż. Ryszard Tadeusiewicz

Kraków, 2016

Panu Profesorowi Grzegorzowi Dobrowolskiemu
składam serdeczne podziękowania za cenne
wskazówki i rady udzielane mi w czasie pisania
pracy doktorskiej

SPIS TREŚCI

1. WSTĘP.....	12
1.1. PROBLEMY ROZPOZNAWANIA STANÓW PRZEDAWARYJNYCH MASZYN ELEKTRYCZNYCH.....	14
2. TECHNIKI ANALIZY INFORMACJI ZAWARTEJ W SYGNAŁACH AKUSTYCZNYCH.....	19
2.1. REJESTRACJA SYGNAŁU AKUSTYCZNEGO, FILTRACJA, PRÓBKOWANIE I KWANTYZACJA.....	22
2.2. METODY PRZETWARZANIA SYGNAŁU AKUSTYCZNEGO.....	23
2.2.1. Podział zarejestrowanego sygnału akustycznego na fragmenty.....	23
2.2.2. Normalizacja amplitudy	24
2.2.3. Segmentacja i okienkowanie.....	24
2.3. WYBRANE METODY EKSTRAKЦИИ CECH SYGNAŁU	25
2.3.1. Szybka Transformacja Fouriera.....	26
2.3.2. Metoda wybierania amplitud dla częstotliwości.....	27
2.3.3. Liniowe kodowanie predycyjne.....	30
2.3.4. Współczynniki liniowego kodowania predycyjnego cepstrum.....	32
2.4. WYBRANE METODY KLASYFIKACJI SYGNAŁÓW AKUSTYCZNYCH.....	33
[Przestawienie] 2.4.3. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów.....	38
2.4.1. Zmodyfikowany klasyfikator Nearest Mean	34

Panu Profesorowi Ryszardowi Tadeusiewiczowi
składam serdeczne podziękowania za cenne
wskazówki i rady udzielane mi w czasie pisania
rozprawy doktorskiej

SPIS TREŚCI

WSTĘP	5
1. PROBLEMY ROZPOZNAWANIA STANÓW PRZEDAWARYJNYCH MASZYN ELEKTRYCZNYCH	8
2. METODY ANALIZY I ROZPOZNAWANIA INFORMACJI ZAWARTEJ W SYGNAŁACH PRĄDOWYCH I NAPIĘCIOWYCH	13
2.1. UWAGI WSTĘPNE	13
2.2. REJESTRACJA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH, FILTRACJA, PRÓBKOWANIE I KWANTYZACJA	16
2.3. METODY PRZETWARZANIA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH	17
2.3.1. Podział zarejestrowanych sygnałów prądowych i napięciowych na fragmenty	18
2.3.2. Normalizacja amplitudy	18
2.3.3. Segmentacja i okienkowanie	18
2.4. WYBRANE METODY EKSTRAKЦИИ CECH SYGNAŁU	20
2.4.1. Dyskretna Transformacja Fouriera DFT	20
2.4.2. Metoda wyboru amplitud dla częstotliwości MSAF	21
2.4.3. Metoda wyboru amplitud dla częstotliwości MSAF Ratio.....	23
2.4.4. Liniowe kodowanie predycyjne LPC	23
2.4.5. Współczynniki liniowego kodowania predycyjnego cepstrum LPCC	25
2.5. WYBRANE METODY KLASYFIKACJI SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH	26
2.5.1. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów.....	27
[Podmiana funkcji:]	
2.5.2. Klasyfikator oparty na metodzie najbliższego sąsiada NN	32

2.4.2. Klasyfikator oparty na słowach..... 36	2.5.3. Klasyfikator Bayesa 33
2.5. PODSUMOWANIE 44	2.5.4. Klasyfikator oparty na liniowej analizie dyskryminacyjnej LDA 33
3. PROJEKT STANOWISKA DIAGNOSTYCZNEGO DO ANALIZY SYGNAŁÓW AKUSTYCZNYCH..... 46	2.6. PODSUMOWANIE 35
3.1. WARUNKI ZASTOSOWANIA PROJEKTOWANEGO STANOWISKA DIAGNOSTYCZNEGO 46	3. PROJEKT STANOWISKA DIAGNOSTYCZNEGO OPARTEGO NA ANALIZIE SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH 36
3.2. WYPOSAŻENIE TECHNICZNE I INFORMATYCZNE STANOWISKA LABORATORYJNEGO..... 47	3.1. WARUNKI ZASTOSOWANIA PROJEKTOWANEGO STANOWISKA DIAGNOSTYCZNEGO 36
3.3. ANALIZA PRZYPADKÓW UŻYCIA STANOWISKA..... 48	3.2. WYPOSAŻENIE TECHNICZNE I INFORMATYCZNE STANOWISKA LABORATORYJNEGO 37
3.4. SYSTEM AUTOMATYCZNEGO ROZPOZNAWANIA SYGNAŁU AKUSTYCZNEGO 49	3.3. ANALIZA PRZYPADKÓW UŻYCIA STANOWISKA 38
3.4.1. Diagram wdrożenia SARSA..... 49	3.4. SYSTEM AUTOMATYCZNEGO ROZPOZNAWANIA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH .. 39
3.4.2. Diagram przypadków użycia SARSA..... 50	3.4.1. Diagram wdrożenia SARSP i SARSN 39
3.4.3. Diagram pakietów MRSA..... 52	3.4.2. Diagram przypadków użycia SARSP i SARSN 41
3.4.4. Realizacja przypadków użycia SARSA 53	3.4.3. Diagram pakietów MRSP i MRSN 43
3.4.5. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania 60	3.4.4. Realizacja przypadków użycia SARSP/SARSN..... 44
3.4.6. Diagram sekwencji procesu identyfikacji..... 62	3.4.5. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania 49
3.5. SYSTEM AUTOMATYCZNEGO ROZPOZNAWANIA PRĄDU 63	3.4.6. Diagram sekwencji procesu identyfikacji 51
3.6. PODSUMOWANIE 63	3.5. SYSTEMY AUTOMATYCZNEGO ROZPOZNAWANIA PRĄDU I NAPIĘCIA 53
4. BADANIA SYGNAŁÓW AKUSTYCZNYCH MASZYN ELEKTRYCZNYCH 64	3.6. PODSUMOWANIE 53
4.1. PLAN EKSPERYMENTÓW..... 64	4. BADANIA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH SILNIKÓW ELEKTRYCZNYCH 54
4.2. EKSPERYMENT MS..... 72	4.1. PLAN EKSPERYMENTÓW 55
4.3. EKSPERYMENT FFT-MS..... 73	4.2. EKSPERYMENT SI (SILNIKI INDUKCYJNE KLATKOWE) 66
[Przestawienie:] 4.3.3. Eksperyment FFT-SN-MS..... 76	4.3. EKSPERYMENT MSAF-SI 69
4.1.1. Eksperyment FFT-NM-MS 74	4.3.1. Eksperyment MSAF-SN-SI 73
4.3.2. Eksperyment FFT-ONS-MS..... 75	[Podmiana funkcji:]
4.4. EKSPERYMENT LPC-MS..... 77	4.3.2. Eksperyment MSAF-NN-SI 74
4.4.1. Eksperyment LPC-NM-MS..... 79	4.3.3. Eksperyment MSAF-BA-SI 74
	4.3.4. Eksperyment MSAF-LDA-SI 75
	[brak wyników]

4.4.2. Eksperyment LPC-ONS-MS	80		
4.4.3. Eksperyment LPC-SN-MS	81		
4.5. EKSPERYMENT LPCC-MS	82	[brak wyników]	
4.5.1. Eksperyment LPCC-NM-MS	83	4.5.2.	
Eksperyment LPCC-ONS-MS.....	85		
4.5.3. Eksperyment LPCC-SN-MS.....	86		
4.6. EKSPERYMENT MPS.....	88	4.4. EKSPERYMENT SPS (SILNIK PRĄDU STAŁEGO)	76
4.7. EKSPERYMENT FFT-MPS	88	4.5. EKSPERYMENT MSAF-SPS	81
[Przestawienie:] 4.7.3. Eksperyment FFT-SN-MPS	91	4.5.1. Eksperyment MSAF-SN-SPS	86
		[Podmiana funkcji:]	
4.7.1. Eksperyment FFT-NM-MPS.....	89	4.5.2. Eksperyment MSAF-NN-SPS	88
4.7.2. Eksperyment FFT-ONS-MPS.....	90	4.5.3. Eksperyment MSAF-BA-SPS	89
4.8. EKSPERYMENT LPC-MPS.....	92	4.5.4. Eksperyment MSAF-LDA-SPS	90
4.8.1. Eksperyment LPC-NM-MPS.....	94	[brak wyników]	
4.8.2. Eksperyment LPC-ONS-MPS.....	95		
4.8.3. Eksperyment LPC-SN-MPS.....	96		
4.9. EKSPERYMENT LPCC-MPS	97	[brak wyników]	
4.9.1. Eksperyment LPCC-NM-MPS.....	98		
4.9.2. Eksperyment LPCC-ONS-MPS	99		
4.9.3. Eksperyment LPCC-SN-MPS	100		
4.10. EKSPERYMENT ZNWMR	101	[brak wyników]	
4.11. EKSPERYMENT WNWMRM	102	[brak weryfikacji]	
4.12. EKSPERYMENT PWMS.....	102	[brak weryfikacji]	
4.13. EKSPERYMENT PTMPS.....	104	[brak weryfikacji]	
4.14. PODSUMOWANIE	105	4.6. PODSUMOWANIE	91
5. PROJEKT URZĄDZENIA MONITORUJĄCEGO MASZYNĘ ELEKTRYCZNĄ.....	106	5. PROJEKT URZĄDZENIA MONITORUJĄCEGO SILNIK ELEKTRYCZNY	93
5.1. PODSUMOWANIE	111	5.1. OPIS PROJEKTU	93
6. PODSUMOWANIE I KIERUNKI DALSZYCH PRAC.....	112	5.2. PODSUMOWANIE	98
		6. PODSUMOWANIE I KIERUNKI DALSZYCH PRAC	99
BIBLIOGRAFIA.....	115	LITERATURA.....	102

DODATEK A – WYKAZ WAŻNIEJSZYCH SKRÓTÓW W TEKŚCIE..... 125	DODATEK A - WYKAZ WAŻNIEJSZYCH SKRÓTÓW W TEKŚCIE118
DODATEK B – WYNIKI ROZPOZNAWANIA SYGNAŁÓW AKUSTYCZNYCH DLA WYBRANYCH MASZYN ELEKTRYCZNYCH..... 126	DODATEK B - WYNIKI ROZPOZNAWANIA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH DLA WYBRANYCH SILNIKÓW ELEKTRYCZNYCH120
DODATEK C – OPIS BADANYCH STANÓW MASZYN ELEKTRYCZNYCH..... 145	DODATEK C - BADANE SILNIKI ELEKTRYCZNE133
MASZYNA SYNCHRONICZNA ZE WZBUDZENIEM ELEKTROMAGNETYCZNYM 145	MASZYNA INDUKCYJNA KLATKOWA133
MASZYNA PRĄDU STAŁEGO OBCOWZBUDNA..... 148	MASZYNA PRĄDU STAŁEGO OBCOWZBUDNA133
DODATEK D – INSTALACJA I URUCHAMIANIE SYSTEMU AUTOMATYCZNEGO ROZPOZNAWANIA SYGNAŁU AKUSTYCZNEGO..... 151	

SPIS ILUSTRACJI

Rys. 1.1. Maszyna elektryczna jako system z przepływem energii i informacji [12].....	15
Rys. 1.2. Syntetyczne ujęcie celów poszczególnych rodzajów diagnostyki w przemyśle [12].....	18
Rys. 2.1. Struktura technik analizy informacji zawartej w sygnałach akustycznych.....	19
Rys. 2.2. Ogólny plan badania sygnałów akustycznych.....	21
Rys. 2.3. Okno Hamminga.....	25
Rys. 2.4. Metoda wybierania amplitud dla częstotliwości sygnału akustycznego maszyn elektrycznych	30
Rys. 2.5. Etap tworzenia wzorców do rozpoznawania oraz etap identyfikacji dla zmodyfikowanego klasyfikatora NM.....	34
Rys. 2.6. Struktura sieci neuronowej do rozpoznawania sygnału akustycznego	39
Rys. 2.7. Uszczegółowiony plan badań sygnałów akustycznych dla celów diagnostyki	42
Rys. 3.1. Diagram wdrożenia stanowiska diagnostycznego do badania sygnałów akustycznych.....	48
Rys. 3.2. Diagram przypadków użycia stanowiska diagnostycznego do badania sygnałów akustycznych	49
Rys. 3.3. Diagram wdrożenia systemu automatycznego rozpoznawania sygnału akustycznego	50
Rys. 3.4. Diagram przypadków użycia SARSA	51
Rys. 3.5. Diagram pakietów modułu rozpoznawania sygnału akustycznego	52
Rys. 3.6. Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania”.....	55
Rys. 3.7. Diagram czynności dla przypadku użycia „Wywołaj proces identyfikacji”.....	57
Rys. 3.8. Diagram czynności dla trybu niemonitorowania.....	58
Rys. 3.9. Diagram czynności dla trybu monitorowania.....	60
Rys. 3.10. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania.....	61
Rys. 3.11. Diagram sekwencji procesu identyfikacji.....	62

SPIS ILUSTRACJI

Rys. 1.1. Maszyna elektryczna jako system z przepływem energii i informacji [10]	9
Rys. 1.2. Syntetyczne ujęcie celów poszczególnych rodzajów diagnostyki w przemyśle [10]	11
Rys. 2.1. Struktura technik analizy informacji zawartej w sygnałach prądowych i napięciowych	13
Rys. 2.2. Ogólny plan badania sygnałów prądowych i napięciowych	15
Rys. 2.3. Okno Hamminga	19
Rys. 2.4. Metoda wyboru amplitud dla częstotliwości sygnałów prądowych i napięciowych silników elektrycznych	22
Rys. 2.5. Struktura sieci neuronowej do rozpoznawania sygnałów prądowych i napięciowych	28
Rys. 2.6. Uszczegółowiony plan badań sygnałów prądowych i napięciowych dla celów diagnostyki	30
Rys. 3.1. Diagram wdrożenia stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych	38
Rys. 3.2. Diagram przypadków użycia stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych	39
Rys. 3.3. Diagram wdrożenia systemu automatycznego rozpoznawania sygnałów prądowych i napięciowych	40
Rys. 3.4. Diagram przypadków użycia SARSP / SARSN	42
Rys. 3.5. Diagram pakietów modułu rozpoznawania sygnałów prądowych i napięciowych ..	43
Rys. 3.6. Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania”	46
Rys. 3.7. Diagram czynności dla przypadku użycia „Wywołaj proces identyfikacji”	48
Rys. 3.8. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania.....	50
Rys. 3.9. Diagram sekwencji procesu identyfikacji	52
Rys. 4.1. Badane silniki prądu przemiennego indukcyjne	54
Rys. 4.2. Badany silnik prądu stałego obcowzbudny	55
Rys. 4.3. Obwody elektryczne silników indukcyjnych klatkowych.....	67
Rys. 4.4. Prąd stojana fazy L1 w stanie uszkodzenia dwóch prętów klatki.....	67
Rys. 4.5. Prąd stojana fazy L1 w stanie uszkodzenia jednego pręta klatki	67
Rys. 4.6. Prąd stojana fazy L1 w stanie uszkodzenia pierścienia klatki	68
Rys. 4.7. Prąd stojana fazy L1 w stanie bez uszkodzeń	68
Rys. 4.8. Napięcie przewodowe stojana między fazami L1 i L2	68 w stanie uszkodzenia dwóch prętów klatki
Rys. 4.9. Napięcie przewodowe stojana między fazami L1 i L2	68 w stanie uszkodzenia jednego pręta klatki
Rys. 4.10. Napięcie przewodowe stojana między fazami L1 i L2	69 w stanie uszkodzenia pierścienia klatki
Rys. 4.11. Napięcie przewodowe stojana między fazami L1 i L2	69 w stanie bez uszkodzeń
Rys. 4.12. Widmo częstotliwości prądu stojana fazy L1 w stanie uszkodzenia dwóch prętów klatki	70
Rys. 4.13. Widmo częstotliwości prądu stojana fazy L1 w stanie uszkodzenia jednego pręta klatki	70

<p>Rys. 4.1. Widmo częstotliwości sygnału akustycznego maszyny synchronicznej dla czterech różnych stanów pracy przy zastosowaniu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz i FFT 73</p> <p>Rys. 4.2. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej: a) bez uszkodzeń, b) ze zwartymi zezwojami stojana, c) z jedną przerwą w obwodzie stojana, d) z trzema przerwami w obwodzie stojana..... 75</p> <p>Rys. 4.3. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej 76</p> <p>Rys. 4.4. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej 77</p> <p>Rys. 4.5. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników filtra predykcji liniowej dla maszyny synchronicznej..... 78</p> <p>Rys. 4.6. Porównanie sześciu współczynników filtra predykcji liniowej dla czterech różnych rodzajów sygnałów akustycznych maszyny synchronicznej z zastosowaniem algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz..... 78</p>	<p>Rys. 4.14. Widmo częstotliwości prądu stojana fazy L1 w stanie uszkodzenia 70 pierścienia klatki 70</p> <p>Rys. 4.15. Widmo częstotliwości prądu stojana fazy L1 w stanie bez uszkodzeń 70</p> <p>Rys. 4.16. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie uszkodzenia dwóch prętów klatki 71</p> <p>Rys. 4.17. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie uszkodzenia jednego pręta klatki 71</p> <p>Rys. 4.18. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie uszkodzenia pierścienia klatki 71</p> <p>Rys. 4.19. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie bez uszkodzeń 71</p> <p>Rys. 4.20. Prąd wzbudzenia w stanie zwarcia sześciu zezwojów 77</p> <p>Rys. 4.21. Prąd wzbudzenia w stanie zwarcia trzech zezwojów 77</p> <p>Rys. 4.22. Prąd wzbudzenia w stanie przerwy jednego zezwoju 77</p> <p>Rys. 4.23. Prąd wzbudzenia w stanie bez uszkodzeń 77</p> <p>Rys. 4.24. Prąd twornika w stanie zwarcia sześciu zezwojów 78</p> <p>Rys. 4.25. Prąd twornika w stanie zwarcia trzech zezwojów 78</p> <p>Rys. 4.26. Prąd twornika w stanie przerwy jednego zezwoju 78</p> <p>Rys. 4.27. Prąd twornika w stanie bez uszkodzeń 78</p> <p>Rys. 4.28. Napięcie wzbudzenia w stanie zwarcia sześciu zezwojów 79</p> <p>Rys. 4.29. Napięcie wzbudzenia w stanie zwarcia trzech zezwojów 79</p> <p>Rys. 4.30. Napięcie wzbudzenia w stanie przerwy jednego zezwoju 79</p> <p>Rys. 4.31. Napięcie wzbudzenia w stanie bez uszkodzeń 79</p> <p>Rys. 4.32. Napięcie twornika w stanie zwarcia sześciu zezwojów 80</p> <p>Rys. 4.33. Napięcie twornika w stanie zwarcia trzech zezwojów 80</p> <p>Rys. 4.34. Napięcie twornika w stanie przerwy jednego zezwoju 80</p> <p>Rys. 4.35. Napięcie twornika w stanie bez uszkodzeń 80</p> <p>Rys. 4.36. Widmo częstotliwości prądu wzbudzenia w stanie zwarcia sześciu zezwojów 81</p> <p>Rys. 4.37. Widmo częstotliwości prądu wzbudzenia w stanie zwarcia trzech zezwojów 81</p> <p>Rys. 4.38. Widmo częstotliwości prądu wzbudzenia w stanie przerwy jednego zezwoju 82</p> <p>Rys. 4.39. Widmo częstotliwości prądu wzbudzenia w stanie bez uszkodzeń 82</p> <p>Rys. 4.40. Widmo częstotliwości prądu twornika w stanie zwarcia sześciu zezwojów 82</p> <p>Rys. 4.41. Widmo częstotliwości prądu twornika w stanie zwarcia trzech zezwojów 82</p> <p>Rys. 4.42. Widmo częstotliwości prądu twornika w stanie przerwy jednego zezwoju 83</p> <p>Rys. 4.43. Widmo częstotliwości prądu twornika w stanie bez uszkodzeń 83</p> <p>Rys. 4.44. Widmo częstotliwości napięcia wzbudzenia w stanie zwarcia sześciu zezwojów 83</p> <p>Rys. 4.45. Widmo częstotliwości napięcia wzbudzenia w stanie zwarcia trzech zezwojów 83</p> <p>Rys. 4.46. Widmo częstotliwości napięcia wzbudzenia w stanie przerwy jednego zezwoju 84</p> <p>Rys. 4.47. Widmo częstotliwości napięcia wzbudzenia w stanie bez uszkodzeń 84</p> <p>Rys. 4.48. Widmo częstotliwości napięcia twornika w stanie zwarcia sześciu zezwojów 84</p> <p>Rys. 4.49. Widmo częstotliwości napięcia twornika w stanie zwarcia trzech zezwojów 84</p> <p>Rys. 4.50. Widmo częstotliwości napięcia twornika w stanie przerwy jednego zezwoju 85</p> <p>Rys. 4.51. Widmo częstotliwości napięcia twornika w stanie bez uszkodzeń 85</p>
--	---

- Rys. 4.7.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami stojana, **c)** z jedną przerwą w obwodzie stojana, **d)** z trzema przerwami w obwodzie stojana..... 80
- Rys. 4.8.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej 81
- Rys. 4.9.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej 82
- Rys. 4.10.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników cepstralnych dla maszyny synchronicznej..... 83
- Rys. 4.11.** Porównanie dziesięciu współczynników cepstralnych dla czterech różnych rodzajów sygnałów akustycznych maszyny synchronicznej po zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz..... 83
- Rys. 4.12.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami stojana, **c)** z jedną przerwą w obwodzie stojana, **d)** z trzema przerwami w obwodzie stojana.... 84
- Rys. 4.13.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej..... 85
- Rys. 4.14.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej 86
- Rys. 4.15.** Widmo częstotliwości sygnału akustycznego maszyny prądu stałego dla dwóch różnych stanów pracy przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i FFT 89
- Rys. 4.16.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny prądu stałego: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami wirnika 90
- Rys. 4.17.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego..... 91
- Rys. 4.18.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego..... 92
- Rys. 4.19.** Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników filtra predykcji liniowej dla maszyny prądu stałego..... 93

Rys. 4.20. Porównanie siedmiu współczynników filtra predykcji liniowej dla dwóch różnych rodzajów sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i LPC.....	93
Rys. 4.21. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566, LPC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny prądu stałego: a) bez uszkodzeń, b) ze zwartymi zezwojami wirnika	94
Rys. 4.22. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego.....	95
Rys. 4.23. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego.....	96
Rys. 4.24. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników cepstralnych dla maszyny prądu stałego	97
Rys. 4.25. Porównanie trzynastu współczynników cepstrum dla dwóch różnych rodzajów sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i LPCC.....	98
Rys. 4.26. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji, stosowanej metryki dla maszyny prądu stałego: a) bez uszkodzeń, b) ze zwartymi zezwojami wirnika.....	99
Rys. 4.27. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego.....	100
Rys. 4.28. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego.....	101
Rys. 4.29. Filtr antyaliasingowy Butterwortha [114].....	102
Rys. 4.30. Widmo częstotliwości prądu wzbudzenia maszyny synchronicznej dla czterech różnych stanów pracy po zastosowaniu algorytmu wybierania amplitudy dla częstotliwości 100 Hz....	103
Rys. 4.31. Widmo częstotliwości prądu twornika maszyny prądu stałego dla dwóch różnych stanów pracy po zastosowaniu algorytmu wybierania amplitudy dla częstotliwości 46,6 Hz	104
Rys. 5.1. Schemat połączeń sprzętu dla urządzenia monitorującego maszynę elektryczną	106
Rys. 5.2. Schemat blokowy układu ISD5100 [110].....	107
Rys. 5.3. Diagram aplikacji ISD5100 [110].....	107
Rys. 5.4. Schemat blokowy układu HT2860 [28].....	108
Rys. 5.5. Schemat elektryczny generatora sygnałów akustycznych [28].....	109
Rys. 5.6. Układ zasilania urządzenia monitorującego maszynę elektryczną.....	109
Rys. 5.7. Diagram przypadków użycia urządzenia monitorującego maszynę elektryczną.....	110
Rys. 5.8. Diagram czynności trybu monitorowania dla zmodyfikowanego klasyfikatora NM.....	110
Rys. C1. Schemat uzwojeń stojana dla maszyny synchronicznej bez uszkodzeń	146
Rys. C2. Schemat uzwojeń stojana dla maszyny synchronicznej ze zwartymi zezwojami (U3-X3)	146
Rys. C3. Schemat uzwojeń stojana dla pracy maszyny synchronicznej z jedną przerwą	

Rys. 5.1. Schemat połączeń sprzętu dla urządzenia monitorującego silnik elektryczny	94
Rys. 5.2. Schemat blokowy układów DaqLab/2001 i DaqLab/2005 [127]	95
Rys. 5.3. Przykład skanowania [127]	95
Rys. 5.4. Schemat blokowy układu ISD9160 [125]	96
Rys. 5.5. Diagram przypadków użycia urządzenia monitorującego silnik elektryczny	97

(X1-X4)	146
Rys. C4. Schemat uzwojeń stojana dla pracy maszyny synchronicznej z trzema przerwami (X1-X4, Y1-Y4, Z1-Z4).....	147
Rys. C5. Badana maszyna synchroniczna ze wzбудzeniem elektromagnetycznym	147
Rys. C6. Schemat uzwojeń wirnika maszyny prądu stałego bez uszkodzeń.....	148
Rys. C7. Schemat uzwojeń wirnika maszyny prądu stałego ze zwartymi zezwojami.....	149
Rys. C8. Badana maszyna prądu stałego obcowzbudna.....	150
Rys. D1. Wyniki rozpoznawania sygnałów akustycznych po uruchomieniu SARSA w trybie niemonitorowania dla pięciosekundowych próbek dźwięku maszyny synchronicznej bez uszkodzeń.....	153

SPIS TABEL

Tab. 4.1. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Manhattan	126
Tab. 4.2. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Euklidesa.....	127
Tab. 4.3. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$	127
Tab. 4.4. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$	127
Tab. 4.5. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$	128
Tab. 4.6. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$	128
Tab. 4.7. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką kosinusową	128
Tab. 4.8. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Jacquarda	129
Tab. 4.9. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na słowach	129
Tab. 4.10. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na sieci neuronowej	129

Rys. C6. Schemat uzwojeń wirnika silnika prądu stałego bez uszkodzeń	134
Rys. C7. Schemat uzwojeń wirnika silnika prądu stałego ze zwartymi zezwojami	135
Rys. C8. Badany silnik prądu stałego obcowzbudny	136

SPIS TABEL

Tab. 4.1. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	73
Tab. 4.2. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	73
Tab. 4.3. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	74
Tab. 4.4. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	74
Tab. 4.5. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	75
Tab. 4.6. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	75
Tab. 4.7. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	75
Tab. 4.8. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek	76

przetawienie:

Tab. 4.25. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej	120
Tab. 4.26. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN	121
Tab. 4.27. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa.....	121
Tab. 4.28. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA	122
Tab. 4.29. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej	122
Tab. 4.30. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN	

<p>Tab. 4.11. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Manhattan..... 130</p> <p>Tab. 4.12. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa..... 130</p> <p>Tab. 4.13. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$..... 130</p> <p>Tab. 4.14. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$..... 131</p> <p>Tab. 4.15. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$..... 131</p> <p>Tab. 4.16. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$..... 131</p> <p>Tab. 4.17. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką kosinusową..... 132</p> <p>Tab. 4.18. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu, algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda..... 132</p> <p>Tab. 4.19. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na słowach..... 132</p> <p>Tab. 4.20. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na sieci neuronowej..... 133</p> <p>Tab. 4.21. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Manhattan..... 133</p> <p>Tab. 4.22. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa..... 133</p> <p>Tab. 4.23. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$..... 134</p> <p>Tab. 4.24. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$..... 134</p> <p>Tab. 4.25. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$..... 134</p>	<p>..... 123</p> <p>Tab. 4.31. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa..... 123</p> <p>Tab. 4.32. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA..... 124</p> <p>[brak wyników]</p> <p>[brak wyników]</p>
---	---

Tab. 4.26. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$	135
Tab. 4.27. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką kosinusową	135
Tab. 4.28. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda	135
Tab. 4.29. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na słowach	136
Tab. 4.30. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na sieci neuronowej	136
Tab. 4.31. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Manhattan	137
Tab. 4.32. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Euklidesa.....	137
Tab. 4.33. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$	137
Tab. 4.34. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$	137
Tab. 4.35. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$	138
Tab. 4.36. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$	138
Tab. 4.37. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką kosinusową	138
Tab. 4.38. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Jacquarda	138
Tab. 4.39. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na słowach	139
Tab. 4.40. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na sieci neuronowej	139

Tab. 4.9. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	87
Tab. 4.10. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek	87
Tab. 4.11. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	87
Tab. 4.12. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek	87
Tab. 4.13. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	88
Tab. 4.14. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek	88
Tab. 4.15. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	88
Tab. 4.16. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek	89
Tab. 4.17. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	89
Tab. 4.18. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek	89
Tab. 4.19. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	90
Tab. 4.20. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek	90
Tab. 4.21. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	90
Tab. 4.22. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek	91
Tab. 4.23. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek	91
Tab. 4.24. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek	91

Tab. 4.33. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora	
---	--

<p>Tab. 4.41. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Manhattan 139</p> <p>Tab. 4.42. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa..... 139</p>	<p>opartego na sieci neuronowej 124</p> <p>Tab. 4.34. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN 125</p> <p>Tab. 4.35. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa..... 125</p> <p>Tab. 4.36. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA 126</p> <p>Tab. 4.37. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej 126</p> <p>Tab. 4.38. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN 127</p> <p>Tab. 4.39. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa..... 127</p> <p>Tab. 4.40. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA 128</p> <p>Tab. 4.41. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej 128</p> <p>Tab. 4.42. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN 129</p> <p>Tab. 4.43. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa..... 129</p> <p>Tab. 4.44. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA 130</p> <p>Tab. 4.45. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej 130</p> <p>Tab. 4.46. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN 131</p> <p>Tab. 4.47. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa..... 131</p> <p>Tab. 4.48. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA 132</p> <p>[brak wyników]</p>
--	---

Tab. 4.43. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$	140
Tab. 4.44. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$	140
Tab. 4.45. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$	140
Tab. 4.46. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$	140
Tab. 4.47. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką kosinusową	141
Tab. 4.48. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda	141
Tab. 4.49. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na słowach	141
Tab. 4.50. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na sieci neuronowej	141
Tab. 4.51. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Manhattan	142
Tab. 4.52. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa.....	142
Tab. 4.53. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$	142
Tab. 4.54. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$	142
Tab. 4.55. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$	143
Tab. 4.56. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$	143
Tab. 4.57. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką kosinusową	143
Tab. 4.58. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda	143
Tab. 4.59. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na słowach	144

[brak wyników]

Tab. 4.60. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na sieci neuronowej 144

1. WSTĘP

Badanie sygnałów akustycznych prowadzone jest aktualnie na świecie w odniesieniu do rozpoznawania: tożsamości mówców, gatunków zwierząt, rodzajów instrumentów muzycznych oraz innych rodzajów sygnałów akustycznych pochodzących ze środowiska naturalnego [9], [24], [55], [75], [93], [115]. Głównym problemem w powoływanych pracach jest dobór metod przetwarzania danych i w konsekwencji metod rozpoznawania, które istotnie zależą od właściwości rozpatrywanego sygnału i celu prowadzonego rozpoznawania. Eksperymenty wykorzystujące sygnały akustyczne do rozpoznawania uszkodzeń urządzeń pojawiły się dość niedawno i tym samym w naturalny sposób nie obejmują szeregu ważnych i interesujących z powodów poznawczych i utylitarnych przypadków technicznych [55], [90], [95].

W sytuacji krótko zarysowanej powyżej pojawia się obiecujący pomysł, aby przeprowadzić badania sygnałów akustycznych również w celu diagnozowania stanów przedawaryjnych maszyn elektrycznych. W przyjętym rozumowaniu powstanie stanu przedawaryjnego interpretowane jest jako zagrożenie istotnym uszkodzeniem maszyny. Często bywa tak, że naprawa maszyny kosztuje mniej, gdy uszkodzenie zostanie wykryte wcześniej i dlatego właśnie badanie stanów przedawaryjnych okazuje się tak ważne.

WSTĘP

W wielu ośrodkach naukowych na świecie prowadzone są aktualnie badania różnych sygnałów pomiarowo dostępnych, które mogą być użyte w diagnostyce technicznej i medycznej. W badaniach tych odnaleźć można wiele cech wspólnych, na przykład ogólny schemat rozpoznawania jest taki sam, niezależnie od tego co się rozpoznaje, natomiast prace te są bardzo zróżnicowane, gdy skupimy uwagę na szczegółach. Ale właśnie te szczegóły decydują zwykle o przydatności i użyteczności różnych metod do poszczególnych celów, dlatego niniejsza praca skoncentrowana jest właśnie na przebadaniu i dopracowaniu szczegółów. W pracy ograniczymy się do zagadnienia rozpoznawania uszkodzeń silników elektrycznych, a badania opisane w pracy skupiają się na dobieraniu metod przetwarzania danych w zależności od rozpatrywanego sygnału. Prowadzone prace oparte zostały mocno na danych literaturowych. Informacje o uszkodzeniach silników elektrycznych zawarte są w sygnałach: prądowych [44], [45], [49], [50], [52], [53], [54], napięciowych [51], akustycznych [34], [35], [36], [40], [42], [43], [46], [47], [48], termowizyjnych [1], [7], [8], [22], [37], [38], [39], [57], [71], mocy elektrycznej [16], siły elektromagnetycznej [116], naprężeń mechanicznych [5], [10], [96], [104].

Dla klasy układów elektromechanicznych, jakimi są rozważane tu silniki elektryczne, metodyczne podstawy analizy stanowi teoria obwodów oraz teoria systemów elektromechanicznych [12], [62], [67], [69], [70], [73], [80], [81], [85], [96]. Większość prac w literaturze dotyczy stanów bezawaryjnych i awaryjnych [6], [11], [18], [19], [20], [56], [60], [78], [98], [100], [101], [104], [105], [106], [111], [113], [118], [120], a tylko w nielicznych opracowaniach przedmiotem zainteresowania autorów są **stany przedawaryjne** [34], [36]. Tymczasem właśnie te stany są ważne dla osób odpowiedzialnych za eksploatację silników i metody automatycznej identyfikacji tych stanów mają duże znaczenie praktyczne, jak również są ważne z punktu widzenia kompletności wiedzy naukowej na temat możliwości automatyzacji diagnostyki technicznej rozważanej klasy maszyn elektrycznych. Eksperymenty wykorzystujące sygnały prądowe i napięciowe do rozpoznawania stanów przedawaryjnych powinny być wykonane w celu diagnozowania tych stanów ponieważ naprawa maszyny kosztuje mniej, gdy uszkodzenie zostanie wykryte wcześniej. W przyjętym tu rozumowaniu powstanie stanu przedawaryjnego interpretowane jest jako zagrożenie uszkodzenia maszyny, do którego można nie dopuścić.

W niniejszej rozprawie doktorskiej skupiono się na metodyce diagnostycznej, która oparta jest na analizie prądów i napięć wybranych maszyn elektrycznych. Dla sformułowania tezy rozprawy doktorskiej przyjęto stwierdzenie, że istnieje możliwość zbudowania stanowiska do badania sygnałów prądowych i napięciowych w warunkach eksperymentalnie wywoływanych stanów przedawaryjnych silników elektrycznych.

Przy takim podejściu, w przekonaniu autora, można postawić następującą tezę:

Zastosowanie algorytmów rozpoznawania umożliwia użycie metod analizy sygnału akustycznego do efektywnej diagnostyki stanów przedawaryjnych maszyn elektrycznych.

Kluczem do przeprowadzenia tezy jest zbudowanie skomputeryzowanego stanowiska do badania sygnałów akustycznych emitowanych przez maszyny elektryczne, które pozwalałoby cyfrowo rejestrować, wszechstronnie przetwarzać (obrabiać) sygnał, dobrać właściwą metodę ekstrakcji cech dystynktywnych, a następnie metodę rozpoznawania pozwalającą na wykrycie zaistnienia jednego z właściwych danej maszyny elektrycznej stanu przedawaryjnego.

Wykazanie powyżej sformułowanej tezy pociąga za sobą konieczność przeprowadzenia następujących zadań badawczych: opracowanie problemu diagnostyki stanów przedawaryjnych maszyn elektrycznych, opracowanie planu badań sygnału akustycznego maszyn elektrycznych, opracowanie projektu i zbudowanie stanowiska do badania sygnałów akustycznych maszyn oraz ukierunkowane przeprowadzenie analizy sygnałów akustycznych wybranych maszyn elektrycznych.

Zasadniczym dla dysertacji zadaniem jest zaprojektowanie środowiska. W ramach tego zadania zaproponowano sprzęt i oprogramowanie, które właściwie zintegrowane daje funkcjonalności niezbędne do właściwego dobierania metod rozpoznawania sygnału akustycznego dla różnych stanów przedawaryjnych oraz różnych typów maszyn elektrycznych.

Jako zadanie uzupełniające dodano opracowanie projektu urządzenia monitorującego w trybie ciągłym maszynę elektryczną, bazującego na wynikach analiz przeprowadzonych za pomocą stanowiska. Wyniki zadania ostatecznie wskazują możliwości praktycznych zastosowań wyników dysertacji.

Warto zauważyć, że uzasadnienie prawdziwości tezy potwierdza również założenie robocze poczynione dla całej dysertacji, iż sygnał akustyczny zawiera użyteczną informację o stanie pracy maszyny elektrycznej.

Oczywistym ograniczeniem proponowanego podejścia jest fakt, że nie każda maszyna generuje sygnały akustyczne. Inne ograniczenia wynikają z konieczności dokonania ingerencji w konstrukcję maszyny, które symulują zachodzenie badanego uszkodzenia, testowa maszyna musi być odpowiednio zmodyfikowana. Koniecznością z punktu widzenia ekonomiczności tego rodzaju diagnostyki jest przyjęcie założenia, że możliwe i wystarczające będzie przeniesienie wyników uzyskanych dla maszyny testowej na wszystkie maszyny tego samego typu produkowanych przez danego producenta. Tym samym przyjmuje się, że rozrzut parametrów maszyn określonego typu nie ma istotnego wpływu na wyniki badań

Przy takim podejściu można postawić następującą tezę:

Zastosowanie wskazanych w rozprawie algorytmów rozpoznawania umożliwia użycie metod analizy sygnałów prądowych i napięciowych do efektywnej diagnostyki stanów przedawaryjnych silników elektrycznych.

Dążenie do wykazania tak sformułowanej tezy pociąga za sobą konieczność realizacji następujących zadań badawczych:

- opracowanie od strony literaturowej problemu diagnostyki stanów przedawaryjnych silników elektrycznych,
- opracowanie planu badań sygnałów prądowych i napięciowych dla stanów przedawaryjnych silników elektrycznych,
- opracowanie projektu i zbudowanie stanowiska do badania sygnałów prądowych i napięciowych dla stanów przedawaryjnych wybranych silników,
- przeprowadzenie analizy sygnałów prądowych i napięciowych wybranych silników elektrycznych w różnych stanach ich pracy ze szczególnym uwzględnieniem stanów przedawaryjnych oraz
- opracowanie projektu urządzenia monitorującego silnik elektryczny, alarmującego obsługę w momencie wykrycia cech sygnałów znamiennej dla stanów przedawaryjnych.

Dla udowodnienia powyższej tezy pracy doktorskiej założono, że sygnały prądowe i napięciowe zawierają informację o stanie pracy silnika elektrycznego wystarczającą dla identyfikacji stanów przedawaryjnych. Należało jednak ustalić, które sygnały, jak zbierane i jak przetwarzane mogą stanowić podstawę do automatycznej identyfikacji stanów przedawaryjnych. W związku z tym należało zaproponować taki ciąg badań sygnału, aby wydobyć informację użyteczną z punktu widzenia diagnostyki. Podstawowym zadaniem było zaprojektowanie środowiska, w którym sygnały prądowe i napięciowe będą przetwarzane i analizowane. Zaproponowane podejście umożliwiło sprecyzowanie dalszych zadań systemu. Kolejno zostało zaproponowane oprogramowanie i została zrealizowana integracja stanowiska do badania sygnałów prądowych i napięciowych w silnikach elektrycznych. Środowisko łączyło sprzęt i oprogramowanie, potrzebne do właściwego przetwarzania i analizy sygnałów prądowych i napięciowych.

proponowanych w pracy. Dlatego też jeszcze raz podkreślić trzeba rolę środowiska do badania, które pracuje nie tylko dla uzyskania wyników zamieszczonych w dysertacji, ale będzie również używane wtedy, gdy proponowanym sposobem diagnostyki trzeba będzie objąć nowy typ maszyny.

Kolejne rozdziały dysertacji omawiają zarysowane powyżej zadania badawcze. W rozdziale pierwszym przedstawiono problemy rozpoznawania stanów przedawaryjnych maszyn elektrycznych. Rozdział drugi omawia techniki analizy informacji zawartej w sygnałach akustycznych maszyn elektrycznych. W ramach rozdziału trzeciego opracowano projekt stanowiska do badania sygnałów akustycznych. W rozdziale czwartym opisano eksperymenty oraz wyniki badania sygnałów, zmierzające do skonfigurowania metod przetwarzania i analizy w celu uzyskania jak najlepszego wariantu metod rozpoznawania dla dwóch wybranych typów maszyn. Następnie przeprowadzono weryfikację uzyskanych wyników przez konfrontację ich z przebiegami prądu dla badanych maszyn. W rozdziale piątym omówiono projekt urządzenia monitorującego maszynę elektryczną w ruchu. Rozdział szósty podsumowuje rezultaty opisane w dysertacji.

W dodatku A przedstawiono wykaz ważniejszych skrótów w tekście. W dodatku B podano wyniki rozpoznawania sygnałów akustycznych dla wybranych maszyn elektrycznych. W dodatku C przedstawiono opis badanych stanów maszyn elektrycznych. W dodatku D omówiono instalacje i uruchamianie systemu automatycznego rozpoznawania sygnału akustycznego.

Stanowisko badawcze służyło do właściwego dobierania metod rozpoznawania sygnałów prądowych i napięciowych dla różnych stanów przedawaryjnych oraz różnych typów silników elektrycznych. W dalszej kolejności został zaproponowany projekt małego urządzenia monitorującego silnik elektryczny w ruchu.

Aby jednak przeanalizować sygnały prądowe i napięciowe silnika elektrycznego, należy je wygenerować. Rozważania prowadzone w niniejszej pracy dotyczyć będą wybranych silników elektrycznych, które generują sygnały prądowe i napięciowe. Zakłada się, że liczba badanych silników elektrycznych tego samego typu jest ograniczona. Wynika z tego, że w dalszym ciągu badań nie bierze się pod uwagę silników tego samego typu z rozrzutem własności, powstałym na etapie wytwarzania. Jest to ważne założenie ponieważ silniki elektryczne tego samego typu będące w tym samym stanie w kontekście rozważanego w pracy problemu wykrywania stanów przedawaryjnych, mogą generować inne sygnały prądowe i napięciowe, powodując tym samym, że diagnostyka nowego nieznanego silnika może być utrudniona. Chcąc przezwyciężyć tę trudność należałoby zbadać jak największą liczbę silników elektrycznych tego samego typu, na co jednak w przypadku tej pracy nie pozwoliły względy kosztowe.

Poszczególne rozdziały pracy doktorskiej podejmują kolejne wyżej wymienione zadania badawcze, które muszą być zrealizowane w celu wykazania słuszności zaprezentowanej tezy. W rozdziale pierwszym przedstawiono problemy rozpoznawania stanów przedawaryjnych silników elektrycznych. Rozdział drugi omawia techniki analizy informacji zawartej w sygnałach prądowych i napięciowych silników elektrycznych. W ramach rozdziału trzeciego opracowano projekt stanowiska do badania sygnałów prądowych i napięciowych z zastosowaniem diagramów UML [77]. W rozdziale czwartym opisano przeprowadzone badania sygnałów, zmierzające do skonfigurowania metod przetwarzania i analizy, w celu uzyskania jak najlepszego wariantu metod rozpoznawania dla danego silnika elektrycznego. Przeprowadzone badania potwierdziły skuteczność proponowanego podejścia. Następnie przeprowadzono weryfikację wyników rozpoznawania sygnałów prądowych i napięciowych. W rozdziale piątym omówiono projekt urządzenia monitorującego silnik elektryczny w ruchu.

W rozdziale szóstym dokonano podsumowania pracy.

1.1. Problemy rozpoznawania stanów przedawaryjnych maszyn elektrycznych

Po raz pierwszy potrzebę diagnozowania stanu pracy urządzeń elektrycznych zauważono w inżynierii elektronicznej przy produkcji i eksploatacji komputerów. Rozwój tej gałęzi przemysłu przyczynił się do opracowania zabiegów i urządzeń diagnostycznych, wskazujących rodzaj i miejsce uszkodzenia w skomplikowanych układach komputerowych.

W konstrukcji, wytwarzaniu i eksploatacji maszyn czynnikiem wpływającym korzystnie na rozwój diagnostyki jest odpowiedzialność za pełnioną funkcję. Odpowiedzialność ta może być wyznaczana w trudno wymiernych kategoriach ekonomicznych lub też bezpieczeństwa ludzi [12]. Początkowo diagnostyka maszyn była wykorzystywana dla środków transportu powietrznego, morskiego oraz w przemyśle energetycznym. Obecnie zaś opracowywane są nowe techniki diagnozujące stan pracy maszyn w innych gałęziach przemysłu [19], [20], [30], [47], [95], [116].

Wyróżnia się trzy czynniki pobudzające rozwój diagnostyki. Pierwszy z nich to złożona struktura systemów produkcyjnych, gdzie awaria jednej z maszyn może zatrzymać całą produkcję fabryki, generując w efekcie olbrzymie straty ekonomiczne. Drugi czynnik, to naprawy dużej liczby maszyn elektrycznych, które pozostają w ciągłym ruchu i to bez jakiegokolwiek nadzoru. Na przykład typowa fabryka chemiczna lub rafineria wykorzystuje w tym samym czasie kilka tysięcy silników. Remont tak dużej liczby maszyn sprawia dużo problemów, jeżeli nie jesteśmy w stanie dokładnie przewidzieć terminu naprawy. Ostatni czynnik to wysoki poziom niezawodności wymagany dla określonych maszyn jednorazowego lub sezonowego użytkowania. Niezawodność taka jest wymagana od pojazdów specjalnych np. samolotów, sprzętu wojskowego, a także rolniczego, gdzie maszyna oczekuje cały rok na kilkudniowy okres pracy [12].

Można by sądzić, że nie powinno być większych problemów w przenoszeniu doświadczeń diagnostycznych z wysoko rozwiniętej inżynierii elektronicznej na obszar diagnostyki maszyn elektrycznych. Niestety, tak nie jest ze względu na różnice w działaniu i zużywaniu się poszczególnych części maszyn. Działanie układów elektronicznych o wysokim stopniu powtarzalności jest dyskretne i zdeterminowane. Z tego też powodu za każdym razem można określić sekwencję stanów funkcjonalnych danego podzespołu elektronicznego. Sekwencja ta w sposób jednoznaczny potwierdza prawidłowość działania danego układu elektronicznego. Natomiast praca i proces zużywania się maszyn elektrycznych mają charakter ciągły, co sprawia, że nie dają podstaw do naturalnego rozgraniczenia stanów. Dodatkowo,

1. PROBLEMY ROZPOZNAWANIA STANÓW PRZEDAWARYJNYCH MASZYN ELEKTRYCZNYCH

Po raz pierwszy potrzebę diagnozowania stanu pracy urządzeń elektrycznych zauważono w inżynierii elektronicznej przy produkcji i eksploatacji komputerów. Rozwój tej gałęzi przemysłu przyczynił się do opracowania zabiegów i urządzeń diagnostycznych, wskazujących rodzaj i miejsce uszkodzenia w skomplikowanych układach elektrycznych wchodzących w skład systemów komputerowych.

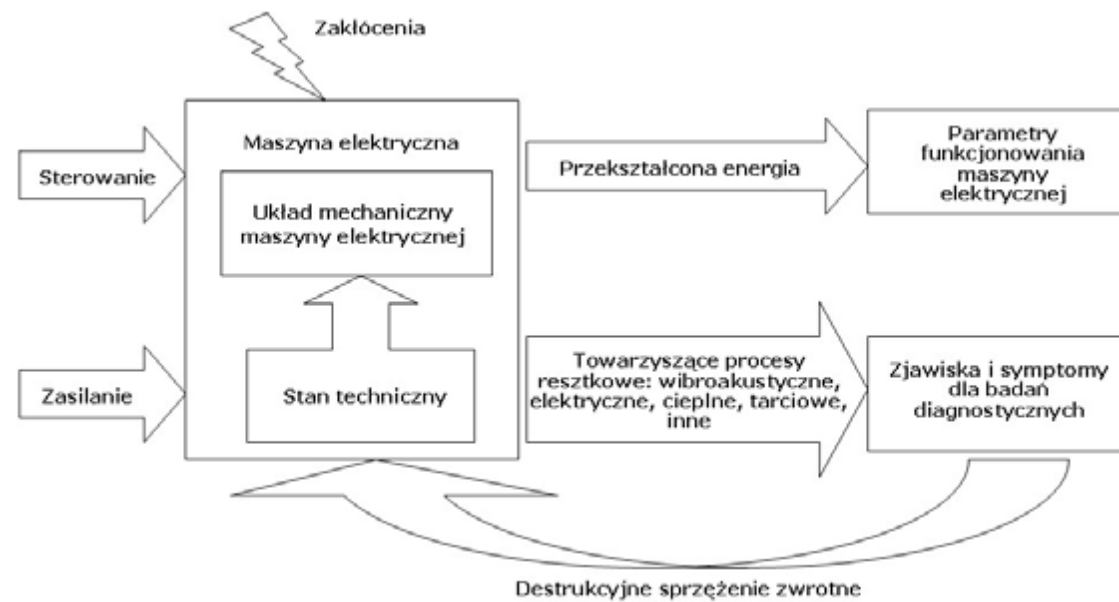
W konstrukcji, wytwarzaniu i eksploatacji maszyn czynnikiem wpływającym korzystnie na rozwój diagnostyki jest odpowiedzialność za pełnioną funkcję. Odpowiedzialność ta może być wyznaczana w kategoriach ekonomicznych lub też w trudno wymiernych kategoriach bezpieczeństwa ludzi. Początkowo diagnostyka maszyn była wykorzystywana dla środków transportu powietrznego, morskiego oraz w przemyśle energetycznym. Obecnie opracowywane są nowe techniki diagnozujące stan pracy maszyn także w innych gałęziach przemysłu.

Wyróżnia się trzy czynniki pobudzające rozwój diagnostyki. Pierwszy z nich to złożona struktura systemów produkcyjnych, gdzie awaria jednej z maszyn może zatrzymać całą produkcję fabryki, generując w efekcie olbrzymie straty ekonomiczne. Drugi czynnik, to konieczność naprawy dużej liczby maszyn elektrycznych, które pozostają w ciągłym ruchu i to bez jakiegokolwiek nadzoru. Na przykład typowa fabryka chemiczna lub rafineria wykorzystuje w tym samym czasie kilka tysięcy silników. Remont tak dużej liczby maszyn sprawia dużo problemów, jeżeli nie jesteśmy w stanie dokładnie przewidzieć terminu naprawy. Ostatni czynnik to wysoki poziom niezawodności wymagany dla określonych maszyn jednorazowego lub sezonowego użytkowania. Niezawodność taka jest wymagana od pojazdów specjalnych np. samolotów, sprzętu wojskowego, a także rolniczego, gdzie maszyna oczekuje cały rok na kilkudniowy okres pracy.

Można by sądzić, że nie powinno być większych problemów w przenoszeniu doświadczeń diagnostycznych z wysoko rozwiniętej inżynierii elektronicznej na obszar diagnostyki maszyn elektrycznych. Niestety, tak nie jest ze względu na różnice w działaniu i zużywaniu się poszczególnych części maszyn. Działanie układów elektronicznych o wysokim stopniu powtarzalności jest dyskretne i zdeterminowane. Z tego też powodu za każdym razem można określić sekwencję stanów funkcjonalnych danego podzespołu elektronicznego. Sekwencja ta w sposób jednoznaczny potwierdza prawidłowość działania danego układu elektronicznego. Natomiast praca i proces zużywania się maszyn elektrycznych mają charakter ciągły, co sprawia, że nie dają podstaw do naturalnego rozgraniczenia stanów. Dodatkowo,

elementy maszyn elektrycznych charakteryzują się większym niż elementy elektroniczne rozrzutem własności, powstałym na etapie wytwarzania. Nieoznaczoność i ciągłość procesu zużywania się maszyn elektrycznych powodują problemy w diagnostyce. Wobec tego, mając podobne cele, należy opracować odpowiednie techniki diagnozowania.

Rola nauki w diagnostyce skupia się na opracowywaniu niezawodnych technik i metod realizacji określonych zadań. Sposoby prawidłowej oceny stanu pracy maszyn elektrycznych wynikają z badań. Diagnostyka koncentruje się na pomiarach dostępnych dla obserwacji symptomów stanu technicznego i opracowaniu wniosków, na podstawie uzyskanego zbioru danych oraz posiadanej wiedzy o danej maszynie elektrycznej [12], [13], [71], [89]. W celu zrealizowania badań diagnostycznych analizuje się maszynę elektryczną jako system z przepływem energii i informacji, przedstawiony na rysunku 1.1.

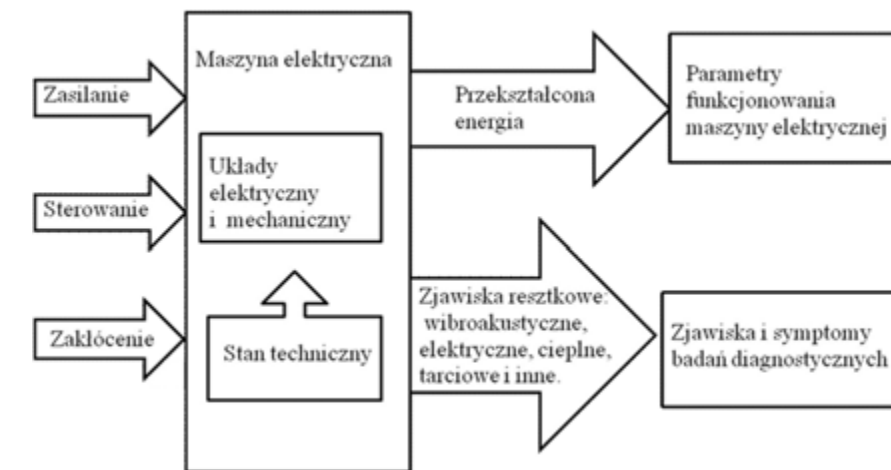


Rys. 1.1. Maszyna elektryczna jako system z przepływem energii i informacji [12]

Pierwszym wejściem układu maszyny elektrycznej jest zasilanie w energię elektryczną, odpowiedzialne jest ono za przepływ energii i oddziaływań siłowych w maszynie. Patrząc od strony diagnostyki stan tego wejścia jest ważny, ale nieczęsto taka informacja jest dostępna bezpośrednio. Bardzo podobnie przedstawia się sytuacja w przypadku wejścia sterowania, które określa sposób pracy maszyny elektrycznej, jak również wejścia zakłóceń wytworzonego we współdziałaniu maszyny elektrycznej z otoczeniem. Na ogół procedura określania stanu technicznego przez obserwację różnych symptomów uszkodzeń musi brać pod uwagę nieznaną wszystkich wejść rozpatrywanego układu maszyny. W diagnostyce maszyn elektrycznych można rozważać parametry funkcjonalne, takie jak np. maksymalna moc i prędkość. Taki rodzaj badań diagnostycznych narzuca konieczność okresowego wyłączenia maszyny z ruchu i przeprowadzenia na niej określonych zabiegów. Drugi rodzaj badań diagnostycznych maszyn elektrycznych obejmuje pomiary

elementy maszyn elektrycznych charakteryzują się większym niż elementy elektroniczne rozrzutem własności, powstałym na etapie wytwarzania. Nieoznaczoność własności i ciągłość procesu zużywania się maszyn elektrycznych powodują trudności w ich diagnostyce. Wobec tego, mając podobne cele, należy opracować odpowiednie techniki diagnozowania.

Rola nauki w diagnostyce skupia się na opracowywaniu niezawodnych technik i metod realizacji określonych zadań. Sposoby prawidłowej oceny stanu pracy maszyn elektrycznych wynikają z badań. Diagnostyka koncentruje się na pomiarach dostępnych dla obserwacji symptomów stanu technicznego i opracowaniu wniosków, na podstawie uzyskanego zbioru danych oraz posiadanej wiedzy o danej maszynie elektrycznej. W celu zrealizowania badań diagnostycznych analizuje się maszynę elektryczną jako system z przepływem energii i informacji, przedstawiony na rysunku 1.1.



Rys. 1.1. Maszyna elektryczna jako system z przepływem energii i informacji [10]

Pierwszym wejściem układu maszyny elektrycznej jest zasilanie w energię elektryczną, odpowiedzialne jest ono za przepływ energii i oddziaływań siłowych w maszynie. Patrząc od strony diagnostyki stan tego wejścia jest ważny, ale nieczęsto taka informacja jest dostępna bezpośrednio. Bardzo podobnie przedstawia się sytuacja w przypadku wejścia sterowania, które określa sposób pracy maszyny elektrycznej, jak również wejścia zakłóceń wytworzonego we współdziałaniu maszyny elektrycznej z otoczeniem. Na ogół procedura określania stanu technicznego przez obserwację różnych symptomów uszkodzeń musi brać pod uwagę nieznaną wszystkich wejść rozpatrywanego układu maszyny. W diagnostyce maszyn elektrycznych można rozważać parametry funkcjonalne, takie jak np. maksymalna moc i prędkość. Taki rodzaj badań diagnostycznych narzuca konieczność okresowego wyłączenia maszyny z ruchu i przeprowadzenia na niej określonych zabiegów. Drugi rodzaj badań diagnostycznych

charakterystyk i parametrów świadczących bezpośrednio o zużyciu elementów urządzenia. Między innymi chodzi tu o pomiary odchyłek kształtów w stosunku do wzorcowych elementów sprawnej maszyny. Kolejny rodzaj diagnostyki maszyn elektrycznych polega na badaniach procesów resztkowych, które występują podczas pracy maszyn [12], [95].

Stanem awaryjnym układu nazywamy niezamierzony stan pracy, który wywołuje niepożądane skutki z punktu widzenia prawidłowości jego funkcjonowania. Stanem przedawaryjnym nazywamy niezamierzony stan pracy, w którym pojawiają się symptomy zjawisk charakterystycznych dla stanu awaryjnego (zagięcia, zarysowania, zwarcia obwodów elektrycznych, przerwy w obwodach elektrycznych) [35]. Wyszczególnić można dwie podstawowe grupy technik badań stanów przedawaryjnych maszyn. Pierwsza z nich obejmuje techniki, które do badań używają stymulatora, np. promieniowania rentgenowskiego, fali ultradźwiękowej, pola magnetycznego, źródła światła [12], [95]. Najczęściej techniki zawarte w tej grupie można zastosować tylko do pojedynczych elementów maszyn elektrycznych. Druga grupa technik opiera się na obserwacji procesów resztkowych występujących podczas pracy maszyn. Badania takie można przeprowadzić w prosty sposób analizując produkty zużycia zawarte w olejach hydraulicznych lub smarnych. Znanych jest tu wiele dobrze opracowanych technik takich jak: analiza spektralna oleju SOA (*ang. Spectrometric Oil Analysis*), korki magnetyczne, wkłady filtracyjne, zliczanie cząstek, ferrografia. Przykładowo analiza spektralna oleju daje możliwość rozróżnienia typów uszkodzeń.

Do wykrywania uszkodzeń izolacji cieplnej stosowana jest diagnostyka termiczna. Ten rodzaj diagnostyki korzysta z kamer termowizyjnych i metod rozpoznawania obrazów [6], [12], [26], [92], [95]. Bardzo istotną rolę odgrywa tutaj pomiar temperatury [5], [22]. Niestety, kamera termowizyjna może rejestrować tylko wybrane punkty badanej powierzchni obiektu, co czyni temperaturę niezbyt dobrym nośnikiem informacji o stanie pracy maszyny. Ponadto szybkość temperaturowej reakcji na zmiany stanu badanego obiektu jest mała.

Obecnie istnieją dobrze opracowane techniki rozpoznawania stanów przedawaryjnych maszyn elektrycznych oparte na badaniach prądów, napięć, mocy czynnej [16], [26], [29], [35], [36], [37], [48], [50], [108], [111], [112], [114]. Są one bardzo skuteczne, jednak ich słabą stroną są: trudny dostęp do badanego sygnału i złożone układy pomiarowe.

Dostęp do sygnałów akustycznych maszyny elektrycznej jest łatwiejszy. Analizując dźwięk maszyny możemy skutecznie i szybko ocenić stan jej pracy. Techniki oparte na rozpoznawaniu sygnału akustycznego mogą wykryć stany przedawaryjne zanim nastąpi awaria maszyny elektrycznej. Ograniczeniem tej techniki jest brak sygnału akustycznego lub brak zmian w sygnale [31], [32], [33], [34]. Innymi znanymi technikami diagnostyki są techniki: wizualne (endoskopowe, holograficzne, penetracyjne

maszyn elektrycznych obejmuje pomiary charakterystyk i parametrów świadczących bezpośrednio o zużyciu elementów urządzenia. Między innymi chodzi tu o pomiary odchyłek kształtów w stosunku do wzorcowych elementów sprawnej maszyny. Kolejny rodzaj diagnostyki maszyn elektrycznych polega na badaniach procesów resztkowych, które występują podczas pracy maszyn.

Stanem awaryjnym układu nazywamy niezamierzony stan pracy, który wywołuje niepożądane skutki z punktu widzenia prawidłowości jego funkcjonowania. Stanem przedawaryjnym nazywamy niezamierzony stan pracy, w którym pojawiają się symptomy zjawisk charakterystycznych dla stanu awaryjnego (zagięcia, zarysowania, zwarcia obwodów elektrycznych, przerwy w obwodach elektrycznych). Wyszczególnić można dwie podstawowe grupy technik badań stanów przedawaryjnych maszyn. Pierwsza z nich obejmuje techniki, które do badań używają stymulatora, np. promieniowania rentgenowskiego, fali ultradźwiękowej, pola magnetycznego, źródła światła. Najczęściej techniki zawarte w tej grupie można zastosować tylko do pojedynczych elementów maszyn elektrycznych. Druga grupa technik opiera się na obserwacji procesów resztkowych występujących podczas pracy maszyn. Badania takie można przeprowadzić w prosty sposób analizując produkty zużycia zawarte w olejach hydraulicznych lub smarnych. Znanych jest tu wiele dobrze opracowanych technik takich jak: analiza spektralna oleju SOA (*ang. Spectrometric Oil Analysis*), korki magnetyczne, wkłady filtracyjne, zliczanie cząstek, ferrografia. Przykładowo analiza spektralna oleju daje możliwość rozróżnienia typów uszkodzeń.

Do wykrywania uszkodzeń izolacji cieplnej stosowana jest diagnostyka termiczna. Ten rodzaj diagnostyki korzysta z kamer termowizyjnych i metod rozpoznawania obrazów. Bardzo istotną rolę odgrywa tutaj pomiar temperatury. Niestety, kamera termowizyjna może rejestrować tylko wybrane punkty badanej powierzchni obiektu, co czyni temperaturę niezbyt dobrym nośnikiem informacji o stanie pracy maszyny. Ponadto szybkość zmian temperatury w ciałach stałych nie jest duża.

Obecnie istnieją dobrze opracowane techniki rozpoznawania stanów przedawaryjnych maszyn elektrycznych oparte na badaniach prądów, napięć, mocy czynnej. Są one bardzo skuteczne, jednak ich słabą stroną są: trudny dostęp do badanego sygnału i złożone układy pomiarowe.

Dostęp do sygnałów prądowych i napięciowych maszyny elektrycznej jest trudniejszy niż do sygnałów akustycznych i termicznych. Analizując sygnały prądowe i napięciowe maszyny możemy skutecznie i szybko ocenić stan jej pracy. Techniki oparte na rozpoznawaniu sygnałów prądowych i napięciowych mogą wykryć stany przedawaryjne zanim nastąpi awaria maszyny elektrycznej. Ograniczeniem tej techniki jest brak dostępu do sygnałów prądowych i napięciowych lub brak zmian w sygnałach. Innymi znanymi technikami diagnostyki są techniki: wizualne (endoskopowe, holograficzne,

barwne, fluorescencyjne), magnetyczne (proszkowe, wiroprądowe), radiograficzne (rentgenowska, izotropowa, neutronowa), ultradźwiękowe, wibroakustyczne.

Głównym celem badań diagnostycznych maszyn elektrycznych jest ocena ich stanu technicznego, lub stopnia zużycia poszczególnych części, takich jak: wał wirnika i układ izolacyjny. Wczesna detekcja zapoczątkowanego uszkodzenia maszyny elektrycznej umożliwia podjęcie odpowiednich zabiegów diagnostycznych, takich jak na przykład przegląd. Zabiegi te pozwalają uniknąć znacznych awarii oraz związanych z tym długich, nieoczekiwanych postojów, co pozwala zaoszczędzić znaczne sumy pieniędzy.

Badania diagnostyczne stosuje się w miejscach, gdzie różne niesprawności urządzenia mogą być zaobserwowane na podstawie zmiany rozkładu temperatury na jego powierzchni. Znalezione w ten sposób anomalie elektryczne, mechaniczne, temperaturowe, mogą zostać usunięte. Wskutek tego ryzyko wystąpienia awarii jest mniejsze. W przypadku, gdy uszkodzenia nie zostaną zlokalizowane we właściwym czasie, wówczas mogą doprowadzić do awarii maszyny, a nawet utraty zdrowia operatora obsługującego urządzenie. Maszyny elektryczne w swoim istnieniu przechodzą przez trzy następujące etapy: konstruowanie, wytwarzanie i eksploatację. Diagnostykę stosuje się podczas trwania każdego z tych etapów. Syntetyczne ujęcie celów poszczególnych rodzajów diagnostyki w przemyśle zostało pokazane na rysunku 1.2. Do podjęcia decyzji o przejściu z jednego etapu do kolejnego potrzebne są odpowiednie metody wartościowania jakości stanu technicznego nowego wytworu.

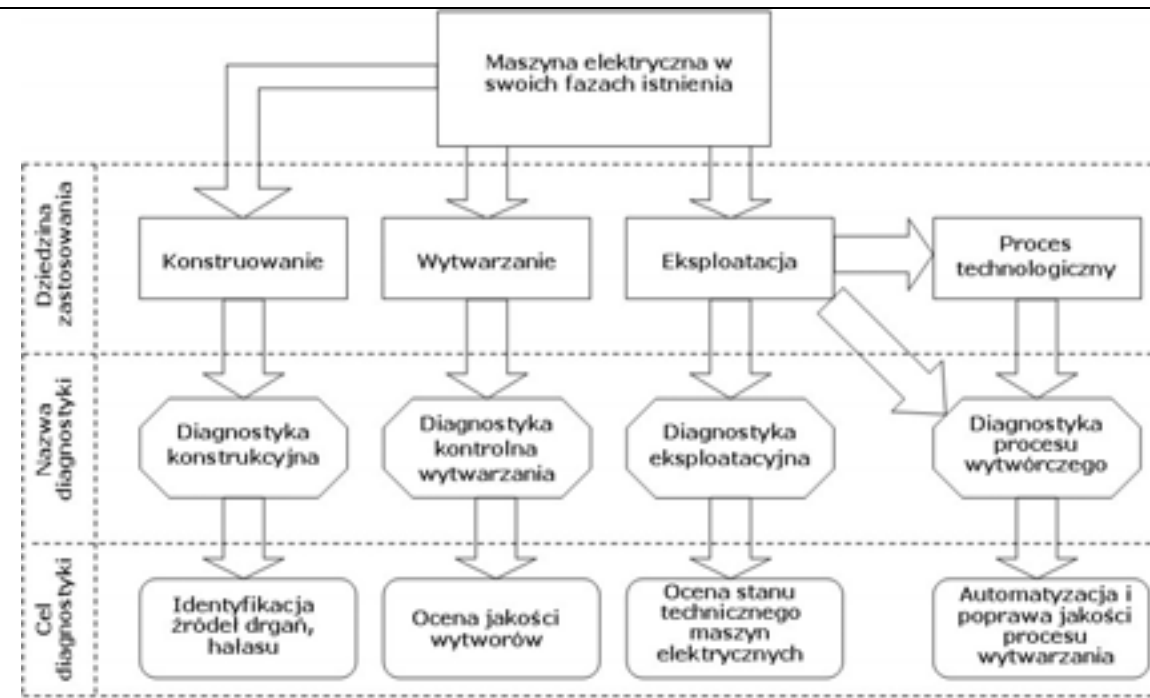
Ważnym elementem eksploatacji maszyn jest ich naprawa, która może obejmować regulację lub wymianę odpowiednich podzespołów. Informacje dostarczone z obserwacji diagnostycznych maszyn elektrycznych umożliwiają zaplanowanie rozmiarów i terminów przeglądów, razem z przygotowaniem odpowiednich części do wymiany. Ponadto, badanie maszyny tuż po naprawie pozwala ocenić jakość zabiegów naprawczych i uniknąć użytkowania maszyny elektrycznej o niepełnej zdatności. Jest to bardzo ważne z ekonomicznego punktu widzenia, ponieważ zaoszczędza się wówczas duże środki finansowe. Z tego też względu warto przeprowadzić badania dla stanów przedawaryjnych maszyn elektrycznych podczas eksploatacji.

penetracyjne barwne, fluorescencyjne), magnetyczne (proszkowe, wiroprądowe), radiograficzne (rentgenowska, izotropowa, neutronowa), ultradźwiękowe, wibroakustyczne.

Głównym celem badań diagnostycznych maszyn elektrycznych jest ocena ich stanu technicznego, lub stopnia zużycia poszczególnych części, takich jak: wał wirnika i układ izolacyjny. Wczesna detekcja zapoczątkowanego uszkodzenia maszyny elektrycznej umożliwia podjęcie odpowiednich zabiegów diagnostycznych, takich jak na przykład przegląd. Zabiegi te pozwalają uniknąć znacznych awarii oraz związanych z tym długich, nieoczekiwanych postojów, co pozwala zaoszczędzić znaczne sumy pieniędzy.

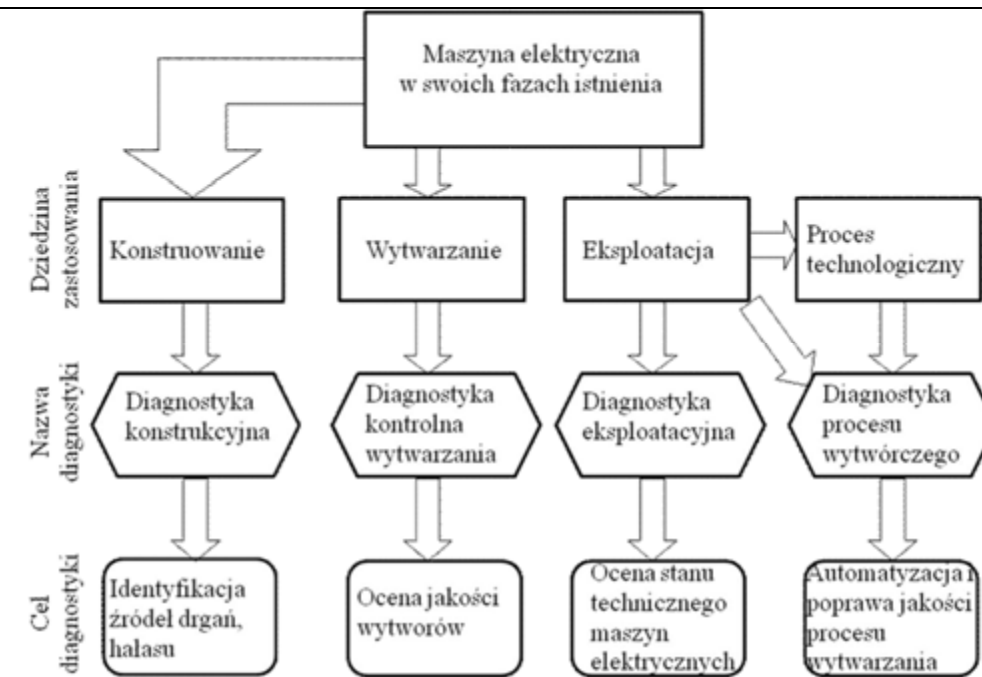
Badania diagnostyczne stosuje się w miejscach, gdzie różne niesprawności urządzenia mogą być zaobserwowane na podstawie zmiany rozkładu temperatury na jego powierzchni. Znalezione w ten sposób anomalie elektryczne, mechaniczne, temperaturowe, mogą zostać usunięte. Wskutek tego ryzyko wystąpienia awarii jest mniejsze. W przypadku, gdy uszkodzenia nie zostaną zlokalizowane we właściwym czasie, wówczas mogą doprowadzić do awarii maszyny, a nawet utraty zdrowia operatora obsługującego urządzenie. Maszyny elektryczne w swoim istnieniu przechodzą przez trzy następujące etapy: konstruowanie, wytwarzanie i eksploatację. Diagnostykę stosuje się podczas trwania każdego z tych etapów. Syntetyczne ujęcie celów poszczególnych rodzajów diagnostyki w przemyśle zostało pokazane na rysunku 1.2. Do podjęcia decyzji o przejściu z jednego etapu do kolejnego potrzebne są odpowiednie metody wartościowania jakości stanu technicznego nowego wytworu.

Ważnym elementem eksploatacji maszyn jest ich naprawa, która może obejmować regulację lub wymianę odpowiednich podzespołów. Informacje dostarczone z obserwacji diagnostycznych maszyn elektrycznych umożliwiają zaplanowanie rozmiarów i terminów przeglądów, razem z przygotowaniem odpowiednich części do wymiany. Ponadto, badanie maszyny tuż po naprawie pozwala ocenić jakość zabiegów naprawczych i uniknąć użytkowania maszyny elektrycznej o niepełnej zdatności. Jest to bardzo ważne z ekonomicznego punktu widzenia, ponieważ zaoszczędza się wówczas duże środki finansowe. Z tego też względu warto przeprowadzić badania dla stanów przedawaryjnych maszyn elektrycznych podczas eksploatacji.



Rys. 1.2. Syntetyczne ujęcie celów poszczególnych rodzajów diagnostyki w przemyśle [12]

Na etapie eksploatacji przedmiotem zabiegów konstruktorów i eksploatorów jest bezawaryjna praca maszyny elektrycznej. Czas pracy jest sprecyzowany przez producenta, o ile spełniony jest warunek przestrzegania zaleceń dokumentacji technicznej. Niemniej jednak w procesie eksploatacji obserwowane są dwa odmienne zjawiska. Pierwsze z nich polega na tym, że dla pewnej grupy maszyn elektrycznych czas pracy jest o wiele krótszy od czasu określonego w dokumentacji technicznej. Drugie charakteryzuje się tym, że naprawy dla pewnej grupy maszyn elektrycznych wykonywane w czasie określonym przez producenta nie znajdują uzasadnienia w ich dobrym stanie technicznym, co więcej naprawa taka zwykle obniża sprawność maszyny. Zjawiska te spowodowane są przez: przypadkowy rozrzut własności nabytych na etapie wytwarzania, pracę maszyn z różnym obciążeniem roboczym, różne oddziaływania z otoczeniem, różnice między pojedynczymi egzemplarzami urządzeń. Procedury bezpieczeństwa i oszczędności związane z utrzymaniem sprzętu skłaniają eksploatorów maszyn elektrycznych do redukcji nieprzewidzianych awarii i napraw. Ponadto procedury te prowadzą do zmniejszenia liczby niepotrzebnych napraw maszyn elektrycznych, które są w dobrym stanie technicznym, pomimo przekroczenia czasu określonego przez producenta. Diagnostyka jest środkiem ochronnym, który może zostać użyty do rozwiązania wymienionych problemów maszyn elektrycznych, bez przerywania ich działania. Diagnostyka ta może obejmować: określenie rodzaju, miejsca, przyczyny uszkodzenia i ocenę zdolności urządzenia do dalszej pracy [12].

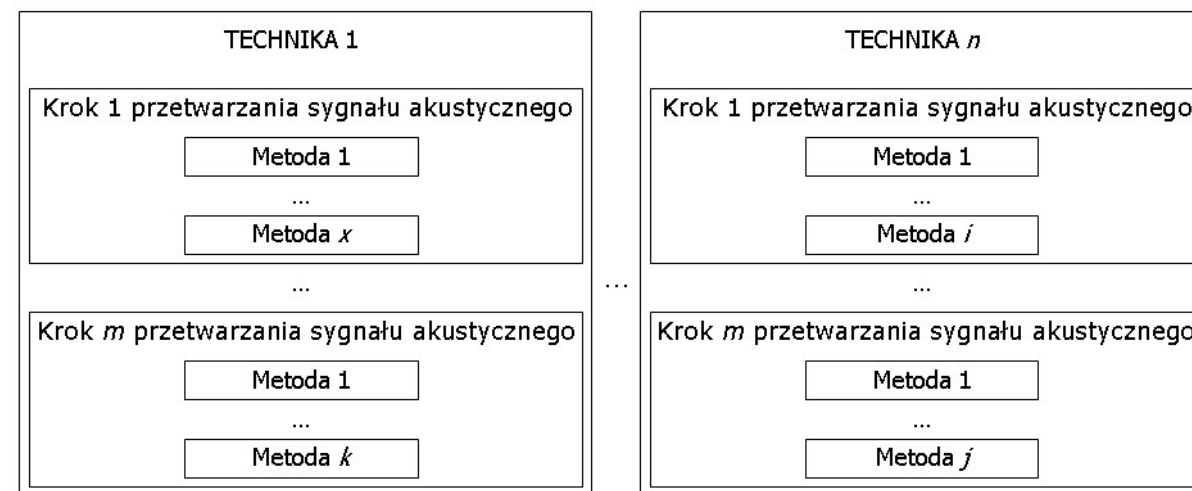


Rys. 1.2. Syntetyczne ujęcie celów poszczególnych rodzajów diagnostyki w przemyśle [10]

Na etapie eksploatacji przedmiotem zabiegów konstruktorów i eksploatorów jest bezawaryjna praca maszyny elektrycznej. Czas pracy jest sprecyzowany przez producenta, o ile spełniony jest warunek przestrzegania zaleceń dokumentacji technicznej. Niemniej jednak w procesie eksploatacji obserwowane są dwa odmienne zjawiska. Pierwsze z nich polega na tym, że dla pewnej grupy maszyn elektrycznych czas pracy jest o wiele krótszy od czasu określonego w dokumentacji technicznej. Drugie charakteryzuje się tym, że naprawy dla pewnej grupy maszyn elektrycznych wykonywane w czasie określonym przez producenta nie znajdują uzasadnienia w ich dobrym stanie technicznym, co więcej naprawa taka zwykle obniża sprawność maszyny. Zjawiska te spowodowane są przez: przypadkowy rozrzut własności nabytych na etapie wytwarzania, pracę maszyn z różnym obciążeniem roboczym, różne oddziaływania z otoczeniem, różnice między pojedynczymi egzemplarzami urządzeń. Procedury bezpieczeństwa i oszczędności związane z utrzymaniem sprzętu skłaniają eksploatorów maszyn elektrycznych do redukcji nieprzewidzianych awarii i napraw. Ponadto procedury te prowadzą do zmniejszenia liczby niepotrzebnych napraw maszyn elektrycznych, które są w dobrym stanie technicznym, pomimo przekroczenia czasu określonego przez producenta. Diagnostyka jest środkiem ochronnym, który może zostać użyty do rozwiązania wymienionych problemów maszyn elektrycznych, bez przerywania ich działania. Diagnostyka ta może obejmować: określenie rodzaju, miejsca, przyczyny uszkodzenia i ocenę zdolności urządzenia do dalszej pracy [10].

2. TECHNIKI ANALIZY INFORMACJI ZAWARTEJ W SYGNAŁACH AKUSTYCZNYCH

Technika jest określonym wzorcem postępowania. W pracy doktorskiej techniki analizy informacji zawartej w sygnałach akustycznych są wariantami metod przetwarzania sygnału akustycznego. W wariacie (technice) wykorzystuje się co najmniej jedną metodę w każdym z kroków przetwarzania sygnału akustycznego (zobacz Rys. 2.1). Metoda jest to ogół czynności i sposobów niezbędnych do rozwiązania problemu.



x, k, i, j, m, n są to liczby całkowite dodatnie

Rys. 2.1. Struktura technik analizy informacji zawartej w sygnałach akustycznych

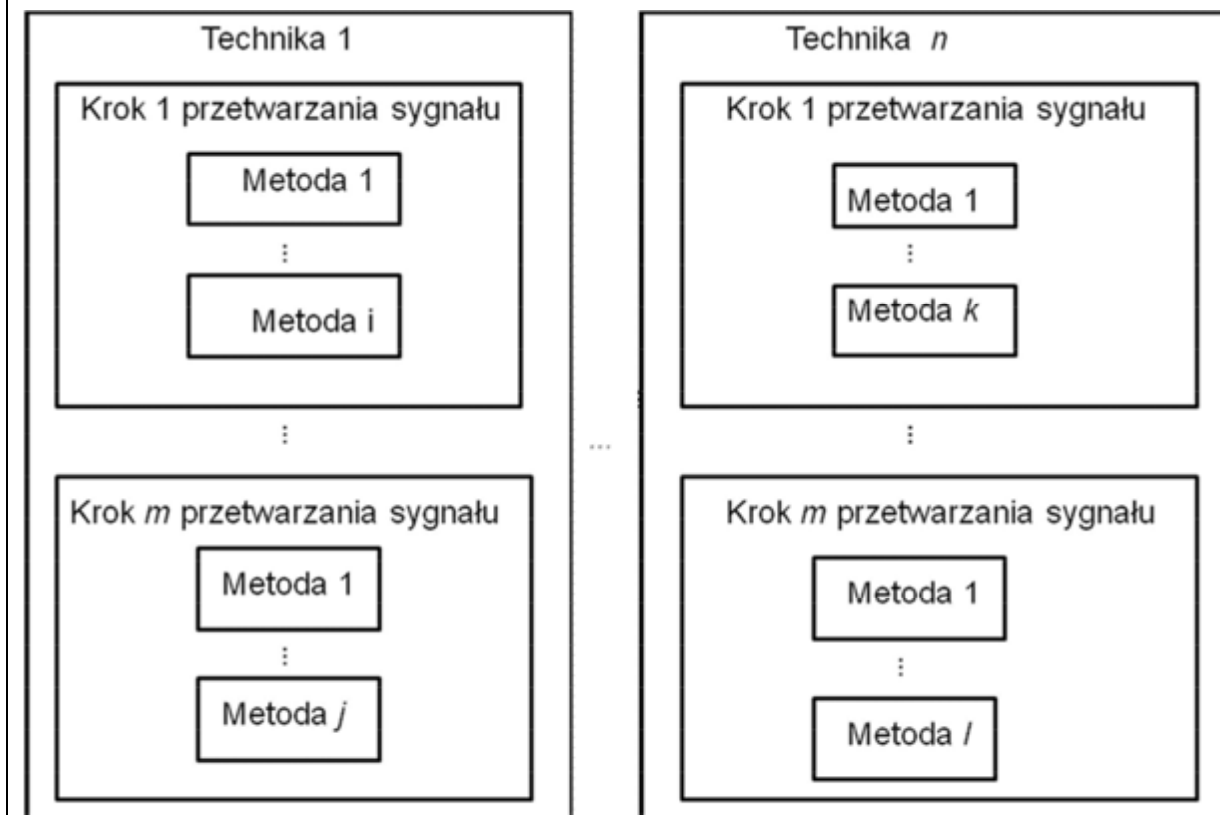
Identyfikacja procesu badania zawartości informacyjnej sygnału akustycznego jest zadaniem warunkującym poprawne zbudowanie stanowiska do badania maszyn elektrycznych. Aby jednak proces badania mógł być przeprowadzony prawidłowo potrzebne są odpowiednie warunki zastosowania

2. METODY ANALIZY I ROZPOZNAWANIA INFORMACJI ZAWARTEJ W SYGNAŁACH PRĄDOWYCH I NAPIĘCIOWYCH

2.1. Uwagi wstępne

[por. recenzja M. Skomorowski]

Technika jest określonym wzorcem postępowania. W pracy doktorskiej techniki analizy informacji zawartej w sygnałach prądowych i napięciowych są wariantami metod przetwarzania sygnałów. W wariacie (technice) wykorzystuje się co najmniej jedną metodę w każdym z kroków przetwarzania sygnału (rysunek 2.1). Metoda jest to ogół czynności i sposobów niezbędnych do rozwiązania problemu.



i, j, k, l, m, n są liczbami całkowitymi dodatnimi

Rys. 2.1. Struktura technik analizy informacji zawartej w sygnałach prądowych i napięciowych

Identyfikacja procesu badania zawartości informacyjnej sygnałów prądowych i napięciowych jest zadaniem warunkującym poprawne zbudowanie stanowiska do badania maszyn elektrycznych. Aby jednak

wspomnianych technik. Warunki te powinny uwzględniać kiedy i w jakim środowisku technika analizy informacji zawartej w sygnale akustycznym maszyny elektrycznej może być zastosowana.

Przyjęto następujące warunki:

- ⌚ Technika będzie słuszna dla maszyn elektrycznych wirujących.
- ⌚ Technika może być stosowana do maszyn elektrycznych tego samego producenta, jeżeli urządzenia te są podobne do siebie. Maszyny są podobne do siebie, gdy ich typy, wymiary, konstrukcja, masa, materiały z których są wykonane, parametry znamionowe są identyczne. Zakłada się, że rozrzut własności maszyn, powstały na etapie wytwarzania jest do pominięcia.
- ⌚ Technika może wykorzystywać zarejestrowane sygnały akustyczne jednej maszyny elektrycznej danego typu, jeżeli stany przedawaryjne są tak przygotowane, aby nie uszkadzać trwale maszyny. Wówczas można badać wielokrotnie sygnały akustyczne maszyny w stanach przedawaryjnych, jak i w stanie bez uszkodzeń. W takim przypadku ze względu na ograniczoną liczbę badanych urządzeń, maszyna elektryczna służy do wygenerowania zbioru wzorcowego i testowego dla sygnałów akustycznych. Wynika z tego, że do rozpoznawania sygnału akustycznego używane będą dwa etapy przetwarzania danych: etap tworzenia wzorców do rozpoznawania oraz etap identyfikacji. Technika będzie rozpoznawać kategorię dźwięku na podstawie uprzednio zarejestrowanych wzorców. Jeśli technika ma zostać zastosowana do całej serii maszyn elektrycznych produkowanych przez fabrykę, to wówczas można badać dodatkowo stany przedawaryjne, które doprowadzają do trwałego uszkodzenia maszyny. Należy przy tym zwrócić uwagę, aby wzorce i nowe sygnały akustyczne były rejestrowane tym samym urządzeniem przy tym samym poziomie: wilgotności powietrza, temperatury ($T = 298,15 \text{ °K}$), ciśnienia atmosferycznego ($p = 1013,25 \text{ hPa}$), napięcia w sieci elektrycznej, przy którym pracuje maszyna elektryczna.
- ⌚ Stany przedawaryjne maszyn elektrycznych mogą być spowodowane przez: czynniki elektryczne, mechaniczne, termiczne oraz magnetyczne. Proponowana technika będzie słuszna dla stanów przedawaryjnych spowodowanych przez czynniki mechaniczne. Zaznaczyć należy, że liczba stanów przedawaryjnych pochodzenia mechanicznego jest bardzo duża. Technika będzie słuszna dla stanów przedawaryjnych, pochodzenia mechanicznego, które wpływają na zmiany sygnałów elektrycznych i akustycznych. Mogą to być przerwy w obwodach stojana i wirnika spowodowane drganiami maszyny czy też zwarcia wywołane przez uszkodzenia izolacji. Stany takie powstają na skutek normalnej eksploatacji maszyny.

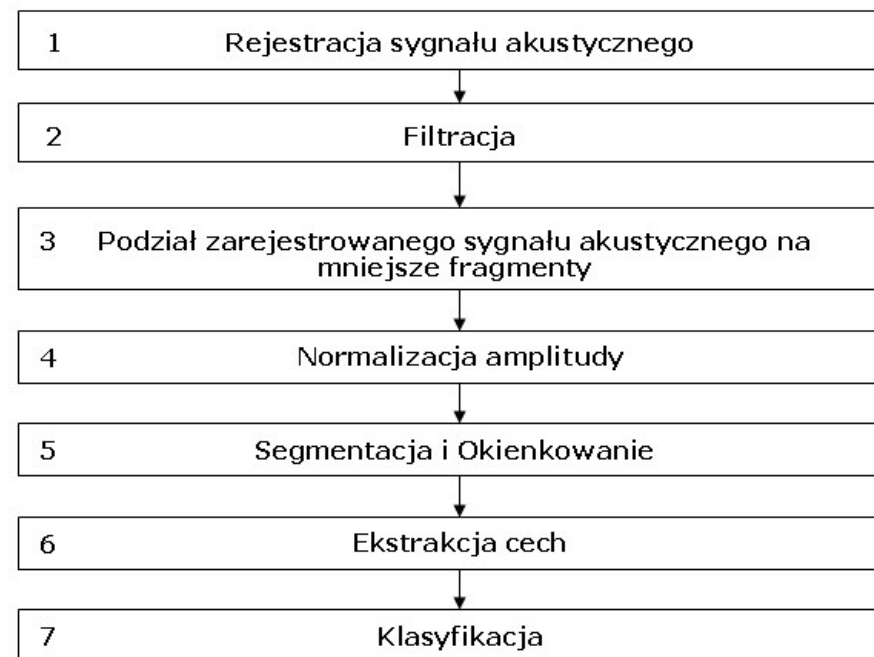
proces badania mógł być przeprowadzony prawidłowo potrzebne są odpowiednie warunki zastosowania wspomnianych technik. Warunki te powinny uwzględniać kiedy i w jakim środowisku technika analizy informacji zawartej w sygnałach prądowych i napięciowych maszyny elektrycznej może być zastosowana.

Przyjęto następujące warunki:

- Technika będzie odpowiednia dla maszyn elektrycznych wirujących.
- Technika może być stosowana do maszyn elektrycznych tego samego producenta, jeżeli urządzenia te są podobne do siebie. Maszyny są podobne do siebie, gdy ich typy, wymiary, konstrukcja, masa, materiały z których są wykonane, parametry znamionowe są identyczne. Zakłada się, że rozrzut własności maszyn, powstały na etapie wytwarzania jest do pominięcia.
- Technika może wykorzystywać zarejestrowane sygnały prądowe i napięciowe jednej maszyny elektrycznej danego typu, jeżeli stany przedawaryjne są tak przygotowane, aby nie uszkadzać trwale maszyny. Wówczas można badać wielokrotnie sygnały prądowe i napięciowe maszyny w stanie przedawaryjnym jak i w stanie bez uszkodzeń. W takim przypadku ze względu na ograniczoną liczbę badanych urządzeń, maszyna elektryczna służy do wygenerowania zbioru wzorcowego i testowego dla sygnałów prądowych i napięciowych. Wynika z tego, że do rozpoznawania sygnałów prądowych i napięciowych używane będą dwa etapy przetwarzania danych: etap tworzenia wzorców do rozpoznawania oraz etap identyfikacji. Technika będzie rozpoznawać kategorie prądów i napięć na podstawie uprzednio zarejestrowanych wzorców. Jeśli technika ma zostać zastosowana do całej serii maszyn elektrycznych produkowanych przez fabrykę, to wówczas można badać dodatkowo stany przedawaryjne, które doprowadzają do trwałego uszkodzenia maszyny. Należy przy tym zwrócić uwagę, aby wzorce i nowe sygnały prądowe lub napięciowe były rejestrowane tym samym urządzeniem przy tym samym poziomie: wilgotności powietrza, temperatury ($T = 298,15 \text{ °K}$), ciśnienia atmosferycznego ($p = 1013,25 \text{ hPa}$), napięcia w sieci elektrycznej, przy którym pracuje maszyna elektryczna.
- Stany przedawaryjne maszyn elektrycznych mogą być spowodowane przez: czynniki elektryczne, mechaniczne, termiczne oraz magnetyczne. Proponowana technika będzie stosowna dla stanów przedawaryjnych spowodowanych przez czynniki mechaniczne. Zaznaczyć należy, że liczba stanów przedawaryjnych pochodzenia mechanicznego jest bardzo duża. Technika będzie słuszna dla stanów przedawaryjnych, pochodzenia mechanicznego, które wpływają na zmiany sygnałów elektrycznych i prądowych i napięciowych. Mogą to być przerwy w obwodach stojana i wirnika spowodowane drganiami maszyny czy też zwarcia wywołane przez uszkodzenia izolacji. Stany takie powstają na skutek normalnej eksploatacji maszyny.

- ⌚ Do rejestracji sygnału akustycznego używany jest jeden mikrofon.
- ⌚ Pominiętymi zjawiskami o charakterze falowym są: rozproszenie, ugięcie, odbicia i nakładanie się fal.
- ⌚ Należy zminimalizować wpływ szumów (hałas spowodowany przez burzę, deszcz, wiatr, samochody, inne maszyny). W czasie wykonywania pomiaru wszystkie drzwi i okna w badanym pomieszczeniu są zamknięte.

Biorąc pod uwagę powyższe warunki zaproponowano ogólny plan badania sygnałów akustycznych, który został przedstawiony na rysunku 2.2.

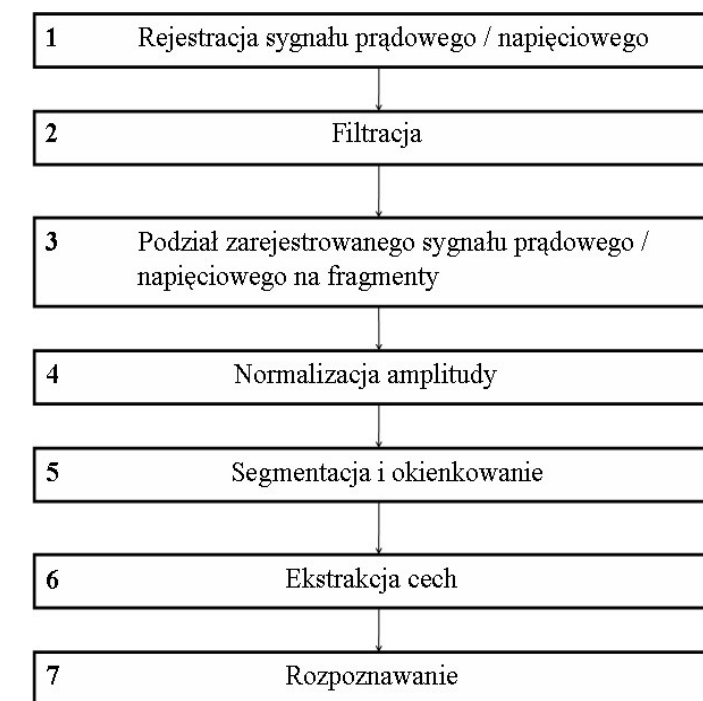


Rys. 2.2. Ogólny plan badania sygnałów akustycznych

Plan ten został sporządzony przez analogię do sposobów rozpoznawania tożsamości mówcy, zwierząt i instrumentów muzycznych [1], [46], [52], [56], [68], [69], [90], [93]. Na podstawie tego planu w pracy doktorskiej proponowane są techniki analizy informacji zawartej w sygnałach akustycznych maszyn elektrycznych (zobacz rysunek 2.2, 2.7). W pierwszym etapie badania sygnałów akustycznych sygnał analogowy zostaje zamieniony na postać cyfrową. W takiej postaci sygnał jest rejestrowany na komputerze. Zanim jednak zostanie zapisany na komputerze poddawany jest filtracji filtrem antyaliasingowym [53], [61], [93], [118]. Filtracja ta stosowana jest w celu usunięcia niepożądanych

- Do rejestracji sygnałów prądowych i napięciowych używany jest przetwornik pomiarowy. Należy zminimalizować wpływ szumów (zakłócenia elektromagnetyczne i mechaniczne spowodowane przez nieodpowiednie ułożenie przewodów pomiarowych, użycie przewodów złej jakości, burzę, deszcz, wiatr).

Biorąc pod uwagę powyższe warunki zaproponowano ogólny plan badania sygnałów prądowych i napięciowych, który został przedstawiony na rysunku 2.2.



Rys. 2.2. Ogólny plan badania sygnałów prądowych i napięciowych

Plan ten został sporządzony przez analogię do sposobów rozpoznawania tożsamości mówcy, zwierząt i instrumentów muzycznych [1], [46], [52], [56], [68], [69], [90], [93]. Na podstawie tego planu w niniejszej pracy doktorskiej proponowane są techniki analizy informacji zawartej w sygnałach prądowych i napięciowych maszyn elektrycznych. W pierwszym etapie badania sygnałów prądowych i napięciowych sygnał analogowy zostaje zamieniony na postać cyfrową. W takiej postaci sygnał jest rejestrowany na komputerze. Zanim jednak zostanie zapisany na komputerze poddawany jest filtracji filtrem antyaliasingowym. Filtracja ta stosowana jest w celu usunięcia niepożądanych składowych o częstotliwości

hałasów z widma częstotliwości sygnału. Kolejny krok polega na podziale zarejestrowanego sygnału akustycznego (ścieżki dźwiękowej) na mniejsze fragmenty zwane próbkami dźwięku. Następnie w każdej próbie dźwięku amplituda sygnału jest normalizowana. Kolejno każda próbka dźwięku dzielona jest na mniejsze segmenty danych zwane ramkami.

Następnie sygnały w ramach mnożone są przez funkcję okna w celu zmniejszenia „nierównomierności” pojawiających się na początku i końcu ramki. Następnym krokiem jest ekstrakcja cech. Jej celem jest otrzymanie z ramek takich cech charakterystycznych sygnału, które będą go najlepiej opisywać. Ostatnim etapem badania sygnałów akustycznych jest klasyfikacja. Decyzja o klasyfikacji sygnału do określonej klasy podejmowana jest na podstawie wybranej metody klasyfikacji [103].

W dalszym ciągu rozdziału naszkicowany plan ogólny (zobacz rysunek 2.2) będzie szczegółowo dyskutowany tak, aby uzyskać właściwy plan eksperymentowania, który następnie stanie się źródłem założeń konstrukcyjnych budowanego stanowiska do badania maszyn elektrycznych.

2.1. Rejestracja sygnału akustycznego, filtracja, próbkowanie i kwantyzacja

Pierwszym krokiem koniecznym do rozpoznawania jest zarejestrowanie sygnału akustycznego. Sygnał ten stanowią czasowe przebiegi ciśnienia akustycznego. Drganiom powietrza odpowiadają zmiany napięcia elektrycznego na wyjściu mikrofonu. Następnie sygnał ten jest podawany na wejście przetwornika A/C. Przed zapisaniem analogowego sygnału akustycznego w postaci cyfrowej, poddawany jest on wzmacnianiu, a następnie filtracji filtrem antyaliasingowym. Wszystkie trzy układy odpowiedzialne za wymienione procesy, tzn. wzmacniacz wstępny, filtr antyaliasingowy i przetwornik analogowo – cyfrowy są zamontowane na standardowej komputerowej karcie dźwiękowej. Podczas zamiany sygnału z postaci analogowej na cyfrową sygnał poddawany jest operacjom próbkowania i kwantyzacji. Celem tych metod jest przekształcenie analogowego sygnału na odpowiednią postać cyfrową [80], [103].

Próbkowanie polega na pobraniu próbek sygnału w określonych odstępach czasu. Podstawowym parametrem jest częstotliwość próbkowania, która powinna być odpowiednio dobrana. Ze względu na dostępność dobrego sprzętu do nagrywania dźwięków o określonej charakterystyce można przyjąć, że do rejestracji sygnałów akustycznych maszyn elektrycznych częstotliwość próbkowania będzie równa 44100 Hz. Częstotliwość taka jest stosowana do nagrań muzycznych na płycie CD [18].

Kolejnym krokiem jest kwantyzacja, która polega na przyporządkowaniu wartości amplitudy do przedziałów określonych przez liczbę bitów, która określa z jaką dokładnością zostanie zapisana wartość

powyżej pewnej określonej wartości z widma częstotliwości sygnału. Kolejny krok polega na podziale zarejestrowanych sygnałów prądowych (ścieżki sygnału) na mniejsze fragmenty zwane próbkami sygnału. Następnie w każdej próbie amplituda sygnału jest normalizowana. Kolejno każda próbka sygnału dzielona jest na mniejsze segmenty danych zwane ramkami.

Następnie sygnały w ramach mnożone są przez funkcję okna w celu zmniejszenia „nierównomierności” pojawiających się na początku i końcu ramki. Następnym krokiem jest ekstrakcja cech. Jej celem jest otrzymanie z ramek takich cech charakterystycznych sygnału, które będą go najlepiej opisywać. Ostatnim etapem badania sygnałów prądowych i napięciowych jest klasyfikacja. Decyzja o klasyfikacji sygnału do określonej klasy podejmowana jest na podstawie wybranej metody klasyfikacji.

W dalszym ciągu rozdziału naszkicowany plan ogólny będzie szczegółowo dyskutowany tak, aby uzyskać właściwy plan eksperymentowania, który następnie stanie się źródłem założeń konstrukcyjnych budowanego stanowiska do badania maszyn elektrycznych.

2.2. Rejestracja sygnałów prądowych i napięciowych, filtracja, próbkowanie i kwantyzacja

Pierwszym krokiem koniecznym do rozpoznawania jest zarejestrowanie sygnałów prądowych i napięciowych. Sygnał ten stanowią czasowe przebiegi prądów i napięć na kablach zasilających silnik. Następnie sygnały te są podawane na wejście przetwornika A/C. Przed zapisaniem analogowych sygnałów w postaci cyfrowej, poddawane są one wzmacnianiu, a następnie filtracji filtrem antyaliasingowym. Wszystkie trzy układy odpowiedzialne za wymienione procesy, tzn. wzmacniacz wstępny, filtr antyaliasingowy i przetwornik analogowo – cyfrowy są zamontowane na standardowej komputerowej karcie pomiarowej. Podczas zamiany sygnału z postaci analogowej na cyfrową sygnał poddawany jest operacjom próbkowania i kwantyzacji. Celem tych metod jest przekształcenie analogowego sygnału na odpowiednią postać cyfrową.

Próbkowanie polega na pobraniu próbek sygnału w określonych odstępach czasu. Podstawowym parametrem jest częstotliwość próbkowania, która powinna być odpowiednio dobrana. Ze względu na dostępność dobrego sprzętu do pomiaru sygnału o określonej charakterystyce można przyjąć, że do rejestracji sygnałów prądowych i napięciowych maszyn elektrycznych częstotliwość próbkowania będzie równa 20000 Hz. Częstotliwość taka jest często stosowana w pomiarach przemysłowych.

Kolejnym krokiem jest kwantyzacja, która polega na przyporządkowaniu wartości amplitudy do przedziałów określonych przez liczbę bitów, która określa z jaką dokładnością zostanie zapisana wartość próbki.

próbki. Najczęściej stosowane liczby bitów to 8 lub 16. Przy wyborze liczby bitów należy znaleźć kompromis pomiędzy wiernością zapisu sygnału, a szybkością obliczeń. Do rejestracji sygnałów akustycznych maszyn elektrycznych powinno się stosować 16 bitów ze względu na uzyskanie dużej dokładności zapisu.

Ważnym parametrem rejestracji sygnału akustycznego jest liczba kanałów dźwięku używanych do nagrywania. Do rejestracji sygnałów akustycznych maszyn elektrycznych używany będzie jeden kanał dźwięku ze względu na łatwość przetwarzania sygnału w kolejnych krokach.

Kolejnym parametrem związanym z rejestracją sygnału akustycznego jest czas nagrywania. Powinien być on na tyle duży, aby zarejestrowany sygnał nadawał się do rozpoznawania. Z drugiej strony czas powinien być ograniczony do minimum, aby nie powiększać niepotrzebnie ilości danych do dalszego przetwarzania. Z tego powodu w badaniach sygnałów akustycznych maszyn elektrycznych rejestrowany będzie sygnał akustyczny (ścieżka dźwiękowa). Następnie sygnał ten dzielony będzie na mniejsze fragmenty (próbki dźwięku). Długość próbek dźwięku będzie dyskutowana w podrozdziale 2.2.1.

Badając zachowanie pracy maszyny elektrycznej można dojść do przekonania, że sygnały akustyczne maszyn można rozpoznać za pomocą narządu słuchu, jakim jest ludzkie ucho. Narząd ten rejestruje częstotliwości w paśmie od 20 Hz do 20000 Hz.

Przyrządy do rejestrowania sygnałów akustycznych w paśmie częstotliwości od 50 Hz do 20000 Hz mają niską cenę i są łatwo dostępne. Z tego też względu przewiduje się przeprowadzenie rejestracji sygnałów akustycznych maszyn elektrycznych w zakresie częstotliwości od 50 Hz do 20000 Hz. Rozważając to pasmo częstotliwości można przyjąć, że metody stosowane w identyfikacji mówcy mogą okazać się przydatne do badania sygnałów akustycznych maszyn elektrycznych [119]. Wybór ograniczonego pasma częstotliwości oznacza pominięcie infradźwięków i ultradźwięków. Jeżeli jednak zepsute maszyny generowałyby infradźwięki, wówczas należałoby zakupić urządzenia do ich rejestracji, co jednak spowoduje znaczne podwyższenie kosztów proponowanej metody. Z tego też względu infradźwięki i ultradźwięki nie będą w tej pracy dyskutowane.

Ostatnim elementem ważnym dla rejestracji sygnału akustycznego jest format zapisu. Rejestrowany sygnał akustyczny powinien być zapisany w formacie WAVE PCM (*ang. Waveform audio format pulse-code modulation*), ponieważ nie jest on skompresowany [122].

2.2. Metody przetwarzania sygnału akustycznego

Badając zachowanie pracy maszyny elektrycznej własnym uchem, można stwierdzić, że nie zawsze da się rozpoznać uszkodzenie. Dzieje się tak, ponieważ różnice między generowanymi sygnałami słyszane

Najczęściej stosowane liczby bitów to 8 lub 16. Przy wyborze liczby bitów należy znaleźć kompromis pomiędzy wiernością zapisu sygnału, a szybkością obliczeń. Do rejestracji sygnałów prądowych i napięciowych maszyn elektrycznych powinno się stosować 16 bitów ze względu na uzyskanie dużej dokładności zapisu.

Ważnym parametrem rejestracji sygnałów prądowych i napięciowych jest liczba używanych kanałów pomiarowych. Do rejestracji sygnałów prądowych i napięciowych w ramach tej pracy będzie używanych 5 kanałów dla maszyny indukcyjnej oraz 6 kanałów dla maszyny prądu stałego.

Kolejnym parametrem związanym z rejestracją sygnałów prądowych i napięciowych jest czas rejestracji. Powinien być on na tyle duży, aby zarejestrowany sygnał nadawał się do rozpoznawania. Z drugiej strony czas powinien być ograniczony do minimum, aby nie powiększać niepotrzebnie ilości danych do dalszego przetwarzania. Z tego powodu w badaniach sygnałów prądowych i napięciowych maszyn elektrycznych rejestrowane będą sygnały prądowe i napięciowe (ścieżka sygnału). Następnie sygnały te dzielone będą na mniejsze fragmenty (próbki sygnału). Długość próbek sygnału będzie dyskutowana w podrozdziale 2.2.1.

Przyrządy do rejestrowania sygnałów prądowych i napięciowych w paśmie częstotliwości do 20000 Hz mają niską cenę i są łatwo dostępne. Z tego też względu przewiduje się przeprowadzenie rejestracji sygnałów prądowych i napięciowych maszyn elektrycznych w zakresie częstotliwości od 0 Hz do 20000 Hz. Rozważając to pasmo częstotliwości można przyjąć, że metody stosowane w identyfikacji mówcy mogą okazać się przydatne do badania sygnałów prądowych i napięciowych maszyn elektrycznych [119]. Wybór ograniczonego pasma częstotliwości oznacza pominięcie wysokich częstotliwości. Jeżeli jednak zepsute maszyny generowałyby wysokie częstotliwości, wówczas należałoby zakupić urządzenia do ich rejestracji, co jednak spowoduje znaczne podwyższenie kosztów proponowanej metody. Z tego też względu wysokie częstotliwości nie będą w tej pracy dyskutowane.

Ostatnim ważnym elementem dla rejestracji sygnałów prądowych i napięciowych jest format zapisu. Rejestrowane sygnały prądowe i napięciowe powinny być zapisane w formacie TXT (Text file) [126].

2.3. Metody przetwarzania sygnałów prądowych i napięciowych

Badając zachowanie pracy maszyny elektrycznej własnym okiem, można stwierdzić, że nie zawsze da się rozpoznać uszkodzenie. Dzieje się tak, ponieważ różnice między generowanymi sygnałami widziane

przez narząd słuchu są zbyt małe. Nasuwa się pytanie, jak przetworzyć posiadane sygnały akustyczne maszyn elektrycznych, aby nadawały się do rozpoznawania. W tym celu należy zastosować odpowiednie metody przetwarzania i analizy sygnałów akustycznych. Celem tych metod jest wyeliminowanie z sygnału informacji nieistotnych, mogących negatywnie wpłynąć na działanie metod używanych w kolejnych krokach.

2.2.1. Podział zarejestrowanego sygnału akustycznego na fragmenty

Zarejestrowany sygnał akustyczny należy podzielić na mniejsze fragmenty. Zabieg ten ma na celu ograniczenie rozmiaru sygnału, a dzięki temu zredukowanie ilości danych, czasu obliczeń i potrzebnej pamięci. W tym celu należy ustalić długość próbki dźwięku do rozpoznawania. Do tego celu zastosowano narząd słuchu, jakim jest ludzkie ucho. Jednosekundowe próbki dźwięku maszyn elektrycznych były dobrze rozpoznawane, natomiast próbki dźwięku o mniejszym czasie trwania były nie do odróżnienia. Z tego powodu przyjęto, że najkrótsza próbka dźwięku będzie mieć czas trwania jednej sekundy. W celu uzyskania lepszych wyników rozpoznawania przewiduje się badać próbki dźwięku o dłuższym czasie trwania. Ze względu jednak na dużą ilość czasu potrzebną do zbadania wszystkich wariantów metod przetwarzania danych oraz próbek dźwięku różnej długości, zbadane zostaną próbki: jednosekundowe, dwusekundowe, trzysekundowe, czterosekundowe i pięciosekundowe.

2.2.2. Normalizacja amplitudy

Następnym krokiem badania dźwięku jest normalizacja amplitudy, która pozwala analizować sygnały akustyczne o różnym poziomie głośności (sygnał akustyczny cichy i głośny). W tym celu każda wartość amplitudy jest dzielona przez jej maksymalną wartość w określonym przedziale czasowym. Uzyskane wartości amplitudy znajdują się w przedziale [-1, 1].

2.2.3. Segmentacja i okienkowanie

Następnym krokiem w badaniu sygnałów akustycznych jest segmentacja i okienkowanie. Zabiegi te są stosowane w celu pobrania małej części całej próbki dźwiękowej. Proces segmentacji sygnału (*ang. frame blocking*) polega na jego podziale na określonej długości segmenty zwane ramkami. Kolejno każda ramka podlega procesowi okienkowania poprzez pomnożenie zawartego w niej sygnału przez

przez narząd jakim jest oko są zbyt małe. Nasuwa się pytanie, jak przetworzyć posiadane sygnały prądowe i napięciowe maszyn elektrycznych, aby nadawały się do rozpoznawania (wzrokowego lub automatycznego). W tym celu należy zastosować odpowiednie metody przetwarzania i analizy sygnałów prądowych i napięciowych. Celem tych metod jest wyeliminowanie z sygnału informacji nieistotnych, mogących negatywnie wpłynąć na działanie metod używanych w kolejnych krokach.

2.3.1. Podział zarejestrowanych sygnałów prądowych i napięciowych na fragmenty

Zarejestrowany sygnał prądowy/napięciowy należy podzielić na mniejsze fragmenty. Zabieg ten ma na celu ograniczenie rozmiaru sygnału, a dzięki temu zredukowanie ilości danych, czasu obliczeń i potrzebnej pamięci. W tym celu należy ustalić długość próbki prądu/napięcia do rozpoznawania. Jednosekundowe próbki prądu/napięcia maszyn elektrycznych były dobrze rozpoznawane, natomiast próbki sygnału o mniejszym czasie trwania były nie do odróżnienia. Z tego powodu przyjęto, że najkrótsza próbka sygnału będzie mieć czas trwania jednej sekundy. W celu uzyskania lepszych wyników rozpoznawania przewiduje się badać próbki sygnału o dłuższym czasie trwania. Ze względu jednak na dużą ilość czasu potrzebną do zbadania wszystkich wariantów metod przetwarzania danych oraz próbek prądu/napięcia różnej długości, zbadane zostaną próbki: jednosekundowe, dwusekundowe, trzysekundowe, czterosekundowe i pięciosekundowe.

2.3.2. Normalizacja amplitudy

Następnym krokiem badania prądów i napięć jest normalizacja amplitudy, która pozwala analizować sygnały prądowe i napięciowe o różnym poziomie natężenia (sygnał mały i duży). W tym celu każda wartość amplitudy jest dzielona przez jej maksymalną wartość w określonym przedziale czasowym. Uzyskane wartości amplitudy znajdują się w przedziale [-1, 1].


2.3.3. Segmentacja i okienkowanie

Następnym krokiem w badaniu sygnałów prądowych i napięciowych jest segmentacja i okienkowanie. Zabiegi te są stosowane w celu pobrania małej części całej próbki sygnału. Proces segmentacji sygnału (*ang. frame blocking*) polega na jego podziale na określonej długości segmenty zwane ramkami. Kolejno każda ramka podlega procesowi okienkowania poprzez pomnożenie zawartego w niej sygnału przez odpowiednią

odpowiednią funkcję okna [61], [118]. Szeroko używanym oknem w literaturze przetwarzania sygnałów akustycznych jest okno Hamminga (zobacz rysunek 2.3) [61], [93], [103]. Stosowanie takiego rozwiązania umożliwia minimalizację błędu estymacji funkcji autokorelacji sygnału na krańcach każdej ramki. Z tego właśnie względu będzie ono stosowane do sygnałów akustycznych maszyn elektrycznych. Okno Hamminga jest tworzone funkcją:

$$w(n) = 0.53836 - 0.46164 \cdot \cos\left(\frac{2\pi n}{m-1}\right) \quad (2.1)$$

gdzie: n jest indeksem próbki w oknie, m jest całkowitą długością okna, $w(n)$ jest amplitudą próbki, $n = 0, 1, 2, \dots, m-1$.



Rys. 2.3. Okno Hamminga

Zastosowanie segmentacji powoduje utworzenie ramek, stosowanych następnie w metodach FFT, LPC, LPCC (metody zostały omówione w podrozdziale 2.3). Tutaj należy zaznaczyć, że dla metody FFT kolejne ramki przylegają do siebie. W przypadku LPC kolejne ramki nakładają się na siebie tak, że każda ramka wcześniejsza zajmuje 1/3 ramki następnej.

Rozmiar okna będzie równy rozmiarowi ramki. Przewidywany rozmiar okna dla algorytmu FFT będzie wynosić 32768 próbek przy częstotliwości próbkowania 44100 Hz. Taki rozmiar okna jest wystarczająco dokładny do rozpoznawania sygnału akustycznego. Zgodnie z literaturą dla algorytmów LPC i LPCC rozmiar okna będzie wynosić 256 próbek przy częstotliwości próbkowania 44100 Hz [24], [93].

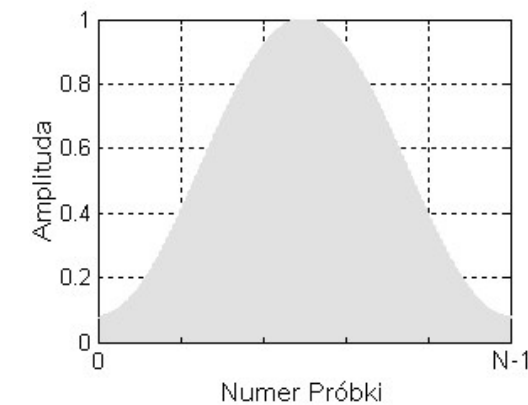
2.3. Wybrane metody ekstrakcji cech sygnału

W kolejnym kroku badania sygnału akustycznego należy zastosować metody ekstrakcji cech. Metody te charakteryzują się tym, że wybierają tylko określone, najistotniejsze z punktu widzenia celu

funkcję okna. Chodzi o to, by nie wprowadzać do badanych próbek sygnałów artefaktów będących skutkiem gwałtownego narastania sygnału na początku próbki i raptownego jej zanikania na końcu. Szeroko używanym oknem w literaturze przetwarzania sygnałów prądowych i napięciowych jest okno Hamminga (rysunek 2.3). Stosowanie takiego rozwiązania umożliwia minimalizację błędu estymacji funkcji autokorelacji sygnału na krańcach każdej ramki. Z tego właśnie względu będzie ono stosowane do sygnałów prądowych i napięciowych maszyn elektrycznych. Okno Hamminga jest tworzone funkcją:

$$w(n) = 0.53836 - 0.46164 \cdot \cos\left(\frac{2\pi n}{m-1}\right) \quad (2.1)$$

gdzie: n jest indeksem próbki w oknie, m jest całkowitą długością okna, $w(n)$ jest amplitudą próbki, $n = 0, 1, 2, \dots, m-1$.



Rys. 2.3. Okno Hamminga

Zastosowanie segmentacji powoduje utworzenie ramek, stosowanych następnie w metodach FFT, LPC, LPCC (metody zostały omówione w podrozdziale 2.3). Tutaj należy zaznaczyć, że dla metody FFT kolejne ramki przylegają do siebie. W przypadku LPC kolejne ramki nakładają się na siebie tak, że każda ramka wcześniejsza zajmuje 1/3 ramki następnej.

Rozmiar okna będzie równy rozmiarowi ramki. Przewidywany rozmiar okna dla algorytmu FFT będzie wynosić 16384 próbek przy częstotliwości próbkowania 20000 Hz. Taki rozmiar okna jest wystarczająco dokładny do rozpoznawania sygnału prądowego/napięciowego. Zgodnie z literaturą dla algorytmów LPC i LPCC rozmiar okna będzie wynosić 256 próbek przy częstotliwości próbkowania 20000 Hz.

2.4. Wybrane metody ekstrakcji cech sygnału

W kolejnym kroku badania sygnału prądowego/napięciowego należy zastosować metody ekstrakcji cech. Metody te charakteryzują się tym, że wybierają tylko określone, najistotniejsze z punktu widzenia celu

rozpoznawania cechy dźwięku. Ekstrakcję cech można dokonać na wiele sposobów, wybierając różne cechy jako najważniejsze [38], [45], [51], [85]. Do metod ekstrakcji cech, które były stosowane w rozpoznawaniu mowy zaliczamy: liniowe kodowanie predykcyjne LPC (*ang. Linear Predictive Coding*) [46], [81], [101], LSF(LSP) (*ang. Line spectral frequencies*) [9], [57], [58], LPCC (*ang. Linear Predictive Cepstrum Coefficients*) [93],

REFL (*ang. Reflection Coefficients*) [17], FFT-cep (*ang. Linear frequency FFTcepstrum*) [46], WDCTC (*ang. Warped Discrete Cosine Transform Cepstrum*) [70] oraz PLP (*ang. Perceptual Linear Prediction*) [39], [40], [41], [75], HFCC (*ang. Human Factor Cepstral Coefficients*) [27], [107], [117].

Metodami ekstrakcji cech, które zostały zastosowane w rozpoznawaniu sygnałów instrumentów muzycznych są: Spectral Centroid [10], MPEG-7 AudioSpectrumCentroid, MPEG-7 AudioSpectrumSpread, MPEG-7 AudioSpectrumFlatness, MPEG-7 Harmonic Ratio, Skewness of the time-domain audio signal, The maximum of the time-domain audio Signac, MPEG-7 AudioSpectrumProjection Coefficients, Delta Spectrum, Spectral Roll-off frequency, RMS energy, Low energy Rate, Loudness [3], [4], MFCC (*ang. Mel Frequency Cepstral Coefficients*) [7], [8], [15], [63], [96], SSD (*ang. Statistical Spectrum Descriptor*) [72], 4 Hz modulation energy, Cepstrum Resynthesis Residual Magnitude, Percentage of “Low-Energy” Frames [87], DWT (*ang. Discrete Wavelet Transform*) [94].

Metodami ekstrakcji cech, które zostały zastosowane w rozpoznawaniu sygnałów akustycznych zwierząt są: BFCC (*ang. Bark Frequency Cepstral Coefficients*) [65], [66], ZCR (*ang. Zero Crossing Rate*) [59], [115], STR (*ang. Short Time Energy*) [115], Spectral Flux (Delta Spectrum Magnitude) [115], Variance of the Spectral Flux, Pitch [115], AD (*ang. Amplitude Descriptor*) [65], Constant Q-Transform [115]. Następnie należy wymienić metodę FFT – *ang. Fast Fourier Transform*), która była stosowana do zmniejszania liczby cech sygnału akustycznego (część autorów nazywa metodę FFT tzw. „schematem ekstrakcji cech”) [11], [54], [55], [83], [104], [115].

Ze względu na dużą liczbę wariantów metod ekstrakcji cech podczas badań będą stosowane wybrane metody FFT, LPC i LPCC [93]. Jakość wyników otrzymanych tymi metodami w badaniach nad sygnałami akustycznymi dają przesłanki, aby zastosować je w diagnostyce maszyn elektrycznych.

rozpoznawania cechy sygnału. Ekstrakcję cech można dokonać na wiele sposobów, wybierając różne cechy jako najważniejsze. Przykładowo do metod ekstrakcji cech, które były stosowane w rozpoznawaniu mowy zaliczamy: liniowe kodowanie predykcyjne LPC (*ang. Linear Predictive Coding*) [14], [40], [74], [119], LPCC (*ang. Linear Predictive Cepstrum Coefficients*) [2], [31], [42]. [91], [121]. Można się było na tym częściowo wzorować.

Metodą ekstrakcji cech, która została zastosowana w rozpoznawaniu sygnałów prądowych i napięciowych była

DWT (*ang. Discrete Wavelet Transform*) [15], [17], [35], [46], [58], [122], [124].

Metodami ekstrakcji cech, które mogą być także zastosowane w rozpoznawaniu sygnałów prądowych i napięciowych są

transformacja Fouriera DFT i metoda wyboru amplitud dla częstotliwości MSAF. Następnie należy wymienić metodę FFT (*ang. Fast Fourier Transform*), która była stosowana do zmniejszania liczby cech sygnału (część autorów nazywa metodę FFT tzw. „schematem ekstrakcji cech”) [43], [68], [76], [82], [89], [122].

Ze względu na dużą liczbę wariantów metod ekstrakcji cech podczas badań będą stosowane wybrane metody: FFT, metoda wyboru amplitud dla częstotliwości MSAF, LPC i LPCC [2], [74], [91], [121], [122]. Jakość wyników (rozkład cech sygnałów) otrzymanych tymi metodami w badaniach sygnałów prądowych i napięciowych daje przesłanki, aby zastosować je w diagnostyce maszyn elektrycznych.

2.3.1. Szybka Transformacja Fouriera

Dyskretna transformacja Fouriera (DFT, *ang. Discrete Fourier Transform*) służy do przekształcenia wartości z dziedziny czasu na wartości w dziedzinie częstotliwości. Jest ona określona następującym wzorem:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j2\pi kn/N} \quad (2.2)$$

gdzie: X_k – współczynnik częstotliwościowy o numerze k , k – numer częstotliwości, n – numer próbki sygnału, x_n – wartość n -tej próbki sygnału, N – liczba próbek.

Z otrzymanych współczynników częstotliwościowych otrzymywane są odpowiednie amplitudy dla częstotliwości, które są cechami sygnału dla metody DFT ($|X_1|, \dots, |X_k|$). W 1965 roku został opublikowany przez Cooleya i Tuckeya artykuł przedstawiający bardzo wydajny algorytm implementujący dyskretną transformację Fouriera. Obecnie algorytm ten znany jest jako szybka transformacja Fouriera (*ang. Fast Fourier Transform*) [55], [77], [118]. Jest on bardzo skutecznym algorytmem (złożoność obliczeniowa FFT wynosi $O(N \log_2 N)$), jednak wymaga ona przed użyciem zastosowania segmentacji i okienkowania (zobacz podrozdział 2.2.3). Założeniem algorytmu FFT jest to, że operuje on na danych wejściowych o liczbie próbek $N = 2^k$, gdzie k to pewna liczba naturalna [61].

W podrozdziale 2.1 ustalono, że częstotliwość próbkowania wynosi 44100 Hz. Zatem jeśli próbka jednosekundowa dźwięku zawiera 44100 próbek, to algorytm FFT wykorzysta z niej tylko $N = 32768$ próbek i wówczas $k=15$. Następnie z owych 32768 próbek wyliczane są amplitudy dla częstotliwości, których zgodnie z twierdzeniem Kotielnikowa-Shannona jest 16384 [61]. Otrzymane amplitudy odpowiadają pasmu częstotliwości od 1 Hz do 22050 Hz. Każda z 16384 amplitud jest w odległości 1,345 Hz od sąsiedniej amplitudy. W przekonaniu autora jest to przybliżenie, które można zaakceptować do obliczenia charakterystycznych częstotliwości maszyn elektrycznych (zobacz podrozdział 2.3.2). Wybierając odpowiednio amplitudy dla częstotliwości będzie można badać pojedynczą amplitudę lub ich grupę. Wówczas połączenie metody wybierania amplitud dla częstotliwości i FFT będzie redukować liczbę cech (amplitud dla częstotliwości).

2.4.1. Dyskretna Transformacja Fouriera DFT

Dyskretna transformacja Fouriera DFT (*ang. Discrete Fourier Transform*) służy do przekształcenia wartości z dziedziny czasu na wartości w dziedzinie częstotliwości [72], [86], [122]. Jest ona określona następującym wzorem:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j2\pi kn/N} \quad (2.2)$$

gdzie: X_k – współczynnik częstotliwościowy o numerze k , k – numer częstotliwości, n – numer próbki sygnału, x_n – wartość n -tej próbki sygnału, N – liczba próbek.

Z otrzymanych współczynników częstotliwościowych otrzymywane są odpowiednie amplitudy dla częstotliwości, które są cechami sygnału dla metody DFT ($|X_1|, \dots, |X_k|$). W 1965 roku został opublikowany przez Cooleya i Tuckeya artykuł przedstawiający bardzo wydajny algorytm implementujący dyskretną transformację Fouriera. Obecnie algorytm ten znany jest jako szybka transformacja Fouriera FFT (*ang. Fast Fourier Transform*) [43], [68], [76], [82], [89], [122]. Jest on bardzo skutecznym algorytmem (złożoność obliczeniowa FFT wynosi $O(N \log_2 N)$), jednak wymaga ona przed użyciem zastosowania segmentacji i okienkowania. Założeniem algorytmu FFT jest to, że operuje on na danych wejściowych z liczbą próbek $N = 2^k$, gdzie k to pewna liczba naturalna [72].

W podrozdziale 2.1 ustalono, że częstotliwość próbkowania wynosi 20000 Hz. Zatem jeśli próbka jednosekundowa prądu/napięcia zawiera 20000 próbek, to algorytm FFT wykorzysta z niej tylko $N = 16384$ próbek i wówczas $k=14$. Następnie z owych 16384 próbek wyliczane są amplitudy dla częstotliwości, których zgodnie z twierdzeniem Kotielnikowa-Shannona jest 8192. Otrzymane amplitudy odpowiadają pasmu częstotliwości od 1 Hz do 10000 Hz. Każda z 8192 amplitud jest w odległości 1,22 Hz od sąsiedniej amplitudy. W przekonaniu autora jest to przybliżenie, które można zaakceptować do obliczenia charakterystycznych częstotliwości maszyn elektrycznych. Wybierając odpowiednio amplitudy dla częstotliwości będzie można badać pojedynczą amplitudę lub ich grupę. Wówczas połączenie metody wyboru amplitud dla częstotliwości i FFT będzie redukować liczbę cech (amplitud dla częstotliwości).

2.3.2. Metoda wybierania amplitud dla częstotliwości

Metoda wybierania amplitud będzie operować na widmie częstotliwości. Analizując prądy maszyn elektrycznych można zauważyć, że stany przedawaryjne są dobrze widoczne dla wielokrotności określonej częstotliwości prądu twornika lub prądu wzbudzenia. Ta częstotliwość zależy od prędkości obrotowej maszyny [48], [114]. Znajdujemy ją w zależności od budowy maszyny. Dla maszyny synchronicznej ze wzbudzeniem elektromagnetycznym można zastosować następujący wzór:

$$k_c = N_{obr} \quad (2.3)$$

W przypadku maszyny prądu stałego obcowzbudnej wzór ten wygląda następująco:

$$k_c = N_{obr} m \quad (2.4)$$

gdzie: k_c – charakterystyczna częstotliwość stanu przedawaryjnego, N_{obr} – liczba obrotów maszyny elektrycznej na sekundę, m – liczba biegunów w maszynie prądu stałego.

Wynika z tego, że dla każdej z maszyn należy zmierzyć prądy przy znanej liczbie obrotów. Kolejno należy przeprowadzić analizę sygnałów akustycznych przewidując, że stany przedawaryjne będą dobrze widoczne dla amplitud o częstotliwościach równych całkowitym wielokrotnościom charakterystycznej częstotliwości prądu k_c . Metodę wyboru charakterystycznych cech sygnału akustycznego można zatem przedstawić w następujących krokach:

- 1) W zależności od obrotów w maszynie elektrycznej, znajdź w widmie prądowym charakterystyczną amplitudę o częstotliwości k_c , odpowiadającą stanowi przedawaryjnemu (zobacz wzory 2.3, 2.4).
- 2) Na podstawie znalezionej amplitudy dla częstotliwości prądu, wybierz w sygnale akustycznym amplitudy dla częstotliwości nk_c , gdzie n to liczba całkowita dodatnia i zachodzi $nk_c < 22050$.
- 3) Oblicz różnicę $||X_{1nk_c} - X_{2nk_c}||$ dla amplitud o częstotliwościach nk_c , gdzie $|X_{1nk_c}|$ – jest amplitudą dla częstotliwości nk_c sygnału akustycznego pierwszego stanu maszyny, $|X_{2nk_c}|$ – jest amplitudą dla częstotliwości nk_c sygnału akustycznego drugiego stanu maszyny.
- 4) Wybierz amplitudy dla częstotliwości spełniające nierówność:

2.4.2. Metoda wyboru amplitud dla częstotliwości MSAF

Proponowana metoda wyboru amplitud dla częstotliwości MSAF (ang. Method of Selection of Amplitudes of Frequencies) jest oparta na widmie częstotliwości sygnałów silnika. W metodzie wyboru amplitud częstotliwości (MSAF) są obliczane różnice pomiędzy amplitudami stanów silnika elektrycznego. Sygnały silnika są zależne od stanu i budowy silnika.

Kroki MSAF są następujące:

- 1) Oblicz widmo częstotliwości dla każdego stanu silnika elektrycznego.
- 2) Oblicz różnice pomiędzy stanami silnika elektrycznego: **a-b**, **a-c**, **a-d**, **b-c**, **b-d**, **c-d**, gdzie **a** oznacza widmo sygnału silnika bez uszkodzeń, **b** oznacza widmo sygnału silnika z uszkodzonym pierścieniem wirnika lub z jedną przerwą w zewojach wirnika, **c** oznacza widmo sygnału silnika z uszkodzonym jednym prętem wirnika lub z trzema zwartymi zewojami wirnika, **d** oznacza widmo sygnału silnika z uszkodzonymi dwoma prętami wirnika lub z sześcioma zwartymi zewojami wirnika.
- 3) Oblicz wartości bezwzględne różnic pomiędzy stanami silnika elektrycznego: **la-bl**, **la-cl**, **la-dl**, **lb-cl**, **lb-dl**, **lc-dl**.

$$\|X_{1nk_c} - X_{2nk_c}\| > t \quad (2.5)$$

gdzie t – to próg wyboru amplitud dla częstotliwości (zobacz wzór 2.6), n – liczba całkowita dodatnia, $\|X_{1nk_c} - X_{2nk_c}\|$ – oznacza różnicę amplitud dla częstotliwości nk_c dwóch różnych stanów pracy maszyny. Przy dobieraniu parametru t należy znaleźć kompromis pomiędzy liczbą badanych stanów, liczbą amplitud dla częstotliwości oraz dokładnością obliczeń na etapie klasyfikacji. Jeżeli maksymalne różnice pomiędzy amplitudami dla częstotliwości stanów maszyny pojawiają się na różnych częstotliwościach, to zmniejszanie parametru t może pomóc w rozpoznawaniu stanów przedawaryjnych. Z drugiej strony zmniejszanie parametru t zwiększa liczbę wybieranych amplitud dla częstotliwości (zobacz wzór 2.5). Zbyt duża liczba badanych amplitud dla częstotliwości może spowodować błędy numeryczne oraz błędy na etapie klasyfikacji. Ponadto różnice pomiędzy amplitudami mogą mieć różne wartości, co może powodować różną liczbę amplitud spełniających wzór 2.5 dla danych dwóch stanów. W takim przypadku należy wybrać wspólne charakterystyczne amplitudy dla częstotliwości dla wszystkich badanych stanów. Ze względu na wyżej wymienione uwagi przyjęto, że parametr t powinien zostać wybrany zgodnie z wzorami 2.6, 2.7. Jeżeli liczba różnic amplitud dla częstotliwości (liczba s) będzie większa niż 7, wykonuj w pętli obliczenia zgodnie z wzorem 2.6. W przeciwnym razie zakończ obliczenia.

$$t = \frac{\sum_{s=1}^s \|X_{1sk_c} - X_{2sk_c}\|}{s}$$

$$s \leq 7$$

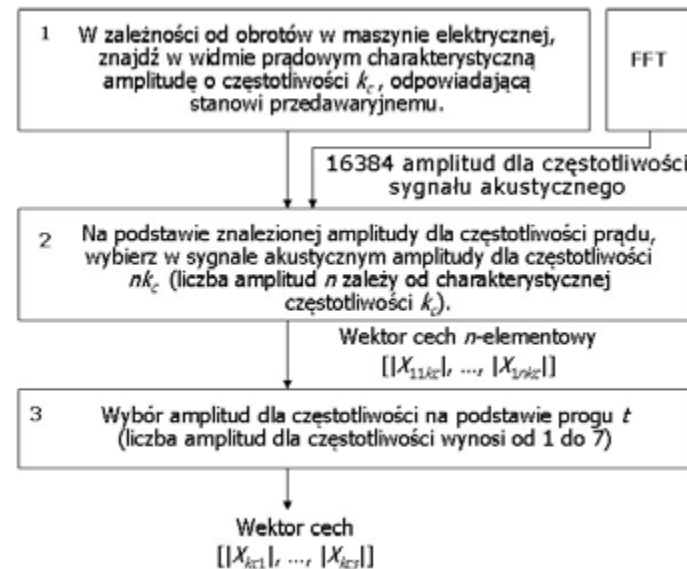
(2.6) (2.7)

gdzie t – to próg wyboru amplitud dla częstotliwości, s – liczba całkowita dodatnia określająca liczbę różnic amplitud dla częstotliwości nk_c (na początku $s=n$). Jeżeli warunek $s > 7$ jest spełniony, to w kolejnych iteracjach za s należy podstawić liczbę różnic amplitud dla częstotliwości, które pozostają po iteracji wcześniejszej. Dla takiej wartości parametru t rozmiar przestrzeni cech nie będzie powodować znaczących błędów na etapie klasyfikacji. Ponadto liczba obliczeń wykonywanych w kolejnych krokach przetwarzania

- 4) Wybierz 8 maksymalnych amplitud częstotliwości dla każdej różnicy pomiędzy stanami silnika elektrycznego $\max_1 |a-b|, \dots, \max_8 |a-c|, \dots, \max_1 |a-d|, \dots, \max_8 |b-c|, \dots, \max_1 |b-d|, \dots, \max_8 |c-d|$ i wyznacz odpowiadające częstotliwości.
- 5) Poszukaj wspólnych częstotliwości i następnie wyznacz dla tych częstotliwości amplitudy widma dla każdego stanu silnika elektrycznego.

zostanie zredukowana. Zgodnie z wzorami 2.6 i 2.7 po ostatniej iteracji otrzymywane są **cechy** sygnału akustycznego danego stanu pracy maszyny, których liczba może wynosić od 1 do 7 ($|X_{kc1}|, \dots, |X_{kcs}|$), gdzie $|X_{kcs}|$ jest amplitudą o numerze s dla wielokrotności częstotliwości k_c .

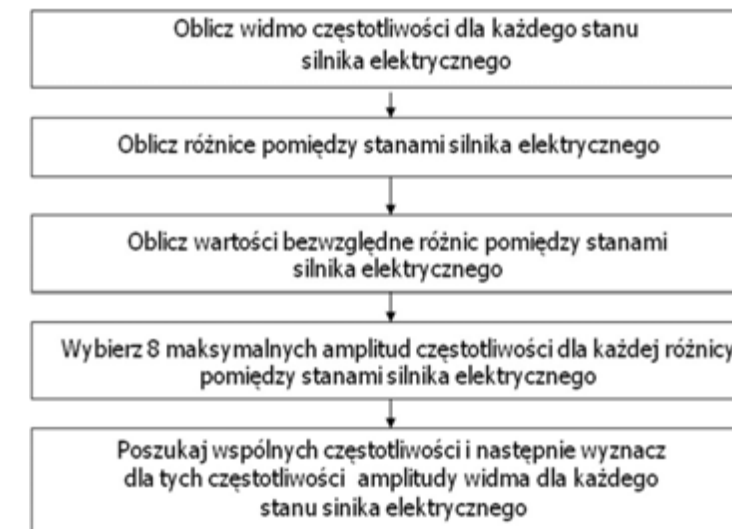
Metodę wybierania amplitud dla częstotliwości przedstawiono na rysunku 2.4.



Rys. 2.4. Metoda wybierania amplitud dla częstotliwości sygnału akustycznego maszyn elektrycznych

Jeśli ekstrakcja cech ograniczy się do wyboru metody FFT i wyboru amplitud dla częstotliwości, to wybrane amplitudy będą tworzyć tzw. **wektor cech** $[|X_{kc1}|, \dots, |X_{kcs}|]$, który będzie używany w etapie klasyfikacji.

Metoda wyboru amplitud dla częstotliwości silnika elektrycznego została przedstawiona na rysunku 2.4.



Rys. 2.4. Metoda wyboru amplitud dla częstotliwości sygnałów prądowych i napięciowych silników elektrycznych

Jeśli ekstrakcja cech ograniczy się do wyboru metody FFT i wyboru amplitud dla częstotliwości, to wybrane amplitudy będą tworzyć tzw. **wektor cech** $[|X_{kc1}|, \dots, |X_{kcs}|]$, który będzie używany w etapie klasyfikacji.

2.4.3. Metoda wyboru amplitud dla częstotliwości MSAF Ratio

Proponowana metoda wyboru amplitud dla częstotliwości (Method of Selection of Amplitudes of Frequencies Ratio) bazuje na widmie częstotliwości sygnałów silnika. W metodzie (MSAF Ratio10) są obliczane różnice pomiędzy amplitudami różnych stanów silnika elektrycznego. Sygnały silnika są zależne od stanu i budowy silnika. Algorytm obliczeniowy dla metody jest następujący:

1. Wyznacz widmo częstotliwości dla każdego stanu silnika elektrycznego.
2. Oblicz różnice pomiędzy stanami silnika elektrycznego: **a-b**, **a-c**, **a-d**, **b-c**, **b-d**, **c-d**, gdzie **a** oznacza widmo sygnału silnika bez uszkodzeń, **b** oznacza widmo sygnału silnika z uszkodzonym pierścieniem wirnika lub z jedną przerwą w zezwojach wirnika, **c** oznacza widmo sygnału silnika z uszkodzonym jednym prętem wirnika lub z trzema zwartymi zezwojami wirnika, **d** oznacza widmo sygnału silnika z uszkodzonymi dwoma prętami wirnika lub z sześcioma zwartymi zezwojami wirnika.
3. Oblicz wartości bezwzględne różnic pomiędzy stanami silnika elektrycznego: **la-bl**, **la-cl**, **la-dl**, **lb-cl**, **lb-dl**, **lc-dl**.

2.3.3. Liniowe kodowanie predykcyjne

Liniowe kodowanie predykcyjne (LPC, *ang. Linear Predictive Coding*), zastosowali po raz pierwszy Saito i Itakura w 1966 roku. Model ten, oparty jest na analizie budowy narządu mowy człowieka [24], [67], [103], [118]. Transmitancja filtru predykcji liniowej jest wyrażona następującym wzorem:

$$H(z) = \frac{1}{1 - \sum_{k=1}^p a_k z^{-k}} \quad (2.8)$$

gdzie p jest liczbą współczynników, a_k jest współczynnikiem filtra predykcji liniowej o indeksie $k = 1, \dots, p$.

Otrzymane moduły współczynników filtra predykcji liniowej $|a_1|, \dots, |a_p|$ są **cechami** sygnału dla metody LPC. Liniowe kodowanie predykcyjne oparte jest na kombinacji liniowej p próbek. Na podstawie p poprzednich wartości sygnału akustycznego $s(n)$ przewiduje się wartości kolejne:

$$s'(n) = -\sum_{k=1}^p a_k \cdot s(n-k) \quad (2.9)$$

gdzie $s'(n)$ jest prognozą wartości sygnału w chwili n -tej.

Błąd między bieżącą próbką i przewidywaną można wyrazić jako:

$$err(n) = s(n) - s'(n) \quad (2.10)$$

4. Wyznacz maksymalne różnice $R_{m1}=\max\{|\mathbf{a}-\mathbf{b}|\}$, $R_{m2}=\max\{|\mathbf{a}-\mathbf{c}|\}$, $R_{m3}=\max\{|\mathbf{a}-\mathbf{d}|\}$, $R_{m4}=\max\{|\mathbf{b}-\mathbf{c}|\}$, $R_{m5}=\max\{|\mathbf{b}-\mathbf{d}|\}$, $R_{m6}=\max\{|\mathbf{c}-\mathbf{d}|\}$,
5. Oblicz stosunki amplitud częstotliwości dla każdej różnicy pomiędzy dwoma stanami silnika do maksymalnej różnicy pomiędzy tymi dwoma stanami.
6. Wybierz te częstotliwości, które mają stosunek większy niż $\text{Ratio}=0,1$.
7. Poszukaj wspólnych częstotliwości i następnie wyznacz dla tych częstotliwości amplitudy widma dla każdego stanu silnika elektrycznego. Wybrane amplitudy będą tworzyć tzw. wektor cech sygnału, który będzie używany w etapie klasyfikacji.

2.4.4. Liniowe kodowanie predykcyjne LPC

Liniowe kodowanie predykcyjne LPC (*ang. Linear Predictive Coding*), zastosowali po raz pierwszy Saito i Itakura w 1966 roku. Model ten, stosowany w fonetyce akustycznej, oparty jest na analizie budowy narządu mowy człowieka [14], [40], [74], [119]. Transmitancja filtru predykcji liniowej jest wyrażona następującym wzorem:

$$H(z) = \frac{1}{1 - \sum_{k=1}^p a_k z^{-k}} \quad (2.3)$$

gdzie p jest liczbą współczynników, a_k jest współczynnikiem filtra predykcji liniowej o indeksie $k = 1, \dots, p$.

Otrzymane moduły współczynników filtra predykcji liniowej $|a_1|, \dots, |a_p|$ są **cechami** sygnału dla metody LPC. Liniowe kodowanie predykcyjne oparte jest na kombinacji liniowej p próbek. Na podstawie p poprzednich wartości sygnału prądowego lub sygnału napięciowego $s(n)$ przewiduje się wartości kolejne:

$$s'(n) = -\sum_{k=1}^p a_k \cdot s(n-k) \quad (2.4)$$

gdzie $s'(n)$ jest prognozą wartości sygnału w chwili n -tej.

Błąd między bieżącą próbką i przewidywaną można wyrazić jako:

$$err(n) = s(n) - s'(n) \quad (2.5)$$

Przyjmując, że N jest liczbą próbek w oknie, należy znaleźć optymalne wartości współczynników a_1, \dots, a_p takie, aby średni błąd prognozy był jak najmniejszy. Najczęściej jako kryterium jakości predykcji wybiera się błąd średniokwadratowy, zdefiniowany następująco:

$$J = \sigma^2 = \frac{1}{N-p} \sum_{n=p}^{N-1} \text{err}^2(n) = \frac{1}{N-p} \sum_{n=p}^{N-1} \left[s(n) + \sum_{j=1}^p a_j s(n-j) \right]^2 \quad (2.11)$$

Aby wyznaczyć optymalne współczynniki a_1, \dots, a_p , należy obliczyć pochodną cząstkową J względem każdego z tych współczynników i przyrównać ją do zera. Otrzymujemy w ten sposób układ p równań z p niewiadomymi, który posiada następujące rozwiązanie:

$$\mathbf{a} = -\mathbf{R}^{-1} \mathbf{r} \quad (2.12)$$

gdzie

$$\mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix}, \mathbf{R} = \begin{bmatrix} r(0) & r(1) & \dots & r(p-1) \\ r(1) & r(0) & \dots & r(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ r(p-1) & r(p-2) & \dots & r(0) \end{bmatrix}, \mathbf{r} = \begin{bmatrix} r(1) \\ r(2) \\ \vdots \\ r(p) \end{bmatrix} \quad (2.13)$$

$$r(k) = \frac{1}{N-p} \sum_{n=p}^{N-1} s(n)s(n+k) \quad (2.14)$$

Znając współczynniki predykcji, można z równania (2.11) obliczyć jej błąd $J_{\min} = \sigma_{\min}^2$:

$$J_{\min} = \sigma_{\min}^2 = r(0) + \mathbf{a}^T \mathbf{r} = r(0) + \sum_{j=1}^p a_j r(j) \quad (2.15)$$

Obliczenie współczynników filtra predykcji liniowej ze wzoru (2.12) wymaga wyznaczenia macierzy odwrotnej \mathbf{R}^{-1} dla każdej „ramki” sygnału akustycznego. Rozwiązaniem tego zadania jest zastosowaniem algorytmu Durбина-Levinsona opisanego w literaturze [14], [118]. Algorytm ten jest skuteczny, ponieważ potrzebuje tylko M^2 mnożeń, aby wyliczyć współczynniki filtra predykcji liniowej a_1, \dots, a_p (złożoność obliczeniowa wynosi $O(N^2)$). Współczynniki te tworzą **wektor cech** $[|a_1|, |a_2|, \dots, |a_p|]$, który będzie używany w etapie klasyfikacji (zobacz wzór 2.8). W literaturze autorzy stosują liczby współczynników

Przyjmując, że N jest liczbą próbek w oknie, należy znaleźć optymalne wartości współczynników a_1, \dots, a_p takie, aby średni błąd prognozy był jak najmniejszy. Najczęściej jako kryterium jakości predykcji wybiera się błąd średniokwadratowy, zdefiniowany następująco:

$$J = \sigma^2 = \frac{1}{N-p} \sum_{n=p}^{N-1} \text{err}^2(n) = \frac{1}{N-p} \sum_{n=p}^{N-1} \left[s(n) + \sum_{j=1}^p a_j s(n-j) \right]^2 \quad (2.6)$$

Aby wyznaczyć optymalne współczynniki a_1, \dots, a_p , należy obliczyć pochodną cząstkową J względem każdego z tych współczynników i przyrównać ją do zera. Otrzymujemy w ten sposób układ p równań z p niewiadomymi, który posiada następujące rozwiązanie:

$$\mathbf{a} = -\mathbf{R}^{-1} \mathbf{r} \quad (2.7)$$

gdzie:

$$\mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix}, \mathbf{R} = \begin{bmatrix} r(0) & r(1) & \dots & r(p-1) \\ r(1) & r(0) & \dots & r(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ r(p-1) & r(p-2) & \dots & r(0) \end{bmatrix}, \mathbf{r} = \begin{bmatrix} r(1) \\ r(2) \\ \vdots \\ r(p) \end{bmatrix} \quad (2.8)$$

$$r(k) = \frac{1}{N-p} \sum_{n=p}^{N-1} s(n)s(n+k) \quad (2.9)$$

Znając współczynniki predykcji, można z równania (2.6) obliczyć jej błąd $J_{\min} = \sigma_{\min}^2$:

$$J_{\min} = \sigma_{\min}^2 = r(0) + \mathbf{a}^T \mathbf{r} = r(0) + \sum_{j=1}^p a_j r(j) \quad (2.10)$$

Obliczenie współczynników filtra predykcji liniowej ze wzoru (2.8) wymaga wyznaczenia macierzy odwrotnej \mathbf{R}^{-1} dla każdej „ramki” sygnału prądowego/napięciowego. Rozwiązaniem tego zadania jest zastosowaniem algorytmu Durбина-Levinsona opisanego w literaturze [14], [122]. Algorytm ten jest efektywny ponieważ potrzebuje tylko M^2 mnożeń, aby wyliczyć współczynniki filtra predykcji liniowej a_1, \dots, a_p (złożoność obliczeniowa wynosi $O(N^2)$). Współczynniki te tworzą **wektor cech** $[|a_1|, |a_2|, \dots, |a_p|]$, który będzie używany w etapie klasyfikacji. W literaturze autorzy stosują liczby współczynników filtra predykcji

filtra predykcji liniowej od 8 do 20 [24], [43], [44], [62], [93], [118], [120]. W badaniach liczba współczynników filtra predykcji liniowej zostanie dobrana tak, aby otrzymać jak najlepsze wyniki rozpoznawania sygnałów akustycznych. Metoda LPC operuje na dziedzinie czasu. Z tego powodu, gdy metodą ekstrakcji cech jest LPC, to po wykonaniu metody FFT i wyboru odpowiednich amplitud dla częstotliwości należy zastosować metodę IFFT (*ang. Inverse Fast Fourier Transform*) oraz segmentację omówioną w podrozdziale 2.2.3.

2.3.4. Współczynniki liniowego kodowania predykcyjnego cepstrum

Metoda LPCC (*ang. Linear Predictive Cepstrum Coefficients*) jest oparta na metodzie LPC, po zastosowaniu którego zostają otrzymane współczynniki filtra predykcji liniowej a_1, \dots, a_p . Kolejno stosuje się wzór 2.16, który przekształca je w współczynniki cepstralne c_1, \dots, c_n [2]. Postać taka może zostać zastosowana do efektywnego porównywania sygnałów,

$$c_n = \begin{cases} a_n + \sum_{k=1}^{n-1} \frac{k}{n} c_k a_{n-k} & 1 \leq n \leq p \\ \sum_{k=n-p}^{n-1} \frac{k}{n} c_k a_{n-k} & n > p \end{cases} \quad (2.16)$$

gdzie: $c_0 = r(0)$, p – rząd predykcji, n – liczba współczynników cepstralnych.

W przypadku metody LPCC **cechami** sygnału są odpowiednie moduły współczynników cepstralnych $|c_1|, \dots, |c_n|$. Współczynniki te tworzą **wektor cech** $[|c_1|, |c_2|, \dots, |c_n|]$, który będzie używany w etapie klasyfikacji. W badaniach liczba współczynników cepstralnych zostanie dobrana tak, aby otrzymać jak najlepsze wyniki rozpoznawania sygnałów akustycznych.

2.4. Wybrane metody klasyfikacji sygnałów akustycznych

Klasyfikacja jest ostatnim krokiem w badaniu sygnałów akustycznych. W kroku tym cechy charakterystyczne sygnałów porównywane są ze sobą. Kolejno na podstawie uzyskanych wyników podejmowana jest decyzja o zaklasyfikowaniu sygnału do danej klasy [103]. Obecnie metody klasyfikacyjne stosowane są do rozpoznawania między innymi: mowy człowieka, tożsamości mówcy, dźwięków zwierząt, urządzeń mechanicznych, instrumentów muzycznych.

liniowej od 8 do 20 [14], [40], [74], [119]. W badaniach liczba współczynników filtra predykcji liniowej zostanie dobrana tak, aby otrzymać jak najlepsze wyniki rozpoznawania sygnałów prądowych i napięciowych. Metoda LPC operuje na dziedzinie czasu. Z tego powodu, gdy metodą ekstrakcji cech jest LPC, to po wykonaniu metody FFT i wyboru odpowiednich amplitud dla częstotliwości należy zastosować metodę IFFT (*ang. Inverse Fast Fourier Transform*) oraz segmentację omówioną w podrozdziale 2.2.3.

2.4.5. Współczynniki liniowego kodowania predykcyjnego cepstrum LPCC

Metoda LPCC (*ang. Linear Predictive Cepstrum Coefficients*) jest oparta na metodzie LPC, po zastosowaniu którego zostają otrzymane współczynniki filtra predykcji liniowej a_1, \dots, a_p . Kolejno stosuje się wzór (2.11), który przekształca je w współczynniki cepstralne c_1, \dots, c_n [2], [31], [42], [91], [121]. Postać taka może zostać zastosowana do efektywnego porównywania sygnałów:

$$c_n = \begin{cases} a_n + \sum_{k=1}^{n-1} \frac{k}{n} c_k a_{n-k} & 1 \leq n \leq p \\ \sum_{k=n-p}^{n-1} \frac{k}{n} c_k a_{n-k} & n > p \end{cases} \quad (2.11)$$

gdzie: $c_0 = r(0)$, p – rząd predykcji, n – liczba współczynników cepstralnych.

W przypadku metody LPCC **cechami** sygnału są odpowiednie moduły współczynników cepstralnych $|c_1|, \dots, |c_n|$. Współczynniki te tworzą **wektor cech** $[|c_1|, |c_2|, \dots, |c_n|]$, który będzie używany w etapie klasyfikacji. W badaniach liczba współczynników cepstralnych zostanie dobrana tak, aby otrzymać jak najlepsze wyniki rozpoznawania sygnałów prądowych i napięciowych.

2.5. Wybrane metody klasyfikacji sygnałów prądowych i napięciowych

Klasyfikacja jest ostatnim krokiem w badaniu sygnałów prądowych i napięciowych. W kroku tym cechy charakterystyczne sygnałów porównywane są ze sobą. Kolejno na podstawie uzyskanych wyników podejmowana jest decyzja o zaklasyfikowaniu sygnału do danej klasy [106]. Obecnie metody klasyfikacyjne stosowane są do rozpoznawania między innymi: mowy [23], [24], [109], [123], dźwięków instrumentów muzycznych [79], [93], [112], obrazów [9], [30], [55], [84], [94], [95], [103] i również do rozpoznawania uszkodzeń izolacji [29], [30], [32], [33], [34], [61], uszkodzeń silników elektrycznych: synchronicznych [25], [42], [47], [53], [54], [64], indukcyjnych [16], [35], [49], [50],

Do najczęściej stosowanych metod w rozpoznawaniu tożsamości mówcy, sygnałów akustycznych, instrumentów muzycznych należą: HMM (*ang. Hidden Markov Models*) [23], [42], [74], [109], VQ (*ang. Vector Quantization*) [101], LVQ (*ang. Learning Vector Quantization*) [115], SOM (*ang. Self-Organising Maps*) [76], ANN (*ang. Artificial Neural Networks*) [55], [73], [99], [102], GMM (*ang. Gaussian Mixture Models*) [8], [64], [100], SVM (*ang. Support Vector Machines*) [55], [97], [98], [103], [115], GSDM (*ang. Genetic Sparse Distributed Memory*) [25], [86]. Powstały też klasyfikatory stosowane w rozpoznawaniu instrumentów muzycznych: F-GC (*ang. Flat Gaussian Classifier*), H-GC (*ang. Hierarchical Gaussian Classifier*) [78]. Metody takie jak ML-HMM (*ang. Maximum Likelihood Hidden Markov Model*) i EP-HMM (*ang. Entropic Prior Hidden Markov Model*) zostały zastosowane do rozpoznawania sygnałów akustycznych pochodzących z gry w golfa, baseballa, piłki nożnej [113].

Często spotykanymi klasyfikatorami są również NN (*ang. Nearest Neighbor*) [49], [115], k -NN [60], [65], NM (*ang. Nearest Mean*) [103]. Zmodyfikowany klasyfikator NM był stosowany w rozpoznawaniu tożsamości mówcy [93]. W podobnym celu stosuje się metodę AHS (*ang. Arithmetic Harmonic Sphericity measure*) [101].

W pracy liczba badanych maszyn elektrycznych tego samego typu jest ograniczona. Można zatem przyjąć, że klasyfikacja będzie obejmować dwa etapy: tworzenia wzorców do rozpoznawania i identyfikacji [88]. Wybór takiego podejścia powoduje, że w badaniach należy utworzyć zbiór uczący i testowy. Zbiór uczący zawierać będzie próbki dźwięku używane w procesie tworzenia wzorców do rozpoznawania. Zbiór testowy zawierać będzie próbki dźwięku używane w procesie identyfikacji. Wyniki rozpoznawania sygnałów akustycznych będą zależeć w dużym stopniu od próbek dźwięku zawartych w tychże zbiorach. Problemem, który się tu pojawia jest brak maszyn elektrycznych tego samego typu (rodzaj maszyny, rozmiar, parametry), z tego powodu próbki dźwięku w obu zbiorach będą pochodzić z tej samej maszyny.

Spośród klasyfikatorów w badaniach stosowane będą zaproponowany przez autora klasyfikator oparty na słowach (zobacz podrozdział 2.4.2) oraz dwa klasyfikatory opisane w literaturze:

[56], [63], [66], [87], [97], [99], [110], [113], [114], prądu stałego [37], [40], [43], [44], [45], [46], [48], [51], [52], [117].

Do najczęściej stosowanych metod w rozpoznawaniu tożsamości mówcy, sygnałów akustycznych, instrumentów muzycznych należą: HMM (*ang. Hidden Markov Models*) [23], GSDM (*ang. Genetic Sparse Distributed Memory*) [27], [92]. Spośród metod klasyfikacji, które mogą być zastosowane w rozpoznawaniu uszkodzeń silników elektrycznych, wybrano do badań następujące metody: sieci neuronowych z algorytmem wstecznej propagacji błędów [3], [13], [28], [84], [102], metodę najbliższych sąsiadów NN (*ang. Nearest Neighbor*) [4], [28], [49], [65], [90], [115], metodę prawdopodobieństwa a posteriori Bayesa [28], [51], [52] oraz metodę LDA (liniowej analizy dyskryminacyjnej) [28], [45], [50], [59], [75].

Często spotykanymi klasyfikatorami są również k -NN [60], [65], NM (*ang. Nearest Mean*) [107]. Zmodyfikowany klasyfikator NM był stosowany na przykład w rozpoznawaniu tożsamości mówcy. W niniejszej pracy klasyfikatorów NM jednak nie stosowano.

W badaniach relacjonowanych w tej pracy liczba badanych maszyn elektrycznych tego samego typu jest ograniczona. Można zatem przyjąć, że klasyfikacja będzie obejmować dwa etapy: tworzenia wzorców do rozpoznawania i identyfikacji [88]. Wybór takiego podejścia powoduje, że w badaniach należy utworzyć zbiór uczący i testowy. Zbiór uczący zawierać będzie próbki prądu/napięcia używane w procesie tworzenia wzorców do rozpoznawania. Zbiór testowy zawierać będzie próbki prądu/napięcia używane w procesie identyfikacji dla potrzeb upewnienia się, że metoda działa poprawnie także na tych danych, które **nie były** używane w trakcie procesu uczenia. Wyniki rozpoznawania sygnałów prądowych i napięciowych będą zależeć w dużym stopniu od próbek prądu/napięcia zawartych w tychże zbiorach. Problemem, który się tu pojawia jest brak wielu egzemplarzy maszyn elektrycznych tego samego typu (rodzaj maszyny, rozmiar, parametry), z tego powodu próbki prądu/napięcia w obu zbiorach będą pochodzić z tej samej maszyny, ale z różnych pomiarów.

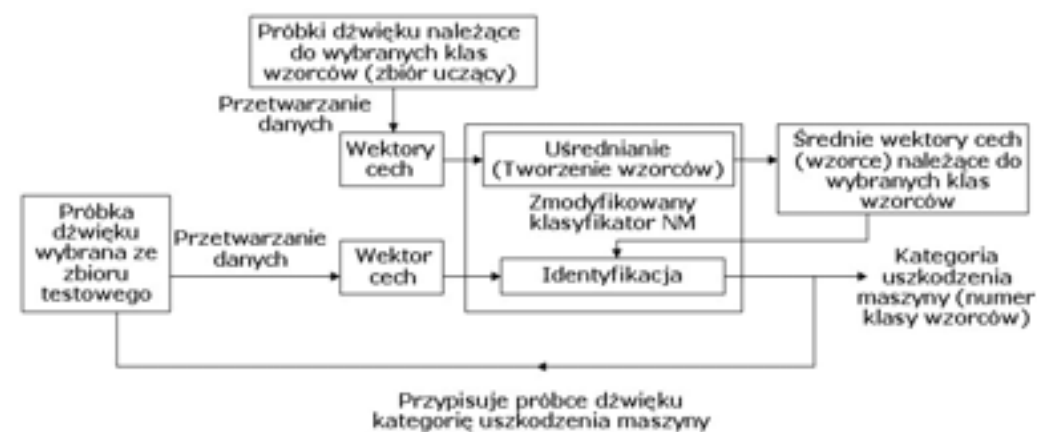
zmodyfikowany klasyfikator NM [31] oraz klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów [33].

Możliwe również będzie wbudowanie kolejnych metod klasyfikacji w zależności od potrzeb.

2.4.1. Zmodyfikowany klasyfikator Nearest Mean

W pracy doktorskiej rozważana jest jedna maszyna danego typu z ograniczoną liczbą stanów przedawaryjnych. Mając, zatem zbiór uczący, który zawiera ograniczoną liczbę stanów przedawaryjnych z jednej maszyny elektrycznej nasuwa się pomysł zmodyfikowania klasyfikatora „najbliższa średnia” (NM, *ang. Nearest Mean*). W dalszej części pracy klasyfikator ten będzie określany jako zmodyfikowany klasyfikator NM.

Podczas użycia zmodyfikowanego klasyfikatora NM stosowane są dwa etapy: tworzenia wzorców do rozpoznawania oraz identyfikacji (zobacz rysunek 2.5). W etapie tworzenia wzorców do rozpoznawania na wejście klasyfikatora podawany jest wektor cech $\mathbf{x} = [x_1, x_2, \dots, x_n]$, gdzie x_1, \dots, x_n są odpowiednimi cechami wyliczonymi dla danej metody FFT, LPC lub LPCC. Wektor ten powstał z określonej próbki dźwięku zawartej w zbiorze uczącym. W zbiorze uczącym można wyróżnić zbiory podobnych próbek dźwięku, które tworzą tak zwane klasy wzorców. Klasy wzorców oznaczono jako w_1, w_2, \dots, w_j , gdzie indeks j jest numerem klasy.



Rys. 2.5. Etap tworzenia wzorców do rozpoznawania oraz etap identyfikacji dla zmodyfikowanego klasyfikatora NM

Następnie podczas etapu tworzenia wzorców do rozpoznawania otrzymywane są średnie wektory cech $\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_j$ (wzorce). Wektory te wyliczone są zgodnie ze wzorem 2.17:

$$\mathbf{m}_j = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (2.17)$$

gdzie: j jest numerem klasy wzorców, \mathbf{x}_i jest i -tym wektorem cech należącym do klasy wzorców w_j , n jest liczbą wektorów cech, które należą do klasy wzorców w_j .

Każda klasa wzorców jest reprezentowana przez średni wektor cech \mathbf{m}_j . W przyjętym klasyfikatorze proces tworzenia wzorców do rozpoznawania wykonywany jest przez MRSA (zobacz podrozdział 3.4.3). Podejście takie zostało zastosowane w bibliotece MARF [84], [93]. Kolejno następuje etap identyfikacji nowego wektora cech $\mathbf{y} = [y_1, y_2, \dots, y_n]$, gdzie y_1, y_2, \dots, y_n są odpowiednimi cechami wyliczonymi dla danej metody FFT, LPC lub LPCC. Wektor ten powstał z określonej próbki dźwięku zawartej w zbiorze testowym. Identyfikacja wektora cech \mathbf{y} polega na przydzieleniu go do klasy, której średni wektor cech znajduje się najbliżej wektora cech \mathbf{y} . Do tego celu zmodyfikowany klasyfikator NM korzysta odpowiednio z jednej wybranej metryki: Manhattan, Euklidesa, Minkowskiego, kosinusowej, Jacquarda. Metryka Minkowskiego, to miara odległości między dwoma wektorami. Metryka ta określona jest w zbiorze \mathbb{R}^n ($n \in \mathbb{N}$) [93]. Dla pary wektorów $\mathbf{y} = [y_1, y_2, \dots, y_n]$, $\mathbf{m}_j = [m_1, m_2, \dots, m_n] \in \mathbb{R}^n$, $r \in \mathbb{N}$, odległość wyraża się wzorem (2.18):

$$d(\mathbf{y}, \mathbf{m}_j) = \left(\sum_{i=1}^n (|y_i - m_i|)^r \right)^{\frac{1}{r}} \quad (2.18)$$

Dla metryki Jacquarda odległość wyraża się wzorem (2.19):

$$d(\mathbf{y}, \mathbf{m}_j) = 1 - \frac{\sum_{i=1}^n y_i m_i}{\sum_{i=1}^n y_i^2 + \sum_{i=1}^n m_i^2 - \sum_{i=1}^n y_i m_i} \quad (2.19)$$

Dla metryki kosinusowej odległość wyraża się wzorem (2.20):

$$d(\mathbf{y}, \mathbf{m}_j) = 1 - \frac{\sum_{i=1}^n y_i m_i}{\sqrt{\sum_{i=1}^n y_i^2} \sqrt{\sum_{i=1}^n m_i^2}} \quad (2.20)$$

gdzie: \mathbf{y} i \mathbf{m}_j są wektorami o tych samych długościach.

Nowy wektor cech \mathbf{y} jest przydzielony do klasy w_j jeżeli $d(\mathbf{y}, \mathbf{m}_j)$ jest odległością najmniejszą:

$$\min(d(\mathbf{y}, \mathbf{m}_j)) \Rightarrow \mathbf{y} \rightarrow w_j \quad j = 1, 2, \dots, M \quad (2.21)$$

gdzie: \mathbf{m}_j jest średnim wektorem cech należącym do klasy w_j , \mathbf{y} jest nowym wektorem cech, M jest numerem klasy wzorców.

Można zauważyć, że działanie tego klasyfikatora NM jest zależne od wybranej metryki. Niestety nie wiadomo, która metryka będzie dawać wyniki najlepsze, dlatego zakłada się badanie metryk: Manhattan, Euklidesa, Minkowskiego, kosinusowej i Jacquarda.

2.4.2. Klasyfikator oparty na słowach

Klasyfikator oparty na słowach bazuje na przekształceniu wartości liczbowych w ciąg znaków, który jest słowem. Podczas użycia klasyfikatora opartego na słowach stosowane są dwa etapy: tworzenia wzorców do rozpoznawania oraz identyfikacji. Podobnie jak dla zmodyfikowanego klasyfikatora NM w klasyfikatorze opartym na słowach przyjmuje się, że w etapie tworzenia wzorców do rozpoznawania na wejście klasyfikatora podawany jest wektor cech $\mathbf{x} = [x_1, x_2, \dots, x_n]$, gdzie x_1, \dots, x_n są odpowiednimi cechami wyliczonymi dla danej metody FFT, LPC lub LPCC. Wektor ten powstał z określonej próbki dźwięku zawartej w zbiorze uczącym. Klasy wzorców oznaczono jako w_1, w_2, \dots, w_j , gdzie indeks j jest numerem klasy. Podczas etapu tworzenia wzorców do rozpoznawania otrzymywane są średnie wektory cech $\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_j$ (zobacz wzór 2.17). Następnie wykonywana jest zamiana średniego wektora cech \mathbf{m}_j na średni wektor słów $\mathbf{v}_j = [v_1, v_2, \dots, v_n]$, gdzie v_1, v_2, \dots, v_n są kolejnymi współrzędnymi (słowami), które tworzą średni wektor słów należący do j -tej klasy wzorców. Zamiana ta wykonywana jest zgodnie z wzorem 2.22:

$$\begin{cases} m_i \in [k, 2k) \Rightarrow m_i \rightarrow v_{i1} \\ m_i \in [2k, 3k) \Rightarrow m_i \rightarrow v_{i2} \\ \dots \\ m_i \in [kg, kg+k) \Rightarrow m_i \rightarrow v_{ig} \end{cases} \quad (2.22)$$

gdzie: $k \in \mathbb{W}$, g jest liczbą słów, v_{ig} oznacza g -te słowo, m_i jest współrzędną i średniego wektora cech \mathbf{m}_j , $i=0, \dots, n$.

Każda klasa wzorców jest reprezentowana przez średni wektor słów \mathbf{v}_j (wzorzec).

Należy zauważyć, że dla wektora \mathbf{v}_j słowo v_{i1} może wystąpić 0 razy lub nawet n razy. W rozważaniach powinno się przyjąć ograniczoną liczbę słów $v_{i1}, v_{i2}, \dots, v_{ig}$, a następnie tak operować parametrem k , aby

uzyskać odpowiednią dokładność rozpoznawania. Podobnie jak dla zmodyfikowanego klasyfikatora NM etap tworzenia wzorców do rozpoznawania wykonywany jest przez MRSA (zobacz podrozdział 3.4.3).

Kolejno następuje etap identyfikacji nowego wektora cech $\mathbf{y} = [y_1, y_2, \dots, y_n]$, gdzie y_1, y_2, \dots, y_n są odpowiednimi cechami wyliczonymi dla danej metody FFT, LPC lub LPCC. Wektor ten powstał z określonej próbki dźwięku zawartej w zbiorze testowym. Następnie wykonywana jest zamiana wektora cech \mathbf{y} na wektor słów $\mathbf{f} = [f_1, f_2, \dots, f_n]$. Odbywa się to dokładnie tak samo jak zamiana średniego wektora cech \mathbf{m}_j na średni wektor słów \mathbf{v}_j (zobacz wzór 2.23).

$$\left\{ \begin{array}{l} y_i \in [k, 2k) \Rightarrow y_i \rightarrow v_{i1} \\ y_i \in [2k, 3k) \Rightarrow y_i \rightarrow v_{i2} \\ \dots \\ y_i \in [kg, kg+k) \Rightarrow y_i \rightarrow v_{ig} \end{array} \right. \quad (2.23)$$

gdzie: $k \in \mathbb{W}$, v_{ig} oznacza g -te słowo, g jest liczbą słów, y_i jest współrzędną i wektora cech \mathbf{y} , $i=0, \dots, n$.

Identyfikacja nowego wektora słów \mathbf{f} polega na przydzieleniu go do klasy, której średni wektor słów \mathbf{v}_j znajduje się najbliżej wektora słów \mathbf{f} . Do tego celu klasyfikator oparty na słowach używa porównania leksykograficznego. Porównywane są dwa łańcuchy znaków (współrzędna średniego wektora słów \mathbf{v}_j z współrzędną nowego wektora słów \mathbf{f}). Porównania są przeprowadzane w następujący sposób:

$$\begin{array}{l} f_1 = v_1 \\ f_2 = v_2 \\ \dots \\ f_n = v_n \end{array}$$

Wynik każdego jednego porównania jest albo *prawdą* albo *falszem*. Aby określić która klasa wzorców (kategoria uszkodzenia maszyny) powinna być wybrana, wprowadza się następujący wzór:

$$U_j = \frac{U_1}{U_2} \cdot 100\% \quad (2.24)$$

gdzie: U_1 jest liczbą dobrze porównanych słów należących do j -tej klasy wzorców, U_2 jest liczbą wszystkich porównań (równa liczbie współrzędnych w wektorze słów $U_2 = n$), U_j jest liczbą

reprezentującą dobrze rozpoznane słowa należące do j -tej klasy wzorców. Aby uzyskać wynik rozpoznawania sygnału akustycznego stosuje się następującą zależność:

$$\max(U_j) \Rightarrow \mathbf{f} \rightarrow w_j \quad j = 1, 2, \dots, M \quad (2.25)$$

gdzie: \mathbf{f} jest nowym wektorem słów, U_j jest liczbą reprezentującą dobrze rozpoznane słowa należące do j -tej klasy wzorców.

Zamiana wektora cech na słowa umożliwia korzystanie z porównania leksykograficznego.

Porównanie to sprawia, że małe różnice w cechach sygnału (małe w zależności od parametru

k) powodują większy wpływ na wyniki rozpoznawania sygnału akustycznego niż w przypadku klasyfikatora NM. Inną właściwością tego porównania jest to, że duże różnice w cechach sygnału powodują mniejsze zmiany w wynikach rozpoznawania sygnału akustycznego niż w przypadku klasyfikatora NM. Złożoność obliczeniowa dla klasyfikatora opartego na słowach wynosi $O(N)$.

Przewiduje się, że największy wpływ na rozpoznawanie sygnału akustycznego tym klasyfikatorem mają: liczba słów potrzebna do oznaczenia współrzędnych wektora cech i parametr k . Liczba słów będzie wynosić 260, ponieważ jest ona wystarczająca do rozpoznawania. Zakłada się prowadzenie badań z klasyfikatorem opartym na słowach, przy różnym dobieraniu parametru k .

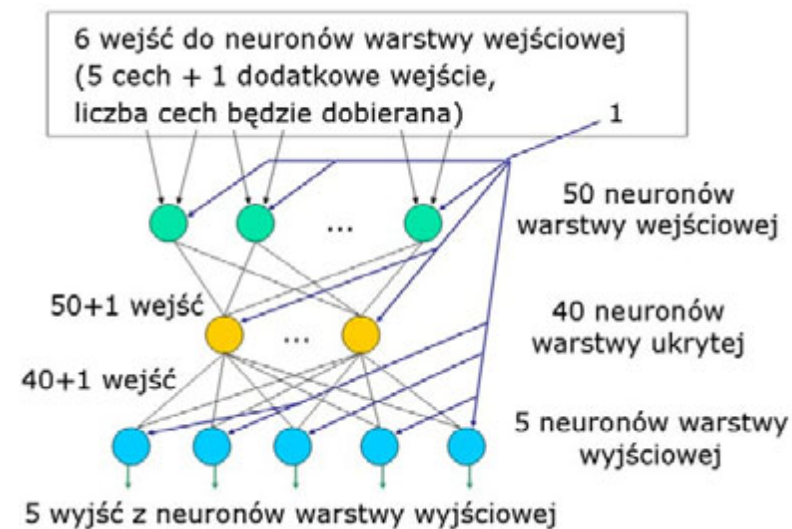
2.4.3. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów

Typowa sieć neuronowa zbudowana jest z dużej liczby elementów przetwarzających informację. Elementy te nazywane są neuronami. Neurony tworzą sieć za pomocą połączeń o parametrach (tak zwanych wagach). Struktura połączeń oraz ich parametry stanowią program działania sieci, natomiast wartości otrzymane na jej wyjściach w odpowiedzi na określone sygnały wejściowe są rozwiązaniami stawianych jej zadań [21], [37], [79], [82], [91], [105]. Podczas użycia klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów stosowane są dwa etapy: uczenia oraz identyfikacji. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów wykonuje najpierw etap uczenia. Podczas etapu uczenia klasyfikator korzysta z algorytmu wstecznej propagacji błędów (*ang. backpropagation algorithm*). Stosując ten algorytm można nauczyć całą sieć, ponieważ każdy neuron warstwy ukrytej albo znajduje się w przedostatniej warstwie sieci i przesyła swoje sygnały do neuronów wyjściowych (wtedy jego błąd może być wyznaczony wyżej podaną metodą) albo znajduje się w jednej z głębiej ukrytych warstw podając sygnały do neuronów innych warstw ukrytych (jego błąd można oszacować z chwilą obliczania błędów w neuronach, które są odbiorcami jego

2.5.1. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów

Typowa sieć neuronowa zbudowana jest z dużej liczby elementów przetwarzających informację. Elementy te nazywane są neuronami. Neurony tworzą sieć za pomocą połączeń o parametrach (tak zwanych wagach). Struktura połączeń oraz ich parametry stanowią program działania sieci, natomiast wartości otrzymane na jej wyjściach w odpowiedzi na określone sygnały wejściowe są rozwiązaniami stawianych jej zadań [3], [13], [21], [28], [41], [49], [54], [65], [83], [84], [88], [99], [102], [107], [108], [114]. Podczas użycia klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów stosowane są dwa etapy: uczenia oraz identyfikacji. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów wykonuje najpierw etap uczenia. Podczas etapu uczenia klasyfikator korzysta z algorytmu wstecznej propagacji błędów (*ang. backpropagation algorithm*). Stosując ten algorytm można nauczyć całą sieć, ponieważ każdy neuron warstwy ukrytej albo znajduje się w przedostatniej warstwie sieci i przesyła swoje sygnały do neuronów wyjściowych (wtedy jego błąd może być wyznaczony wyżej podaną metodą) albo znajduje się w jednej z głębiej ukrytych warstw

sygnałów) [91]. W trakcie etapu uczenia parametry połączeń sieci neuronowej są modyfikowane. Sieć neuronowa, która będzie użyta do rozpoznawania sygnałów akustycznych została przedstawiona na rysunku 2.6. Struktura sieci jest trójwarstwowa, gdzie każda kolejna warstwa ma coraz mniej neuronów. Jest to typowe podejście stosowane dla sieci neuronowych [91].



Rys. 2.6. Struktura sieci neuronowej do rozpoznawania sygnału akustycznego


Podczas uczenia sieci neuronowej wzorce są przechowywane w postaci liczb zmiennoprzecinkowych. Liczby te reprezentują odpowiednie znaki w kodzie ASCII. Znaki te tworzą nazwę danej kategorii dźwięku (klasy wzorcowej). Można zatem zauważyć, że dla klasy wzorców w_j istnieje wektor \mathbf{b}_j , który zawiera jej nazwę:

$\mathbf{b}_j = [b_{1j}, b_{2j}, b_{3j}, b_{4j}, b_{5j}]$ – wektor znaków, określający nazwę klasy wzorcowej w_j . Ze względu na to, że w warstwie wyjściowej jest 5 neuronów (każdy ma 1 wyjście), wektor znaków powinien zawierać dokładnie 5 znaków.

$\mathbf{a}_j = [a_{1j}, a_{2j}, a_{3j}, a_{4j}, a_{5j}]$ – wektor zawierający liczby zmiennoprzecinkowe, określające nazwę klasy wzorcowej w_j , przy czym zachodzi następująca zależność:

$$a_{ij} = \frac{(\text{WARTOSC_KOD_ASCII}(b_{ij}))}{128} \quad (2.26)$$

podając sygnały do neuronów innych warstw ukrytych (jego błąd można oszacować z chwilą obliczania błędów w neuronach, które są odbiorcami jego sygnałów) [91]. W trakcie etapu uczenia parametry połączeń sieci neuronowej są modyfikowane. Sieć neuronowa, która będzie użyta do rozpoznawania sygnałów prądowych i napięciowych została przedstawiona na rysunku 2.5. Struktura sieci jest trójwarstwowa, gdzie każda kolejna warstwa ma coraz mniej neuronów. Jest to założenie arbitralne, ale typowo stosowane dla sieci neuronowych wykorzystywanych w podobnych zadaniach [102].



Rys. 2.5. Struktura sieci neuronowej do rozpoznawania sygnałów prądowych i napięciowych

gdzie: $WARTOSC_KOD_ASCII(b_{ij})$ oznacza wartość liczbową znaku b_{ij} w kodzie ASCII, j – numer klasy wzorcowej, a_{ij} – współrzędna o numerze i wektora \mathbf{a}_j , $i = 1, 2, 3, 4, 5$.

Sieć neuronowa uczy się w ten sposób, że dla klasy wzorcowej w_j podawany jest na jej wyjścia (na 5 wyjść z neuronów warstwy wyjściowej) wektor \mathbf{a}_j . Natomiast na jej wejścia (wejścia do neuronów warstwy wejściowej) podawane są kolejne wektory cech $\mathbf{x} = [x_1, x_2, \dots, x_n]$ przynależące do klasy wzorców w_j , gdzie x_1, \dots, x_n są odpowiednimi cechami wyliczonymi dla danej metody FFT, LPC lub LPCC. Liczba współrzędnych wektora cech odpowiada liczbie wejść do neuronów warstwy wejściowej sieci neuronowej pomniejszonej o jeden.

Po nauczaniu sieci neuronowej, wykonywany jest etap identyfikacji. W etapie tym nowy wektor cech $\mathbf{y} = [y_1, y_2, \dots, y_n]$ podawany jest na wejścia sieci neuronowej, gdzie y_1, y_2, \dots, y_n są odpowiednimi cechami wyliczonymi dla danej metody FFT, LPC lub LPCC. Wektor ten powstał z określonej próbki dźwięku zawartej w zbiorze testowym. Kolejno na wyjściach neuronów w warstwie wyjściowej otrzymywane są wartości oznaczone jako c_1, c_2, c_3, c_4, c_5 . Następnie można utworzyć z nich wektor $\mathbf{c} = [c_1, c_2, c_3, c_4, c_5]$. Zazwyczaj w etapie identyfikacji wartość na wyjściu neuronu w warstwie wyjściowej nie jest równa dokładnej wartości danego znaku w kodzie ASCII podzielonej przez 128. Do określenia klasy wzorców stosowana jest metryka Manhattan. Metryka ta porównuje każdy z wektorów $\mathbf{a}_j = [a_{1j}, a_{2j}, a_{3j}, a_{4j}, a_{5j}]$ z nowo otrzymanym wektorem $\mathbf{c} = [c_1, c_2, c_3, c_4, c_5]$.

Metryka Manhattan określona jest w zbiorze \mathbb{R}^n ($n \in \mathbb{N}$). Dla pary wektorów $\mathbf{c} = [c_1, c_2, \dots, c_n]$, $\mathbf{a} = [a_1, a_2, \dots, a_n] \in \mathbb{R}^n$, wyraża się wzorem (2.27):

$$d(\mathbf{c}, \mathbf{a}) = \sum_{i=1}^n (|c_i - a_i|) \quad (2.27)$$

gdzie: \mathbf{c} i \mathbf{a} są wektorami o tych samych długościach.

Nowy wektor cech \mathbf{y} jest przydzielony do klasy w_j jeżeli $d(\mathbf{c}, \mathbf{a}_j)$ jest odległością najmniejszą.

$$\min(d(\mathbf{c}, \mathbf{a}_j)) \Rightarrow \mathbf{y} \rightarrow w_j \quad j = 1, 2, \dots, M \quad (2.28)$$

gdzie: \mathbf{a}_j jest wektorem zawierającym liczby zmiennoprzecinkowe określające nazwę klasy wzorcowej w_j , \mathbf{y} jest nowym wektorem cech, \mathbf{c} jest nowym wektorem utworzonym z wartości otrzymanych na wyjściach neuronów warstwy wyjściowej sieci neuronowej, M jest numerem klasy wzorców.

W badaniach dobierane będą parametry sieci neuronowej w celu uzyskania jak najlepszych wyników rozpoznawania sygnałów akustycznych. Ważniejsze parametry sieci neuronowej na które należy zwrócić uwagę to:

1. Maksymalny błąd = 0,01 (powszechnie przyjmowana wartość) [82], [91].
2. Liczba warstw sieci neuronowej = 3 (powszechnie przyjmowana wartość) [82], [91].
3. Struktura sieci neuronowej – trójkątna [91].
4. Liczba neuronów w warstwach sieci neuronowej – ze względu na dużą liczbę wariantów w badaniach stosowane będą następujące liczby neuronów: 50 neuronów w warstwie wejściowej sieci neuronowej, 40 neuronów w warstwie ukrytej, 5 neuronów w warstwie wyjściowej.
5. Współczynnik uczenia = 0,1 (powszechnie przyjmowana wartość) [82], [91].
6. Współczynnik momentum = 0,5 (powszechnie przyjmowana wartość) [82], [91].
7. Liczba wejść do neuronów warstwy wejściowej sieci neuronowej (przykładowo liczba ta może wynosić 6 i wówczas może odpowiadać ona 5 cechom sygnału oraz 1 dodatkowemu wejściu).

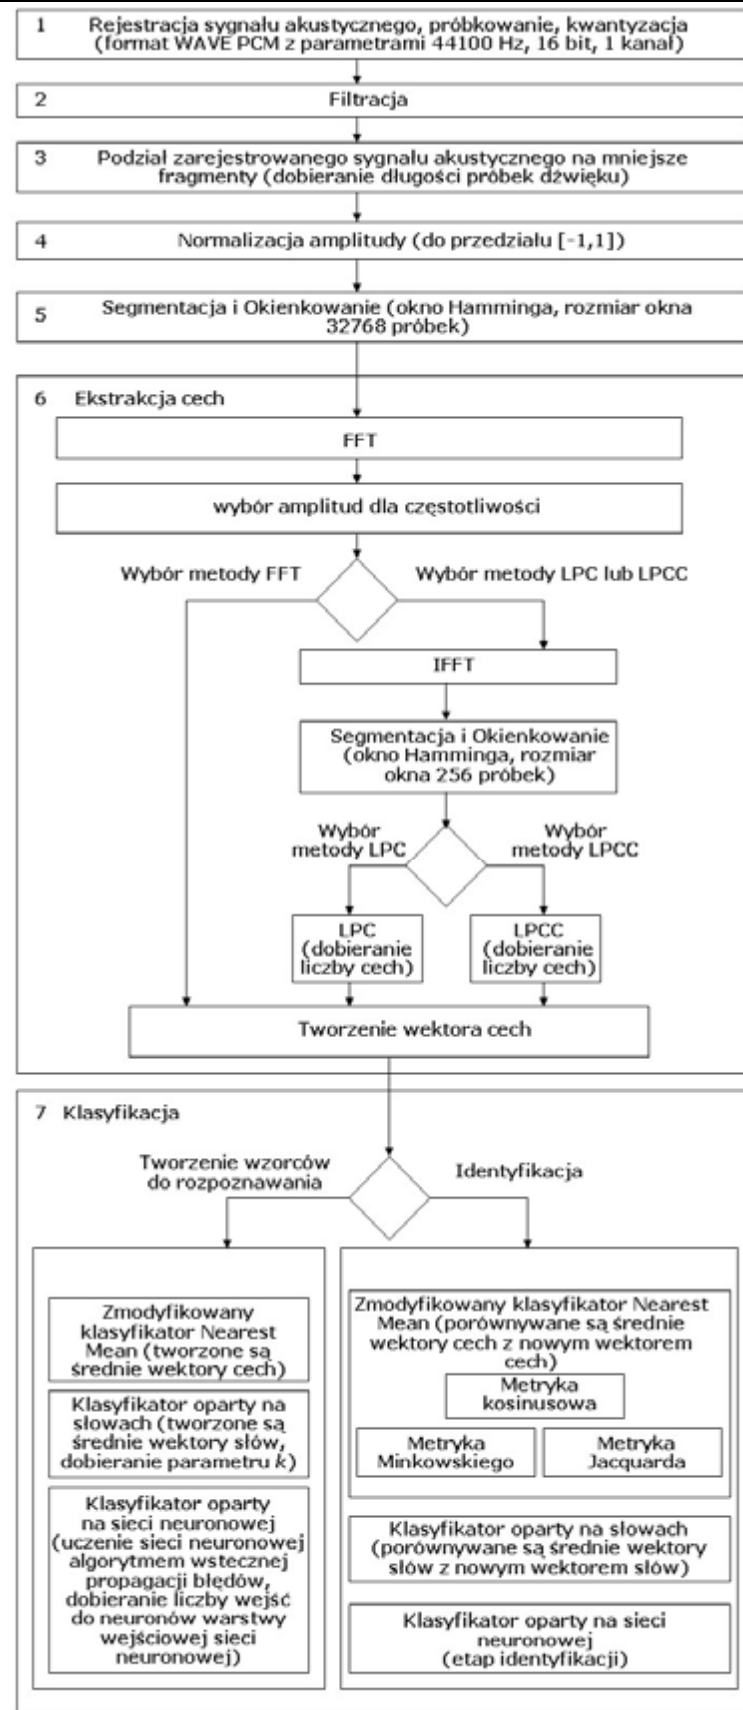
Podane parametry mają duży wpływ na rozpoznawanie sygnału akustycznego.

Uszczegółowiony plan badań sygnałów akustycznych dla celów diagnostyki został przedstawiony na rysunku 2.7. Plan ten zawiera wybrane algorytmy przetwarzania i analizy sygnałów akustycznych: normalizację amplitudy, segmentację, okienkowanie, FFT, wybór amplitud dla częstotliwości, LPC, LPCC, zmodyfikowany klasyfikator NM, klasyfikator oparty na słowach, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów.

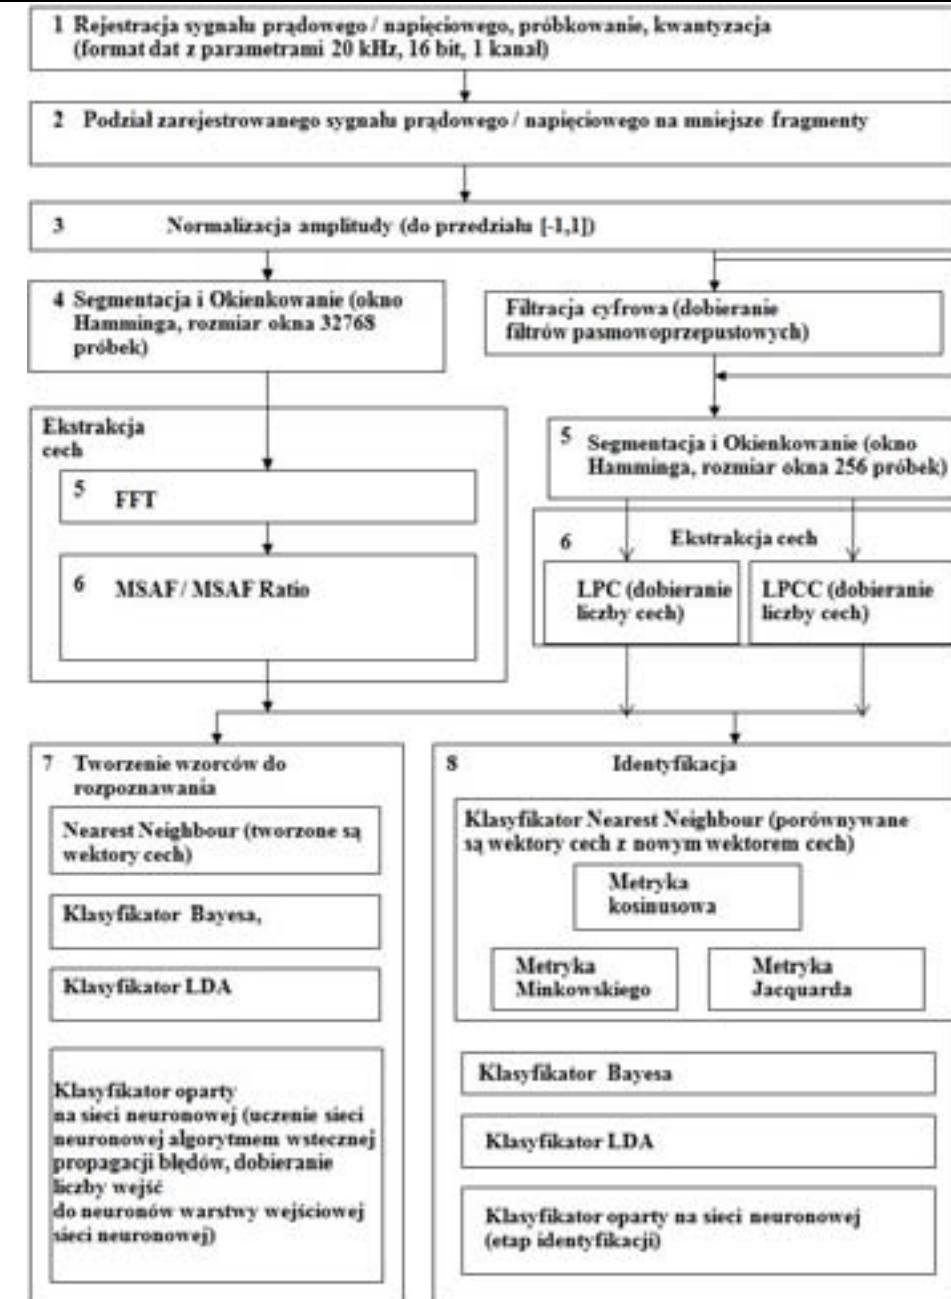
W badaniach dobierane będą parametry sieci neuronowej w celu uzyskania jak najlepszych wyników rozpoznawania sygnałów prądowych i napięciowych. Ważniejsze parametry sieci neuronowej na które należy zwrócić uwagę to:

1. Maksymalny błąd = 0,01 (powszechnie przyjmowana wartość) [88], [102].
2. Liczba warstw sieci neuronowej = 3 (powszechnie przyjmowana wartość) [88], [102].
3. Struktura sieci neuronowej – trapezoidalna [102].
4. Liczba neuronów w warstwach sieci neuronowej – ze względu na dużą liczbę wariantów w badaniach stosowane będą następujące liczby neuronów: 40 neuronów w warstwie ukrytej 1 sieci neuronowej, 30 neuronów w warstwie ukrytej 2, 4 neuronów w warstwie ukrytej 3.
5. Współczynnik uczenia = 0,1 (powszechnie przyjmowana wartość) [88], [102].
6. Współczynnik momentum = 0,5 (powszechnie przyjmowana wartość) [88], [102].
7. Liczba wejść do neuronów warstwy wejściowej sieci neuronowej (przykładowo liczba ta może wynosić 6 i wówczas może odpowiadać ona 5 cechom sygnału oraz 1 dodatkowemu wejściu – tzw. BIAS).

Podane parametry mają duży wpływ na rozpoznawanie sygnału prądowego/napięciowego. Uszczegółowiony plan badań sygnałów prądowych i napięciowych dla celów diagnostyki został przedstawiony na rysunku 2.6. Plan ten zawiera wybrane algorytmy przetwarzania i analizy sygnałów prądowych i napięciowych: normalizację amplitudy, segmentację, okienkowanie, FFT, wybór amplitud dla częstotliwości, LPC, LPCC, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów, najbliższego sąsiada NN, Bayesa, LDA.



Rys. 2.7. Uszczegółowiony plan badań sygnałów akustycznych dla celów diagnostyki



Rys. 2.6. Uszczegółowiony plan badań sygnałów prądowych i napięciowych dla celów diagnostyki

W algorytmach tych dobierane będą wybrane parametry omówione szczegółowo w rozdziale drugim. Plan ten stanowi punkt wyjścia do zaprojektowania komputerowego stanowiska do badania sygnałów akustycznych maszyn elektrycznych. Z planu tego wynika również, że metody przetwarzania sygnału akustycznego będzie można dobierać w sposób wariantowy. Metody w krokach od 1 do 5 są takie same dla wszystkich technik proponowanych w pracy doktorskiej. Można zatem stwierdzić, że dla każdej techniki dobierane będą różne metody ekstrakcji cech i klasyfikacji. Kolejno techniki te będą porównywane w prowadzonych eksperymentach (zobacz rozdział 4). Eksperymenty będą korzystały z takich pojęć jak *skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika)* oraz *średnia skuteczność rozpoznawania sygnału akustycznego*.

Skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika) określona została następująco:

$$E = \frac{N_1}{N} \cdot 100\% \quad (2.29)$$

gdzie: E – skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika), N_1 – liczba poprawnie zidentyfikowanych próbek danej kategorii, N – liczba wszystkich próbek danej kategorii biorących udział w procesie identyfikacji.

Wzór 2.29 będzie używany do obliczeń dotyczących sygnałów akustycznych (zobacz podrozdziały 4.1-4.10), sygnałów prądu wzbudzenia (zobacz podrozdział 4.11), sygnałów prądu twornika (zobacz podrozdział 4.12). Jeżeli N_1 i N będą oznaczać liczbę próbek dźwięku to E będzie skutecznością rozpoznawania sygnału akustycznego. Jeżeli N_1 i N będą oznaczać liczbę próbek prądu wzbudzenia (twornika) to E będzie skutecznością rozpoznawania sygnału prądu wzbudzenia (twornika).

Średnia skuteczność rozpoznawania sygnału akustycznego (maszyny synchronicznej, prądu stałego) określona została następująco:

$$E_{sr} = \frac{\sum_{n=1}^5 E_n}{5} \quad (2.30)$$

gdzie: E_{sr} – średnia skuteczność rozpoznawania sygnału akustycznego (maszyny synchronicznej, prądu stałego), E_n – skuteczność rozpoznawania sygnału akustycznego dla n sekundowych próbek dźwięku stanu pracy maszyny, $n \in \{1,2,3,4,5\}$.

W przypadku maszyny synchronicznej badane będą cztery różne stany pracy (zobacz podrozdział 4.2). Zatem do obliczenia E_n przyjęto wzór.

W algorytmach tych dobierane będą wybrane parametry omówione szczegółowo w rozdziale drugim. Plan ten stanowi punkt wyjścia do zaprojektowania komputerowego stanowiska do badania sygnałów prądowych i napięciowych maszyn elektrycznych. Z planu tego wynika również, że metody przetwarzania sygnału prądowego/napięciowego będzie można dobierać w sposób wariantowy. Metody w krokach od 1 do 5 są takie same dla wszystkich technik proponowanych w pracy doktorskiej. Można zatem stwierdzić, że dla każdej techniki dobierane będą różne metody ekstrakcji cech i klasyfikacji. Kolejno techniki te będą porównywane w prowadzonych eksperymentach. Eksperymenty będą korzystały z takich pojęć jak *skuteczność rozpoznawania sygnału prądowego/napięciowego* oraz *średnia skuteczność rozpoznawania sygnału prądowego/napięciowego silnika elektrycznego*.

Skuteczność rozpoznawania sygnału prądowego/napięciowego określona została następująco:

$$E = \frac{N_1}{N} \cdot 100\% \quad (2.12)$$

gdzie: E – skuteczność rozpoznawania sygnału prądowego/napięciowego, N_1 – liczba poprawnie zidentyfikowanych próbek danej kategorii, N – liczba wszystkich próbek danej kategorii biorących udział w procesie identyfikacji.

Wzór (2.12) będzie używany do obliczeń dotyczących sygnałów prądowych i napięciowych, silnika indukcyjnego i silnika prądu stałego.

Średnia skuteczność rozpoznawania sygnału (silnika indukcyjnego i silnika prądu stałego) określona została następująco:

$$E_{ms} = \frac{\sum_{n=1}^4 E_n}{4} \quad (2.13)$$

gdzie: E_{ms} – średnia skuteczność rozpoznawania sygnału (silnika indukcyjnego i silnika prądu stałego), E_n – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia stanu pracy silnika, $n \in \{1,2,3,4\}$.

W przypadku silnika indukcyjnego badane były cztery różne stany pracy. Zatem do obliczenia E_{ms} przyjęto wzór:

$$E_n = \frac{E_{nb} + E_{nz} + E_{n1} + E_{n3}}{4} \quad (2.31)$$

gdzie: E_n – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej, E_{nb} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej bez uszkodzeń,

E_{nz} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej ze zwartymi zezwojami stojana, E_{n1} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej z jedną przerwą w obwodzie stojana, E_{n3} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej z trzema przerwami w obwodzie stojana.

W przypadku maszyny prądu stałego badane będą dwa różne stany pracy (zobacz podrozdział 4.6). Zatem do obliczenia E_n przyjęto wzór.

$$E_n = \frac{E_{nb} + E_{nz}}{2} \quad (2.32)$$

gdzie: E_n – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego, E_{nb} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego bez uszkodzeń, E_{nz} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego ze zwartymi zezwojami wirnika.

$$E_{ns} = \frac{E_{nb} + E_{nu1} + E_{nu2} + E_{nu3}}{4} \quad (2.14)$$

gdzie: E_{ns} – średnia skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika indukcyjnego, E_{nb} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika indukcyjnego bez uszkodzeń, E_{nu1} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika indukcyjnego z uszkodzonym pierścieniem wirnika, E_{nu2} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika indukcyjnego z jednym uszkodzonym prętem wirnika, E_{nu3} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika indukcyjnego z dwoma uszkodzonymi prętami wirnika.

W przypadku silnika prądu stałego badane były cztery różne stany pracy. Zatem do obliczenia E_{ns} przyjęto wzór:

$$E_{ns} = \frac{E_{nb} + E_{nu1} + E_{nu2} + E_{nu3}}{4} \quad (2.14)$$

gdzie: E_{ns} – średnia skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika prądu stałego, E_{nb} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika prądu stałego bez uszkodzeń, E_{nu1} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika prądu stałego z jedną przerwą zezwojów wirnika, E_{nu2} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika prądu stałego z trzema zwartymi zezwojami wirnika, E_{nu3} – skuteczność rozpoznawania sygnału dla n -sekundowych próbek prądu lub napięcia silnika prądu stałego z sześcioma zwartymi zezwojami wirnika.

2.5.2. Klasyfikator oparty na metodzie najbliższego sąsiada NN

Niekiedy trudno jest znaleźć obraz wzorcowy, który dobrze reprezentowałby skupisko odpowiadające klasie. Dzieje się tak, jeśli skupiska nie mają regularnego charakteru, ale są np. „postrzępione” w różnych kierunkach. W takim przypadku możemy zastosować metodę najbliższego sąsiada NN (ang. Nearest Neighbour) zdefiniowaną przez Thomasa M. Rovera i Petera E. Harta w 1967 roku. W metodzie tej obliczamy odległości nieznanego obrazu \mathbf{X} od wszystkich elementów ciągu uczącego U , a następnie wybieramy tę klasę, do której należy obraz ciągu uczącego, który jest najbliższy \mathbf{X} [28],

[115]. Metoda ta ma też intuicyjną interpretację. Kiedy stykamy się pierwszy raz z nieznanym obiektem (wydarzeniem, sytuacją) i chcemy go zaklasyfikować, możemy przypomnieć sobie podobny obiekt (wydarzenie, sytuację) i przypisać nieznanemu obiektowi klasyfikację obiektu podobnego.

Regułę najbliższego sąsiada możemy formalnie przedstawić w następujący sposób:

Niech U^k oznacza podciąg takich elementów ciągu uczącego, które należą do klasy ω^k , czyli:

$$U^k = \{ \mathbf{x}^j : (\mathbf{x}^j, u^j) \in U \text{ oraz } u^j = \omega^k \} \quad (2.16)$$

Wtedy \mathbf{X} przypiszemy do klasy ω^L , jeśli:

$$\rho(\mathbf{X}, \mathbf{X}^r) = \min_{j=1, \dots, M} \{ \rho(\mathbf{X}, \mathbf{X}^j) \} \text{ oraz } \mathbf{X}^r \in U^L \quad (2.17)$$

W praktyce zdarza się, że ciąg uczący zawiera elementy obarczone błędami pomiarowymi czy też nieprawidłowo zaklasyfikowane. Wówczas metoda najbliższego sąsiada mogłaby dawać nieprawidłowe wyniki, gdyby najbliższym sąsiadem był taki właśnie błędny element ciągu uczącego.

W celu wyeliminowania tej nieprawidłowości stosuje się klasyfikator k -najbliższych sąsiadów, k -NN.

W metodzie tej szuka się nie jednego najbliższego sąsiada, ale k najbliższych sąsiadów (k jest niewielką liczbą nieparzystą). Następnie w grupie tych k sąsiadów sprawdza się, która klasa ma najwięcej reprezentantów i do tej właśnie klasy przypisuje się nieznaną obraz.

2.5.3. Klasyfikator Bayesa

Klasyfikator oparty jest na modelu Bayesa. W metodach statystycznych przedstawionych w 1973 roku przez Richarda o. Dudę oraz Petera E. Harta, podejmując decyzję o przypisaniu nieznanego sygnału do klasy, bierzemy pod uwagę prawdopodobieństwa związane z przynależnością obiektów do klas oraz koszty błędnych klasyfikacji. Klasyfikator Bayesa przypisuje sygnałowi klasę, dla której prawdopodobieństwo *a posteriori* jest największe [28], [51], [52].

Zatem \square zostanie przypisany do klasy ω^L , jeśli:

$$P(\omega^L | X_I) > P(\omega^j | X_I), \text{ dla każdego } j \in \{1, 2, \dots, C\} \quad (2.18)$$

W przypadku gdy chcemy rozpoznawać sygnały w n -wymiarowej przestrzeni cech, tzn. $\square = \{X_1, X_2, \dots, X_n\}$, możemy wykorzystać prosty klasyfikator Bayesa.

W klasyfikatorze tym przyjmuje się założenie o wzajemnej niezależności cech. Wówczas gęstość rozkładu prawdopodobieństwa definiujemy dla n -wymiarowego wektora cech w następujący sposób:

$$p(\mathbf{X}|\omega^j) = \prod_{i=1}^n p(X_i|\omega^j) \quad (2.19)$$

kolejne uogólnienie klasyfikatora Bayesa polega na uwzględnieniu faktu, że nie wszystkie błędne decyzje w rozpoznawaniu obiektu są tak samo „kosztowne” (czyli mają takie same negatywne konsekwencje). W celu wzięcia pod uwagę tego faktu, wprowadza się funkcję kosztów (pomyłek), na podstawie której oraz na podstawie prawdopodobieństwa *a posteriori* definiuje się funkcję ryzyka klasyfikatora. Zadaniem takiego klasyfikatora jest minimalizacja funkcji ryzyka.

2.5.4. Klasyfikator oparty na liniowej analizie dyskryminacyjnej LDA

Istnieje wiele metod przetwarzania danych i klasyfikacji wektorów cech. W Liniowej Analizie Dyskryminacyjnej LDA (ang. Linear Discriminant Analysis) jest obliczany współczynnik wariancji między-klasowej do wariancji wewnątrz-klasowej. Metoda LDA dąży do tego, aby maksymalizować ten współczynnik. Maksymalny współczynnik gwarantuje dobrą rozdzielność między klasami i dobrą spójność wewnątrz klas. Zbiory uczące i testowe powinny być określone odpowiednio na początku klasyfikacji. Zbiory trenujące są zdefiniowane jako set_1, \dots, set_k . Następnie są obliczane średnie dla każdego zbioru trenującego i średnia wszystkich zbiorów uczących.

Średnie zbiorów set_1, \dots, set_k są zdefiniowane jako μ_1, \dots, μ_k . Podczas gdy średnia wszystkich zbiorów uczących nazwana jest μ . Średnia ta zdefiniowana jest przez równanie:

$$\mu = p_1 \times \mu_1 + \dots + p_k \times \mu_k \quad (2.20)$$

gdzie p_1, \dots, p_k są prawdopodobieństwami a priori klas.

Następnie liniowa kombinacja cech jest utworzona przez Liniową Analizę Dyskryminacyjną. Metoda ta używa macierzy rozproszonej wewnątrz-klasowej i macierzy rozproszonej międzyklasowej [28], [45], [50], [75]. Obie macierze są używane do formułowania kryterium rozdzielności klas. Macierz rozproszona wewnątrz-klasowa jest zdefiniowana następująco:

$$W_s = \sum_{k=1}^c \sum_{i=1}^{N_k} (x_i^k - \mu_k)(x_i^k - \mu_k)^T \quad (2.21)$$

gdzie μ_k oznacza średnią klasy k , x_i^k jest próbką z indeksem i klasy k , c oznacza liczbę klas zbiorów trenujących i N_k jest liczbą próbek klasy k .

Macierz rozproszona między-klasowa jest wyrażona wzorem:

2.5. Podsumowanie

W rozdziale drugim przedstawiono warunki zastosowania technik analizy informacji zawartej w sygnałach akustycznych. Kolejno zaprezentowano ogólny plan badania sygnałów akustycznych (zobacz Rys. 2.2). Na podstawie tego planu w pracy doktorskiej zaproponowane zostały techniki analizy informacji zawartej w sygnałach akustycznych maszyn elektrycznych. W pracy doktorskiej techniki są wariantami metod przetwarzania sygnału akustycznego. Techniki te zostały zrealizowane w następujących etapach: rejestracji sygnału akustycznego, filtracji, normalizacji amplitudy, segmentacji, okienkowania, ekstrakcji cech i klasyfikacji. Każdy krok został szczegółowo omówiony (zobacz podrozdziały 2.1-2.4). Następnie zaproponowano uszczegółowiony plan badań sygnałów akustycznych dla celów diagnostyki. Został on przedstawiony na rysunku 2.7. Plan ten zawierał wybrane algorytmy przetwarzania i analizy sygnałów akustycznych: normalizację amplitudy, segmentację, okienkowanie, FFT, wybór amplitud dla częstotliwości, LPC, LPCC, zmodyfikowany klasyfikator NM, klasyfikator oparty na słowach, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów. Plan ten stanowi punkt wyjścia do zaprojektowania komputerowego stanowiska do badania sygnałów akustycznych maszyn elektrycznych. Z planu tego wynika również, że metody przetwarzania sygnału akustycznego będzie można dobierać w sposób wariantowy.

$$B_s = \sum_{k=1}^c (\mu_k - \mu)(\mu_k - \mu)^T \quad (2.22)$$

gdzie μ oznacza średnią wszystkich zbiorów uczących.

Współczynnik macierzy rozproszonej między-klasowej do macierzy wewnątrz-klasowej jest kryterium Liniowej Analizy Dyskryminacyjnej. W metodzie tej istotne jest, aby maksymalizować współczynnik ($Det|B_s| / Det|W_s|$) [28], [75], gdzie Det oznacza wyznacznik macierzy.

2.6. Podsumowanie

W rozdziale drugim przedstawiono warunki zastosowania metod analizy informacji zawartej w sygnałach prądowych i napięciowych. Kolejno zaprezentowano ogólny plan badania sygnałów prądowych i napięciowych przyjęty dla realizacji celów tej pracy. Na podstawie tego planu w dalszej części pracy doktorskiej zaproponowane zostały techniki analizy informacji zawartej w sygnałach prądowych i napięciowych silników elektrycznych. W pracy tej użyte techniki są wariantami metod przetwarzania sygnałów prądowych i napięciowych. Techniki te zostały zrealizowane w następujących etapach: rejestracji sygnału, filtracji, normalizacji amplitudy, segmentacji, okienkowania, ekstrakcji cech i klasyfikacji. Każdy krok został szczegółowo omówiony. Następnie zaproponowano uszczegółowiony plan badań sygnałów prądowych i napięciowych dla celów diagnostyki. Został on przedstawiony na rysunku 2.6. Plan ten zawierał wybrane algorytmy przetwarzania i analizy sygnałów prądowych i napięciowych: normalizację amplitudy, segmentację, okienkowanie, FFT, wybór amplitud dla częstotliwości, LPC, LPCC, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów, najbliższego sąsiada, Bayesa, LDA. Plan ten stanowi punkt wyjścia do zaprojektowania komputerowego stanowiska do badania sygnałów prądowych i napięciowych silników elektrycznych. Z planu tego wynika również, że metody przetwarzania sygnałów prądowych i napięciowych będzie można dobierać w sposób wariantowy.

3. PROJEKT STANOWISKA DIAGNOSTYCZNEGO DO ANALIZY SYGNAŁÓW AKUSTYCZNYCH

W rozdziale opisano projekt stanowiska do badania sygnałów akustycznych maszyn elektrycznych. Następnie omówiono sposób łączenia sprzętu i oprogramowania, potrzebnego do właściwego dobierania metod rozpoznawania sygnału akustycznego dla różnych stanów przedawaryjnych maszyn elektrycznych. Kolejne podrozdziały pokazują szczegółowy projekt tego stanowiska.

3.1. Warunki zastosowania projektowanego stanowiska diagnostycznego

Punktem wyjścia do zaproponowania rozwiązań w zakresie struktury i funkcjonalności stanowiska diagnostycznego do badania sygnałów akustycznych jest plan badań opracowany w rozdziale poprzednim (zobacz rysunek 2.7). W celu zrealizowania poszczególnych kroków przetwarzania sygnału akustycznego przyjęto następujące warunki zastosowania stanowiska:

Stanowisko spełnia warunki stosowania technik analizy informacji zawartej w sygnale akustycznym (zobacz rozdział 2).

Stanowisko rozpoznaje stany przedawaryjne spowodowane przez czynniki mechaniczne, które wpływają na zmiany sygnałów elektrycznych i akustycznych.

Do rejestracji sygnału akustycznego używany jest jeden mikrofon pojemnościowy, ustawiony w odległości 1 metra od końca wału, na którym zamontowany jest wirnik maszyny elektrycznej.

Stanowisko rejestruje sygnały akustyczne pochodzące od jednej określonej maszyny elektrycznej.

Stanowisko łączy w sobie wyposażenie techniczne i informatyczne.

Udostępniony jest interfejs, który umożliwia wpisywanie inżynierowi odpowiednich komend.

Algorytmy przetwarzania danych dobierane są w sposób wariantowy: algorytm wyboru amplitud dla częstotliwości z różnymi parametrami (zobacz podrozdziały 4.1, 4.5), FFT, LPC, LPCC, klasyfikator oparty na słowach, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów i zmodyfikowany klasyfikator NM (metryki Manhattan, Euklidesa, Minkowskiego, Jacquarda, kosinusowa). Algorytm LPC może zostać wykonany z różną liczbą współczynników filtra predykcji liniowej. Algorytm LPCC może zostać użyty z różną liczbą współczynników cepstralnych. Klasyfikator oparty na słowach może zostać wywołany z różnym parametrem k . Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów może zostać użyty z różną liczbą wejść do neuronów warstwy wejściowej. Zmodyfikowany klasyfikator NM może zostać wywołany z metrykami: Manhattan, Euklidesa, Minkowskiego, Jacquarda, kosinusową.

Stanowisko umożliwia badanie zbiorów testowych zawierających próbki dźwięków różnej długości.

Stanowisko weryfikuje wyniki rozpoznawania sygnałów akustycznych z wynikami rozpoznawania sygnałów prądu wzbudzenia lub twornika.

Stanowisko jest przenośne.

Stanowisko obsługuje tryb monitorowania maszyny elektrycznej.

Stanowisko porównuje wyniki, w kolejnych etapach przetwarzania sygnału akustycznego.

Stanowisko mierzy czas rozpoznawania sygnału akustycznego (procesu identyfikacji sygnału akustycznego, zobacz Rys. 3.7).

3. PROJEKT STANOWISKA DIAGNOSTYCZNEGO OPARTEGO NA ANALIZIE SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH

W rozdziale opisano projekt stanowiska do badania sygnałów prądowych i napięciowych silników elektrycznych. Następnie omówiono sposób łączenia sprzętu i oprogramowania, potrzebnego do właściwego dobierania metod rozpoznawania sygnałów prądowych i napięciowych dla różnych stanów przedawaryjnych silników elektrycznych. Kolejne podrozdziały pokazują szczegółowy projekt tego stanowiska.

3.1. Warunki zastosowania projektowanego stanowiska diagnostycznego

Punktem wyjścia do zaproponowania rozwiązań w zakresie struktury i funkcjonalności stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych jest plan badań opracowany w rozdziale poprzednim. W celu zrealizowania poszczególnych kroków przetwarzania sygnału przyjęto następujące warunki zastosowania stanowiska:

Stanowisko spełnia warunki przedstawione w rozdziale 2.

Stanowisko rozpoznaje stany przedawaryjne spowodowane przez czynniki mechaniczne, które wpływają na zmiany sygnałów prądowych i napięciowych.

Do rejestracji sygnałów prądowych i napięciowych używana jest karta pomiarowa z przetwornikami prądowymi i napięciowymi LEM.

Stanowisko rejestruje sygnały prądowe i napięciowe pochodzące od jednej określonej maszyny elektrycznej.

Stanowisko łączy w sobie wyposażenie techniczne i informatyczne.

Udostępniony jest interfejs, który umożliwia wpisywanie inżynierowi odpowiednich komend.

Algorytmy przetwarzania danych dobierane są w sposób wariantowy: algorytm wyboru amplitud dla częstotliwości z różnymi parametrami, FFT, LPC, LPCC, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów, klasyfikator oparty na metodzie najbliższego sąsiada NN, klasyfikator Bayesa, klasyfikator oparty na liniowej analizie dyskryminacyjnej LDA.

Algorytm LPC może zostać wykonany z różną liczbą współczynników filtra predykcji liniowej, a algorytm LPCC z różną liczbą współczynników cepstralnych. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów może zostać użyty z różną liczbą wejść do neuronów warstwy wejściowej.

Stanowisko umożliwia badanie zbiorów testowych zawierających próbki prądów/napięć różnej długości.

Stanowisko jest przenośne.

Stanowisko obsługuje tryb monitorowania maszyny elektrycznej.

Stanowisko porównuje wyniki, w kolejnych etapach przetwarzania sygnałów prądowych i napięciowych.

Stanowisko mierzy czas rozpoznawania sygnałów prądowych i napięciowych (procesu identyfikacji sygnałów).

3.2. Wyposażenie techniczne i informatyczne stanowiska laboratoryjnego

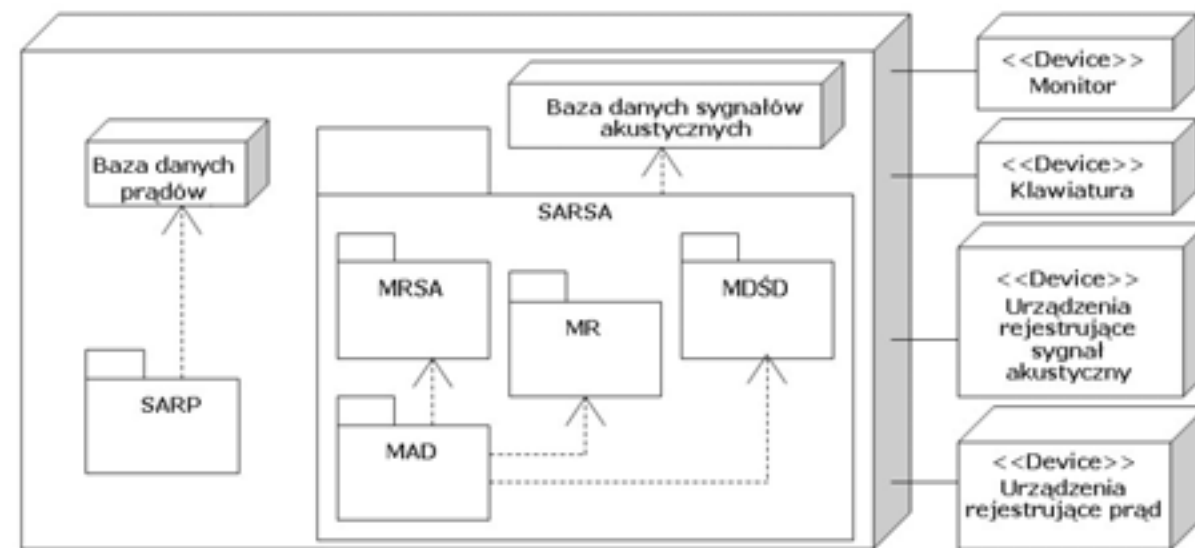
Zgodnie z warunkami w rozdziale 3.1 zaprojektowano i zbudowano stanowisko diagnostyczne do badania sygnałów akustycznych. Stanowisko to składało się z wyposażenia technicznego i wyposażenia informatycznego.

Wyposażenie techniczne stanowił komputer TravelMate 4061NLMi zawierający: kartę dźwiękową Realtek HD Audio, procesor Intel Pentium M730, 512MB pamięci RAM DDR2, dysk twardy 60 GB, monitor, klawiaturę, mikrofon OLYMPUS TP-7, urządzenia rejestrujące prąd (karta pomiarowa mierząca prąd wzbudzenia lub twornika, filtr antyaliasingowy, przetworniki).

Wyposażenie informatyczne zawierało: system operacyjny Windows XP, oprogramowanie Mplayer w wersji 1.0pre6a-1, oprogramowanie Perl w wersji 5.84 lub wyższej, oprogramowanie Java Platform JDK w wersji 1.4 lub wyższej, system automatycznego rozpoznawania sygnału akustycznego – SARSA (zobacz podrozdział 3.4), narzędzia do weryfikacji wyników rozpoznawania sygnałów akustycznych, to jest system automatycznego rozpoznawania prądu – SARP (zobacz podrozdział 3.5) i bazy danych sygnałów akustycznych, prądów maszyn elektrycznych.

Wyposażenie informatyczne zajmowało 1,2 GB pamięci na dysku twardym. Rozmiar ten zależał jednak od wielkości baz danych sygnałów akustycznych, prądów maszyn elektrycznych. Istnieje zatem możliwość zainstalowania wyposażenia informatycznego na wolniejszym komputerze z mniejszą pamięcią na dysku twardym, jednakże komputer ten powinien być w stanie obsłużyć system operacyjny Windows XP.

Na podstawie przyjętych warunków (zobacz podrozdział 3.1) zaproponowano diagram wdrożenia stanowiska diagnostycznego do badania sygnałów akustycznych. Diagram ten został pokazany na rysunku 3.1.



Rys. 3.1. Diagram wdrożenia stanowiska diagnostycznego do badania sygnałów akustycznych

Diagram ten pokazuje architekturę stanowiska diagnostycznego do badania sygnałów akustycznych.

3.2. Wyposażenie techniczne i informatyczne stanowiska laboratoryjnego

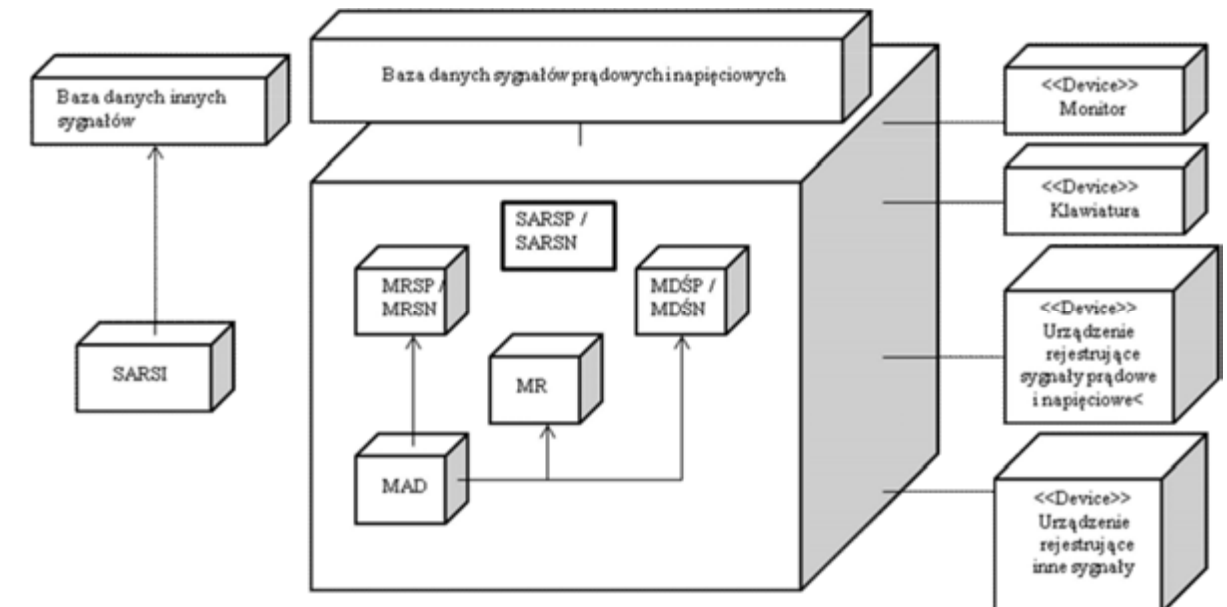
Zgodnie z warunkami w rozdziale 3.1 zaprojektowano i zbudowano stanowisko diagnostyczne do badania sygnałów prądowych i napięciowych. Stanowisko to składało się z wyposażenia technicznego i wyposażenia informatycznego.

Wyposażenie techniczne stanowił komputer TravelMate 4061NLMi zawierający: kartę pomiarową Realtek HD Audio, procesor Intel Pentium M730, 512MB pamięci RAM DDR2, dysk twardy 60 GB, monitor, klawiaturę, urządzenia rejestrujące prąd i napięcie (karta pomiarowa mierząca prądy i napięcia silnika, filtr antyaliasingowy, przetworniki).

Wyposażenie informatyczne zawierało: system operacyjny Windows XP, oprogramowanie Perl w wersji 5.84 lub wyższej, oprogramowanie Java Platform JDK w wersji 1.4 lub wyższej, systemy automatycznego rozpoznawania sygnału prądowego/napięciowego – SARSP/SARSN oraz bazy danych sygnałów prądowych i napięciowych silników elektrycznych.

Wyposażenie informatyczne zajmowało 1,2 GB pamięci na dysku twardym. Rozmiar ten zależał jednak od wielkości baz danych sygnałów prądowych i napięciowych, prądów silników elektrycznych. Istnieje zatem możliwość zainstalowania wyposażenia informatycznego na wolniejszym komputerze z mniejszą pamięcią na dysku twardym, jednakże komputer ten powinien być w stanie obsłużyć system operacyjny Windows XP.

Na podstawie przyjętych warunków zaproponowano diagram wdrożenia stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych. Diagram ten został pokazany na rysunku 3.1.

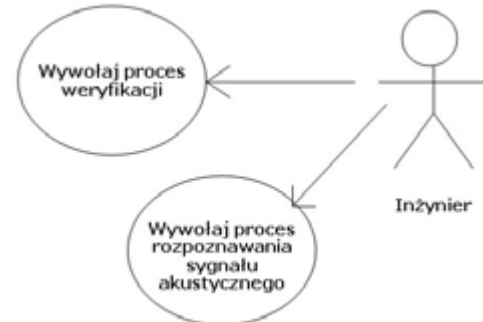


Rys. 3.1. Diagram wdrożenia stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych

Diagram ten pokazuje architekturę stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych. Stanowisko diagnostyczne zawiera: moduł automatycznego działania (MAD), moduł dzielenia ścieżki prądowej/napięciowej (MDSP/MDŚN), moduł rejestracji sygnału prądowego/napięciowego (MR), moduł rozpoznawania sygnału prądowego/napięciowego (MRSP/MRSN), moduł automatycznego rozpoznawania innego sygnału (SARSI).

3.3. Analiza przypadków użycia stanowiska

W stanowisku diagnostycznym do badania sygnałów akustycznych stosowane są dwa główne przypadki użycia. Pierwszym z nich jest „Wywołaj proces rozpoznawania sygnału akustycznego”, drugim jest „Wywołaj proces weryfikacji”. Przypadki te można rozłożyć na kilka przypadków składowych, tworzących pewną funkcjonalność systemu. Diagram przypadków użycia stanowiska diagnostycznego do badania sygnałów akustycznych został przedstawiony na rysunku 3.2.



Rys. 3.2. Diagram przypadków użycia stanowiska diagnostycznego do badania sygnałów akustycznych

Na początku inżynier wywołuje proces rozpoznawania sygnału akustycznego. Następnie po otrzymaniu wyników rozpoznawania sygnałów akustycznych, inżynier wywołuje proces weryfikacji. Proces weryfikacji jest to proces rozpoznawania prądu. Inżynier po zakończeniu obydwóch przypadków użycia powinien uzyskać informację dotyczącą stanu technicznego maszyny elektrycznej.

3.4. System automatycznego rozpoznawania sygnału akustycznego

System automatycznego rozpoznawania sygnału akustycznego (SARSA) odpowiedzialny jest za rejestrację i przetwarzanie sygnałów akustycznych. Kolejne podrozdziały opisują strukturę SARSA.

3.4.1. Diagram wdrożenia SARSA

Diagram wdrożenia systemu automatycznego rozpoznawania sygnału akustycznego został przedstawiony na rysunku 3.3. Z diagramu tego wynika, że system ten zawiera: moduł automatycznego działania (MAD), moduł dzielenia ścieżki dźwiękowej (MDŚD), moduł rejestracji sygnału akustycznego (MR), moduł rozpoznawania sygnału akustycznego (MRSA).

Moduł automatycznego działania (MAD) składa się z komponentów, które automatycznie uruchamiają cały system (skrypty uruchamiające, skrypty przetwarzające dane oraz skrypty odpowiedzialne za modyfikacje formatu ścieżki dźwiękowej). Moduł dzielenia ścieżki dźwiękowej (MDŚD) składa się z pojedynczego komponentu, odpowiedzialnego za podział ścieżki dźwiękowej na mniejsze fragmenty oraz przypisanie każdej nowej próbce dźwięku znacznika czasowego (znacznik ten informuje o czasie trwania

3.3. Analiza przypadków użycia stanowiska

W stanowisku diagnostycznym do badania sygnałów prądowych i napięciowych stosowane są dwa główne przypadki użycia. Pierwszym z nich jest „Wywołaj proces rozpoznawania sygnału prądowego/napięciowego”, drugim jest „Wywołaj proces weryfikacji”. Przypadki te można rozłożyć na kilka przypadków składowych, tworzących pewną funkcjonalność systemu. Diagram przypadków użycia stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych został przedstawiony na rysunku 3.2.



Rys. 3.2. Diagram przypadków użycia stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych

Na początku inżynier wywołuje proces rozpoznawania sygnału prądowego/napięciowego. Następnie po otrzymaniu wyników rozpoznawania sygnałów prądowych i napięciowych, inżynier wywołuje proces weryfikacji, który jest procesem rozpoznawania stanu silnika inną metodą. Inżynier po zakończeniu obydwóch przypadków użycia powinien uzyskać informację dotyczącą stanu technicznego silnika elektrycznego.

3.4. System automatycznego rozpoznawania sygnałów prądowych i napięciowych

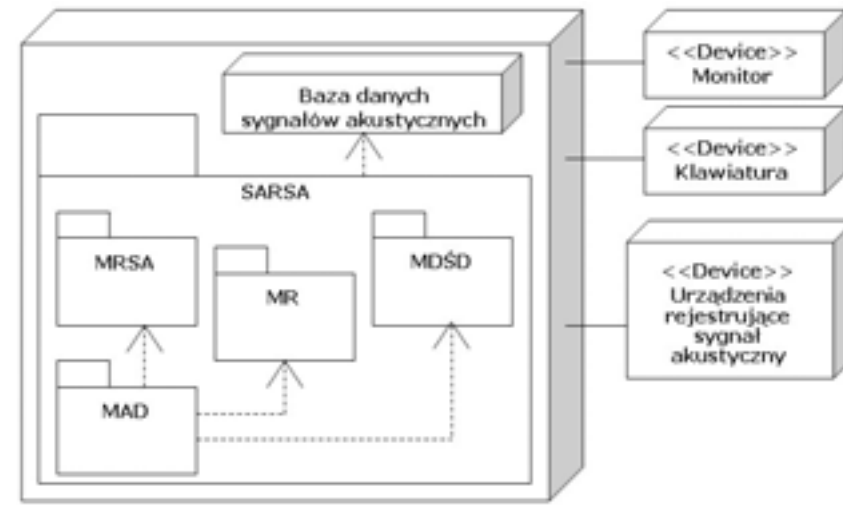
System automatycznego rozpoznawania sygnału prądowego/napięciowego (SARSP/SARSN) odpowiedzialny jest za rejestrację i przetwarzanie sygnałów prądowych i napięciowych. Kolejne podrozdziały opisują strukturę SARSP/SARSN.

3.4.1. Diagram wdrożenia SARSP i SARSN

Diagram wdrożenia systemu automatycznego rozpoznawania sygnału prądowego/napięciowego został przedstawiony na rysunku 3.3.

Moduł automatycznego działania (MAD) składa się z komponentów, które automatycznie uruchamiają cały system (skrypty uruchamiające, skrypty przetwarzające dane oraz skrypty odpowiedzialne za modyfikacje formatu ścieżki prądowej/napięciowej). Moduł dzielenia ścieżki prądowej/napięciowej (MDŚP/MDŚN) składa się z pojedynczego komponentu, odpowiedzialnego za podział ścieżki prądu/napięcia na mniejsze fragmenty oraz przypisanie każdej nowej próbce prądu/napięcia znacznika czasowego (znacznik ten informuje o czasie trwania próbki prądu/napięcia). Moduł rejestracji sygnału

próbki dźwięku). Moduł rejestracji sygnału akustycznego (MR) składa się z komponentu do rejestrowania dźwięku. Moduł rozpoznawania sygnału akustycznego (MRSA) odpowiedzialny jest za normalizację amplitudy, segmentację, okienkowanie, ekstrakcję cech i klasyfikację sygnału akustycznego. Moduł rozpoznawania sygnału akustycznego będzie dokładnie omówiony w podrozdziale 3.4.3, ze względu na jego złożoność i ważną funkcję w procesie rozpoznawania sygnału akustycznego.



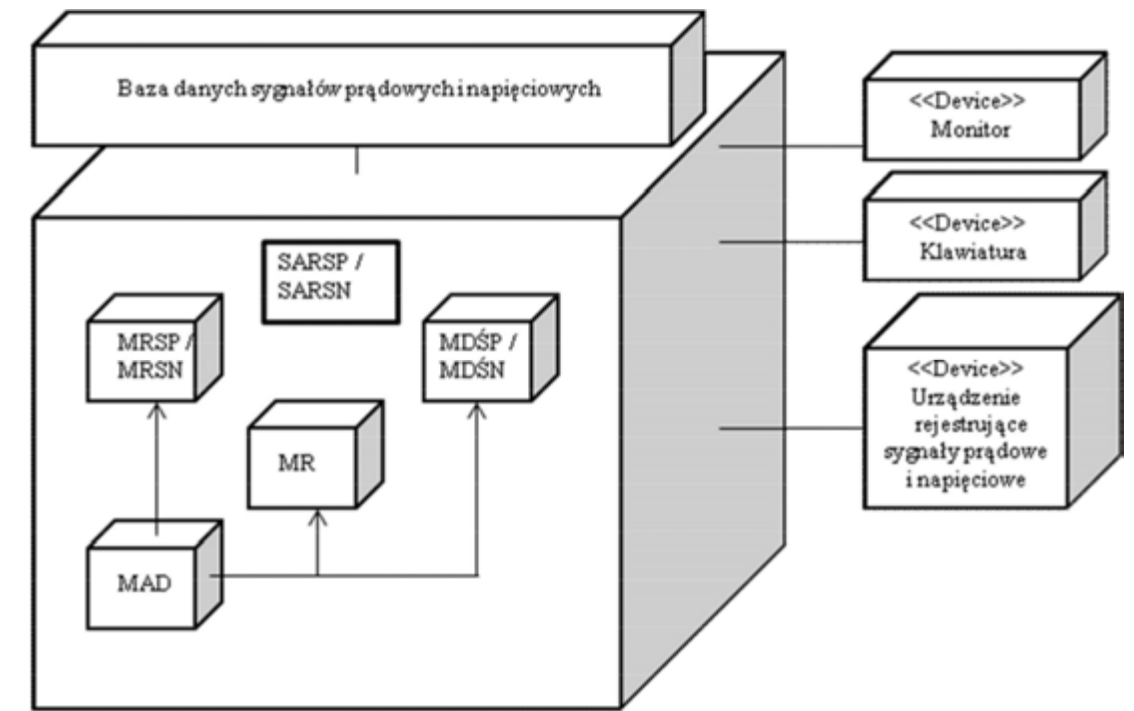
Rys. 3.3. Diagram wdrożenia systemu automatycznego rozpoznawania sygnału akustycznego

SARSA wykorzystuje następujące urządzenia: monitor, klawiaturę, komputer, mikrofon i kartę dźwiękową. Ponadto SARSA korzysta z bazy danych sygnałów akustycznych, która zawiera zbiór uczący i zbiór testowy. Zbiory te zawierają zarejestrowane sygnały akustyczne maszyn elektrycznych podczas różnych stanów pracy (stanu bez uszkodzeń i stanów przedawaryjnych): maszyny synchronicznej bez uszkodzeń, maszyny synchronicznej ze zwartymi zewzwojami stojana, maszyny synchronicznej z jedną przerwą w obwodzie stojana, maszyny synchronicznej z trzema przerwami w obwodzie stojana, maszyny prądu stałego bez uszkodzeń oraz maszyny prądu stałego ze zwartymi zewzwojami wirnika.

3.4.2. Diagram przypadków użycia SARSA

W SARSA stosowany jest jeden główny przypadek użycia „Wywołaj proces rozpoznawania sygnału akustycznego”. Podstawowy ciąg zdarzeń przypadku użycia „Wywołaj proces rozpoznawania sygnału akustycznego” przebiega w następujący sposób. Na początku system wyświetla okno konsoli. Kolejny inżynier wpisuje parametry odpowiedzialne za zastosowanie odpowiednich metod wstępnej obróbki danych, ekstrakcji cech i klasyfikacji. Podane przez inżyniera parametry określone są jako konfiguracja. Następnie inżynier zatwierdza wpisaną konfigurację. Kolejny MRSA sprawdza poprawność wprowadzonych danych. MRSA przetwarza sygnał akustyczny. Podczas przetwarzania tego sygnału MRSA informuje o dokonanych operacjach wyświetlając na ekranie komputera odpowiednie komunikaty. Alternatywny ciąg zdarzeń przebiega w następujący sposób. MRSA może stwierdzić niekompletność lub niepoprawność danych (złe wpisanie konfiguracji). Wówczas MRSA nie wykonuje przetwarzania sygnału

prądowego/napięciowego (MR) składa się z komponentu do rejestrowania prądu/napięcia. Moduł rozpoznawania sygnału prądowego/napięciowego (MRSP/MRSN) odpowiedzialny jest za normalizację amplitudy, segmentację, okienkowanie, ekstrakcję cech i klasyfikację sygnału prądowego/napięciowego. Moduł rozpoznawania sygnału prądowego/napięciowego będzie dokładnie omówiony w podrozdziale 3.4.3 ze względu na jego złożoność i ważną funkcję w procesie rozpoznawania sygnału prądowego/napięciowego.



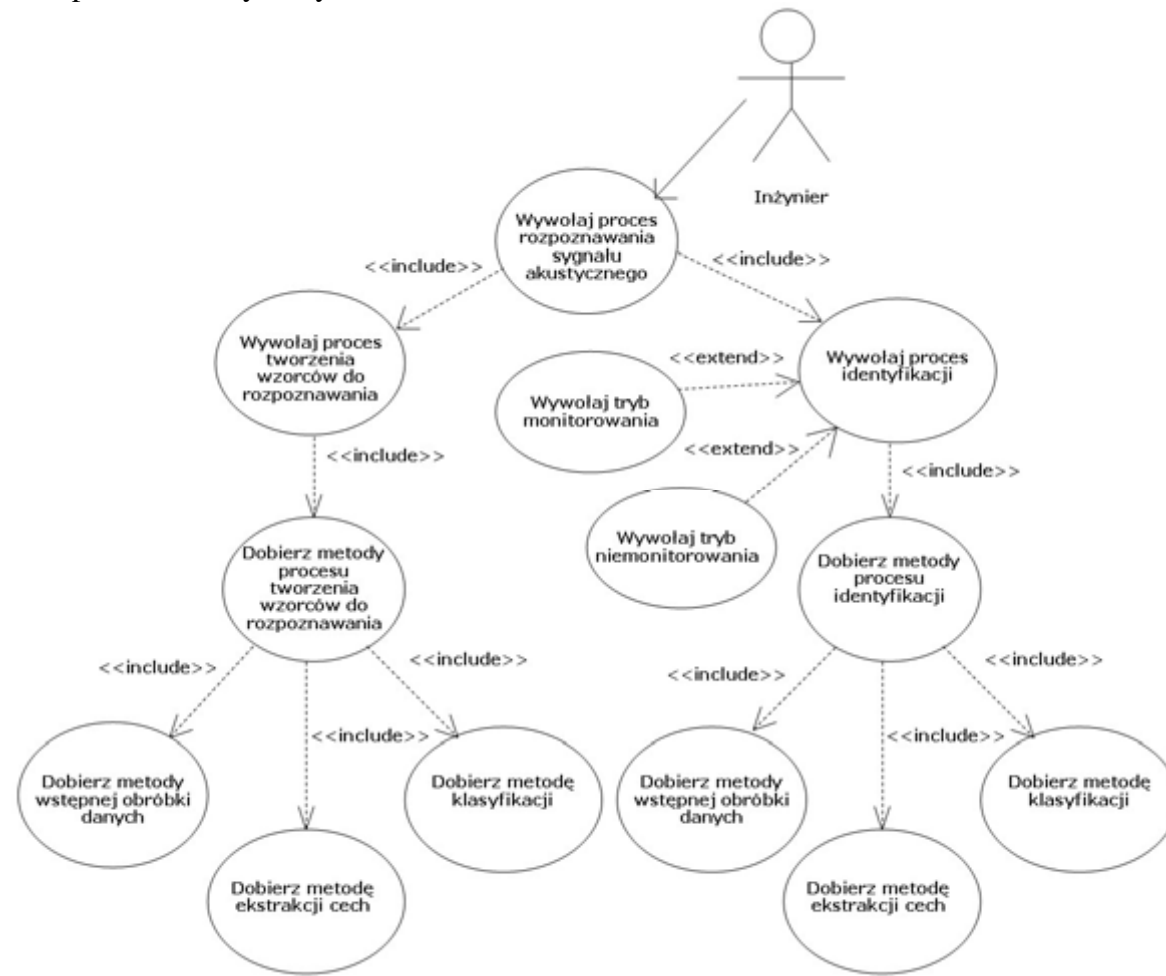
Rys. 3.3. Diagram wdrożenia systemu automatycznego rozpoznawania sygnałów prądowych i napięciowych

SARSP / SARSN wykorzystuje następujące urządzenia: monitor, klawiaturę, komputer i kartę pomiarową. Ponadto SARSP/SARSN korzysta z bazy danych sygnałów prądowych i napięciowych, która zawiera zbiór uczący i zbiór testowy. Zbiory te zawierają zarejestrowane sygnały prądowe i napięciowe silników elektrycznych podczas różnych stanów pracy (stanu bez uszkodzeń i stanów przedawaryjnych): silnika indukcyjnego bez uszkodzeń, silnika indukcyjnego z uszkodzonym pierścieniem, silnika indukcyjnego z dwoma uszkodzonymi prętami, silnika indukcyjnego z jednym uszkodzonym prętem, silnika prądu stałego bez uszkodzeń, silnika prądu stałego z sześcioma zwartymi zewzwojami wirnika, silnika prądu stałego z trzema zwartymi zewzwojami wirnika, silnika prądu stałego z jedną przerwą w uzwojeniu wirnika.

3.4.2. Diagram przypadków użycia SARSP i SARSN

W SARSA stosowany jest jeden główny przypadek użycia „Wywołaj proces rozpoznawania sygnału prądowego/napięciowego”. Podstawowy ciąg zdarzeń przypadku użycia „Wywołaj proces rozpoznawania sygnału prądowego/napięciowego” przebiega w następujący sposób. Na początku system wyświetla okno konsoli. Kolejny inżynier wpisuje parametry odpowiedzialne za zastosowanie odpowiednich metod wstępnej obróbki danych, ekstrakcji cech i klasyfikacji. Podane przez inżyniera parametry określone są jako konfiguracja. Następnie inżynier zatwierdza wpisaną konfigurację. Kolejny MRSP/MRSN sprawdza poprawność wprowadzonych danych. MRSP/MRSN przetwarza sygnał prądowy/napięciowy. Podczas przetwarzania tego sygnału MRSP/MRSN informuje o dokonanych operacjach wyświetlając na ekranie komputera odpowiednie komunikaty. Alternatywny ciąg zdarzeń przebiega w następujący sposób.

akustycznego, tylko wyświetla odpowiedni komunikat z informacją o błędzie. Diagram przypadków użycia SARSA został przedstawiony na rysunku 3.4.

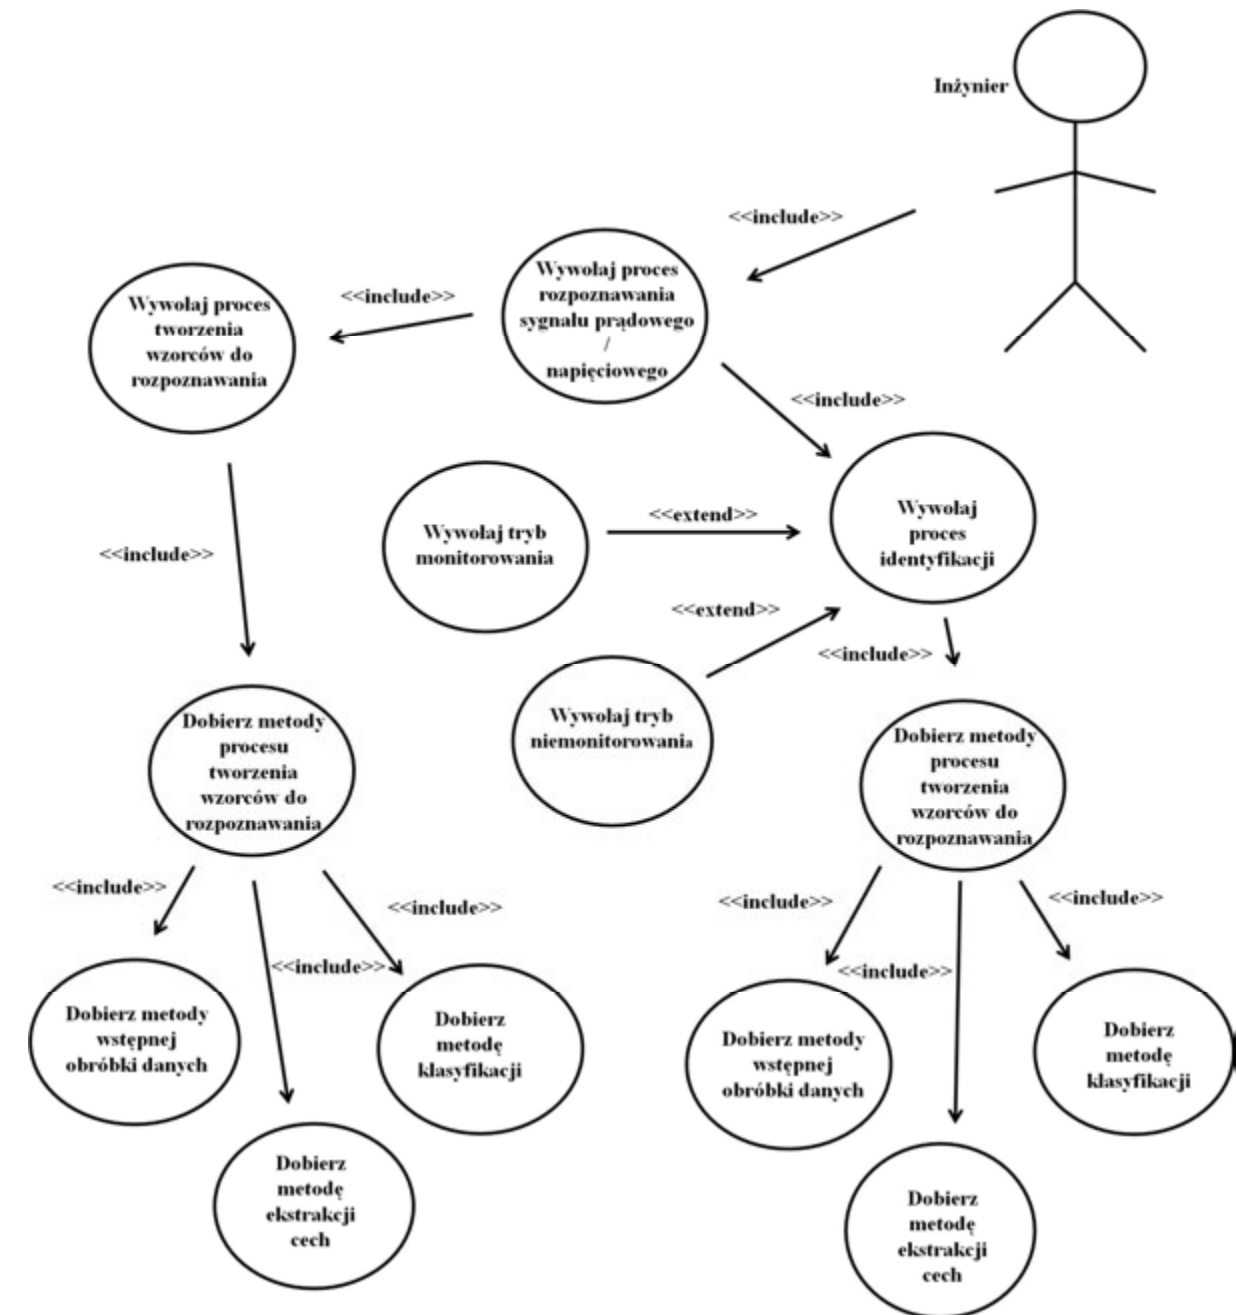


Rys. 3.4. Diagram przypadków użycia SARSA

Obejmuje on jeden główny przypadek użycia, który można rozłożyć na składowe:

„Wywołaj proces tworzenia wzorców do rozpoznawania” – pobiera konfigurację, według której MRSA ma tworzyć wzorce do rozpoznawania. Wykonuje określone przetwarzanie danych próbek dźwięku zawartych w zbiorze uczącym. Tworzy wzorce do rozpoznawania.

MRSP/MRSN może stwierdzić niekompletność lub niepoprawność danych (złe wpisanie konfiguracji). Wówczas MRSP/MRSN nie wykonuje przetwarzania sygnału prądowego/napięciowego, tylko wyświetla odpowiedni komunikat z informacją o błędzie. Diagram przypadków użycia SARSP/SARSN został przedstawiony na rysunku 3.4.



Rys. 3.4. Diagram przypadków użycia SARSP / SARSN

Obejmuje on jeden główny przypadek użycia, który można rozłożyć na składowe:

„Wywołaj proces tworzenia wzorców do rozpoznawania” – pobiera konfigurację, według której MRSP/MRSN ma tworzyć wzorce do rozpoznawania. Wykonuje określone przetwarzanie danych próbek prądu/napięcia zawartych w zbiorze uczącym. Tworzy wzorce do rozpoznawania.

„Wywołaj proces identyfikacji” – pobiera konfigurację, według której MRSA ma przetwarzać i rozpoznawać jedną próbkę dźwięku ze zbioru testowego. Wykonuje określone przetwarzanie danych, a następnie rozpoznaje stan pracy maszyny elektrycznej.

„Wywołaj tryb niemonitorowania” – modyfikuje format ścieżki dźwiękowej, gdy nie jest on obsługiwany przez MRSA. Dzieli ścieżkę dźwiękową na mniejsze fragmenty.

Wykonuje proces identyfikacji dla zbioru testowego.

„Wywołaj tryb monitorowania” – rejestruje sygnał akustyczny maszyny elektrycznej. Dzieli ścieżkę dźwiękową na mniejsze fragmenty. Wykonuje proces identyfikacji dla zbioru testowego. Powtarza proces identyfikacji w nieskończonej pętli.

„Dobierz metody procesu tworzenia wzorców do rozpoznawania” – dobiera określone metody wstępnej obróbki danych, ekstrakcji cech i klasyfikacji.

„Dobierz metody procesu identyfikacji” – dobiera określone metody wstępnej obróbki danych, ekstrakcji cech i klasyfikacji.

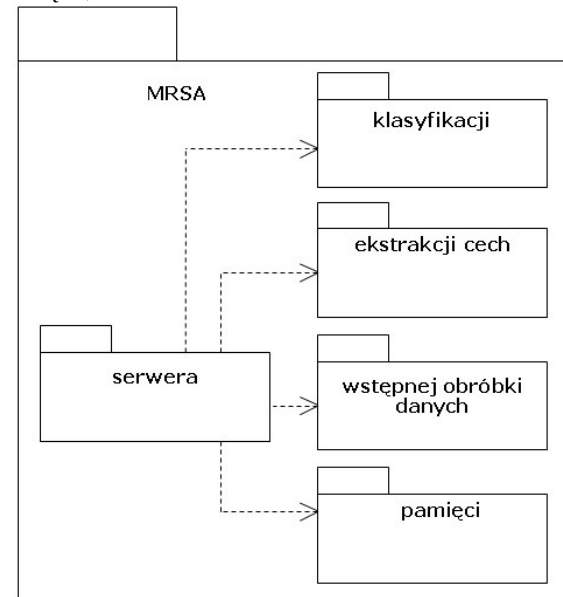
„Dobierz metody wstępnej obróbki danych” – dobiera metody wstępnej obróbki danych. Dobiera parametry segmentacji i okienkowania, które mają być zastosowane przez MRSA.

„Dobierz metodę ekstrakcji cech” – dobiera metodę ekstrakcji cech, która ma być zastosowana przez MRSA.

„Dobierz metodę klasyfikacji” – dobiera metodę klasyfikacji, która ma być zastosowana przez MRSA.

3.4.3. Diagram pakietów MRSA

Diagram pakietów modułu rozpoznawania sygnału akustycznego (MRSA) został przedstawiony na rysunku 3.5. Z diagramu tego wynika, że MRSA zawiera następujące pakiety: wstępnej obróbki danych, ekstrakcji cech, klasyfikacji, pamięci, serwera.



Rys. 3.5. Diagram pakietów modułu rozpoznawania sygnału akustycznego

„Wywołaj proces identyfikacji” – pobiera konfigurację, według której MRSP / MRSN ma przetwarzać i rozpoznawać jedną próbkę prądu/napięcia ze zbioru testowego. Wykonuje określone przetwarzanie danych, a następnie rozpoznaje stan pracy maszyny elektrycznej.

„Dobierz metody procesu tworzenia wzorców do rozpoznawania” – dobiera określone metody wstępnej obróbki danych, ekstrakcji cech i klasyfikacji.

„Dobierz metody procesu identyfikacji” – dobiera określone metody wstępnej obróbki danych, ekstrakcji cech i klasyfikacji.

„Dobierz metody wstępnej obróbki danych” – dobiera metody wstępnej obróbki danych.

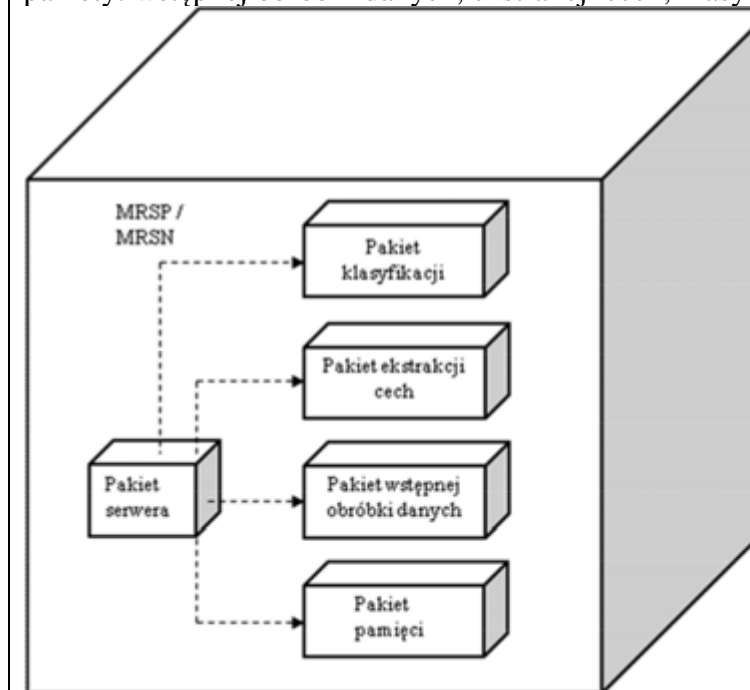
Dobiera parametry segmentacji i okienkowania, które mają być zastosowane przez MRSP/MRSN.

„Dobierz metodę ekstrakcji cech” – dobiera metodę ekstrakcji cech, która ma być zastosowana przez MRSP/MRSN.

„Dobierz metodę klasyfikacji” – dobiera metodę klasyfikacji, która ma być zastosowana przez MRSP/MRSN.

3.4.3. Diagram pakietów MRSP i MRSN

Diagram pakietów modułu rozpoznawania sygnałów prądowych i napięciowych (MRSP / MRSN) został przedstawiony na rysunku 3.5. Z diagramu tego wynika, że MRSP / MRSN zawiera następujące pakiety: wstępnej obróbki danych, ekstrakcji cech, klasyfikacji, pamięci, serwera.



Rys. 3.5. Diagram pakietów modułu rozpoznawania sygnałów prądowych i napięciowych

Pakiet wstępnej obróbki danych zawiera algorytmy: normalizacji amplitudy, segmentacji, okienkowania z zastosowaniem okna Hamminga. W pakiecie ekstrakcji cech zaimplementowano następujące algorytmy: wyboru amplitud dla częstotliwości (parametry dobrane na podstawie badań – zobacz rozdział 4), FFT, LPC, LPCC. W pakiecie klasyfikacji zaimplementowane zostały następujące klasyfikatory: klasyfikator oparty na słowach, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów, zmodyfikowany klasyfikator NM z metryką kosinusową, Jacquarda, Euklidesa, Manhattan, Minkowskiego z parametrami $r = 3, 4, 5, 6$. Pakiet pamięci odpowiedzialny jest za wczytywany format pliku (próbki dźwięku) przez MRSA. MRSA obsługuje format pliku

WAVE PCM z parametrami 44100 Hz, 16 bit, 1 kanał dźwięku (zobacz podrozdział 2.1). Z kolei w pakiecie serwera zaimplementowano obsługę procesu tworzenia wzorców do rozpoznawania i procesu identyfikacji.

MRSA jest zmodyfikowaną biblioteką MARF [93]. W ramach modyfikacji do biblioteki MARF dodano algorytm wybierania amplitud dla częstotliwości, LPC, LPCC, klasyfikator oparty na słowach, klasyfikator oparty na sieci neuronowej, zmodyfikowany klasyfikator NM z metryką kosinusową i metryką Jacquarda. Modyfikacje obejmowały również wczytywanie danych w formacie WAVE PCM.

3.4.4. Realizacja przypadków użycia SARSA

Realizacja przypadków użycia SARSA została przedstawiona na diagramach czynności. Diagramy te zostały przedstawione dla następujących przypadków użycia: „Wywołaj proces tworzenia wzorców do rozpoznawania”, „Wywołaj proces identyfikacji”, „Wywołaj tryb niemonitorowania”, „Wywołaj tryb monitorowania”.

Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania”

Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania” został przedstawiony na rysunku 3.6. Zawiera on następujące czynności:

„Utwórz konfigurację procesu tworzenia wzorców do rozpoznawania” – tworzy konfigurację zawierającą parametry procesu tworzenia wzorców do rozpoznawania.

„Wyślij konfigurację procesu tworzenia wzorców do rozpoznawania” – przesyła konfigurację procesu tworzenia wzorców do rozpoznawania od inżyniera do MRSA.

„Sprawdź poprawność konfiguracji procesu tworzenia wzorców do rozpoznawania” – porównuje otrzymaną konfigurację procesu tworzenia wzorców do rozpoznawania z możliwymi konfiguracjami, które mogą być obsługiwane przez MRSA. Jeśli dana konfiguracja została właściwie wprowadzona przez inżyniera do konsoli, to MRSA rozpoczyna przetwarzanie sygnału akustycznego. Jeśli konfiguracja została wprowadzona do konsoli błędnie, wtedy tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj wstępną obróbkę danych” – wykonuje wstępną obróbkę danych. Wykonywana jest normalizacja amplitudy. Następnie wykonywane są segmentacja i okienkowanie. Jeśli wstępna obróbka danych zostanie wykonana niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj ekstrakcję cech” – wykonuje ekstrakcję cech. W zależności od parametru ustawionego w konfiguracji algorytm wybierania amplitud dla częstotliwości może zostać wykonany z różnymi parametrami. Kolejno wybierany jest jeden z trzech następujących algorytmów: FFT, LPC, LPCC. Jeśli wybrany algorytm zostanie wykonany niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Twórz wzorce do rozpoznawania” – tworzy wzorce do rozpoznawania. W zależności od parametru ustawionego w konfiguracji wybierany jest jeden z trzech następujących klasyfikatorów: zmodyfikowany klasyfikator NM, oparty na słowach, oparty na sieci neuronowej z algorytmem wstecznej propagacji

Pakiet wstępnej obróbki danych zawiera algorytmy: normalizacji amplitudy, segmentacji, okienkowania z zastosowaniem okna Hamminga. W pakiecie ekstrakcji cech

zaimplementowano następujące algorytmy: wyboru amplitud dla częstotliwości (parametry dobrane na podstawie badań, FFT, LPC, LPCC. W pakiecie klasyfikacji zaimplementowane zostały następujące klasyfikatory, klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów, zmodyfikowany **klasyfikator NM** z metryką kosinusową, Jacquarda, Euklidesa, Manhattan, Minkowskiego z parametrami $r = 3, 4, 5, 6$. Pakiet pamięci odpowiedzialny jest za wczytywany format pliku (próbki prądu/napięcia) przez MRSP/MRSN. MRSP/MRSN obsługuje format pliku TXT z parametrami 20000 Hz, 16 bit, 1 kanał prądu/napięcia.

Z kolei w pakiecie serwera zaimplementowano obsługę procesu tworzenia wzorców do rozpoznawania i procesu identyfikacji.

MARSP/MARSN jest biblioteką. W ramach prac badawczych do biblioteki dodano algorytm wyboru amplitud dla częstotliwości, LPC, LPCC, klasyfikator oparty na sieci neuronowej, klasyfikator NN z metryką kosinusową i metryką Jacquarda.

3.4.4. Realizacja przypadków użycia SARSP/SARSN

Realizacja przypadków użycia SARSP/SARSN została przedstawiona na diagramach czynności. Diagramy te zostały przedstawione dla następujących przypadków użycia: „Wywołaj proces tworzenia wzorców do rozpoznawania”, „Wywołaj proces identyfikacji”.

Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania”

Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania” został przedstawiony na rysunku 3.6. Zawiera on następujące czynności:

„Utwórz konfigurację procesu tworzenia wzorców do rozpoznawania” – tworzy konfigurację zawierającą parametry procesu tworzenia wzorców do rozpoznawania.

„Wyślij konfigurację procesu tworzenia wzorców do rozpoznawania” – przesyła konfigurację procesu tworzenia wzorców do rozpoznawania od inżyniera do MRSP/MRSN.

„Sprawdź poprawność konfiguracji procesu tworzenia wzorców do rozpoznawania” – porównuje otrzymaną konfigurację procesu tworzenia wzorców do rozpoznawania z możliwymi konfiguracjami, które mogą być obsługiwane przez MRSP/MRSN. Jeśli dana konfiguracja została właściwie wprowadzona przez inżyniera do konsoli, to MRSP/MRSN rozpoczyna przetwarzanie sygnału prądowego/napięciowego. Jeśli konfiguracja została wprowadzona do konsoli błędnie, wtedy tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj wstępną obróbkę danych” – wykonuje wstępną obróbkę danych. Wykonywana jest normalizacja amplitudy. Następnie wykonywane są segmentacja i okienkowanie. Jeśli wstępna obróbka danych zostanie wykonana niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj ekstrakcję cech” – wykonuje ekstrakcję cech. W zależności od parametru ustawionego w konfiguracji algorytm wyboru amplitud dla częstotliwości może zostać wykonany z różnymi parametrami. Kolejno wybierany jest jeden z trzech następujących algorytmów: FFT, LPC, LPCC. Jeśli wybrany algorytm zostanie wykonany niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Twórz wzorce do rozpoznawania” – tworzy wzorce do rozpoznawania. W zależności od parametru ustawionego w konfiguracji wybierany jest jeden z trzech następujących klasyfikatorów: zmodyfikowany **klasyfikator NM, oparty na słowach, oparty na sieci neuronowej z algorytmem wstecznej propagacji**

błędów. Jeśli tworzenie wzorców zostanie wykonane niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Zapisz wzorce do rozpoznawania w pliku” – zapisuje wzorce do rozpoznawania w określonym pliku.

„Potwierdź prawidłowe wykonanie procesu tworzenia wzorców do rozpoznawania” – wyświetla potwierdzenie prawidłowego wykonania procesu tworzenia wzorców do rozpoznawania na ekranie komputera.

„Utwórz komunikat z informacją o błędzie” – tworzy odpowiedni komunikat z informacją o błędzie. Komunikat ten zależny jest od etapu przetwarzania, w którym błąd wystąpił.

„Wyślij komunikat z informacją o błędzie” – przesyła komunikat z informacją o błędzie z MRSA na ekran komputera.

„Wyświetl komunikat z informacją o błędzie na ekranie komputera” – wyświetla komunikat z informacją o błędzie na ekranie komputera.

błędów. Jeśli tworzenie wzorców zostanie wykonane niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

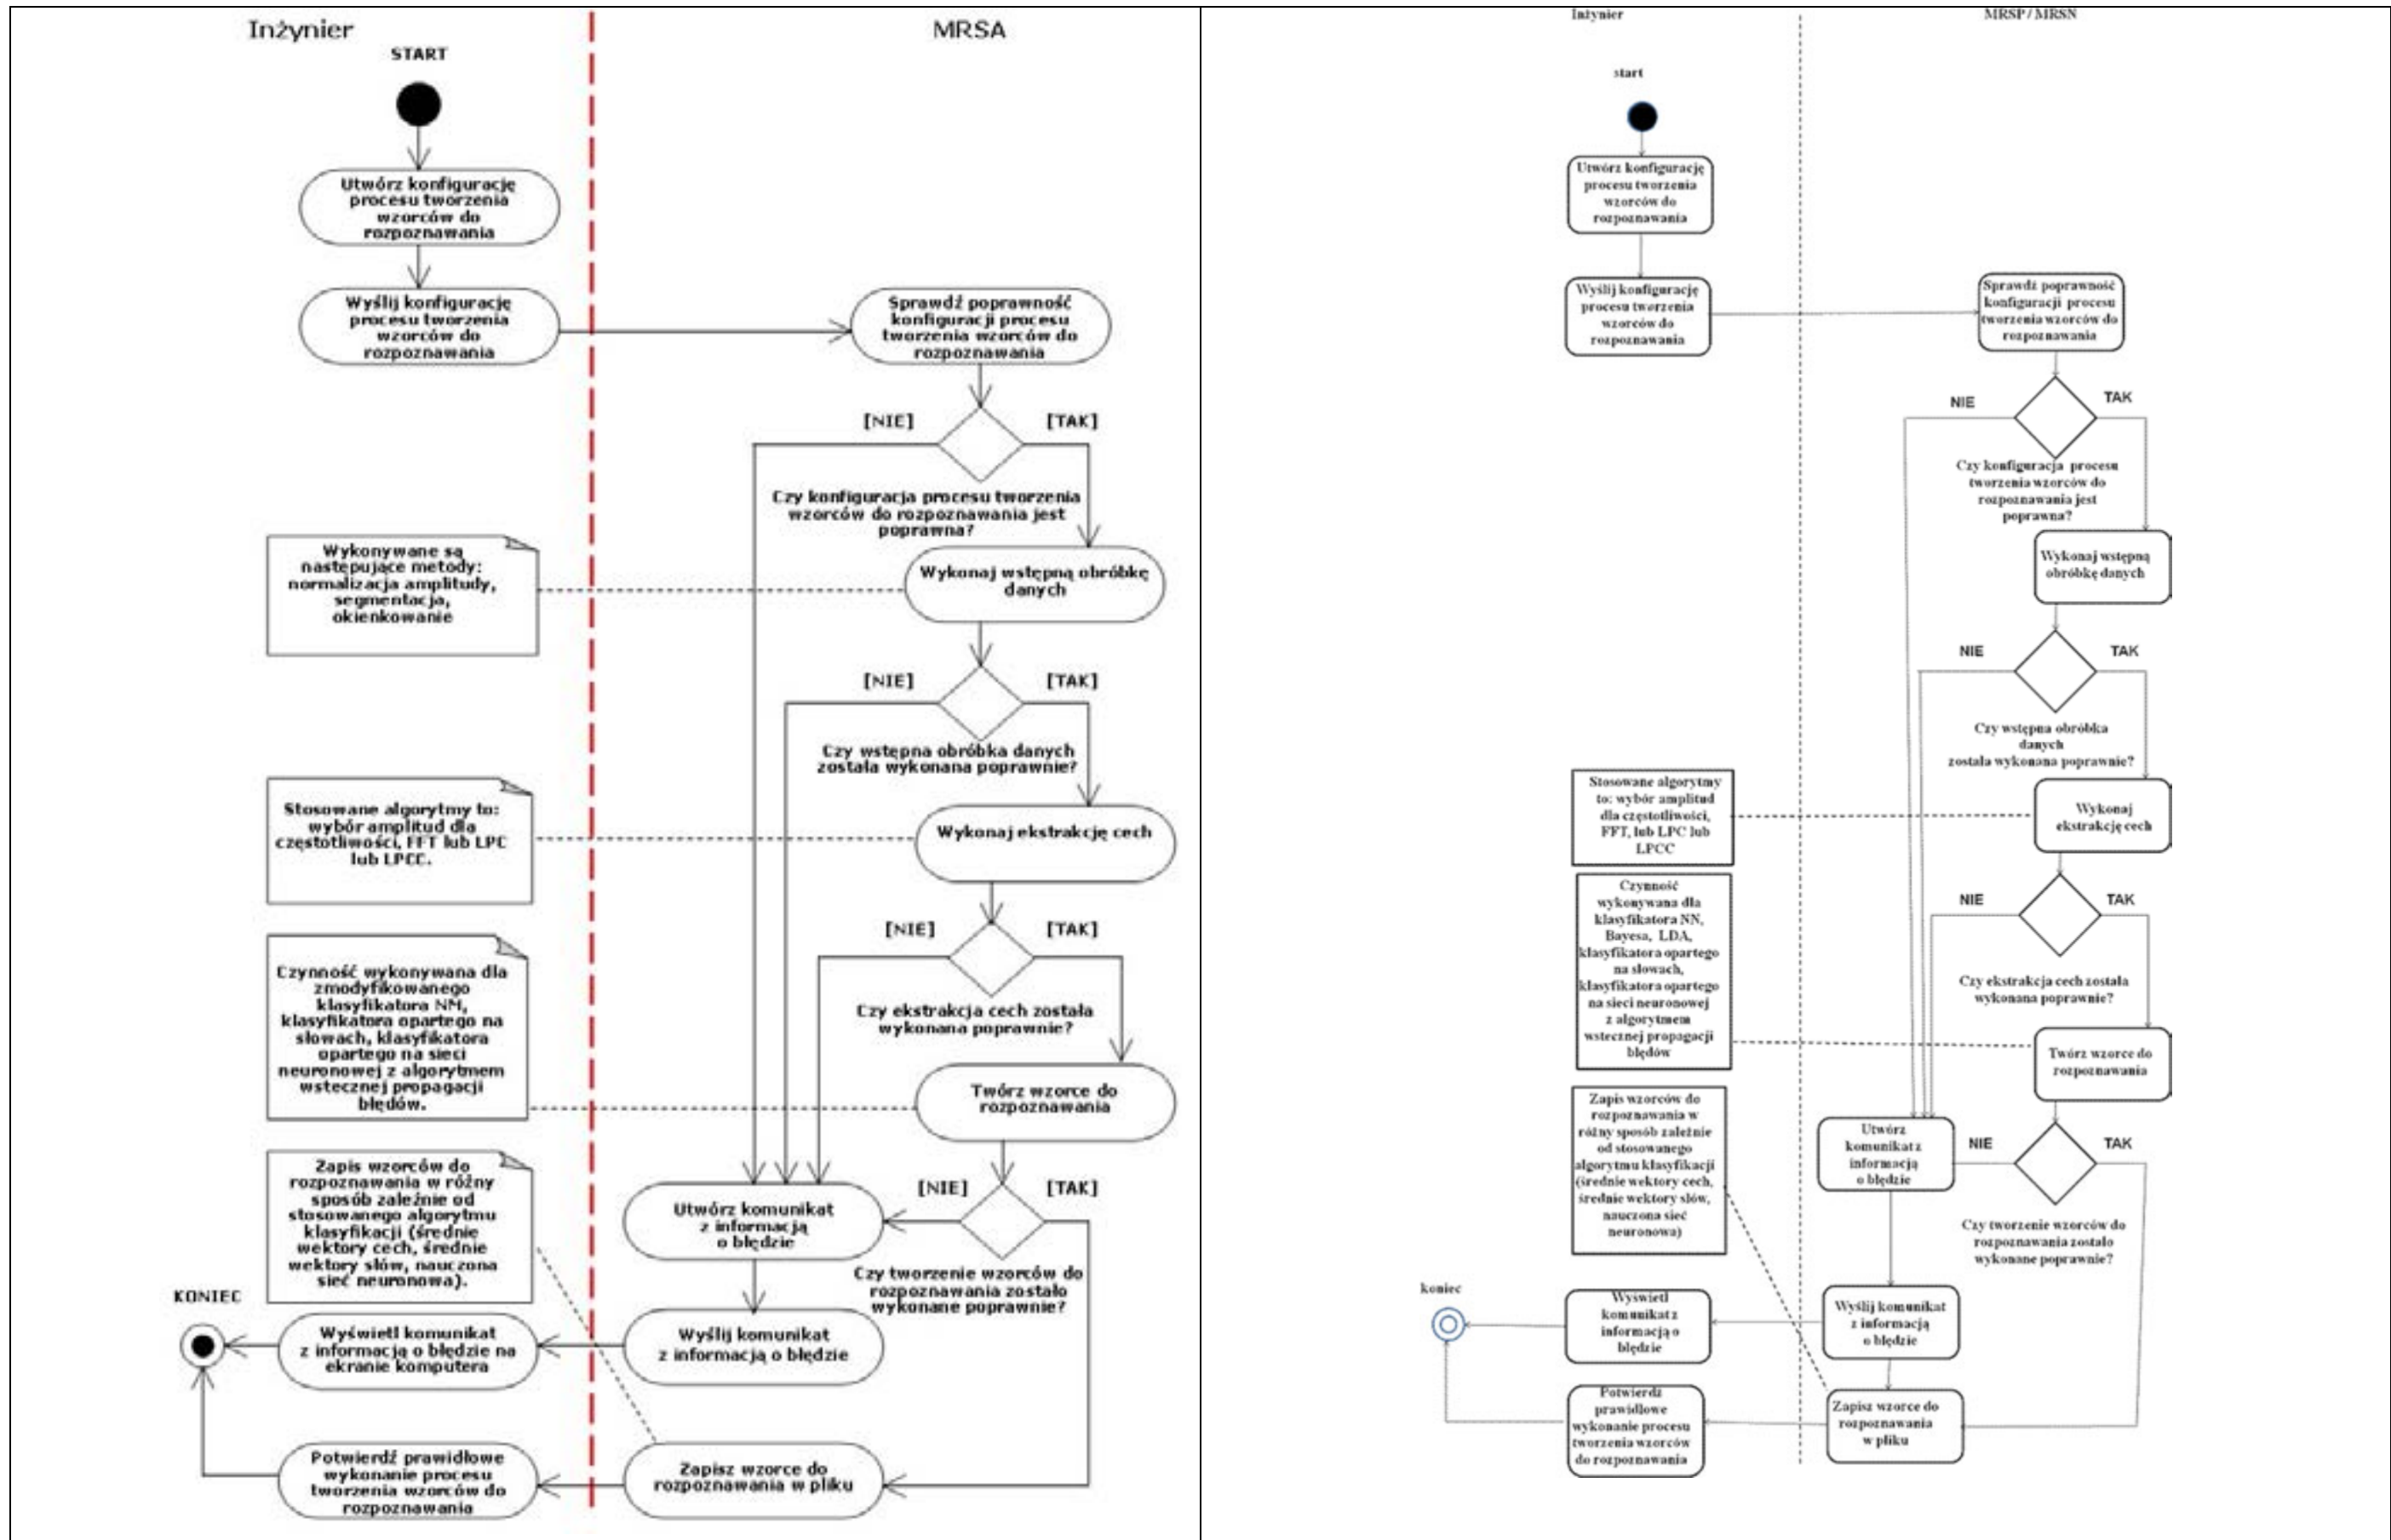
„Zapisz wzorce do rozpoznawania w pliku” – zapisuje wzorce do rozpoznawania w określonym pliku.

„Potwierdź prawidłowe wykonanie procesu tworzenia wzorców do rozpoznawania” – wyświetla potwierdzenie prawidłowego wykonania procesu tworzenia wzorców do rozpoznawania na ekranie komputera.

„Utwórz komunikat z informacją o błędzie” – tworzy odpowiedni komunikat z informacją o błędzie. Komunikat ten zależny jest od etapu przetwarzania, w którym błąd wystąpił.

„Wyślij komunikat z informacją o błędzie” – przesyła komunikat z informacją o błędzie z MRSP/MRSN na ekran komputera.

„Wyświetl komunikat z informacją o błędzie na ekranie komputera” – wyświetla komunikat z informacją o błędzie na ekranie komputera.



Rys. 3.6. Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania”**Diagram czynności dla przypadku „Wywołaj proces identyfikacji”**

Diagram czynności dla przypadku użycia „Wywołaj proces identyfikacji” został przedstawiony na rysunku 3.7. Zawiera on następujące czynności:

„Utwórz konfigurację procesu identyfikacji” – tworzy konfigurację zawierającą parametry procesu identyfikacji.

„Wyślij konfigurację procesu identyfikacji” – przesyła konfigurację procesu identyfikacji od inżyniera do MRSA.

„Sprawdź poprawność konfiguracji procesu identyfikacji” – porównuje otrzymaną konfigurację procesu identyfikacji z możliwymi konfiguracjami, które mogą być obsługiwane przez MRSA. Jeśli dana konfiguracja została właściwie wprowadzona przez inżyniera do konsoli, to MRSA rozpoczyna przetwarzanie sygnału akustycznego. Jeśli konfiguracja została wprowadzona do konsoli błędnie, wtedy tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj wstępną obróbkę danych” – wykonuje wstępną obróbkę danych. Wykonywana jest normalizacja amplitudy. Następnie wykonywane są segmentacja i okienkowanie. Jeśli wstępna obróbka danych zostanie wykonana niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj ekstrakcję cech” – wykonuje ekstrakcję cech. W zależności od parametru ustawionego w konfiguracji algorytm wybierania amplitud dla częstotliwości może zostać wykonany z różnymi parametrami. Kolejno wybierany jest jeden z trzech następujących algorytmów: FFT, LPC, LPCC. Jeśli wybrany algorytm zostanie wykonany niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj identyfikację” – wykonuje identyfikację. W zależności od parametru ustawionego w konfiguracji wybierany jest jeden z klasyfikatorów: zmodyfikowany klasyfikator NM, oparty na słowach, oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów. Jeśli klasyfikacja zostanie wykonana niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Zapisz wyniki identyfikacji w pliku” – zapisuje wyniki identyfikacji w pliku.

„Wyświetl wyniki identyfikacji na ekranie komputera” – wyświetla wyniki identyfikacji na ekranie komputera.

„Utwórz komunikat z informacją o błędzie” – tworzy odpowiedni komunikat z informacją o błędzie. Komunikat ten zależny jest od etapu przetwarzania, w którym błąd wystąpił.

„Wyślij komunikat z informacją o błędzie” – przesyła komunikat z informacją o błędzie z MRSA na ekran komputera.

„Wyświetl komunikat z informacją o błędzie na ekranie komputera” – wyświetla komunikat z informacją o błędzie na ekranie komputera.

Rys. 3.6. Diagram czynności dla przypadku użycia „Wywołaj proces tworzenia wzorców do rozpoznawania”**Diagram czynności dla przypadku „Wywołaj proces identyfikacji”**

Diagram czynności dla przypadku użycia „Wywołaj proces identyfikacji” został przedstawiony na rysunku 3.7. Zawiera on następujące czynności:

„Utwórz konfigurację procesu identyfikacji” – tworzy konfigurację zawierającą parametry procesu identyfikacji.

„Wyślij konfigurację procesu identyfikacji” – przesyła konfigurację procesu identyfikacji od inżyniera do MRSP/MRSN.

„Sprawdź poprawność konfiguracji procesu identyfikacji” – porównuje otrzymaną konfigurację procesu identyfikacji z możliwymi konfiguracjami, które mogą być obsługiwane przez MRSP/MRSN. Jeśli dana konfiguracja została właściwie wprowadzona przez inżyniera do konsoli, to MRSP/MRSN rozpoczyna przetwarzanie sygnału prądowego/napięciowego. Jeśli konfiguracja została wprowadzona do konsoli błędnie, wtedy tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj wstępną obróbkę danych” – wykonuje wstępną obróbkę danych. Wykonywana jest normalizacja amplitudy. Następnie wykonywane są segmentacja i okienkowanie. Jeśli wstępna obróbka danych zostanie wykonana niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj ekstrakcję cech” – wykonuje ekstrakcję cech. W zależności od parametru ustawionego w konfiguracji algorytm wyboru amplitud dla częstotliwości może zostać wykonany z różnymi parametrami. Kolejno wybierany jest jeden z trzech następujących algorytmów: FFT, LPC, LPCC. Jeśli wybrany algorytm zostanie wykonany niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

„Wykonaj identyfikację” – wykonuje identyfikację. W zależności od parametru ustawionego w konfiguracji wybierany jest jeden z klasyfikatorów: zmodyfikowany klasyfikator NM, oparty na słowach, oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów. Jeśli klasyfikacja zostanie wykonana niepoprawnie, wówczas tworzony jest komunikat z odpowiednią informacją o błędzie.

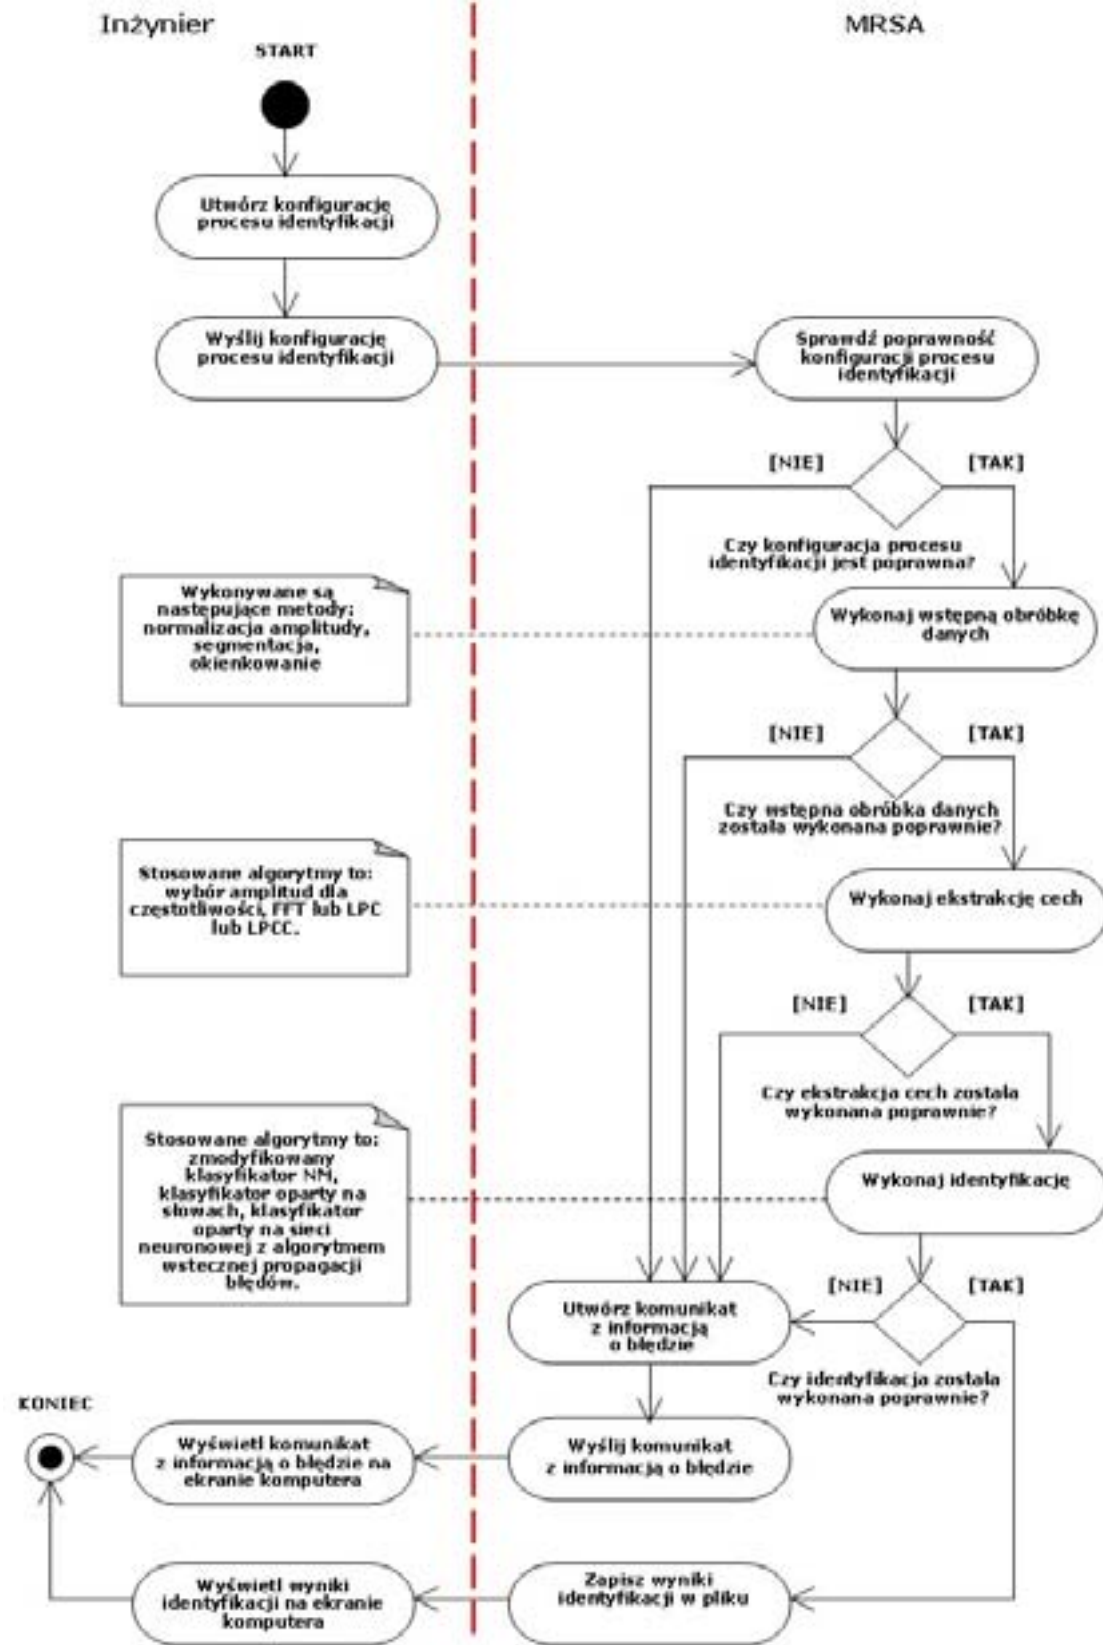
„Zapisz wyniki identyfikacji w pliku” – zapisuje wyniki identyfikacji w pliku.

„Wyświetl wyniki identyfikacji na ekranie komputera” – wyświetla wyniki identyfikacji na ekranie komputera.

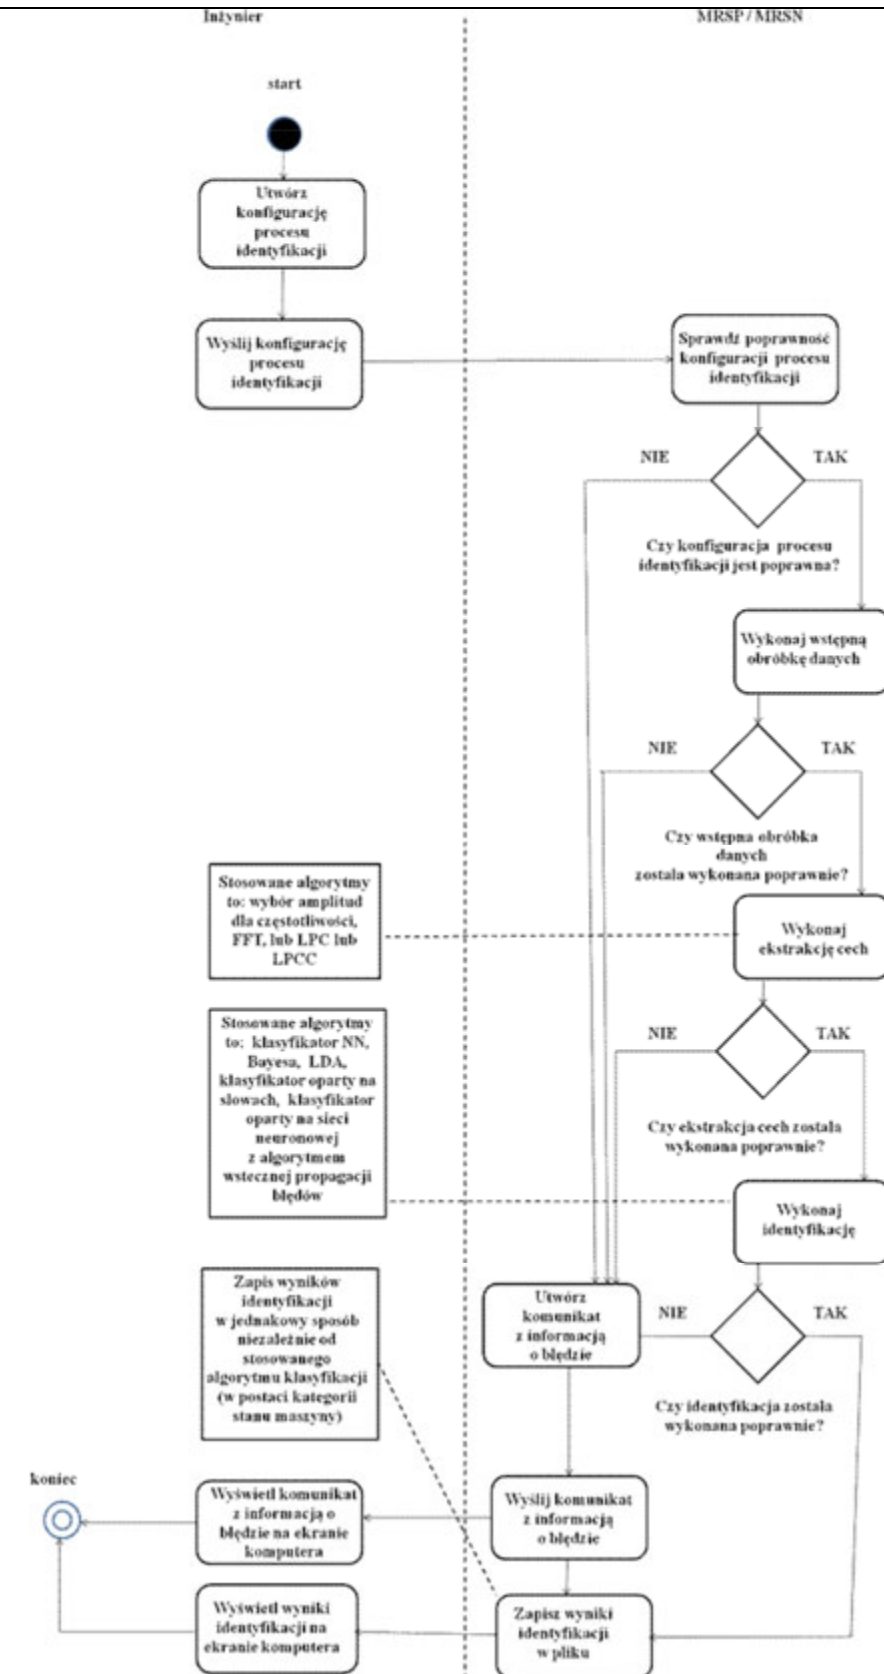
„Utwórz komunikat z informacją o błędzie” – tworzy odpowiedni komunikat z informacją o błędzie. Komunikat ten zależny jest od etapu przetwarzania, w którym błąd wystąpił.

„Wyślij komunikat z informacją o błędzie” – przesyła komunikat z informacją o błędzie z MRSP/MRSN na ekran komputera.

„Wyświetl komunikat z informacją o błędzie na ekranie komputera” – wyświetla komunikat z informacją o błędzie na ekranie komputera.



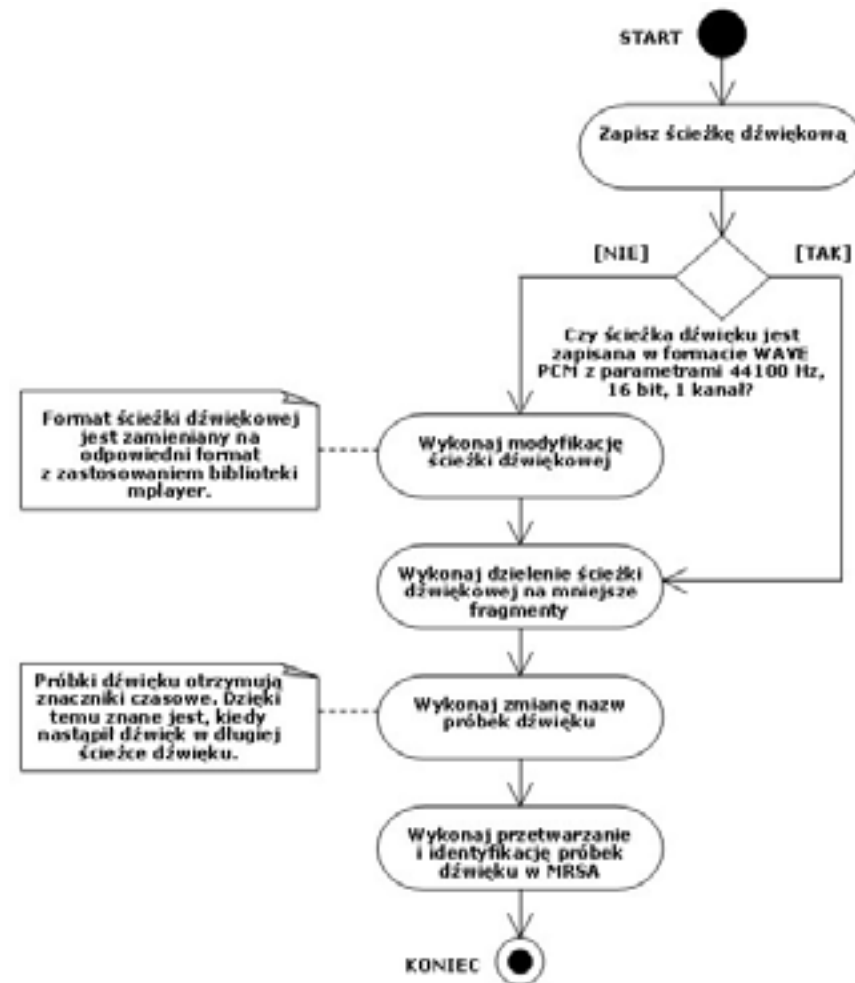
Rys. 3.7. Diagram czynności dla przypadku użycia „Wywołaj proces identyfikacji”



Rys. 3.7. Diagram czynności dla przypadku użycia „Wywołaj proces identyfikacji”

Diagram czynności dla trybu niemonitorowania

Po zbudowaniu stanowiska diagnostycznego do badania sygnałów akustycznych zauważono potrzebę wprowadzenia odmiennych trybów uruchamiania w zależności od danych wejściowych. W trybie niemonitorowania na wejście SARSA podawany format pliku nie musi być obsługiwany przez MRSA. W takim przypadku stosowana jest biblioteka „mplayer” [121]. Biblioteka ta zamienia format ścieżki dźwiękowej na taki, który jest obsługiwany przez MRSA (zobacz podrozdział 3.4.3). Drugim powodem, dla którego taki tryb powstał jest zaistnienie sytuacji w której dane nie są przesyłane na komputer automatycznie (rejestrowanie sygnału akustycznego dyktafonem, następnie zapisywanie ścieżki dźwiękowej na komputerze). Diagram czynności dla trybu niemonitorowania został przedstawiony na rysunku 3.8.



Rys. 3.8. Diagram czynności dla trybu niemonitorowania

Tryb niemonitorowania posiada następujące czynności:

„Zapisz ścieżkę dźwiękową” – zapisuje ścieżkę dźwiękową.

„Wykonaj modyfikację ścieżki dźwiękowej” – wykonuje modyfikację ścieżki dźwiękowej z zastosowaniem biblioteki „mplayer”. Czynność ta jest stosowana dla formatu pliku audio, który nie jest obsługiwany przez MRSA.

„Wykonaj dzielenie ścieżki dźwiękowej na mniejsze fragmenty” – wykonuje dzielenie ścieżki dźwiękowej na mniejsze fragmenty.

„Wykonaj zmianę nazw próbek dźwięku” – nadaje próbkom dźwięku odpowiednie znaczniki czasowe. Dzięki temu znany jest czas wystąpienia dźwięku w długiej ścieżce dźwiękowej.

„Wykonaj przetwarzanie i identyfikację próbek dźwięku w MRSA” – wykonuje przetwarzanie i identyfikację próbek dźwięku w MRSA. Dla tej czynności wykonywany jest proces identyfikacji.

Diagram czynności dla trybu monitorowania

W trybie monitorowania zarejestrowany sygnał akustyczny maszyny elektrycznej jest zapisywany na dysk komputera automatycznie (przy zastosowaniu mikrofonu, karty dźwiękowej, komputera). Po rejestracji sygnału akustycznego następuje zapis znacznika czasowego. Następnie wykonywane są: dzielenie ścieżki dźwiękowej na mniejsze fragmenty, proces identyfikacji i zapis wyników rozpoznawania. Gdy nagrywana ścieżka dźwiękowa przekroczy 7,001 sekundy, wtedy wyniki rozpoznawania sygnałów akustycznych są przenoszone do określonego katalogu. Zapis znacznika czasowego następuje co najmniej po upływie 7,001 sekundy (najdłuższy czas próbki dźwięku do rozpoznawania wynosi 5 sekund, natomiast 2,001 sekundy potrzebne jest na dzielenie ścieżki dźwiękowej na mniejsze fragmenty i proces identyfikacji). Zauważyć należy, że w trybie monitorowania stanowisko działa do momentu wystąpienia przerwania z zewnątrz (np. przez inżyniera obsługującego stanowisko). Diagram czynności dla trybu monitorowania został przedstawiony na rysunku 3.9. Tryb monitorowania ma następujące czynności:

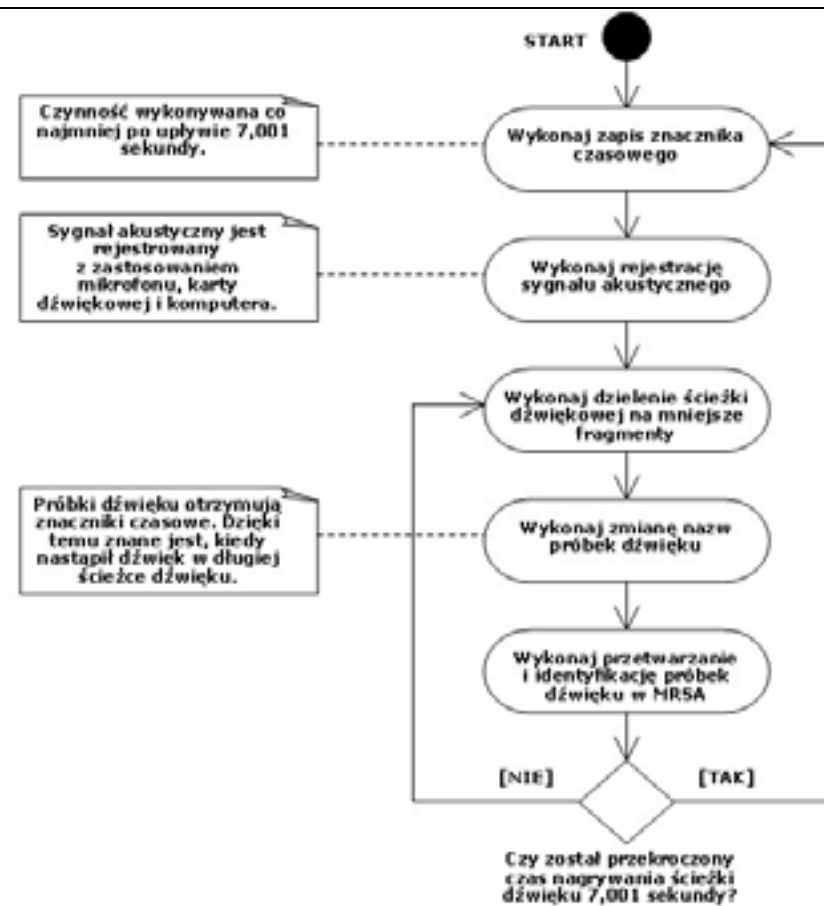
„Wykonaj zapis znacznika czasowego” – wykonuje zapis znacznika czasowego. Czynność ta jest wykonywana co najmniej po upływie 7,001 sekundy.

„Wykonaj rejestrację sygnału akustycznego” – wykonuje rejestrację sygnału akustycznego z zastosowaniem mikrofonu, karty dźwiękowej i komputera.

„Wykonaj dzielenie ścieżki dźwiękowej na mniejsze fragmenty” – wykonuje dzielenie ścieżki dźwiękowej na mniejsze fragmenty.

„Wykonaj zmianę nazw próbek dźwięku” – nadaje próbkom dźwięku znaczniki czasowe.

„Wykonaj przetwarzanie i identyfikację próbek dźwięku w MRSA” – wykonuje przetwarzanie i identyfikację próbek dźwięku w MRSA. Dla tej czynności wykonywany jest proces identyfikacji.



Rys. 3.9. Diagram czynności dla trybu monitorowania

3.4.5. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania

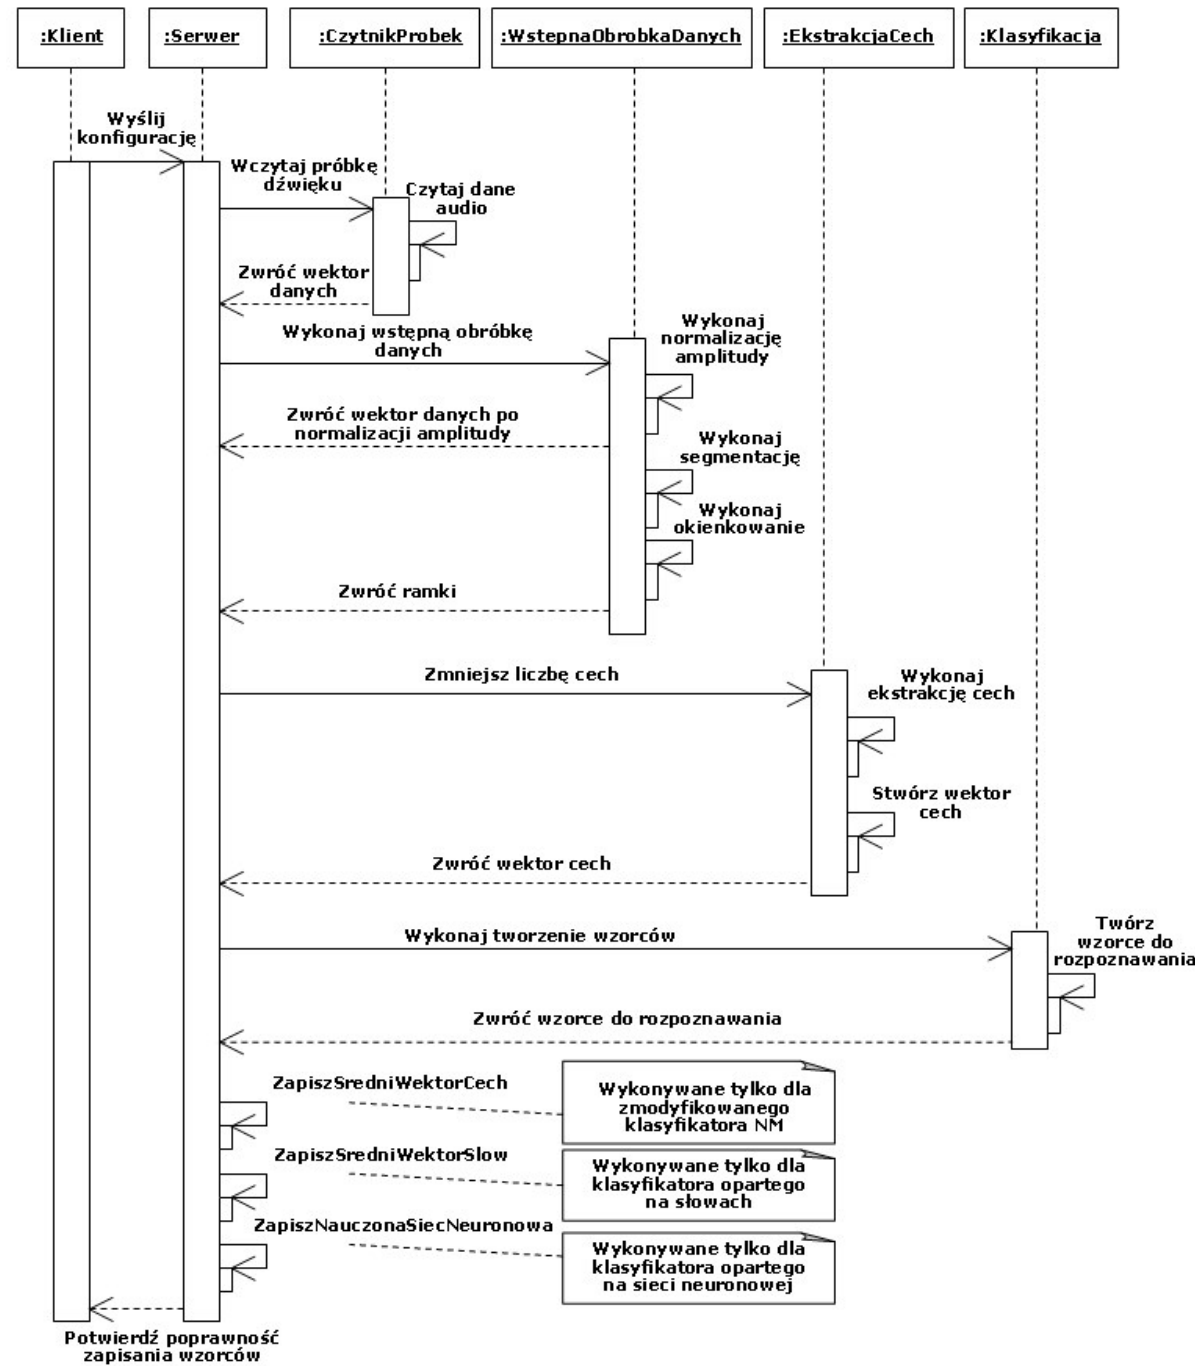
Aby umożliwić inżynierowi prawidłowe rozpoznawanie sygnału akustycznego, najpierw należy przeprowadzić proces tworzenia wzorców do rozpoznawania. W tym celu operator stanowiska wpisuje w konsoli konfigurację procesu tworzenia wzorców do rozpoznawania. Konfiguracja zostaje przekazana od inżyniera do MRSA (klasy „Klient” i „Serwer”). Następnie MRSA sprawdza poprawność konfiguracji. Kolejno zostaje podjęta decyzja o przeprowadzeniu przetwarzania próbki dźwięku. Po uruchomieniu procesu tworzenia wzorców do rozpoznawania wykonywane jest wczytanie próbki dźwięku (klasa „CzytnikPróbek”). Otrzymywany jest wektor danych zawierający sygnał akustyczny w postaci cyfrowej. Później wykonywana jest wstępna obróbka danych (klasa „WstępnaObrobkaDanych”). Amplituda sygnału akustycznego jest normalizowana. W ten sposób zostaje utworzony ciąg danych, który zawiera znormalizowane wartości próbki dźwiękowej w przedziale [-1, 1]. Kolejno wykonywane są segmentacja i okienkowanie. Później następuje ekstrakcja cech (klasa „EkstrakcjaCech”). Ostatnim etapem jest tworzenie wzorców do rozpoznawania (klasa „Klasyfikacja”). W przypadku stosowania zmodyfikowanego klasyfikatora NM tworzone są średnie wektory cech dla każdej kategorii dźwięku (klasy wzorców). Kolejno zapisywane są one w pliku razem z odpowiadającymi identyfikatorami danej kategorii. W przypadku stosowania klasyfikatora opartego na słowach tworzone są średnie wektory słów, które następnie są odpowiednio zapisywane w pliku. Dla klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów nauczona sieć neuronowa jest zapisywana na dysku komputera. Odpowiedni komunikat informuje o uzyskaniu wzorców do rozpoznawania lub o błędach, które wystąpiły podczas przetwarzania

3.4.5. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania

Aby umożliwić inżynierowi prawidłowe rozpoznawanie sygnału prądowego/napięciowego, najpierw należy przeprowadzić proces tworzenia wzorców do rozpoznawania. W tym celu operator stanowiska wpisuje w konsoli konfigurację procesu tworzenia wzorców do rozpoznawania. Konfiguracja zostaje przekazana od inżyniera do MRSP/MRSN (klasy „Klient” i „Serwer”). Następnie MRSP/MRSN sprawdza poprawność konfiguracji. Kolejno zostaje podjęta decyzja o przeprowadzeniu przetwarzania próbki prądu/napięcia. Po uruchomieniu procesu tworzenia wzorców do rozpoznawania wykonywane jest wczytanie próbki prądu/napięcia (klasa „CzytnikPróbek”). Otrzymywany jest wektor danych zawierający **sygnał akustyczny** w postaci cyfrowej. Później wykonywana jest wstępna obróbka danych (klasa „WstępnaObrobkaDanych”). Amplituda sygnału prądowego/napięciowego jest normalizowana. W ten sposób zostaje utworzony ciąg danych, który zawiera znormalizowane wartości próbki w przedziale [-1, 1]. Kolejno wykonywane są segmentacja i okienkowanie. Później następuje ekstrakcja cech (klasa „EkstrakcjaCech”).

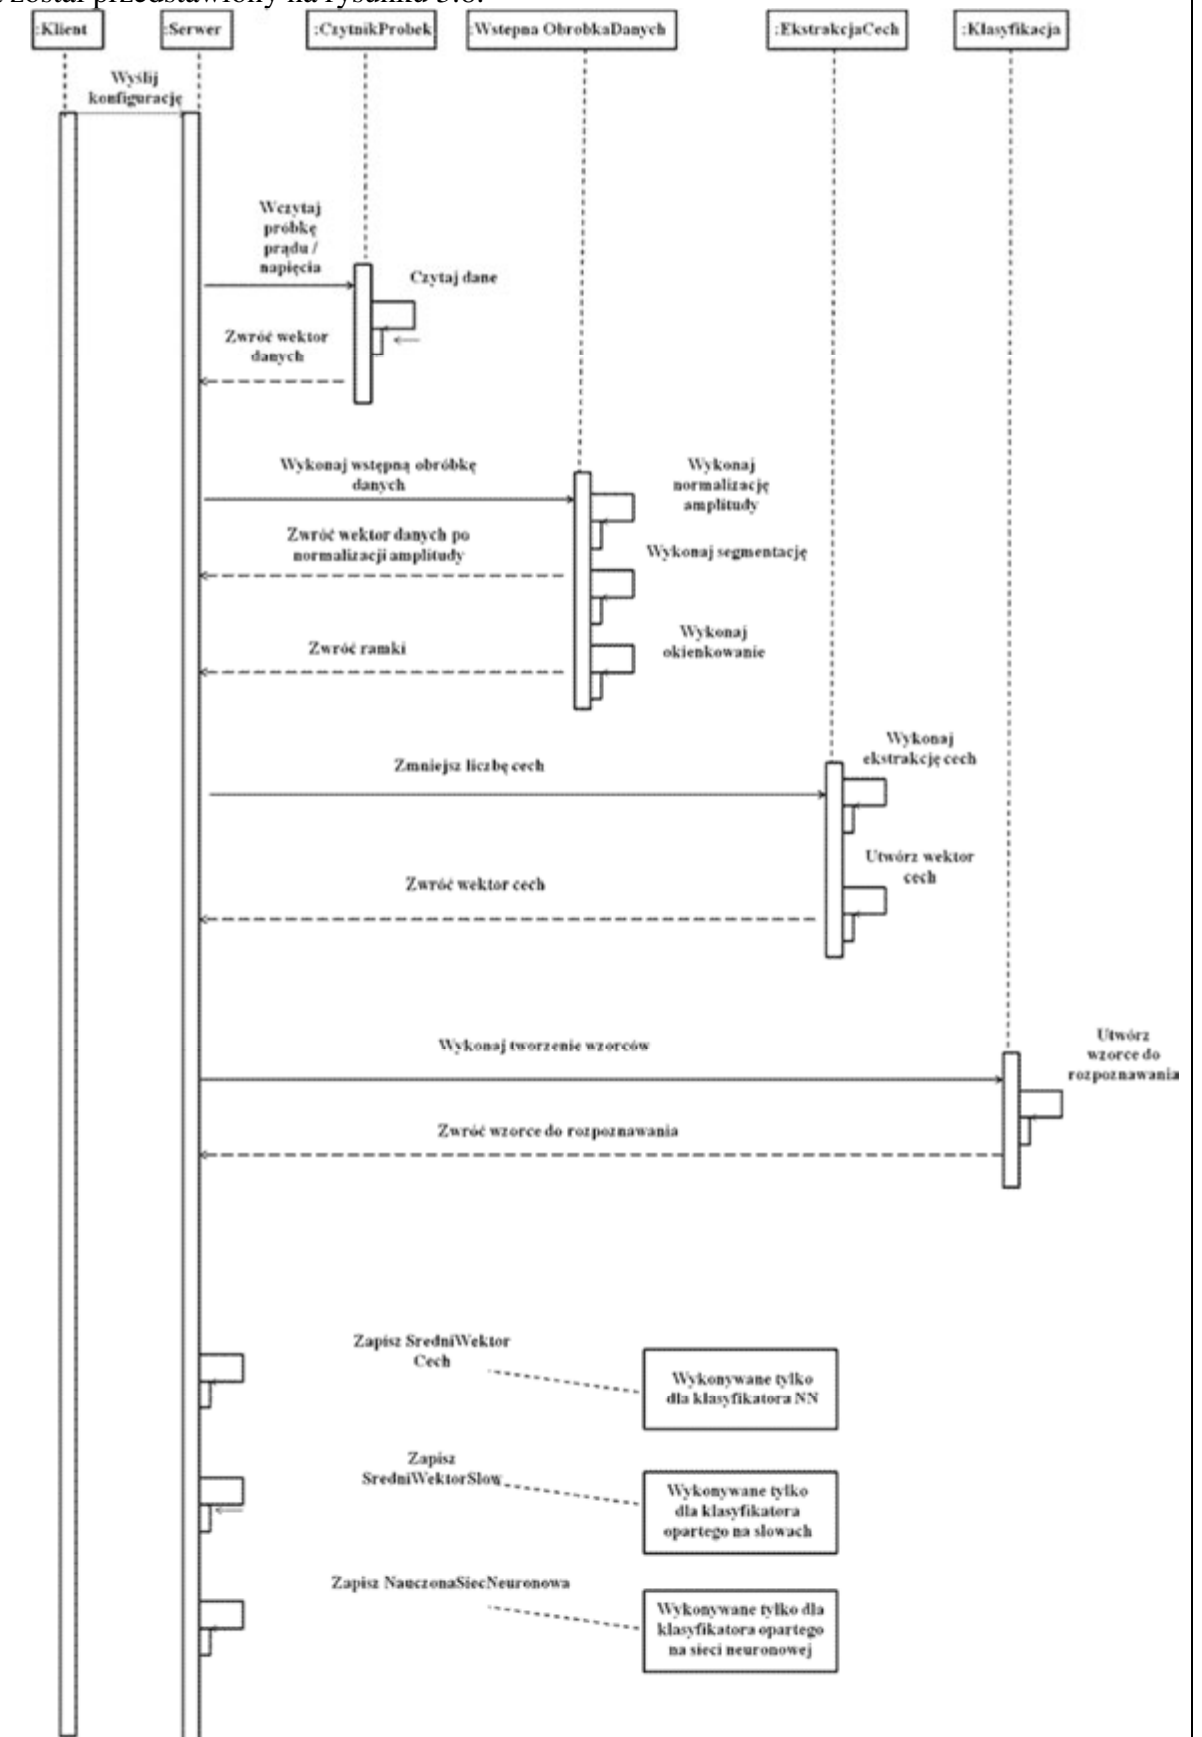
Ostatnim etapem jest tworzenie wzorców do rozpoznawania (klasa „Klasyfikacja”). W przypadku stosowania zmodyfikowanego **klasyfikatora NM** tworzone są średnie wektory cech dla każdej kategorii prądu/napięcia (klasy wzorców). Kolejno zapisywane są one w pliku razem z odpowiadającymi identyfikatorami danej kategorii. W przypadku stosowania **klasyfikatora opartego na słowach** tworzone są średnie wektory słów, które następnie są odpowiednio zapisywane w pliku. Dla **klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów** nauczona sieć neuronowa jest zapisywana na dysku komputera. Odpowiedni komunikat informuje o uzyskaniu wzorców do rozpoznawania lub o błędach,

danych. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania został przedstawiony na rysunku 3.10.



Rys. 3.10. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania

które wystąpiły podczas przetwarzania danych. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania został przedstawiony na rysunku 3.8.



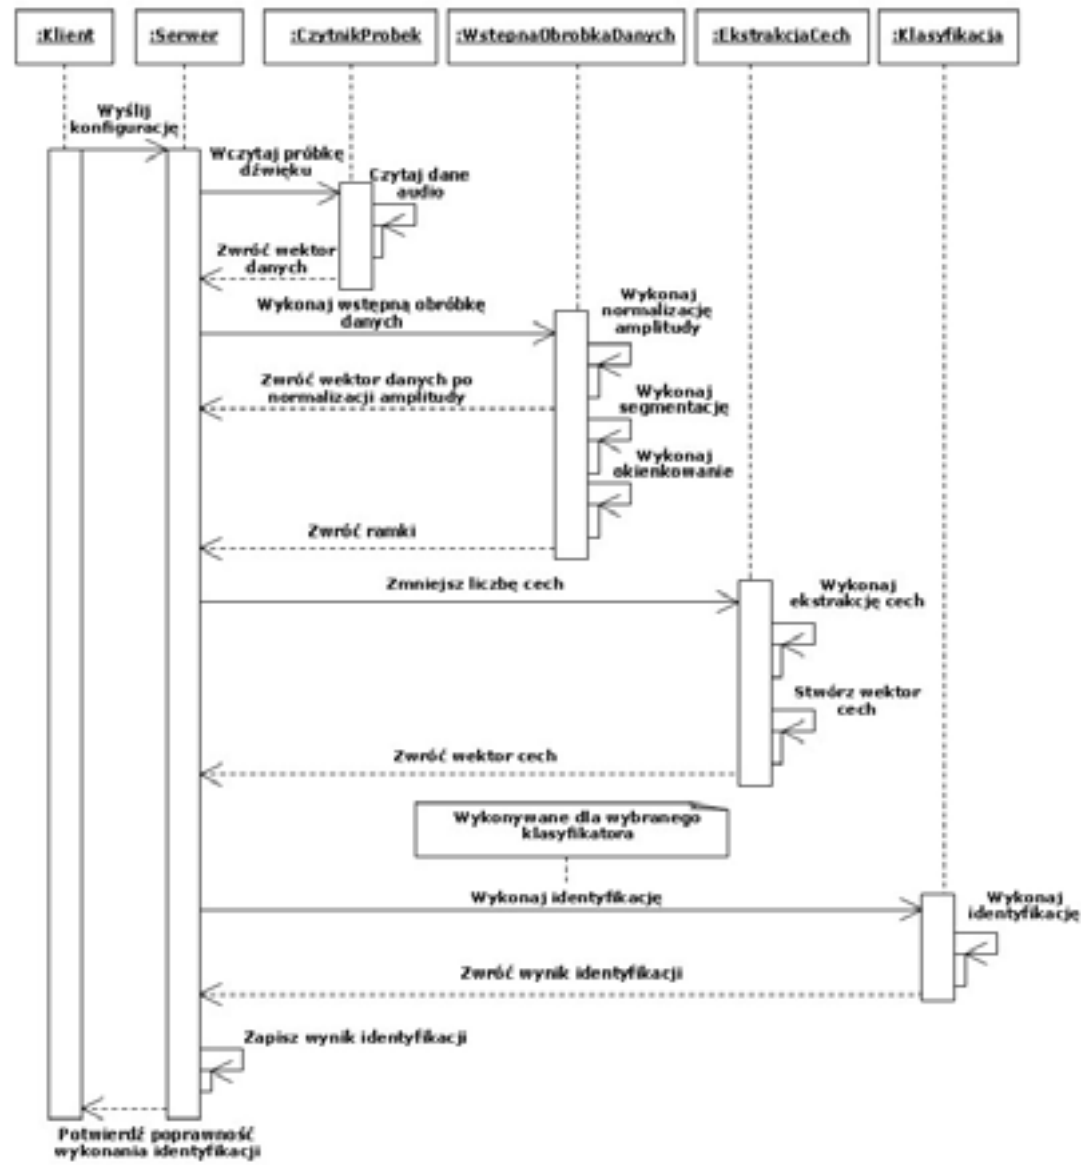
3.4.6. Diagram sekwencji procesu identyfikacji

Po prawidłowym wykonaniu procesu tworzenia wzorców do rozpoznawania, należy wykonać proces identyfikacji. Kolejno wykonywane są: utworzenie konfiguracji procesu identyfikacji, wczytywanie próbki dźwięku, normalizacja amplitudy, segmentacja, okienkowanie, ekstrakcja cech. Ostatnim etapem jest identyfikacja (klasa „Klasyfikacja”). W identyfikacji stosowany jest: zmodyfikowany klasyfikator NM lub klasyfikator oparty na słowach lub klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów. Następnie wyniki rozpoznawania sygnałów akustycznych zostają zapisane w pliku. Odpowiedni komunikat informuje o uzyskaniu wyników rozpoznawania lub o błędach, które wystąpiły podczas przetwarzania danych. Diagram sekwencji procesu identyfikacji został przedstawiony na rysunku 3.11.

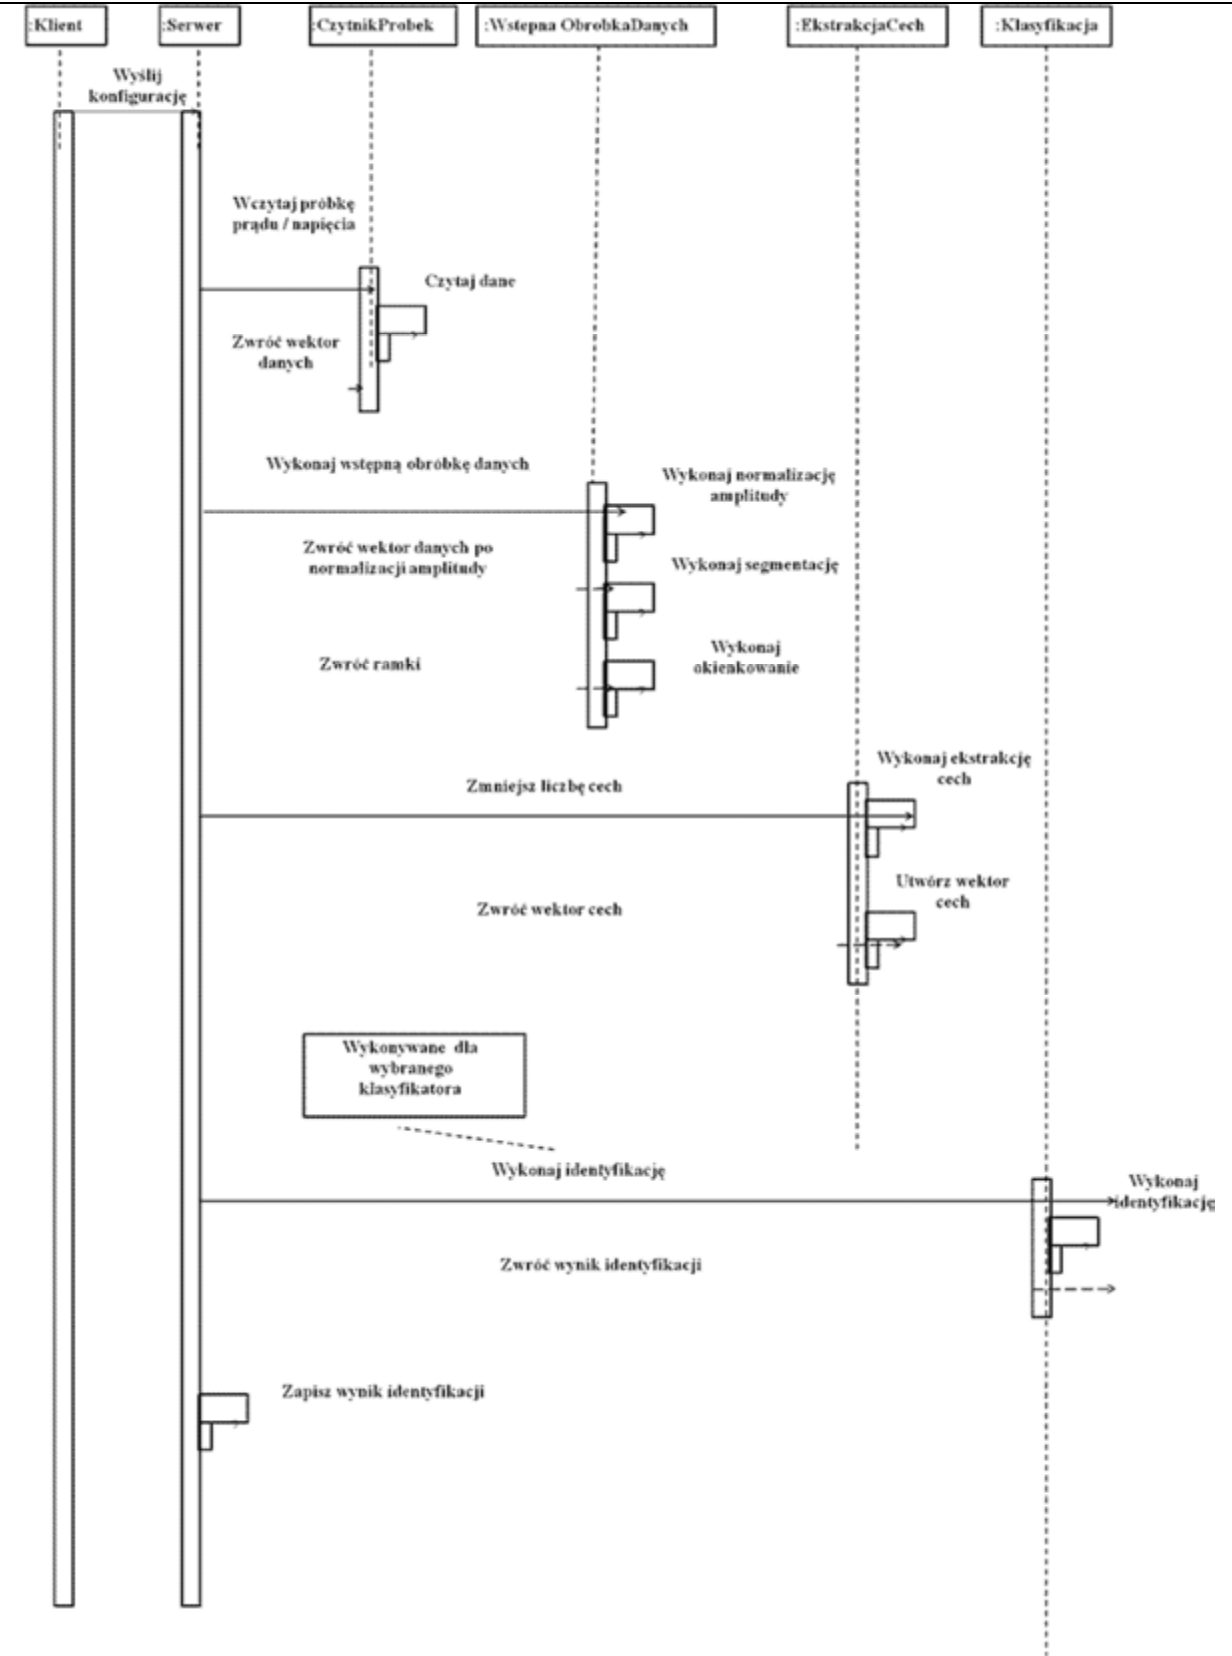
Rys. 3.8. Diagram sekwencji procesu tworzenia wzorców do rozpoznawania

3.4.6. Diagram sekwencji procesu identyfikacji

Po prawidłowym wykonaniu procesu tworzenia wzorców do rozpoznawania, należy wykonać proces identyfikacji. Kolejno wykonywane są: utworzenie konfiguracji procesu identyfikacji, wczytywanie próbki prądu/napięcia, normalizacja amplitudy, segmentacja, okienkowanie, ekstrakcja cech. Ostatnim etapem jest identyfikacja (klasa „Klasyfikacja”). W identyfikacji stosowany jest: zmodyfikowany klasyfikator NM lub klasyfikator oparty na słowach lub klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów. Następnie wyniki rozpoznawania sygnałów prądowych i napięciowych zostają zapisane w pliku. Odpowiedni komunikat informuje o uzyskaniu wyników rozpoznawania lub o błędach, które wystąpiły podczas przetwarzania danych. Diagram sekwencji procesu identyfikacji został przedstawiony na rysunku 3.9.



Rys. 3.11. Diagram sekwencji procesu identyfikacji



Rys. 3.9. Diagram sekwencji procesu identyfikacji

3.5. System automatycznego rozpoznawania prądu

System automatycznego rozpoznawania prądu (SARP) rejestruje i przetwarza sygnał prądu. Struktura budowy SARP jest bardzo podobna do SARSA. SARP wykorzystuje następujące urządzenia: monitor, klawiaturę, komputer, urządzenia rejestrujące prąd twornika lub wzbudzenia (karta pomiarowa mierząca prąd, filtr antyaliasingowy oraz przetworniki). SARP wykorzystuje bazę danych prądów. Baza ta składa się ze zbiorów uczących i zbiorów testowych. Zbiory te zawierają zarejestrowane prądy twornika i wzbudzenia maszyn elektrycznych podczas różnych stanów pracy (stanu bez uszkodzeń i stanów przedawaryjnych): maszyny synchronicznej bez uszkodzeń, maszyny synchronicznej ze zwartymi zezwojami stojana, maszyny synchronicznej z jedną przerwą w obwodzie stojana, maszyny synchronicznej z trzema przerwami w obwodzie stojana, maszyny prądu stałego bez uszkodzeń oraz maszyny prądu stałego ze zwartymi zezwojami wirnika. Charakterystyczne częstotliwości prądu mogą wystąpić w różnych sygnałach prądu w zależności od rodzaju maszyny, stanu przedawaryjnego i liczby obrotów. W przypadku rozpatrywanych stanów przedawaryjnych dla maszyny synchronicznej i prądu stałego należy badać prądy wzbudzenia i twornika. Algorytmy używane przez SARP są takie same jak dla SARSA. Stąd wynika, że rozpoznawanie sygnału prądu odbywa się w taki sam sposób jak rozpoznawanie sygnału akustycznego.

3.6. Podsumowanie

W rozdziale trzecim opisano projekt stanowiska diagnostycznego do badania sygnałów akustycznych maszyn elektrycznych. Omówiono warunki zastosowania stanowiska diagnostycznego do badania sygnałów akustycznych (zobacz podrozdział 3.1). Opisano wyposażenie techniczne i informatyczne stanowiska laboratoryjnego (zobacz podrozdział 3.2).

Kolejno omówiono sposób łączenia sprzętu i oprogramowania, potrzebnego do właściwego dobierania metod rozpoznawania sygnału akustycznego dla różnych stanów przedawaryjnych maszyn elektrycznych (zobacz podrozdziały 3.3, 3.4). Następnie omówiono system automatycznego rozpoznawania prądu, który będzie używany do weryfikacji wyników rozpoznawania sygnałów akustycznych (zobacz podrozdział 3.5). Podczas użycia tego stanowiska badane mogą być metody wstępnej obróbki danych, ekstrakcji cech i klasyfikacji.

3.5. Systemy automatycznego rozpoznawania prądu i napięcia

Systemy automatycznego rozpoznawania prądu (SARP) i napięcia (SARN) rejestrują i przetwarzają sygnały prądu i napięcia. Struktura budowy SARP i SARN jest bardzo podobna do SARSP i SARSN. SARP i SARN wykorzystują następujące urządzenia: monitor, klawiaturę, komputer, urządzenia rejestrujące prąd i napięcie obwodów twornika oraz wzbudzenia (karta pomiarowa mierząca prąd i napięcie, filtr antyaliasingowy oraz przetworniki). SARP wykorzystuje bazę danych prądów, SARN bazę danych napięć. Bazy te składają się ze zbiorów uczących i zbiorów testowych. Zbiory te zawierają zarejestrowane prądy i napięcia obwodów wzbudzenia oraz twornika maszyn elektrycznych podczas różnych stanów pracy (stanu bez uszkodzeń i stanów przedawaryjnych): maszyny indukcyjnej bez uszkodzeń, maszyny indukcyjnej z uszkodzonym pierścieniem klatki, maszyny indukcyjnej z uszkodzonym 1 prętami klatki, maszyny indukcyjnej z uszkodzonymi 2 prętami klatki, maszyny prądu stałego bez uszkodzeń, maszyny prądu stałego z przerwą uzwojenia wirnika, maszyny prądu stałego ze zwartymi trzema zezwojami wirnika, maszyny prądu stałego ze zwartymi sześcioma zezwojami wirnika. Charakterystyczne częstotliwości prądu i napięcia mogą wystąpić w różnych sygnałach prądu i napięcia w zależności od rodzaju maszyny, stanu przedawaryjnego i liczby obrotów. W przypadku rozpatrywanych stanów przedawaryjnych dla maszyny indukcyjnej i prądu stałego należy badać prądy i napięcia obwodów wzbudzenia i twornika. Algorytmy używane przez SARP i SARN są takie same jak dla SARSP i SARSN. Stąd wynika, że rozpoznawanie sygnałów prądowych i napięciowych odbywa się w taki sam sposób jak rozpoznawanie sygnału prądowego.

3.6. Podsumowanie

W rozdziale trzecim opisano projekt stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych maszyn elektrycznych. Omówiono warunki zastosowania tego stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych. Opisano wyposażenie techniczne i informatyczne stanowiska laboratoryjnego.

Kolejno omówiono sposób łączenia sprzętu i oprogramowania, potrzebnego do właściwego dobierania metod rozpoznawania sygnału prądowego/napięciowego dla różnych stanów przedawaryjnych maszyn elektrycznych. Podczas użycia tego stanowiska badane mogą być metody wstępnej obróbki danych, ekstrakcji cech i klasyfikacji.

4. BADANIA SYGNAŁÓW AKUSTYCZNYCH MASZYN ELEKTRYCZNYCH

Po zbudowaniu stanowiska (zobacz rozdział 3), przeprowadzono badania sygnałów, akustycznych zmierzające do skonfigurowania metod przetwarzania i analizy w celu uzyskania jak najlepszego wariantu metod rozpoznawania dla danej maszyny elektrycznej.

Badania miały również wykazać pośrednio, że stanowisko zostało zbudowane właściwie.

W tym celu został przygotowany plan eksperymentów (zobacz podrozdział 4.1).

[Por. Diagnostics of rotor damages of three-phase induction motors using acoustic signals and SMOFS-20-EXPANDED / Adam GŁOWACZ // Archives of Acoustics ; ISSN 0137-5075. — 2016 vol. 41 no. 3, s. 507–515. — Bibliogr. s. 513–515. — Publikacja dostępna online od: 2016-10-27. — tekst: <https://goo.gl/IMCn6I>

Diagnostics of DC and induction motors based on the analysis of acoustic signals / A. GŁOWACZ // Measurement Science Review [Dokument elektroniczny]. — Czasopismo Bibliografia Publikacji Pracowników AGH [12.08.2017; 10:54] [1/12] Adam Głowacz, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej elektroniczne : journal of the Institute of Measurement Science / Slovak Academy of Sciences ; ISSN 1335-8871. — 2014 vol. 14 no. 5, s. 257–262. — Bibliogr. s. 261–262 <http://www.measurement.sk/2014/Glowacz.pdf>

Recognition of acoustic signals of induction motors with the use of MSAF10 and bayes classifier / A. GŁOWACZ // Archives of Metallurgy and Materials / Polish Academy of Sciences. Committee of Metallurgy. Institute of Metallurgy and Materials Science ; ISSN 1733-3490. — 2016 vol. 61 no 1, s. 153–157. — Bibliogr. s. 156–157 http://www.imim.pl/files/archiwum/Vol1_2016/28.pdf

i inne]



Fig. 1. Analysed three phase induction motors and system of fault diagnostics.

4. BADANIA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH SILNIKÓW ELEKTRYCZNYCH

Po zbudowaniu stanowiska opisanego w poprzednim rozdziale, przeprowadzono badania sygnałów, prądowych i napięciowych zmierzające do skonfigurowania metod przetwarzania i analizy, w celu uzyskania jak najlepszego wariantu metod rozpoznawania dla danej maszyny elektrycznej. Badania miały również wykazać pośrednio, że stanowisko zostało zbudowane właściwie.

W tym celu został przygotowany plan eksperymentów z wykorzystaniem silników elektrycznych:

- indukcyjnych klatkowych prądu przemiennego (rysunek 4.1),
- prądu stałego obcowzbudnego (rysunek 4.2).



Rys. 4.1. Badane silniki prądu przemiennego indukcyjne




Fig.1. Investigated induction motors.



Fig. 1. Induction motors

[Dodatek C:]



Rys. C8. Badana maszyna prądu stałego obcowzbudna



Rys. 4.2. Badany silnik prądu stałego obcowzbudny

4.1. Plan eksperymentów

Plan ten zawierał następujące eksperymenty:

1. MS (Badanie Sygnałów Akustycznych Maszyny Synchronicznej) – eksperyment polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy (zobacz podrozdział 4.2). Badanie to miało potwierdzić skuteczność przyjętych metod rozpoznawania dla maszyny synchronicznej (zobacz Rys. 2.7). W tym celu badano różne warianty metod ekstrakcji cech i klasyfikacji w zależności od długości próbek dźwięku do rozpoznawania (zobacz podrozdział 2.2.1 i Rys. 2.7). Przeprowadzenie takich badań pozwalało zaobserwować zmiany skuteczności rozpoznawania (zobacz wzór 2.29) w zależności od długości próbek dźwięku dla danego wariantu metod rozpoznawania. Po przeprowadzeniu tak przygotowanego badania można stwierdzić, który wariant metod rozpoznawania jest najlepszy i jaka długość próbki jest właściwa do rozpoznawania. Określenie właściwej długości próbki było

4.1. Plan eksperymentów

Plan ten zawierał następujące eksperymenty:

1. SI (Badanie sygnałów prądowych i napięciowych silnika indukcyjnego) – eksperyment polegał na badaniu zbioru testowego zawierającego próbki prądu/napięcia silnika indukcyjnego w różnych stanach pracy. Badanie to miało potwierdzić skuteczność przyjętych metod rozpoznawania dla silnika indukcyjnego. W tym celu badano różne warianty metod ekstrakcji cech i klasyfikacji w zależności od długości próbek prądu/napięcia do rozpoznawania. Przeprowadzenie takich badań pozwalało zaobserwować zmiany skuteczności rozpoznawania w zależności od długości próbek prądu/napięcia dla danego wariantu metod rozpoznawania. Po przeprowadzeniu tak przygotowanego badania można stwierdzić, który wariant metod rozpoznawania jest najlepszy i jaka długość próbki jest właściwa do rozpoznawania. Określenie właściwej

istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyny synchronicznej.

Ponadto eksperyment potwierdzał, że w sygnale akustycznym zawarta jest informacja o stanie pracy maszyny. Eksperyment MS został podzielony na 3 eksperymenty: FFT-MS, LPC-MS, LPCC-MS.

☞ FFT-MS (Badanie Sygnałów Akustycznych metodą FFT dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą FFT i trzech klasyfikatorów. Ponadto dobierano w nim amplitudy dla częstotliwości, które są właściwe do rozpoznawania sygnałów akustycznych maszyny.

Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody FFT i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

Eksperyment FFT-MS podzielony został na 3 mniejsze eksperymenty: FFT-NM-MS, FFT-ONS-MS, FFT-SN-MS.

[przeniesienie:]

⌚ FFT-SN-MS (Badanie Sygnałów Akustycznych metodą FFT i klasyfikatora opartego na Sieci Neuronowej dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

⌚ FFT-NM-MS (Badanie Sygnałów Akustycznych metodą FFT i NM dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą FFT i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania

długości próbki było istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu silnika indukcyjnego.

Ponadto eksperyment potwierdzał, że w sygnale prądowym/napięciowym zawarta jest informacja o stanie pracy silnika. Eksperyment MS został podzielony na 3 eksperymenty: MSAF-SI, LPC-SI, LPCC-SI.

❖ MSAF-SI (Badanie sygnałów prądowych i napięciowych metodą MSAF dla silnika indukcyjnego SI) – w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą MSAF i czterech klasyfikatorów. Ponadto dobierano w nim amplitudy dla częstotliwości, które są właściwe do rozpoznawania sygnałów prądowych i napięciowych silnika. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody MSAF i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

Eksperyment MSAF-SI podzielony został na 4 mniejsze eksperymenty: MSAF-SN-SI, MSAF-NN-SI, MSAF-BA-SI, MSAF-LDA-SI.

➤ MSAF-SN-SI (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora opartego na Sieci Neuronowej dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

➤ MSAF-NN-SI (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora Najbliższego Sąsiada opartego na metodzie Najbliższego Sąsiada dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą MSAF i

sygnałów akustycznych. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod FFT i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

- ⌚ FFT-ONS-MS (Badanie Sygnałów Akustycznych metodą FFT i klasyfikatora Opartego Na Słowach dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą FFT i klasyfikatora opartego na słowach.

W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod FFT i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

- ∞ LPC-MS (Badanie Sygnałów Akustycznych metodą LPC dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą LPC i trzech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników filtra predykcji

klasyfikatora Najbliższego Sąsiada.

W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Najbliższego Sąsiada. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora opartego na Metodzie Najbliższego Sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

- MSAF-BA-SI (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora Bayesa dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą MSAF i klasyfikatora Bayesa. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Bayesa, Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

[powtórzenie z podmianą funkcji:]

- MSAF-LDA-SI (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą MSAF i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora LDA. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

[poniższych eksperymentów dot. LPC i LPCC w ogóle nie zamieszczono w pracy!]

- ❖ LPC-SI (Badanie sygnałów prądowych i napięciowych metodą LPC dla silnika indukcyjnego) – w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPC i czterech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników filtra predykcji

liniowej, która jest najlepsza do rozpoznawania sygnałów akustycznych maszyny. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

Eksperyment LPC-MS podzielony został na 3 mniejsze eksperymenty: LPCNM-MS, LPC-ONS-MS, LPC-SN-MS.

[przeniesienie:]

- ⌚ LPC-SN-MS (Badanie Sygnałów Akustycznych metodą LPC i klasyfikatora opartego na Sieci Neuronowej dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.
- ⌚ LPC-NM-MS (Badanie Sygnałów Akustycznych metodą LPC i NM dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.
- ⌚ LPC-ONS-MS (Badanie Sygnałów Akustycznych metodą LPC i klasyfikatora Opartego Na Słowach dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla

liniowej, która jest najlepsza do rozpoznawania sygnałów prądowych i napięciowych silnika. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPC i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

Eksperyment LPC-SI podzielony został na 4 mniejsze eksperymenty: LPC-SNSI, LPC-NN-SI, LPC-BA-SI, LPC-LDA-SI.

- LPC-SN-SI (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora opartego na Sieci Neuronowej dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.
- LPC-NN-SI (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora Najbliższego Sąsiada opartego na metodzie Najbliższego Sąsiada dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora Najbliższego Sąsiada. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Najbliższego Sąsiada. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na Metodzie Najbliższego Sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.
- LPC-BA-SI (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora Bayesa dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora Bayesa. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Bayesa. Wykonanie takiego badania

tego klasyfikatora. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

∞ LPCC-MS (Badanie Sygnałów Akustycznych metodą LPCC dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą LPCC i trzech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników cepstralnych, która jest najlepsza do rozpoznawania sygnałów akustycznych maszyny. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPCC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

Eksperyment LPCC-MS podzielony został na 3 mniejsze eksperymenty: LPCC-NM-MS, LPCC-ONSMS, LPCC-SN-MS.

[przeniesienie:]

- ⌚ LPCC-SN-MS (Badanie Sygnałów Akustycznych metodą LPCC i klasyfikatora opartego na Sieci Neuronowej dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów.
- ⌚ W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej

powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

[powtórzenie z podmianą funkcji:]

- LPC-LDA-SI (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora LDA. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

❖ LPCC-SI (Badanie sygnałów prądowych i napięciowych metodą LPCC dla silnika indukcyjnego) – w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPCC i czterech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników cepstralnych, która jest najlepsza do rozpoznawania sygnałów prądowych i napięciowych silnika. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPCC i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

Eksperyment LPCC-SI podzielony został na 4 mniejsze eksperymenty: LPCC-SN-SI, LPCC-NN-SI, LPCC-BA-SI, LPCC-LDA-SI.

- LPCC-SN-SI (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora opartego na Sieci Neuronowej dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić

sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

- ⌚ LPCC-NM-MS (Badanie Sygnałów Akustycznych metodą LPCC i NM dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą LPCC i zmodyfikowanego klasyfikatora NM.

W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

- ⌚ LPCC-ONS-MS (Badanie Sygnałów Akustycznych metodą LPCC i klasyfikatora Opartego Na Słowach dla Maszyny Synchronicznej) – w eksperymencie używano próbek dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

- LPCC-NN-SI (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora Najbliższego Sąsiada opartego na metodzie Najbliższego Sąsiada dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora Najbliższego Sąsiada.

W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Najbliższego Sąsiada. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC

i klasyfikatora opartego na Metodzie Najbliższego Sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

- LPCC-BA-SI (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora Bayesa dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora Bayesa.

W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Bayesa, Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

[powtórzenie z podmianą funkcji:]

- LPCC-LDA-SI (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA dla silnika indukcyjnego SI) - w eksperymencie używano próbek prądu/napięcia silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora LDA. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA w

2. MPS (Badanie Sygnałów Akustycznych **Maszyny** Prądu Stałego) – eksperyment polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy (zobacz podrozdział 4.6). Badanie to miało potwierdzić skuteczność przyjętych metod rozpoznawania dla maszyny prądu stałego (zobacz Rys. 2.7). W tym celu badano różne warianty metod ekstrakcji cech i klasyfikacji w zależności od długości próbek dźwięku do rozpoznawania. Przeprowadzenie takich badań pozwalało zaobserwować zmiany skuteczności rozpoznawania (zobacz wzór 2.29) w zależności od długości próbek dźwięku dla danego wariantu metod rozpoznawania. Po przeprowadzeniu tak przygotowanego badania można stwierdzić, który wariant metod rozpoznawania jest najlepszy i jaka długość próbki jest właściwa do rozpoznawania. Określenie właściwej długości próbki było istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyny prądu stałego. Ponadto eksperyment potwierdzał, że w sygnale akustycznym zawarta jest informacja o stanie pracy maszyny. Eksperyment MPS został podzielony na 3 eksperymenty:

☞ FFT-MPS (Badanie Sygnałów Akustycznych metodą FFT dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą FFT i trzech klasyfikatorów. Ponadto dobierano w nim amplitudy dla częstotliwości, które są właściwe do rozpoznawania sygnałów akustycznych maszyny. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody FFT i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

Eksperyment FFT-MPS podzielony został na 3 mniejsze eksperymenty: FFT-NM-MPS, FFT-ONS-MPS, FFT-**SN**-MPS.

[poniższy punkt przeniesiony do porównania:]

⌚ FFT-**SN**-MPS (Badanie Sygnałów Akustycznych metodą FFT i klasyfikatora opartego na Sieci Neuronowej dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów.

rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

2. SPS (Badanie sygnałów prądowych i napięciowych **silnika** prądu stałego) eksperyment polegał na badaniu zbioru testowego zawierającego próbki prądu/napięcia silnika prądu stałego w różnych stanach pracy. Badanie to miało potwierdzić skuteczność przyjętych metod rozpoznawania dla silnika prądu stałego. W tym celu badano różne warianty metod ekstrakcji cech i klasyfikacji w zależności od długości próbek prądu/napięcia do rozpoznawania. Przeprowadzenie takich badań pozwalało zaobserwować zmiany skuteczności rozpoznawania w zależności od długości próbek prądu/napięcia dla danego wariantu metod rozpoznawania. Po przeprowadzeniu tak przygotowanego badania można stwierdzić, który wariant metod rozpoznawania jest najlepszy i jaka długość próbki jest właściwa do rozpoznawania. Określenie właściwej długości próbki było istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu silnika prądu stałego. Ponadto eksperyment potwierdzał, że w sygnale prądowym/napięciowym zawarta jest informacja o stanie pracy silnika. Eksperyment SPS został podzielony na 3 eksperymenty: MSAF-SPS, LPC-SPS, LPCC-SPS.

❖ MSAF-SPS (Badanie sygnałów prądowych i napięciowych metodą MSAF dla silnika prądu stałego SPS) – w eksperymencie używano próbek prądu/napięcia maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą MSAF i czterech klasyfikatorów. Ponadto dobierano w nim amplitudy dla częstotliwości, które są właściwe do rozpoznawania sygnałów prądowych i napięciowych silnika. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody MSAF i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

Eksperyment MSAF-SPS podzielony został na 4 mniejsze eksperymenty:

MSAF-**SN**-SPS, MSAF-NN-SPS, MSAF-BA-SPS, MSAF-LDA-SPS.

➤ MSAF-**SN**-SPS (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora opartego na Sieci Neuronowej dla silnika prądu stałego SPS) – w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów.

W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych prądu stałego.

- ⌚ FFT-NM-MPS (Badanie Sygnałów Akustycznych metodą FFT i NM dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę FFT i zmodyfikowanego klasyfikatora NM.

W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod FFT i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

- ⌚ FFT-ONS-MPS (Badanie Sygnałów Akustycznych metodą FFT i klasyfikatora Opartego Na Słowach dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę FFT i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod FFT i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

- MSAF-NN-SPS (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora Najbliższego Sąsiada opartego na metodzie Najbliższego Sąsiada dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodę MSAF i klasyfikatora Najbliższego Sąsiada.

W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Najbliższego Sąsiada. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora opartego na Metodzie Najbliższego Sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

- MSAF-BA-SPS (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora Bayesa dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodę MSAF i klasyfikatora Bayesa.

W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Bayesa. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

[powtórzenie:]

- MSAF-LDA-SPS (Badanie sygnałów prądowych i napięciowych metodą MSAF i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodę MSAF i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora LDA. Wykonanie takiego

☞ LPC-MPS (Badanie Sygnałów Akustycznych metodą LPC dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i trzech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników filtra predykcji liniowej, która jest najlepsza do rozpoznawania sygnałów akustycznych maszyny. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

Eksperyment LPC-MPS podzielony został na 3 mniejsze eksperymenty: LPC-NM-MPS, LPCONS-MPS, LPC-SN-MPS.

[poniższy punkt przeniesiony do porównania:]

⌚ LPC-SN-MPS (Badanie Sygnałów Akustycznych metodą LPC i klasyfikatora opartego na Sieci Neuronowej dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

⌚ LPC-NM-MPS (Badanie Sygnałów Akustycznych metodą LPC i NM dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i zmodyfikowanego klasyfikatora NM.

badania powinno potwierdzić

przydatność lub nieprzydatność wariantu metod MSAF

i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA

w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

[poniższych eksperymentów dot. LPC i LPCC w ogóle nie zamieszczono w pracy!]

❖ LPC-SPS (Badanie sygnałów prądowych i napięciowych metodą LPC dla silnika prądu stałego) – w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i czterech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników filtra predykcji liniowej, która jest najlepsza do rozpoznawania sygnałów prądowych i napięciowych silnika. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPC i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

Eksperyment LPC-SPS podzielony został na 4 mniejsze eksperymenty: LPCSN-SPS, LPC-NN-SPS, LPC-BA-SPS, LPC-LDA-SPS.

➤ LPC-SN-SPS (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora opartego na Sieci Neuronowej dla silnika prądu stałego SPS – w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

➤ LPC-NN-SPS (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora Najbliższego Sąsiada opartego na metodzie Najbliższego Sąsiada dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora Najbliższego Sąsiada.

W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

- ⌚ LPC-ONS-MPS (Badanie Sygnałów Akustycznych metodą LPC i klasyfikatora Opartego Na Słowach dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

- ∞ LPCC-MPS (Badanie Sygnałów Akustycznych metodą LPCC dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i trzech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników cepstralnych, która jest najlepsza do rozpoznawania sygnałów akustycznych maszyny. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPCC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

- W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Najbliższego Sąsiada. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na Metodzie Najbliższego Sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

- LPC-BA-SPS (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora Bayesa dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora Bayesa.

W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Bayesa, Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod MSAF i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

[powtórzenie z podmianą funkcji:]

- LPC-LDA-SPS (Badanie sygnałów prądowych i napięciowych metodą LPC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora LDA. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

- ❖ LPCC-SPS (Badanie sygnałów prądowych i napięciowych metodą LPCC dla silnika prądu stałego) – w eksperymencie używano próbek prądu/napięcia silnika w różnych stanach pracy, o różnych długościach, metodą LPCC i czterech klasyfikatorów. Ponadto dobierano w nim liczbę współczynników cepstralnych, która jest najlepsza do rozpoznawania sygnałów prądowych i napięciowych silnika. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność metody LPCC i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu

Eksperyment **LPCC-MPS** podzielony został na 3 mniejsze eksperymenty: LPCC-NM-MPS, LPCC-ONSMPS, LPCC-**SN**-MPS.

[przeniesienie do porównania:]

⌚ LPCC-SN-MPS (Badanie Sygnałów Akustycznych metodą LPCC i klasyfikatora opartego na Sieci Neuronowej dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

⌚ LPCC-NM-MPS (Badanie Sygnałów Akustycznych metodą LPCC i NM dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

⌚ LPCC-ONS-MPS (Badanie Sygnałów Akustycznych metodą LPCC i klasyfikatora Opartego Na Słowach dla Maszyny Prądu Stałego) – w eksperymencie używano próbek dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

stałego.

Eksperyment **LPCCSPS** podzielony został na 4 mniejsze eksperymenty: LPCC-**SN**-SPS, LPCC-NNSPS, LPCC-BA-SPS, LPCC-LDA-SPS.

➤ LPCC-SN-SPS (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora opartego na Sieci Neuronowej dla silnika prądu stałego SPS – w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

➤ LPCC-NN-SPS (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora Najbliższego Sąsiada opartego na metodzie Najbliższego Sąsiada dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora Najbliższego Sąsiada. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Najbliższego Sąsiada. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na Metodzie Najbliższego Sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

➤ LPCC-BA-SPS (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora Bayesa dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodą LPCC i klasyfikatora Bayesa. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora Bayesa, Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora Bayesa w rozpoznawaniu sygnałów

3. ZNWMR (Znalezienie Najlepszego Wariantu Metod Rozpoznawania) – zadaniem eksperymentu było znalezienie najlepszego wariantu metod rozpoznawania, który będzie można zastosować w małym urządzeniu monitorującym stan maszyny. W tym celu należało porównać: średnią skuteczność rozpoznawania sygnału akustycznego (zobacz wzór 2.30) dla wszystkich rozpatrywanych wariantów i maszyn elektrycznych.
4. WNWMM (Weryfikacja Najlepszego Wariantu Metod Rozpoznawania programem Matlab) – zadaniem eksperymentu była weryfikacja najlepszego wariantu metod rozpoznawania sygnału akustycznego programem Matlab. Badanie takie miało potwierdzić, że wyniki uzyskane za pomocą SARSA i programu Matlab są takie same.
5. PWMS (Weryfikacja Technika Badania Prądów Wzbudzenia Maszyny Synchronicznej) – zadaniem eksperymentu była weryfikacja metod rozpoznawania sygnału akustycznego za pomocą techniki badania prądów wzbudzenia maszyny synchronicznej. Badanie takie pozwalało stwierdzić, czy metody rozpoznawania sygnałów akustycznych rozpoznają właściwe stany pracy maszyny synchronicznej.
6. PTMPS (Weryfikacja Technika Badania Prądów Twornika Maszyny Prądu Stałego) – zadaniem eksperymentu była weryfikacja metod rozpoznawania sygnału akustycznego za pomocą techniki badania prądów twornika maszyny prądu stałego. W przypadku maszyny prądu stałego rozpoznawanie prądów twornika było alternatywnym podejściem do badania prądów

prądowych i napięciowych silnika prądu stałego.

[powtórzenie z podmianą funkcji:]

LPCC-LDA-SPS (Badanie sygnałów prądowych i napięciowych metodą LPCC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA dla silnika prądu stałego SPS) - w eksperymencie używano próbek prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPCC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA. W badaniu należało dobrać właściwie liczbę wejść do klasyfikatora LDA. Wykonanie takiego badania powinno potwierdzić przydatność lub nieprzydatność wariantu metod LPCC i klasyfikatora opartego na Liniowej Analizie Dyskryminacyjnej LDA w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

[brak]

[brak weryfikacji]

[brak weryfikacji]

[brak weryfikacji]

wzbudzenia. Badanie takie pozwalało stwierdzić, czy metody rozpoznawania sygnałów akustycznych rozpoznają właściwe stany pracy maszyny prądu stałego.

W kolejnych podrozdziałach przeprowadzono badania sygnałów akustycznych. Na ich podstawie zaproponowano końcowe parametry stosowanych algorytmów. Technika (wariant metod) rozpoznawania, dla której uzyskano najwyższą średnią skuteczność rozpoznawania, została zweryfikowana programem Matlab. Kolejno wykonano weryfikację techniką badania prądów wzbudzenia i twornika maszyn elektrycznych.

4.2. Eksperyment MS


Eksperyment MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy. W badaniach użyto czterech różnych sygnałów akustycznych: maszyny synchronicznej bez uszkodzeń, maszyny synchronicznej ze zwartymi zewojami stojana, maszyny synchronicznej z jedną przerwą w obwodzie stojana oraz maszyny synchronicznej z trzema przerwami w obwodzie stojana. Skuteczność rozpoznawania sygnału akustycznego określona została wzorem (2.29).

[fragment przeniesiony na koniec podrozdziału]


4.2. Eksperyment SI (silniki indukcyjne klatkowe)

Obiektem badań były cztery silniki indukcyjne klatkowe (rysunek 4.1), które umożliwiły realizację czterech stanów silnika: bez uszkodzeń, uszkodzenia pierścienia klatki, uszkodzenia jednego pręta klatki, uszkodzenia dwóch prętów klatki. Silniki miały następujące dane znamionowe: $P_N = 0,55$ kW, $U_N = 220/380$ V, $I_N = 2,52/1,47$ A, $\cos(\varphi_N) = 0,77$, $n_N = 1400$ obr/min.


Obciążeniem badanego silnika był drugi silnik na wspólnym wale, w którym połączono trzy uzwojenia i wymuszono w nich stały prąd (rysunek 4.3). Pomiary wykonano w warunkach laboratoryjnych kartą pomiarową z częstotliwością próbkowania 20 kHz i czasem rejestracji 10 s. Rejestrowano następujące wielkości: napięcie między fazami L1 i L2, napięcie między fazami L3 i L2, prąd fazy L1, prąd fazy L2, prąd fazy L3. Wykonano wielowariantowe rejestracje obciążonego silnika w stanach: bez uszkodzeń, uszkodzenia pierścienia zwierającego klatki, uszkodzenia jednego pręta klatki, uszkodzenia dwóch prętów klatki, dla prądu obciążenia: 5 A, 4 A, 3 A, 1 A, 0 A, dla procesu uczenia i procesu identyfikacji. Spośród zarejestrowanych wielkości jako sygnał diagnostyczny przyjęto prąd stojana fazy L1 i napięcie przewodowe między fazami L1 i L2 (rysunki 4.4 - 4.11).




Rys. 4.3. Obwody elektryczne silników indukcyjnych klatkowych




Rys. 4.4. Prąd stojana fazy L1 w stanie uszkodzenia dwóch prętów klatki




Rys. 4.5. Prąd stojana fazy L1 w stanie uszkodzenia jednego pręta klatki




Rys. 4.6. Prąd stojana fazy L1 w stanie uszkodzenia pierścienia klatki




Rys. 4.7. Prąd stojana fazy L1 w stanie bez uszkodzeń




Rys. 4.8. Napięcie przewodowe stojana między fazami L1 i L2 w stanie uszkodzenia dwóch prętów klatki



Rys. 4.9. Napięcie przewodowe stojana między fazami L1 i L2 w stanie uszkodzenia jednego pręta klatki



Rys. 4.10. Napięcie przewodowe stojana między fazami L1 i L2 w stanie uszkodzenia pierścienia klatki



Rys. 4.11. Napięcie przewodowe stojana między fazami L1 i L2 w stanie bez uszkodzeń

Zarejestrowano sygnały diagnostyczne: prąd stojana fazy L1 i napięcie przewodowe między fazami L1 i L2. Zbiór testowy zawierał próbki prądu i napięcia o długości od 1 do 5 sekund ponieważ istotnym było zbadanie skuteczności rozpoznawania sygnału prądowego/napięciowego w zależności od długości próbki prądu/napięcia. Określenie właściwej długości próbki było potrzebne ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyny indukcyjnej.

Ponadto eksperyment miał potwierdzić, że w sygnale prądu/napięcia zawarta jest informacja o stanie maszyny indukcyjnej. W tym celu eksperyment SI został podzielony na 3 eksperymenty: MSAF-SI, LPC-SI, LPCC-SI. W eksperymentach LPC-SI, LPCC-SI uzyskano gorsze wyniki, niż w MSAF-SI.

4.3. Eksperyment MSAF-SI

Eksperyment MSAF-SI polegał na badaniu zbioru testowego zawierającego próbki prądu/napięcia maszyny indukcyjnej w różnych stanach pracy, o różnych długościach, za pomocą metody MSAF i czterech klasyfikatorów (sieci neuronowej, NN, Bayesa i LDA).


Wykonano analizę **FFT** sygnałów diagnostycznych. Wyniki analizy FFT prądu stojana fazy L1

Ponadto eksperyment miał potwierdzić, że w sygnale akustycznym zawarta jest informacja o stanie pracy maszyny synchronicznej. W tym celu eksperyment MS został podzielony na 3 eksperymenty: FFT-MS, LPC-MS, LPCC-MS.

4.3. Eksperyment FFT-MS


Eksperyment FFT-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę FFT i trzech klasyfikatorów. W przypadku maszyny synchronicznej pracującej z prędkością wynoszącą 1500 obr/min w widmach prądów

twornika oraz wzbudzenia pojawiały się amplitudy o częstotliwościach, które są wielokrotnościami częstotliwości $k_c = 25$ Hz (zobacz wzór 2.3) [48]. Z tego powodu dla sygnałów akustycznych maszyny synchronicznej badano amplitudy o częstotliwościach, które były wielokrotnościami częstotliwości 25 Hz. Metoda wybierania amplitud dla częstotliwości wskazała, że najlepiej rozróżnialne amplitudy występują dla częstotliwości 75, 100, 125, 150, 175, 250 Hz (zobacz wzory 2.3, 2.5, 2.6, 2.7). Widmo częstotliwości sygnału akustycznego maszyny synchronicznej dla czterech różnych stanów pracy, przy zastosowaniu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz i FFT, zostało przedstawione na rysunku 4.1. Na podstawie tego rysunku można wywnioskować, że różnice między poszczególnymi amplitudami dla częstotliwości są duże.




Rys. 4.1. Widmo częstotliwości sygnału akustycznego maszyny synchronicznej dla czterech różnych stanów pracy przy zastosowaniu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz i FFT


i napięcia przewodowego między fazami L1 i L2, dla prądu obciążenia 5 A, przedstawiono na rysunkach 4.12 - 4.19.



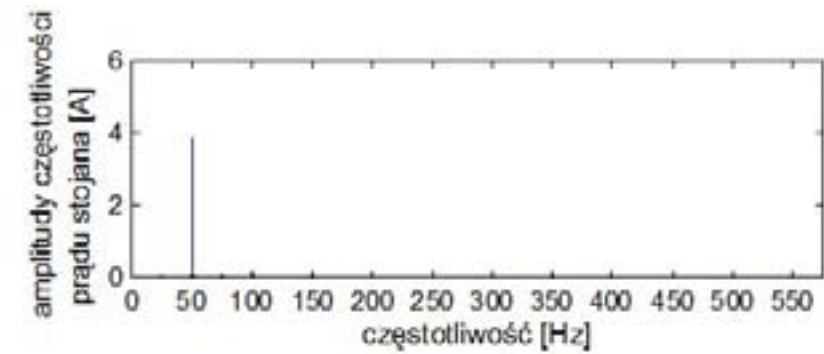
Rys. 4.12. Widmo częstotliwości prądu stojana fazy L1 w stanie uszkodzenia dwóch prętów klatki




Rys. 4.13. Widmo częstotliwości prądu stojana fazy L1 w stanie uszkodzenia jednego pręta klatki




Rys. 4.14. Widmo częstotliwości prądu stojana fazy L1 w stanie uszkodzenia pierścienia klatki



Rys. 4.15. Widmo częstotliwości prądu stojana fazy L1 w stanie bez uszkodzeń




Rys. 4.16. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie uszkodzenia dwóch prętów klatki




Rys. 4.17. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w

W celu potwierdzenia przydatności metody FFT i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej eksperyment FFT-MS podzielony został na 3 mniejsze eksperymenty: FFT-NM-MS, FFT-ONS-MS, FFT-SN-MS.

stanie uszkodzenia jednego pręta klatki



Rys. 4.18. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie uszkodzenia pierścienia klatki



Rys. 4.19. Widmo częstotliwości napięcia przewodowego stojana między fazami L1 i L2 w stanie bez uszkodzeń

Dla każdej długości próbki sygnału diagnostycznego określono zbiór najistotniejszych częstotliwości, dla których różnice odpowiadających sygnałów w dwóch stanach silnika są największe.

Metoda MSAF pozwoliła wyznaczyć najistotniejsze częstotliwości: 26Hz, 51Hz, 76 Hz dla prądu fazy L1 oraz częstotliwości: 49Hz, 50Hz, 52 Hz dla napięcia między fazami L1 i L2.

W procesie uczenia i identyfikacji zastosowano cztery klasyfikatory: sieci neuronowej, NN, Bayesa i LDA.

W procesach uczenia i identyfikacji utworzono wektory cech sygnału diagnostycznego dla częstotliwości należących do zbioru najistotniejszych częstotliwości. Składowymi wektorów cech były amplitudy dla częstotliwości prądu stojana fazy L1 i napięcia przewodowego stojana między fazami L1 i L2 w czterech stanach: bez uszkodzeń, uszkodzenia pierścienia zwierającego klatki,

[Fragment przeniesiony z rozdziału 2:]

Skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika) określona została następująco:

$$E = \frac{N_1}{N} \cdot 100\% \quad (2.29)$$

gdzie: E – skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika), N_1 – liczba poprawnie zidentyfikowanych próbek danej kategorii, N – liczba wszystkich próbek danej kategorii biorących udział w procesie identyfikacji.

Wzór 2.29 będzie używany do obliczeń dotyczących sygnałów akustycznych (zobacz podrozdziały 4.1-4.10), sygnałów prądu wzbudzenia (zobacz podrozdział 4.11), sygnałów prądu twornika (zobacz podrozdział 4.12). Jeżeli N_1 i N będą oznaczać liczbę próbek dźwięku to E będzie skutecznością rozpoznawania sygnału akustycznego. Jeżeli N_1 i N będą oznaczać liczbę próbek prądu wzbudzenia (twornika) to E będzie skutecznością rozpoznawania sygnału prądu wzbudzenia (twornika).

Średnia skuteczność rozpoznawania sygnału akustycznego (maszyny synchronicznej, prądu stałego) określona została następująco:

$$E_{sr} = \frac{\sum_{n=1}^5 E_n}{5} \quad (2.30)$$

gdzie: E_{sr} – średnia skuteczność rozpoznawania sygnału akustycznego (maszyny synchronicznej, prądu stałego), E_n – skuteczność rozpoznawania sygnału akustycznego dla n sekundowych próbek dźwięku stanu pracy maszyny, $n \in \{1,2,3,4,5\}$.

W przypadku maszyny synchronicznej badane będą cztery różne stany pracy (zobacz podrozdział 4.2).

Zatem do obliczenia E_n przyjęto wzór.

$$E_n = \frac{E_{nb} + E_{nz} + E_{n1} + E_{n3}}{4} \quad (2.31)$$

gdzie: E_n – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej, E_{nb} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej bez uszkodzeń,

E_{nz} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej ze zwartymi zewzwojami stojana, E_{n1} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej z jedną przerwą w obwodzie stojana, E_{n3} –

uszkodzenia jednego pręta klatki, uszkodzenia dwóch prętów klatki.

Skuteczność rozpoznawania sygnału silnika została zdefiniowana:

$$E_n = \frac{N_{np}}{N_{nw}} \cdot 100\% \quad (4.1)$$

gdzie: E_n – skuteczność rozpoznawania sygnału silnika dla n -sekundowych próbek sygnału, N_{np} , N_{nw} – liczby pomyślnych rozpoznań i wszystkich rozpoznań sygnału dla n -sekundowych próbek sygnału silnika w stanach: bez uszkodzeń, uszkodzenia pierścienia zwierającego klatki, uszkodzenia jednego pręta klatki, uszkodzenia dwóch prętów klatki.

Średnią skuteczność rozpoznawania sygnału silnika zdefiniowano:

$$E_{ns} = \frac{E_{nb} + E_{np} + E_{np1} + E_{np2}}{4} \quad (4.2)$$

gdzie: E_{ns} – średnia skuteczność rozpoznawania sygnału silnika dla n -sekundowych próbek sygnału, E_{nb} , E_{np} , E_{np1} , E_{np2} – skuteczności rozpoznawania sygnału silnika dla n -sekundowych próbek sygnału odpowiednio w stanach: bez uszkodzeń, uszkodzenia pierścienia klatki, uszkodzenia jednego pręta klatki, uszkodzenia dwóch prętów klatki.

skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej z trzema przerwami w obwodzie stojana.

W przypadku maszyny prądu stałego badane będą dwa różne stany pracy (zobacz podrozdział 4.6). Zatem do obliczenia E_n przyjęto wzór.

$$E_n = \frac{E_{nb} + E_{nz}}{2} \quad (2.32)$$

gdzie: E_n – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego, E_{nb} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego bez uszkodzeń, E_{nz} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego ze zwartymi zewzwojami wirnika.

[koniec fragmentu]

[fragment przeniesiony z początku podrozdziału:]

Proces tworzenia wzorców do rozpoznawania został przeprowadzony na podstawie zbioru uczącego zawierającego 88 próbek dźwięku. Aby zmniejszyć liczbę możliwych przypadków obliczeniowych, zbiór uczący zawierał tylko pięciosekundowe próbki dźwięku. W procesie identyfikacji wykorzystano zbiory testowe zawierające: 96 pięciosekundowych próbek dźwięku, 120 czterosekundowych próbek dźwięku, 160 trzysiekundowych próbek dźwięku, 240 dwusekundowych próbek dźwięku i 480 jednosekundowych próbek dźwięku. Zbiór testowy zawierał próbki dźwięku o długości od 1 do 5 sekund, ponieważ istotnym było zbadanie skuteczności rozpoznawania sygnału akustycznego w zależności od długości próbki dźwięku. Określenie właściwej długości próbki było istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyny synchronicznej.

Ponadto eksperyment miał potwierdzić, że w sygnale akustycznym zawarta jest informacja o stanie pracy maszyny synchronicznej. W tym celu eksperyment MS został podzielony na 3 eksperymenty: FFT-MS, LPC-MS, LPCC-MS.

Zastosowane metody analizy i rozpoznawania pozwalają określić stan silnika indukcyjnego klatkowego, tj. stan bez uszkodzeń, stan z uszkodzonym pierścieniem klatki, stan z jednym uszkodzonym prętem klatki, stan z dwoma uszkodzonymi prętami klatki, na podstawie próbek sygnału diagnostycznego prądu stojana fazy L1 i napięcia przewodowego stojana między fazami L1 i L2, dla prądu obciążenia 5 A.


Proces tworzenia wzorców do rozpoznawania został przeprowadzony na podstawie zbioru uczącego zawierającego 8 próbek sygnału. Aby zmniejszyć liczbę możliwych przypadków obliczeniowych, zbiór uczący zawierał tylko jednosekundowe próbki sygnału. W procesie identyfikacji wykorzystano zbiory testowe zawierające: 32 jednosekundowych próbek sygnału, 20 dwusekundowych próbek sygnału, 12 trzysiekundowych próbek sygnału, 8 czterosekundowych próbek sygnału i 8 pięciosekundowych próbek sygnału.

W celu potwierdzenia przydatności metody MSAF i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych maszyny indukcyjnej eksperyment MSAF-SI podzielony został na 4 mniejsze eksperymenty: MSAF-SN-SI, MSAF-NN-SI, MSAF-BA-SI, MSAF-LDA-SI.

[przeniesienie 4.3.3:]

4.3.3. Eksperyment FFT-SN-MS

Eksperyment FFT-SN-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodą FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech (zobacz podrozdział 4.3), liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 7 (6+1). Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej została przedstawiona na rysunku 4.4.



Rys. 4.4. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej

[por. tab. 4.1 – 4.10 w dodatku B]

Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 57,5% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.10 załączono 20 wyników rozpoznawania tychże sygnałów akustycznych. Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 83,37%.

Wykonanie takiego badania potwierdziło przydatność wariantu metod FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych

4.3.1. Eksperyment MSAF-SN-SI

Eksperyment MSAF-SN-SI polegał na badaniu zbioru testowego zawierającego próbki prądów i napięć silnika indukcyjnego w różnych stanach pracy, o różnych długościach, metodą MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech, liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 4 (3+1).

Wyniki rozpoznawania sygnałów silnika indukcyjnego klatkowego przy użyciu klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów dla próbek jednosekundowych przedstawiono w tabelach 4.1 i 4.2.

Tab. 4.1. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	87,5
z uszkodzonym pierścieniem	100
z uszkodzonym jednym prętym	100
z uszkodzonymi dwoma prętami	100

Tab. 4.2. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z uszkodzonym pierścieniem	62,5
z uszkodzonym jednym prętym	62,5
z uszkodzonymi dwoma prętami	100

Przy użyciu klasyfikatora opartego na sieci neuronowej skuteczność rozpoznawania sygnałów prądowych wynosiła od 66,6% do 100%, a napięciowych od 50% do 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.25 i 4.29).


Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu

maszyny synchronicznej.

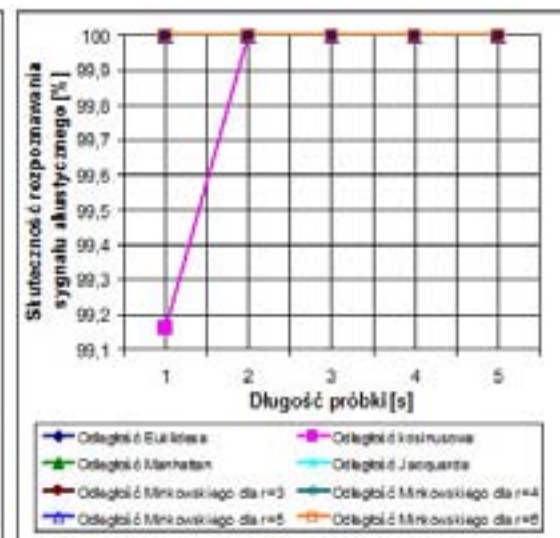
4.3.1. Eksperyment FFT-NM-MS

Eksperyment FFT-NM-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę FFT i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych. Pierwszymi badaniami jakie przeprowadzono były badania FFT i zmodyfikowanego klasyfikatora NM z metrykami: Euklidesa, Manhattan, Jacquarda, kosinusową, Minkowskiego dla parametrów $r = 3, 4, 5, 6$. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej została pokazana na rysunkach 4.2a, 4.2b, 4.2c, 4.2d. Przy użyciu metryki Manhattan, Euklidesa, Minkowskiego z parametrami $r = 3, 4, 5, 6$ skuteczność rozpoznawania sygnału akustycznego dla próbek dźwięku o długości od 1 do 5 sekund wynosiła od 99,16% do 100%. W tabelach 4.1–4.8 załączono 160 wyników rozpoznawania sygnałów akustycznych dla próbek dźwięku o długości od 1 do 5 sekund.

a)



b)



c)

d)

sygnałów prądowych i napięciowych silnika indukcyjnego.

4.3.2. Eksperyment MSAF-NN-SI


Wyniki rozpoznawania sygnałów silnika indukcyjnego klatkowego przy użyciu klasyfikatora opartego na metodzie najbliższego sąsiada dla próbek jednosekundowych przedstawiono w tabelach 4.3 i 4.4.

Tab. 4.3. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z uszkodzonym pierścieniem	100
z uszkodzonym jednym prętem	100
z uszkodzonymi dwoma prętami	100

Tab. 4.4. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	62,5
z uszkodzonym pierścieniem	100
z uszkodzonym jednym prętem	100
z uszkodzonymi dwoma prętami	62,5



Rys. 4.2. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami stojana, **c)** z jedną przerwą w obwodzie stojana, **d)** z trzema przerwami w obwodzie stojana

[por. tab. 4.1 – 4.10 w dodatku B]

W celu określenia najlepszej metryki dla zmodyfikowanego klasyfikatora NM zastosowano wzór 2.30. Najlepsza średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 99,58%. Została ona otrzymana dla metryki Manhattan, Euklidesa i Minkowskiego.

Wykonanie takiego badania potwierdziło przydatność wariantu metod FFT i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

4.3.2. Eksperyment FFT-ONS-MS

Eksperyment FFT-ONS-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę FFT i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Najlepsze wyniki rozpoznawania sygnałów akustycznych dla tego klasyfikatora i FFT otrzymano, gdy wartość parametru k wynosiła 0,007. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej została przedstawiona na rysunku 4.3.


Przy użyciu klasyfikatora opartego na metodzie najbliższego sąsiada skuteczność rozpoznawania sygnałów prądowych wynosiła 100%, a napięciowych od 50% do 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.26 i 4.30).

Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora opartego na metodzie najbliższego sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

4.3.3. Eksperyment MSAF-BA-SI

Wyniki rozpoznawania sygnałów silnika indukcyjnego klatkowego przy użyciu klasyfikatora Bayesa dla próbek jednosekundowych przedstawiono w tabelach 4.5 i 4.6.

Tab. 4.5. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek



Rys. 4.3. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej

[por. tab. 4.1 – 4.10 w dodatku B]

Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 82,5% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabelach 4.9 załączono 20 wyników tego klasyfikatora. Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 98,29%.

Wykonanie takiego badania potwierdziło przydatność wariantu metod FFT i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

[por. tab. 4.1 – 4.10 w dodatku B]

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z uszkodzonym pierścieniem	100
z uszkodzonym jednym prętem	100
z uszkodzonymi dwoma prętami	100

Tab. 4.6. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z uszkodzonym pierścieniem	62,5
z uszkodzonym jednym prętem	62,5
z uszkodzonymi dwoma prętami	100

Przy użyciu klasyfikatora Bayesa skuteczność rozpoznawania sygnałów prądowych wynosiła 100%, a napięciowych od 50% do 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.27 i 4.31).

Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.

[powtórzenie z podmienioną funkcją:]

4.3.4. Eksperyment MSAF-LDA-SI

Wyniki rozpoznawania sygnałów silnika indukcyjnego klatkowego przy użyciu klasyfikatora LDA dla próbek jednosekundowych przedstawiono w tabelach 4.7 i 4.8.

Tab. 4.7. Wyniki rozpoznawania prądu i_{L1} pierwszej fazy stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z uszkodzonym pierścieniem	100
z uszkodzonym jednym prętem	100
z uszkodzonymi dwoma prętami	100

[Dodatek C:]

Maszyna prądu stałego obcowzbudna

Maszyna prądu stałego pracowała jako generator. Maszyna wytwarzała określony sygnał akustyczny przy pracy normalnej (bez uszkodzeń maszyny) i inny charakterystyczny sygnał akustyczny przy zwarcu zezwojów wirnika (3 zwarte zezwoje z 126 zezwojów). Zwarcie zostało zlokalizowane w obwodzie wirnika przy prądzie wzbudzenia generatora 0,22 A. Maszyna miała następujące parametry operacyjne: $P_N = 13 \text{ kW}$, $U_N = 75 \text{ V}$, $I_N = 200 \text{ A}$, $U_{fN} = 220 \text{ V}$, $I_{fN} = 4 \text{ A}$, $n_N = 700 \text{ obr/min}$, $R_{bz} = 7,7 \text{ m}\Omega$, gdzie: P_N – moc czynna na wirniku, U_N – napięcie znamionowe twornika, I_N – prąd znamionowy twornika, U_{fN} – napięcie znamionowe wzbudzenia, I_{fN} – prąd znamionowy wzbudzenia, n_N – ilość obrotów wirnika na minutę.

Tab. 4.8. Wyniki rozpoznawania napięcia przewodowego u_{L1L2} stojana silnika indukcyjnego klatkowego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z uszkodzonym pierścieniem	62,5
z uszkodzonym jednym prętem	62,5
z uszkodzonymi dwoma prętami	100

Przy użyciu klasyfikatora LDA skuteczność rozpoznawania sygnałów prądowych wynosiła 100%, a napięciowych od 50% do 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.28 i 4.32).

Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora LDA w rozpoznawaniu sygnałów prądowych i napięciowych silnika indukcyjnego.


4.4. Eksperyment SPS (silnik prądu stałego)

Obiektem badań był silnik obcowzbudny prądu stałego wykonany przez BOBRME KOMEL w Katowicach (rysunek 4.2), który umożliwiał realizację czterech stanów silnika: bez uszkodzeń, przerwy zezwojów wirnika, zwarcia trzech zezwojów wirnika oraz zwarcia sześciu zezwojów wirnika. Silnik miał następujące dane:


$$P_N = 13 \text{ kW}, U_N = 75 \text{ V}, I_N = 200 \text{ A}, U_{fN} = 220 \text{ V}, n_N = 700 \text{ obr/min}, p = 2, N_r = 42, K = 126.$$

Silnik posiadał uzwojenie pętlicowe proste w wirniku i był zasilany z generatora napięcia stałego. Obciążeniem silnika był generator napięcia stałego pracujący na zewnętrznej rezystancję. Pomiarów wykonano w warunkach laboratoryjnych kartą pomiarową z częstotliwością próbkowania 20 kHz i czasem rejestracji 10 s. Rejestrowano następujące wielkości: prędkość wirnika, napięcie twornika, prąd twornika, napięcie wzbudzenia, prąd wzbudzenia, prąd w zwartych zezwojach wirnika. Wykonano wielowariantowe rejestracje obciążonego silnika w stanach: bez uszkodzeń, przerwy zezwojów wirnika, zwarcia trzech zezwojów wirnika, zwarcia sześciu zezwojów wirnika, przerwy zezwojów wirnika i zwarcia trzech zezwojów wirnika, przerwy zezwojów wirnika i zwarcia sześciu zezwojów wirnika, dla prędkości wirnika: 700 obr/min, 600 obr/min, 500 obr/min, 400 obr/min, dla procesu uczenia i procesu identyfikacji. Spośród zarejestrowanych wielkości jako sygnały diagnostyczne wybrano: prąd wzbudzenia, prąd twornika, napięcie wzbudzenia i napięcie twornika


(rysunki
4.20 - 4.35).




Rys. 4.20. *Prąd wzbudzenia w stanie zwarcia sześciu zezwojów*







Rys. 4.21. *Prąd wzbudzenia w stanie zwarcia trzech zezwojów*




Rys. 4.22. *Prąd wzbudzenia w stanie przerwy jednego zezwoju*




Rys. 4.23. *Prąd wzbudzenia w stanie bez uszkodzeń***Rys. 4.24.** *Prąd twornika w stanie zwarcia sześciu zezwojów***Rys. 4.25.** *Prąd twornika w stanie zwarcia trzech zezwojów***Rys. 4.26.** *Prąd twornika w stanie przerwy jednego zezwoju*




Rys. 4.27. Prąd twornika w stanie bez uszkodzeń




Rys. 4.28. Napięcie wzbudzenia w stanie zwarcia sześciu zezwojów




Rys. 4.29. Napięcie wzbudzenia w stanie zwarcia trzech zezwojów




Rys. 4.30. Napięcie wzbudzenia w stanie przerwy jednego zezwoju




Rys. 4.31. *Napięcie wzbudzenia w stanie bez uszkodzeń*




Rys. 4.32. *Napięcie twornika w stanie zwarcia sześciu zezwojów*



Rys. 4.33. *Napięcie twornika w stanie zwarcia trzech zezwojów*



Rys. 4.34. *Napięcie twornika w stanie przerwy jednego zezwoju*



Rys. 4.35. Napięcie twornika w stanie bez uszkodzeń

Zarejestrowane sygnały diagnostyczne: prąd wzbudzenia, prąd twornika, napięcie wzbudzenia, napięcie twornika, podzielono na próbki o długości: 1s, 2s, 3s, 4s, 5s.

Zbiór testowy zawierał próbki prądu i napięcia o długości od 1 do 5 sekund ponieważ istotnym było zbadanie skuteczności rozpoznawania sygnału prądowego/napięciowego w zależności od długości próbki prądu/napięcia. Określenie właściwej długości próbki było potrzebne ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyny prądu stałego. Ponadto eksperyment miał potwierdzić, że w sygnale prądu/napięcia zawarta jest informacja o stanie maszyny prądu stałego. W celu potwierdzenia przydatności metody MSAF i czterech klasyfikatorów (sieci neuronowej, NN, Bayesa, LDA) w rozpoznawaniu sygnałów prądowych i napięciowych maszyny prądu stałego eksperyment SPS podzielony został na 3 mniejsze eksperymenty: MSAF-SPS, LPC-SPS, LPCC-SPS.

W eksperymentach LPC-SPS, LPCC-SPS uzyskano gorsze wyniki, niż w MSAF-SPS.

[przetawienie:]

4.7. Eksperyment FFT-MPS

Eksperyment FFT-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę FFT i trzech klasyfikatorów.

W przypadku maszyny prądu stałego pracującej z prędkością wynoszącą 700 obr/min w widmach prądów twornika oraz wzbudzenia pojawiały się amplitudy o częstotliwościach, które są wielokrotnościami częstotliwości $k_c = 46,66$ Hz (zobacz wzór 2.4) [114]. Z tego powodu dla sygnałów

4.5. Eksperyment MSAF-SPS

Eksperyment MSAF-SPS polegał na badaniu zbioru testowego zawierającego próbki prądu/napięcia silnika prądu stałego w różnych stanach pracy, o różnych długościach, za pomocą metody MSAF


i czterech klasyfikatorów (sieci neuronowej, NN, Bayesa i LDA).

Wykonano analizę FFT sygnałów diagnostycznych.

Wyniki analizy FFT prądu wzbudzenia, prądu twornika, napięcia wzbudzenia i napięcia twornika dla prędkości wirnika 700 obr/min, dla prądu obciążenia 45 A,


akustycznych maszyny prądu stałego badano amplitudy o częstotliwościach, które były wielokrotnościami częstotliwości 46,66 Hz. Metoda wybierania amplitud dla częstotliwości wskazała, że najlepiej rozróżnialne amplitudy występują dla częstotliwości 233 Hz, 887 Hz, 1260 Hz, 2286 Hz, 2566 Hz (zobacz wzory 2.4–2.7).

Widmo częstotliwości sygnału akustycznego maszyny prądu stałego dla dwóch różnych stanów pracy przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i FFT zostało przedstawione na rysunku 4.15.




Rys. 4.15. Widmo częstotliwości sygnału akustycznego maszyny prądu stałego dla dwóch różnych stanów pracy przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i FFT


przedstawiono na rysunkach 4.36 - 4.51.




Rys. 4.36. Widmo częstotliwości prądu wzbudzenia w stanie zwarcia sześciu zewojów




Rys. 4.37. Widmo częstotliwości prądu wzbudzenia w stanie zwarcia trzech zewojów




Rys. 4.38. Widmo częstotliwości prądu wzbudzenia w stanie przerwy jednego zewoju




Rys. 4.39. Widmo częstotliwości prądu wzbudzenia w stanie bez uszkodzeń




Rys. 4.40. Widmo częstotliwości prądu twornika w stanie zwarcia sześciu zezwojów




Rys. 4.41. Widmo częstotliwości prądu twornika w stanie zwarcia trzech zezwojów




Rys. 4.42. Widmo częstotliwości prądu twornika w stanie przerwy jednego zezwoju




Rys. 4.43. Widmo częstotliwości prądu twornika w stanie bez uszkodzeń




Rys. 4.44. Widmo częstotliwości napięcia wzbudzenia w stanie zwarcia sześciu zezwojów




Rys. 4.45. Widmo częstotliwości napięcia wzbudzenia w stanie zwarcia trzech zezwojów




Rys. 4.46. Widmo częstotliwości napięcia wzbudzenia w stanie przerwy jednego zezwoju




Rys. 4.47. Widmo częstotliwości napięcia wzbudzenia w stanie bez uszkodzeń




Rys. 4.48. Widmo częstotliwości napięcia twornika w stanie zwarcia sześciu zezwojów



Rys. 4.49. Widmo częstotliwości napięcia twornika w stanie zwarcia trzech zezwojów



Rys. 4.50. Widmo częstotliwości napięcia twornika w stanie przerwy jednego zezwoju



Rys. 4.51. Widmo częstotliwości napięcia twornika w stanie bez uszkodzeń

[fragment powielony z początku:]

W przypadku maszyny prądu stałego pracującej z prędkością wynoszącą 700 obr/min w widmach prądów twornika oraz wzbudzenia pojawiały się amplitudy o częstotliwościach, które są wielokrotnościami częstotliwości $k_c = 46,66$ Hz (zobacz wzór 2.4) [114]. Z tego powodu dla sygnałów akustycznych maszyny prądu stałego badano amplitudy o częstotliwościach, które były wielokrotnościami częstotliwości 46,66 Hz. Metoda wybierania amplitud dla częstotliwości wskazała, że najlepiej rozróżnialne amplitudy występują dla częstotliwości 233 Hz, 887 Hz, 1260 Hz, 2286 Hz, 2566 Hz (zobacz wzory 2.4–2.7).

W celu potwierdzenia przydatności metody FFT i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego eksperyment FFT-MPS podzielony został na 3 mniejsze eksperymenty: FFT-NM-MPS, FFT-ONS-MPS, FFT-SN-MPS.

[Fragment przeniesiony z rozdziału 2:]

Skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika) określona została następująco:

$$E = \frac{N_1}{N} \cdot 100\% \quad (2.29)$$

gdzie: E – skuteczność rozpoznawania sygnału akustycznego (prądu wzbudzenia, twornika), N_1 – liczba poprawnie zidentyfikowanych próbek danej kategorii, N – liczba wszystkich próbek danej kategorii

Dla każdej długości próbki sygnału diagnostycznego określono zbiór najistotniejszych częstotliwości, dla których różnice odpowiadających sygnałów w dwóch stanach silnika są największe.

W przypadku maszyny prądu stałego pracującej z prędkością wynoszącą 700 obr/min w widmach prądów wzbudzenia i twornika oraz napięć wzbudzenia i twornika pojawiają się amplitudy o częstotliwościach, które są wielokrotnościami częstotliwości $k_c = 46,66$ Hz [54]. Z tego powodu dla sygnałów prądowych i napięciowych maszyny prądu stałego badano amplitudy o częstotliwościach, które były wielokrotnościami częstotliwości 46,66 Hz. Metoda wyboru amplitud dla częstotliwości wskazała, że najlepiej rozróżnialne amplitudy występują dla częstotliwości 233 Hz, 887 Hz, 1260 Hz, 2286 Hz, 2566 Hz.

W procesie uczenia i identyfikacji zastosowano cztery klasyfikatory: sieci neuronowej, NN, Bayesa i LDA. W procesach uczenia i identyfikacji utworzono wektory cech sygnału diagnostycznego dla częstotliwości należących do zbioru najistotniejszych częstotliwości. Składowymi wektorów cech były amplitudy dla częstotliwości prądu wzbudzenia, prądu twornika, napięcia wzbudzenia i napięcia twornika, w czterech stanach: stanie bez uszkodzeń, stanie przerwy zezwojów wirnika, stanie zwarcia trzech zezwojów wirnika, stanie zwarcia sześciu zezwojów wirnika.

Skuteczność rozpoznawania sygnału silnika została zdefiniowana:

$$E_n = \frac{N_{np}}{N_{nw}} \cdot 100\% \quad (4.3)$$

gdzie: E_n – skuteczność rozpoznawania sygnału silnika dla n -sekundowych próbek sygnału, N_{np} , N_{nw} – liczba pomyślnych rozpoznań i wszystkich rozpoznań sygnału dla n -sekundowych próbek sygnału

biorących udział w procesie identyfikacji.

Wzór 2.29 będzie używany do obliczeń dotyczących sygnałów akustycznych (zobacz podrozdziały 4.1-4.10), sygnałów prądu wzbudzenia (zobacz podrozdział 4.11), sygnałów prądu twornika (zobacz podrozdział 4.12). Jeżeli N_1 i N będą oznaczać liczbę próbek dźwięku to E będzie skutecznością rozpoznawania sygnału akustycznego. Jeżeli N_1 i N będą oznaczać liczbę próbek prądu wzbudzenia (twornika) to E będzie skutecznością rozpoznawania sygnału prądu wzbudzenia (twornika).

Średnia skuteczność rozpoznawania sygnału akustycznego (maszyny synchronicznej, prądu stałego) określona została następująco:

$$E_{sr} = \frac{\sum_{n=1}^5 E_n}{5} \quad (2.30)$$

gdzie: E_{sr} – średnia skuteczność rozpoznawania sygnału akustycznego (maszyny synchronicznej, prądu stałego), E_n – skuteczność rozpoznawania sygnału akustycznego dla n sekundowych próbek dźwięku stanu pracy maszyny, $n \in \{1,2,3,4,5\}$.

W przypadku maszyny synchronicznej badane będą cztery różne stany pracy (zobacz podrozdział 4.2).

Zatem do obliczenia E_n przyjęto wzór.

$$E_n = \frac{E_{nb} + E_{nz} + E_{n1} + E_{n3}}{4} \quad (2.31)$$

gdzie: E_n – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej, E_{nb} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej bez uszkodzeń,

E_{nz} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej ze zwartymi zewojami stojana, E_{n1} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej z jedną przerwą w obwodzie stojana, E_{n3} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny synchronicznej z trzema przerwami w obwodzie stojana.

W przypadku maszyny prądu stałego badane będą dwa różne stany pracy (zobacz podrozdział 4.6). Zatem do obliczenia E_n przyjęto wzór.

$$E_n = \frac{E_{nb} + E_{nz}}{2} \quad (2.32)$$

silnika w stanach: bez uszkodzeń, przerwy zewojów wirnika i zwarcia trzech zewojów wirnika.

Średnią skuteczność rozpoznawania sygnału silnika zdefiniowano:

$$E_{ns} = \frac{E_{nb} + E_{np} + E_{nz3} + E_{nz6}}{4} \quad (4.4)$$

gdzie: E_{ns} – średnia skuteczność rozpoznawania sygnału silnika dla n -sekundowych próbek sygnału, $E_{nb}, E_{np}, E_{nz3}, E_{nz6}$ – skuteczności rozpoznawania sygnału silnika dla n -sekundowych próbek sygnału odpowiednio w stanach: bez uszkodzeń, przerwy zewojów wirnika, zwarcia trzech zewojów wirnika, zwarcia sześciu zewojów wirnika.

gdzie: E_n – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego, E_{nb} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego bez uszkodzeń, E_{nz} – skuteczność rozpoznawania sygnału akustycznego dla n -sekundowych próbek dźwięku maszyny prądu stałego ze zwartymi zezwojami wirnika.

[koniec fragmentu]

[Przestawienie:]

4.6. Eksperyment MPS

Eksperyment MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy. W badaniach użyto dwóch różnych sygnałów akustycznych: maszyny prądu stałego bez uszkodzeń oraz maszyny prądu stałego ze zwartymi zezwojami wirnika. Skuteczność rozpoznawania sygnału akustycznego określona została wzorem (2.29).

Proces tworzenia wzorców do rozpoznawania został przeprowadzony na podstawie zbioru uczącego zawierającego 16 próbek dźwięku. Aby zmniejszyć liczbę możliwych przypadków obliczeniowych, zbiór uczący zawierał tylko pięciosekundowe próbki dźwięku. Proces identyfikacji został przeprowadzony odpowiednio dla zbiorów testowych zawierających: 18 pięciosekundowych próbek dźwięku, 21 czterosekundowych próbek dźwięku, 30 trzysekundowych próbek dźwięku, 46 dwusekundowych próbek dźwięku i 91 jednosekundowych próbek dźwięku. Zbiór testowy zawierał próbki dźwięku o długości od 1 do 5 sekund, ponieważ istotnym było zbadanie skuteczności rozpoznawania sygnału akustycznego w zależności od długości próbki dźwięku. Określenie właściwej długości próbki było istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyny prądu stałego

Ponadto eksperyment miał potwierdzić, że w sygnale akustycznym zawarta jest informacja o stanie pracy maszyny prądu stałego. W tym celu eksperyment MPS został podzielony na 3 eksperymenty: FFT-MPS, LPC-MPS, LPCC-MPS.

[przestawienie:]

4.7.3. Eksperyment FFT-SN-MPS

Eksperyment MSAF-SPS polegał na badaniu zbioru testowego zawierającego próbki prądów i napięć silnika prądu stałego w różnych stanach pracy, o różnych długościach, metodę MSAF i cztery klasyfikatory.

Zastosowane metody analizy i rozpoznawania pozwalają określić stan silnika prądu stałego, tj. stan bez uszkodzeń, stan z przerwą zezwojów wirnika, stan ze zwarcie trzech zezwojów wirnika, stan ze zwarcie sześciu zezwojów wirnika, na podstawie próbek sygnału diagnostycznego prądu wzbudzenia, prądu twornika, napięcia wzbudzenia i napięcia twornika, dla prądu obciążenia 45 A.


Proces tworzenia wzorców do rozpoznawania został przeprowadzony na podstawie zbioru uczącego zawierającego 8 próbek sygnału. Aby zmniejszyć liczbę możliwych przypadków obliczeniowych, zbiór uczący zawierał tylko jednosekundowe próbki sygnału. W procesie identyfikacji wykorzystano zbiory testowe zawierające: 32 jednosekundowych próbek sygnału, 20 dwusekundowych próbek sygnału, 12 trzysekundowych próbek sygnału, 8 czterosekundowych próbek sygnału i 8 pięciosekundowych próbek sygnału.

W celu potwierdzenia przydatności metody MSAF i czterech klasyfikatorów w rozpoznawaniu sygnałów prądowych i napięciowych maszyny prądu stałego eksperyment MSAF-SPS podzielony został na 4 mniejsze eksperymenty: MSAF-SN-SPS, MSAF-NN-SPS, MSAF-BA-SPS, MSAF-LDA-SPS.

4.5.1. Eksperyment MSAF-SN-SPS

Eksperyment FFT-SN-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech (zobacz podrozdział 4.7), liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 6 (5+1).

Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego została pokazana na rysunku 4.18. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 43,47% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.40 załączono 10 wyników rozpoznawania sygnałów akustycznych.



Rys. 4.18. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego [por. tab. 4.31 – 4.40 w dodatku B]

Eksperyment MSAF-SN-SPS polegał na badaniu zbioru testowego zawierającego próbki prądów i napięć maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodą MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech, liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 6 (5+1).

Wyniki rozpoznawania sygnałów silnika prądu stałego opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów dla próbek jednosekundowych przedstawiono w tabelach 4.9, 4.10, 4.11, 4.12

Tab. 4.9. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	62,5
z trzema zwartymi zewojami wirnika	100
z sześcioma zwartymi zewojami wirnika	100

Tab. 4.10. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zewojami wirnika	100
z sześcioma zwartymi zewojami wirnika	100

Tab. 4.11. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zewojami wirnika	100

Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 75,25%. Wykonanie takiego badania potwierdziło przydatność wariantu metod FFT i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

4.7.1. Eksperyment FFT-NM-MPS

Eksperyment FFT-NM-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę FFT i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych.

Przeprowadzono badania FFT i zmodyfikowanego klasyfikatora NM z metrykami: Euklidesa, Manhattan, Jacquarda, kosinusową, Minkowskiego dla parametru $r = 3, 4, 5, 6$. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny prądu stałego została pokazana na rysunkach 4.16a, 4.16b.

Przy użyciu metryki Manhattan, Euklidesa, Minkowskiego z parametrami $r = 3, 4, 5, 6$ skuteczność rozpoznawania sygnału akustycznego dla próbek dźwięku o długości od 1 do 5 sekund wynosiła od 97,82% do 100%. W tabelach 4.31–4.38 załączono 80 wyników rozpoznawania sygnałów akustycznych.

a)

b)

z sześcioma zwartymi zezwojami wirnika	100
--	-----

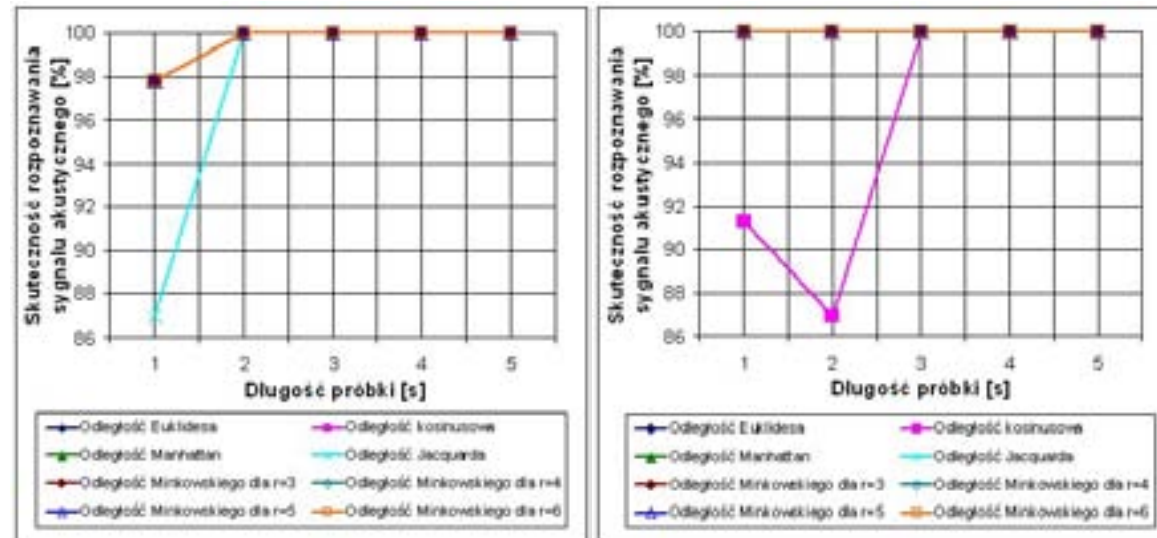
Tab. 4.12. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Przy użyciu klasyfikatora opartego na sieci neuronowej skuteczność rozpoznawania sygnałów prądowych wynosiła od 50% do 100%, a napięciowych 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.33, 4.37, 4.41, 4.45). Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

4.5.2. Eksperyment MSAF-NN-SPS

Wyniki rozpoznawania sygnałów silnika prądu stałego przy użyciu klasyfikatora opartego na metodzie najbliższego sąsiada dla próbek jednosekundowych przedstawiono w tabelach 4.13, 4.14, 4.15, 4.16.



Rys. 4.16. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny prądu stałego: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami wirnika [por. tab. 4.31 – 4.40 w dodatku B]

Tab. 4.13. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	62,5
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.14. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.15. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.16. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

W celu określenia najlepszej metryki dla zmodyfikowanego klasyfikatora NM zastosowano wzór 2.30. Najlepsza średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 99,78%. Została ona


Przy użyciu klasyfikatora opartego na metodzie najbliższego sąsiada skuteczność rozpoznawania sygnałów prądowych wynosiła od 50% do 100%, a napięciowych 100% (próbki o

otrzymana dla metryki Manhattan, Euklidesa i Minkowskiego. Wykonanie takiego badania potwierdziło przydatność wariantu metod FFT i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

4.7.2. Eksperyment FFT-ONS-MPS

Eksperyment FFT-ONS-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę FFT i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora.

Najlepsze wyniki rozpoznawania sygnałów akustycznych dla tego klasyfikatora i FFT otrzymano, gdy wartość parametru k wynosiła 0,001. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego została pokazana na rysunku 4.17. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 76,08% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.39 załączono 10 wyników.



Rys. 4.17. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego

[por. tab. 4.31 – 4.40 w dodatku B]

długości od 1 do 5 sekund, dodatek B, tabele 4.34, 4.38, 4.42, 4.46). Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora opartego na metodzie najbliższego sąsiada w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

4.5.3. Eksperyment MSAF-BA-SPS

Wyniki rozpoznawania sygnałów silnika prądu stałego przy użyciu klasyfikatora Bayesa dla próbek jednosekundowych przedstawiono w tabelach 4.17, 4.18, 4.19, 4.20.

Tab. 4.17. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	62,5
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.18. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	75
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.19. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 90,73%. Wykonanie takiego badania potwierdziło przydatność wariantu metod FFT i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

[por. tab. 4.31 – 4.40 w dodatku B]

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zezwojami wirnika	62,5
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.20. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	62,5
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Przy użyciu klasyfikatora Bayesa skuteczność rozpoznawania sygnałów prądowych wynosiła od 50% do 100%, a napięciowych od 50% do 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.35, 4.39, 4.43, 4.47). Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora Bayesa w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

[powtórzenie z podmianą funkcji:]

4.5.4. Eksperyment MSAF-LDA-SPS

Wyniki rozpoznawania sygnałów silnika prądu stałego przy użyciu klasyfikatora LDA dla próbek jednosekundowych przedstawiono w tabelach 4.21, 4.22, 4.23, 4.24.

Tab. 4.21. Wyniki rozpoznawania prądu i_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	62,5
z trzema zwartymi zezwojami wirnika	100
z sześcioma zwartymi zezwojami wirnika	100

Tab. 4.22. Wyniki rozpoznawania prądu i_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zewojami wirnika	100
z sześcioma zwartymi zewojami wirnika	100

Tab. 4.23. Wyniki rozpoznawania napięcia u_w wzbudzenia silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zewojami wirnika	100
z sześcioma zwartymi zewojami wirnika	100

Tab. 4.24. Wyniki rozpoznawania napięcia u_t twornika silnika prądu stałego dla jednosekundowych próbek

Stan silnika	Skuteczność rozpoznawania [%]
bez uszkodzeń	100
z jedną przerwą w uzwojeniu wirnika	100
z trzema zwartymi zewojami wirnika	100
z sześcioma zwartymi zewojami wirnika	100


Przy użyciu klasyfikatora LDA skuteczność rozpoznawania sygnałów prądowych wynosiła od 50% do 100%, a napięciowych 100% (próbki o długości od 1 do 5 sekund, dodatek B, tabele 4.36, 4.40, 4.44, 4.48). Wykonanie takiego badania potwierdziło przydatność wariantu metod MSAF i klasyfikatora LDA w rozpoznawaniu sygnałów prądowych i napięciowych silnika prądu stałego.

[brak]

4.4. Eksperyment LPC-MS


Eksperyment LPC-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i trzech klasyfikatorów.

Podczas użycia algorytmu LPC należało dobrać najlepszą liczbę współczynników filtra predykcji liniowej do rozpoznawania sygnału akustycznego. Zgodnie z literaturą liczba badanych współczynników powinna była wynosić od 8 do 20 [93], [118], [120]. Dodatkowo przeprowadzono badania dla liczby współczynników od 1 do 7. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników filtra predykcji liniowej dla maszyny synchronicznej została przedstawiona na rysunku 4.5. W problematyce rozpoznawania wzorców dąży się do minimalizacji liczby cech. Z badań można wywnioskować, że najmniejszą liczbą współczynników, która daje najlepsze wyniki rozpoznawania sygnałów akustycznych jest $p = 6$ (p jest liczbą współczynników filtra predykcji liniowej). Liczba ta będzie stosowana w algorytmie LPC dla maszyny synchronicznej.



Rys. 4.5. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników filtra predykcji liniowej dla maszyny synchronicznej

Na rysunku 4.6 porównano sześć współczynników filtra predykcji liniowej dla czterech różnych rodzajów sygnałów akustycznych maszyny synchronicznej po zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz.



Rys. 4.6. Porównanie sześciu współczynników filtra predykcji liniowej dla czterech różnych rodzajów sygnałów akustycznych maszyny synchronicznej z zastosowaniem algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz

W celu potwierdzenia przydatności metody LPC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej eksperyment LPC-MS podzielony został na 3 mniejsze eksperymenty: LPC-NM-MS, LPC-ONS-MS, LPC-SN-MS.

4.4.1. Eksperyment LPC-NM-MS

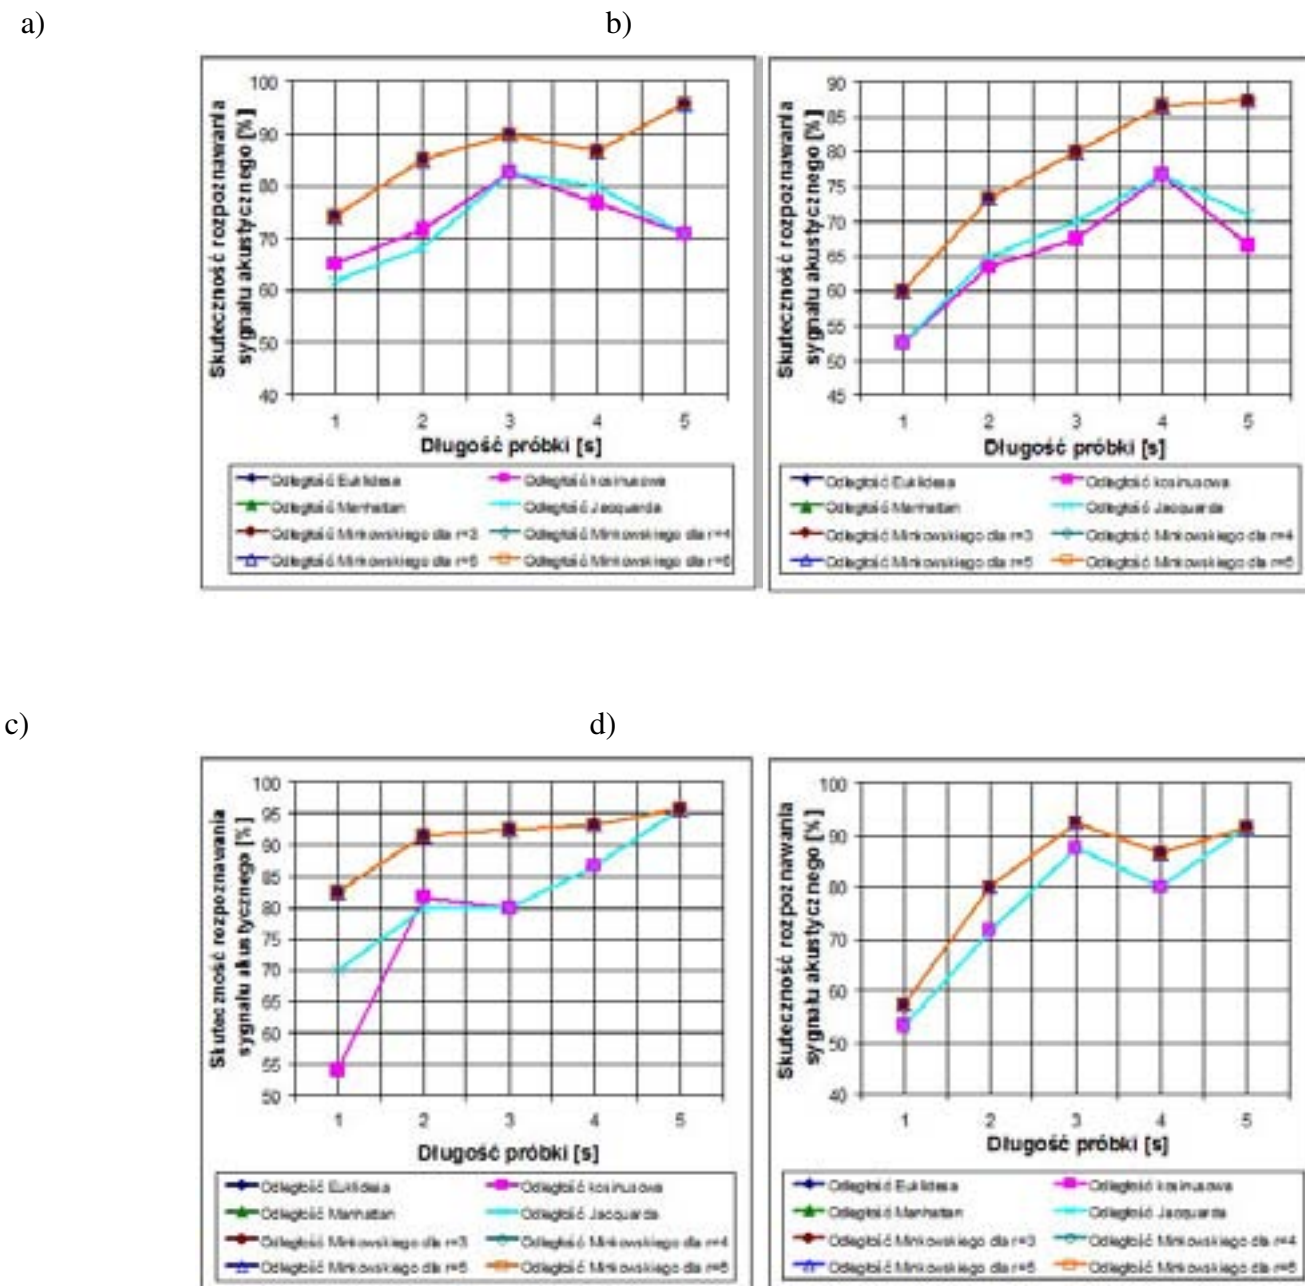
Eksperyment LPC-NM-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych.

Zbadano LPC i zmodyfikowany klasyfikator NM z metrykami: Euklidesa, Manhattan, Jacquarda, kosinusową, Minkowskiego dla parametrów $r = 3, 4, 5, 6$. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej została pokazana na rysunkach 4.7a, 4.7b, 4.7c, 4.7d. Przy użyciu metryki Manhattan, Euklidesa, Minkowskiego z parametrami $r = 3, 4, 5, 6$ skuteczność rozpoznawania sygnału akustycznego dla próbek dźwięku o długości od 1 do 5 sekund wynosiła od 57,5% do 95,83%. W tabelach 4.11–4.18 załączono 160 wyników rozpoznawania tychże sygnałów akustycznych.

W celu określenia najlepszej metryki dla zmodyfikowanego klasyfikatora NM zastosowano wzór 2.30. Najlepsza średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 84,16%. Została ona otrzymana dla metryki Manhattan, Euklidesa i Minkowskiego. Wykonanie takiego badania potwierdziło

[brak]

przydatność wariantu metod LPC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.



Rys. 4.7. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami stojana, **c)** z jedną przerwą w obwodzie stojana, **d)** z trzema przerwami w obwodzie stojana


[brak]

4.4.2. Eksperyment LPC-ONS-MS

Eksperyment LPC-ONS-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku

maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora.

Najlepsze wyniki rozpoznawania sygnałów akustycznych dla tego klasyfikatora otrzymano, gdy wartość parametru k wynosiła 0,01. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej została pokazana na rysunku 4.8. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 69,16% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.19 załączono 20 wyników.



Rys. 4.8. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej

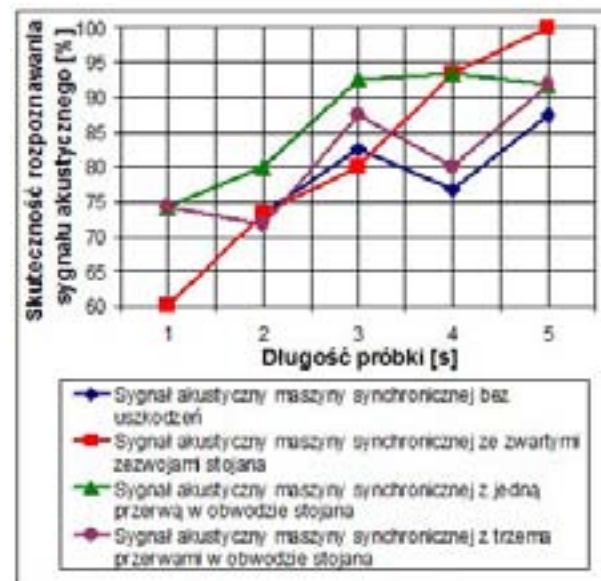
Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 90,53%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPC i zmodyfikowanego klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

4.4.3. Eksperyment LPC-SN-MS

Eksperyment LPC-SN-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną

[brak]

wcześniej liczbę cech (zobacz podrozdział 4.4), liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 7 (6+1). Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej została przedstawiona na rysunku 4.9. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 60% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.20 załączono 20 wyników.



Rys. 4.9. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej

Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 81,15%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

4.5. Eksperyment LPCC-MS

Eksperyment LPCC-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPCC i trzech klasyfikatorów. Podczas użycia algorytmu LPCC należało dobrać najlepszą liczbę współczynników cepstralnych do rozpoznawania sygnału akustycznego. Zbadano kolejne liczby współczynników od 1 do 20. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud

[brak]

dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników cepstralnych w przypadku maszyny synchronicznej została przedstawiona na rysunku 4.10.



Rys. 4.10. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników cepstralnych dla maszyny synchronicznej

W problematyce rozpoznawania wzorców dąży się do minimalizacji liczby cech. Z przeprowadzonych badań można zauważyć, że najmniejszą liczbą współczynników, która daje dobre wyniki rozpoznawania sygnałów akustycznych jest $c = 10$ (c jest liczbą współczynników cepstralnych). Liczba ta będzie stosowana w algorytmie LPCC dla maszyny synchronicznej. Na rysunku 4.11 porównano dziesięć współczynników cepstralnych dla czterech różnych rodzajów sygnałów akustycznych maszyny synchronicznej po zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz.

W celu potwierdzenia przydatności metody LPCC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej eksperyment LPCC-MS podzielony został na 3 mniejsze eksperymenty: LPCC-NM-MS, LPCC-ONS-MS, LPCC-SNMS.



Rys. 4.11. Porównanie dziesięciu współczynników cepstralnych dla czterech różnych rodzajów sygnałów akustycznych maszyny synchronicznej po zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz

[brak]


4.5.1. Eksperyment LPCC-NM-MS

Eksperyment LPCC-NM-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPCC i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych.


Przeprowadzono badania LPCC i zmodyfikowanego klasyfikatora NM z metrykami: Euklidesa, Manhattan, Jacquarda, kosinusową, Minkowskiego dla parametrów $r = 3, 4, 5, 6$. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej została pokazana na rysunkach 4.12a, 4.12b, 4.12c,

4.12d.

a)

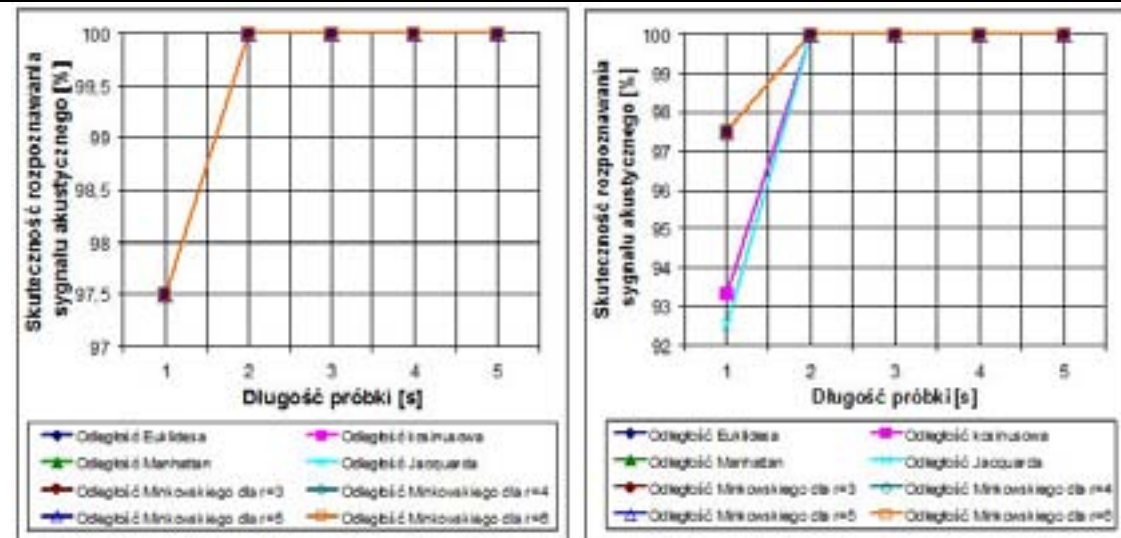


b)



c)

d)




Rys. 4.12. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny synchronicznej: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami stojana, **c)** z jedną przerwą w obwodzie stojana, **d)** z trzema przerwami w obwodzie stojana

Przy użyciu metryki Manhattan, Euklidesa, Minkowskiego z parametrami $r = 3, 4, 5, 6$ skuteczność rozpoznawania sygnału akustycznego dla próbek dźwięku o długości od 1 do 5 sekund wynosiła od 97,5% do 100%. W tabelach 4.21–4.28 załączono 160 wyników rozpoznawania tychże sygnałów akustycznych. W celu określenia najlepszej metryki dla zmodyfikowanego klasyfikatora NM zastosowano wzór 2.30. Najlepsza średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 99,5%. Została ona otrzymana dla metryki Manhattan, Euklidesa i Minkowskiego. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPCC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

4.5.2. Eksperyment LPCC-ONS-MS

Eksperyment LPCC-ONS-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPCC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Najlepsze wyniki rozpoznawania sygnałów akustycznych dla tego klasyfikatora i algorytmu LPCC otrzymano, gdy wartość parametru k wynosiła 0,01. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej została pokazana na rysunku 4.13.

[brak]



Rys. 4.13. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej

Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 95,83% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.29 załączono 20 wyników. Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 99,45%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPCC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.


4.5.3. Eksperyment LPCC-SN-MS

Eksperyment LPCC-SN-MS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny synchronicznej w różnych stanach pracy, o różnych długościach, metodę LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech (zobacz podrozdział 4.5), liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 11 (10+1).

Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej została przedstawiona na rysunku 4.14. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 70,83% do 100% (próbki dźwięku o długości od 1 do 5 sekund).

[brak]

W tabeli 4.30 załączono 20 wyników.



Rys. 4.14. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny synchronicznej

Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 82,87%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny synchronicznej.

4.8. Eksperyment LPC-MPS

Eksperyment LPC-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPC i trzech klasyfikatorów.

Podczas użycia algorytmu LPC należało dobrać najlepszą liczbę współczynników filtra predykcji liniowej do rozpoznawania sygnału akustycznego. Zgodnie z literaturą liczba badanych współczynników powinna być wynosić od 8 do 20 [93], [118], [120]. Po przebadaniu liczby współczynników od 8 do 20 okazało się, że należy jeszcze zbadać liczbę współczynników od 1 do 7. W badaniach zastosowano zmodyfikowany klasyfikator NM z metryką Euklidesa i algorytm wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz. Na rysunku 4.19 została przedstawiona skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby

[brak]


współczynników filtra predykcji liniowej dla maszyny prądu stałego. W problematyce rozpoznawania wzorców dąży się do minimalizacji liczby cech. Z badań wynika, że najmniejszą liczbą współczynników, która daje dobre wyniki rozpoznawania sygnałów akustycznych jest $p = 7$ (p jest liczbą współczynników filtra predykcji liniowej).

Liczba ta będzie stosowana w algorytmie LPC dla maszyny prądu stałego.



Rys. 4.19. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników filtra predykcji liniowej dla maszyny prądu stałego

Na rysunku 4.20 porównano siedem współczynników filtra predykcji liniowej dla dwóch różnych rodzajów sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i LPC.



Rys. 4.20. Porównanie siedmiu współczynników filtra predykcji liniowej dla dwóch różnych rodzajów sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i LPC

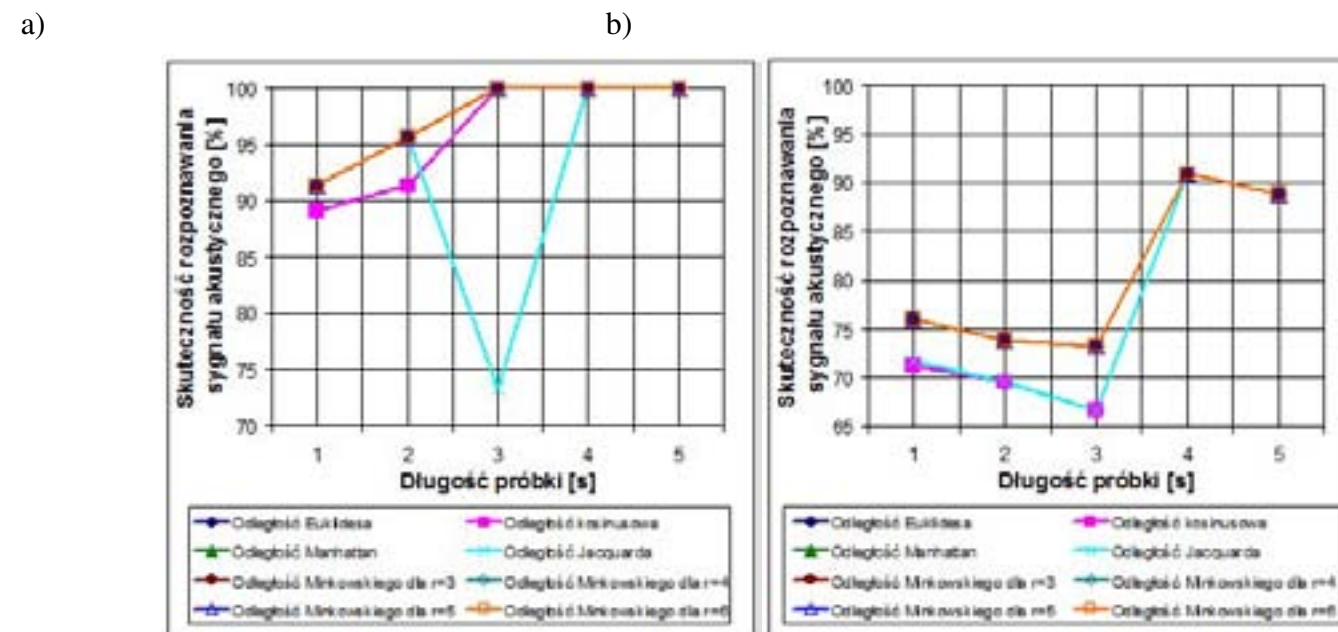
W celu potwierdzenia przydatności metody LPC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego eksperyment LPC-MPS podzielony został na 3 mniejsze

eksperymenty: LPC-NM-MPS, LPC-ONS-MPS, LPC-SN-MPS.

4.8.1. Eksperyment LPC-NM-MPS

Eksperyment LPC-NM-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPC i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych.

Zbadano LPC i zmodyfikowany klasyfikator NM z metrykami: Euklidesa, Manhattan, Jacquarda, kosinusową, Minkowskiego dla parametru $r = 3, 4, 5, 6$. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny prądu stałego została przedstawiona na rysunkach 4.21a, 4.21b.



Rys. 4.21. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566, LPC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji i stosowanej metryki dla maszyny prądu stałego: **a)** bez uszkodzeń, **b)** ze zwartymi zewojami wirnika

Przy użyciu metryki Manhattan, Euklidesa, Minkowskiego z parametrami $r = 3, 4, 5, 6$ skuteczność rozpoznawania sygnału akustycznego dla próbek dźwięku o długości od 1 do 5 sekund wynosiła od 73,33% do 100%. W tabelach 4.41–4.48 załączono 80 wyników. W celu określenia najlepszej metryki dla zmodyfikowanego klasyfikatora NM zastosowano wzór 2.30. Najlepsza średnia


[brak]

skuteczność rozpoznawania sygnału akustycznego wynosiła 89%. Została ona otrzymana dla metryki Manhattan, Euklidesa i Minkowskiego. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

4.8.2. Eksperyment LPC-ONS-MPS

Eksperyment LPC-ONS-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora.

Najlepsze wyniki rozpoznawania sygnałów akustycznych dla tego klasyfikatora otrzymano, gdy wartość parametru k wynosiła 0,005. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego została pokazana na rysunku 4.22. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 73,91% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.49 załączono 10 wyników rozpoznawania sygnałów akustycznych.



Rys. 4.22. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego


Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 89,65%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

[brak]

4.8.3. Eksperyment LPC-SN-MPS

Eksperyment LPC-SN-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech (zobacz podrozdział 4.8), liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 8.

Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego została pokazana na rysunku 4.23.



Rys. 4.23. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego

Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 63,04% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.50 załączono 10 wyników rozpoznawania sygnałów akustycznych. Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 88,36%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

4.9. Eksperyment LPCC-MPS

[brak]

[brak]


Eksperyment LPCC-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPCC i trzech klasyfikatorów.

Podczas badań przy użyciu algorytmu LPCC należało dobrać najlepszą liczbę współczynników cepstralnych do rozpoznawania sygnału akustycznego. Zbadano kolejne liczby współczynników od 1 do 20. W badaniach zastosowano zmodyfikowany klasyfikator NM z metryką Euklidesa i algorytm wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz. Na rysunku 4.24 przedstawiono skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników cepstralnych dla maszyny prądu stałego.



Rys. 4.24. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa w zależności od liczby współczynników cepstralnych dla maszyny prądu stałego

Z badań można zauważyć, że najmniejszą liczbą współczynników, która daje dobre wyniki rozpoznawania sygnałów akustycznych jest $c = 13$ (c jest liczbą współczynników cepstralnych). Liczba ta będzie stosowana w algorytmie LPCC dla maszyny prądu stałego. Na rysunku 4.25 porównano 13 współczynników cepstrum dla dwóch różnych rodzajów sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i LPCC.



Rys. 4.25. Porównanie trzynastu współczynników cepstrum dla dwóch różnych rodzajów sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz i LPCC

W celu potwierdzenia przydatności metody LPCC i trzech klasyfikatorów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego eksperyment LPCC-MPS podzielony został na 3 mniejsze eksperymenty: LPCC-NM-MPS, LPCC-ONS-MPS, LPCC-SN-MPS.

4.9.1. Eksperyment LPCC-NM-MPS

Eksperyment LPCC-NM-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPCC i zmodyfikowanego klasyfikatora NM. W badaniu należało wybrać najlepszą metrykę do rozpoznawania sygnałów akustycznych.

Przeprowadzono badania LPCC i zmodyfikowanego klasyfikatora NM z metrykami: Euklidesa, Manhattan, Jacquarda, kosinusową, Minkowskiego dla parametrów $r = 3, 4, 5, 6$. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC, zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji, stosowanej metryki dla maszyny prądu stałego została pokazana na rysunkach 4.26a, 4.26b.


Przy użyciu metryki Manhattan, Euklidesa, Minkowskiego z parametrami $r = 3, 4, 5, 6$ skuteczność rozpoznawania sygnału akustycznego dla próbek dźwięku o długości od 1 do 5 sekund wynosiła od 71,73% do 100%. W tabelach 4.51–4.58 załączono 80 wyników. W celu określenia najlepszej metryki dla zmodyfikowanego klasyfikatora NM zastosowano wzór 2.30. Najlepsza średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 92,33%.

[brak]

Została ona otrzymana dla metryki Manhattan, Euklidesa i Minkowskiego.

a)

b)




Rys. 4.26. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM w zależności od długości próbki dźwięku do identyfikacji, stosowanej metryki dla maszyny prądu stałego: **a)** bez uszkodzeń, **b)** ze zwartymi zezwojami wirnika

Wykonanie takiego badania potwierdziło przydatność wariantu metod LPCC i zmodyfikowanego klasyfikatora NM w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

4.9.2. Eksperyment LPCC-ONS-MPS

Eksperyment LPCC-ONS-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPCC i klasyfikatora opartego na słowach. W badaniu należało dobrać właściwie parametr k dla tego klasyfikatora. Najlepsze wyniki rozpoznawania sygnałów akustycznych dla tego klasyfikatora i LPCC otrzymano, gdy wartość parametru k wynosiła 0,01. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego została pokazana na rysunku 4.27. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 73,91% do 100% (próbki dźwięku o długości od 1 do 5 sekund). W tabeli 4.59 załączono 10 wyników.

[brak]



Rys. 4.27. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na słowach w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego

Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 92,14%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPCC i klasyfikatora opartego na słowach w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.


4.9.3. Eksperyment LPCC-SN-MPS

Eksperyment LPCC-SN-MPS polegał na badaniu zbioru testowego zawierającego próbki dźwięku maszyny prądu stałego w różnych stanach pracy, o różnych długościach, metodę LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów. W badaniu należało dobrać właściwie liczbę wejść do neuronów warstwy wejściowej sieci neuronowej. Ze względu na wybraną wcześniej liczbę cech (zobacz podrozdział 4.9), liczba wejść do neuronów warstwy wejściowej sieci neuronowej wynosiła 14.

Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego została pokazana na rysunku 4.28. Przy użyciu tego klasyfikatora skuteczność rozpoznawania sygnału akustycznego wynosiła od 67,39% do 100% (próbki dźwięku o długości od 1 do 5 sekund).

W tabeli 4.60 załączono 10 wyników rozpoznawania sygnałów akustycznych.

[brak]



Rys. 4.28. Skuteczność rozpoznawania sygnału akustycznego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w zależności od długości próbki dźwięku do identyfikacji dla maszyny prądu stałego

Średnia skuteczność rozpoznawania sygnału akustycznego wynosiła 88,8%. Wykonanie takiego badania potwierdziło przydatność wariantu metod LPCC i klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów w rozpoznawaniu sygnałów akustycznych maszyny prądu stałego.

4.10. Eksperyment ZNWMR

Celem eksperymentu ZNWMR było znalezienie najlepszego wariantu metod rozpoznawania, który będzie można zastosować w małym urządzeniu monitorującym stan maszyny. Porównano średnią skuteczność rozpoznawania sygnału akustycznego dla wszystkich rozpatrywanych wariantów i maszyn elektrycznych (zobacz wzór 2.30). Wyniki zaprezentowano w rozdziałach 4.2–4.9. Wynika z nich, że najlepsza średnia skuteczność rozpoznawania została otrzymana dla metody FFT i zmodyfikowanego klasyfikatora NM z metrykami: Manhattan, Euklidesa i Minkowskiego (zobacz podrozdziały 4.3.1 i 4.7.1). W przypadku maszyny synchronicznej wynosiła 99,58%. Z kolei dla maszyny prądu stałego równała się 99,78%. Wyniki te (zobacz podrozdziały 4.3.1 i 4.7.1) pokazały, że próbki pięciosekundowe dawały skuteczność rozpoznawania sygnału akustycznego na poziomie 100% dla obydwóch maszyn elektrycznych. Ponadto z badań wynikało, że próbki o długościach od 1 do 4 sekund dają niższą skuteczność rozpoznawania od próbek pięciosekundowych (zobacz podrozdział 4.4.1).

[brak]

4.11. Eksperyment WNWMM

Celem eksperymentu WNWMM była weryfikacja najlepszego wariantu metod rozpoznawania programem Matlab. W tym celu zaimplementowano FFT i zmodyfikowany klasyfikator NM z metrykami Manhattan, Euklidesa, Minkowskiego w programie Matlab. Kolejno przeprowadzono rozpoznawanie próbek dźwięku maszyn elektrycznych z zastosowaniem programu Matlab. Wyniki były identyczne z SARSA (zobacz podrozdziały 4.3.1, 4.7.1). Badanie takie potwierdziło, że wyniki uzyskane za pomocą SARSA i programu Matlab są takie same dla obydwóch maszyn elektrycznych.

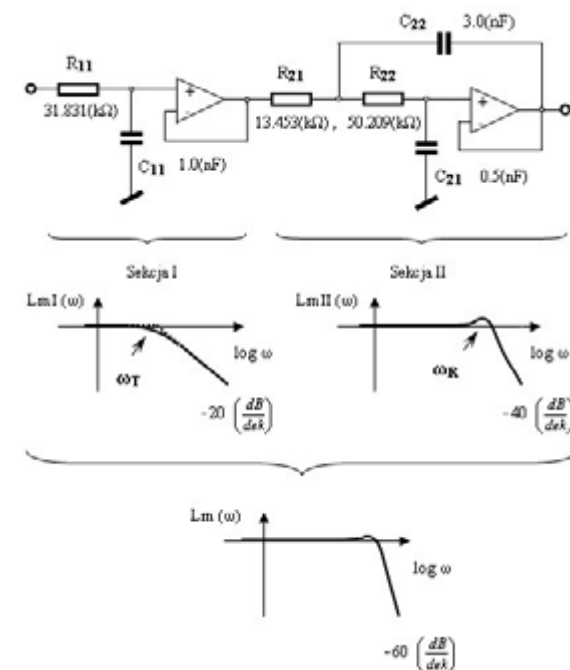
[brak weryfikacji]

4.12. Eksperyment PWMS

Celem eksperymentu PWMS była weryfikacja metod rozpoznawania sygnału akustycznego za pomocą techniki badania prądów wzbudzenia maszyny synchronicznej. Pomiary sygnałów zostały przeprowadzone przy zastosowaniu oprogramowania komputerowego i karty pomiarowej, której częstotliwość próbkowania wynosiła $f_p = 40000$ Hz. W celu zapewnienia skutecznego odcinania niepożądanych częstotliwości zaproponowano filtr antyaliasingowy, którego częstotliwość odcięcia miała wartość 5 kHz.

[brak weryfikacji]

Filtr ten został pokazany na rysunku 4.29.




Rys. 4.29. Filtr antyaliasingowy Butterwortha [114]

Pomiary wykonano przy użyciu sprzętu komputerowego z 16-bitową kartą A/C. Ze względu na

istniejące zagrożenie zniszczenia maszyn, pomiary wykonano przy ograniczeniu prądów w obwodach maszyn poprzez wprowadzenie rezystancji do tych obwodów. W celu zabezpieczenia karty pomiarowej przed uszkodzeniami elektrycznymi ze strony obwodów siłowych maszyn zastosowano separatory elektroniczne. Dzięki zastosowaniu przetworników typu LEM uzyskano pomiary z napięciową reprezentacją mierzonych wielkości oraz dopasowanie zakresu zmian sygnałów dla karty pomiarowej [114]. Do rozpoznawania sygnału prądu zastosowano system automatycznego rozpoznawania prądu (SARP). W systemie przyjęto następujące metody przetwarzania danych, segmentację, okienkowanie, metodę wyboru amplitud dla częstotliwości, FFT i zmodyfikowany klasyfikator NM z metryką Euklidesa. Metody te razem tworzyły technikę badania prądów. Technika ta została wybrana ze względu na jej prawidłowe działanie dla sygnałów akustycznych (zobacz podrozdziały 4.3.1, 4.7.1).

W badaniach stany pracy maszyny synchronicznej zostały określone następująco: bez uszkodzeń, ze zwartymi zewzwojami stojana, z jedną przerwą w obwodzie stojana oraz z trzema przerwami w obwodzie stojana. Metoda wybierania amplitud dla częstotliwości wskazała, że najlepiej rozróżnialne amplitudy występują dla częstotliwości 100 Hz (w przypadku tego eksperymentu wszystkie operacje były wykonywane na sygnale prądu wzbudzenia zobacz wzory 2.3, 2.5, 2.6, 2.7). Na rysunku 4.30 zostało przedstawione widmo częstotliwości prądu wzbudzenia maszyny synchronicznej dla czterech różnych stanów pracy po zastosowaniu algorytmu wybierania amplitudy dla częstotliwości 100 Hz. Analizując wykresy 4.1 i 4.30 można zauważyć jak zmieniają się wartości amplitud dla częstotliwości w zależności od stanu pracy maszyny synchronicznej.



Rys. 4.30. Widmo częstotliwości prądu wzbudzenia maszyny synchronicznej dla czterech różnych stanów pracy po zastosowaniu algorytmu wybierania amplitudy dla częstotliwości 100 Hz


Zmiany widoczne są zarówno w widmach częstotliwości generowanych sygnałów akustycznych, jak i prądu wzbudzenia. W procesie tworzenia wzorców do rozpoznawania stosowano 16 jednosekundowych próbek sygnału prądu wzbudzenia. W procesie identyfikacji zastosowano 176 próbek. Próbki te były

jednosekundowe, ponieważ długość taka była wystarczająca do rozpoznawania stanu maszyny synchronicznej. Zarówno w przypadku maszyny synchronicznej bez uszkodzeń, maszyny synchronicznej ze zwartymi zezwojami stojana, maszyny synchronicznej z jedną przerwą w obwodzie stojana, jak i maszyny synchronicznej z trzema przerwami w obwodzie stojana, skuteczność rozpoznawania prądu wzbudzenia wynosiła 100% (zobacz wzór 2.29). Wykonanie takiego badania potwierdziło, że metody rozpoznawania sygnałów akustycznych rozpoznawały właściwe stany pracy maszyny synchronicznej.

4.13. Eksperyment PTMPS

Celem eksperymentu PTMPS była weryfikacja metod rozpoznawania sygnału akustycznego za pomocą techniki badania prądów twornika maszyny prądu stałego. Pomiary sygnałów i obliczenia zostały przeprowadzone przy zastosowaniu takich samych narzędzi i metod jak w przypadku maszyny synchronicznej (zobacz podrozdział 4.12).

W badaniach stany pracy maszyny prądu stałego zostały określone następująco: bez uszkodzeń oraz ze zwartymi zezwojami wirnika. Metoda wybierania amplitud dla częstotliwości wskazała, że najlepiej rozróżnialne amplitudy występują dla częstotliwości 46,6 Hz (w przypadku tego eksperymentu wszystkie operacje były wykonywane na sygnale prądu twornika zobacz wzory 2.4, 2.5, 2.6, 2.7). Widmo częstotliwości prądu twornika maszyny prądu stałego dla dwóch różnych stanów pracy po zastosowaniu algorytmu wybierania amplitudy dla częstotliwości 46,6 Hz zostało przedstawione na rysunku 4.31.



Rys. 4.31. Widmo częstotliwości prądu twornika maszyny prądu stałego dla dwóch różnych stanów pracy po zastosowaniu algorytmu wybierania amplitudy dla częstotliwości 46,6 Hz

Z rysunku tego wynika, że amplitudy dla częstotliwości prądu twornika maszyny prądu stałego ze zwartymi zezwojami wirnika są kilka razy większe w porównaniu z amplitudami dla częstotliwości w stanie pracy bezawaryjnej. Taka relacja jest wystarczająca, aby stwierdzić zaistnienie uszkodzenia. Analizując wykresy 4.15 i 4.31 można zauważyć jak zmieniają się wartości amplitud dla częstotliwości w

[brak weryfikacji]

zależności od stanu pracy maszyny prądu stałego. Zmiany widoczne są zarówno w widmach częstotliwości generowanych sygnałów akustycznych, jak i prądu twornika.

W procesie tworzenia wzorców do rozpoznawania stosowano 16 jednosekundowych próbek sygnałów prądu. W procesie identyfikacji zastosowano 88 próbek. Próbki te były jednosekundowe, ponieważ długość taka była wystarczająca do rozpoznawania stanu maszyny prądu stałego. W przypadku maszyny prądu stałego bez uszkodzeń i tej ze zwartymi zewzwojami wirnika skuteczność rozpoznawania prądu twornika wynosiła 100% (zobacz wzór 2.29). Wykonanie takiego badania potwierdziło, że metody rozpoznawania sygnałów akustycznych rozpoznawały właściwe stany pracy maszyny prądu stałego.

4.14. Podsumowanie

Przeprowadzono badania sygnałów, akustycznych zmierzające do skonfigurowania metod przetwarzania i analizy w celu uzyskania jak najlepszego wariantu metod rozpoznawania dla danej maszyny elektrycznej. Badania miały również wykazać pośrednio, że stanowisko zostało zbudowane właściwie. W tym celu zostały przeprowadzone odpowiednie eksperymenty (zobacz podrozdziały 4.2-4.13). W eksperymentach badano różne warianty metod ekstrakcji cech i klasyfikacji w zależności od długości próbek dźwięku do rozpoznawania.

Przeprowadzenie takich badań pozwalało zaobserwować zmiany skuteczności rozpoznawania sygnału akustycznego w zależności od długości próbek dźwięku dla danego wariantu metod rozpoznawania. Po przeprowadzeniu tak przygotowanych badań można było stwierdzić, który wariant metod rozpoznawania jest najlepszy i jaka długość próbki jest właściwa do rozpoznawania (zobacz podrozdział 4.10). Określenie właściwej długości próbki było istotne, ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyn elektrycznych.

Ponadto eksperymenty potwierdzały, że w sygnale akustycznym zawarta jest informacja o stanie pracy maszyn (zobacz podrozdziały 4.2-4.10).

Technika (wariant metod) rozpoznawania, dla której uzyskano najwyższą średnią skuteczność rozpoznawania, została zweryfikowana programem Matlab (zobacz podrozdział 4.11).

Kolejno wykonano weryfikację techniką badania prądów wzbudzenia i twornika maszyn elektrycznych (zobacz podrozdziały 4.12-4.13). Wykonanie weryfikacji potwierdziło, że metody rozpoznawania sygnałów akustycznych rozpoznawały właściwe stany pracy maszyn elektrycznych.

4.6. Podsumowanie

Przeprowadzono badania sygnałów prądowych i napięciowych zmierzające do skonfigurowania metod przetwarzania i analizy, w celu uzyskania jak najlepszego wariantu metod rozpoznawania dla danej maszyny elektrycznej. Badania miały również wykazać pośrednio, że stanowisko zostało zbudowane właściwie. W tym celu zostały przeprowadzone odpowiednie eksperymenty. W eksperymentach badano różne warianty metod ekstrakcji cech i klasyfikacji w zależności od długości próbek prądu/napięcia do rozpoznawania.

Przeprowadzenie takich badań pozwalało zaobserwować zmiany skuteczności rozpoznawania sygnału prądowego/napięciowego w zależności od długości próbek prądu/napięcia dla danego wariantu metod rozpoznawania (dodatek B, tabele 4.25 - 4.48). Analizując wyniki można było stwierdzić, który wariant metod rozpoznawania jest najlepszy i jaka długość próbki jest właściwa do rozpoznawania. Określenie właściwej długości próbki było istotne ponieważ potwierdzało możliwość zastosowania stanowiska do monitoringu maszyn elektrycznych.

Eksperymenty potwierdziły, że w sygnałach prądowych i napięciowych zawarta jest informacja o stanie pracy maszyn. Zastosowane metody rozpoznawania sygnałów prądowych i napięciowych pozwoliły prawidłowo określić stan pracy maszyn elektrycznych.

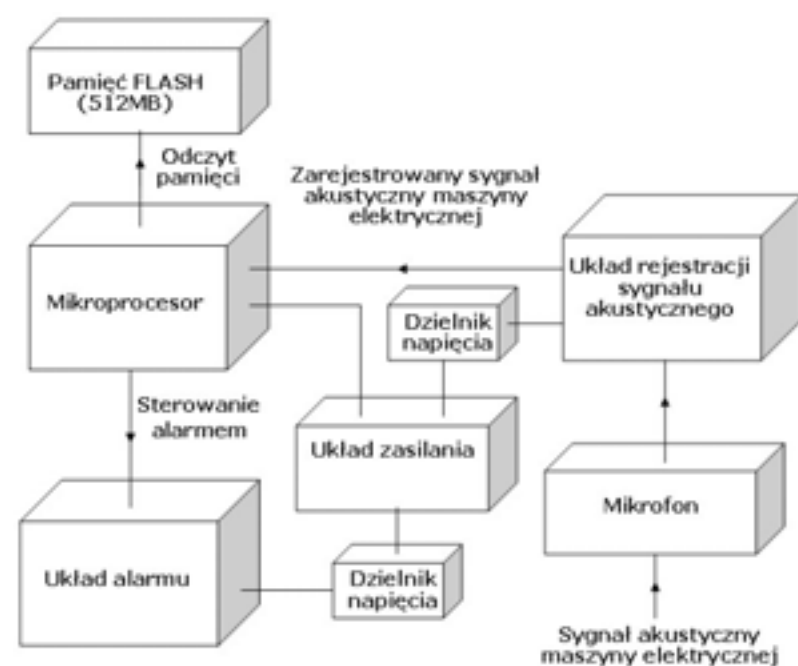
Skuteczność rozpoznawania wyznaczono za pomocą programu Matlab [128].

Wyniki przedstawione w pracy zostały uzyskane w warunkach laboratoryjnych.

W badaniach przemysłowych skuteczność rozpoznawania będzie gorsza.

5. PROJEKT URZĄDZENIA MONITORUJĄCEGO MASZYNĘ ELEKTRYCZNĄ

W rozdziale tym zaproponowano projekt urządzenia monitorującego maszynę elektryczną w ruchu. Projekt ten zawierał propozycję powiązania opracowanych algorytmów ze sprzętem właściwym do prowadzenia diagnostyki maszyny. W dalszym ciągu umożliwi to budowę urządzenia, które sprawi, że diagnostyka maszyn oparta na badaniu sygnałów akustycznych stanie się bardziej opłacalna. Urządzenie takie będzie: małe, tanie, bezprzewodowe oraz przenośne. Podobnie jak w przypadku stanowiska diagnostycznego w projekcie urządzenia należy uwzględnić wyposażenie informatyczne i sprzętowe. Pierwsze zostanie omówione wyposażenie sprzętowe. Wyposażenie to powinno zawierać: układ rejestracji sygnału akustycznego, mikrofon, układ alarmu, układ zasilania, pamięć FLASH oraz mikroprocesor. Schemat połączeń sprzętu dla urządzenia monitorującego maszynę elektryczną został przedstawiony na rysunku 5.1. Mikroprocesor zostanie podłączony do układu rejestracji sygnału akustycznego, układu alarmu, układu zasilania oraz pamięci FLASH (512MB). Mikroprocesor ten powinien mieć odpowiednią moc obliczeniową, aby móc przetwarzać kolejne próbki dźwięku.

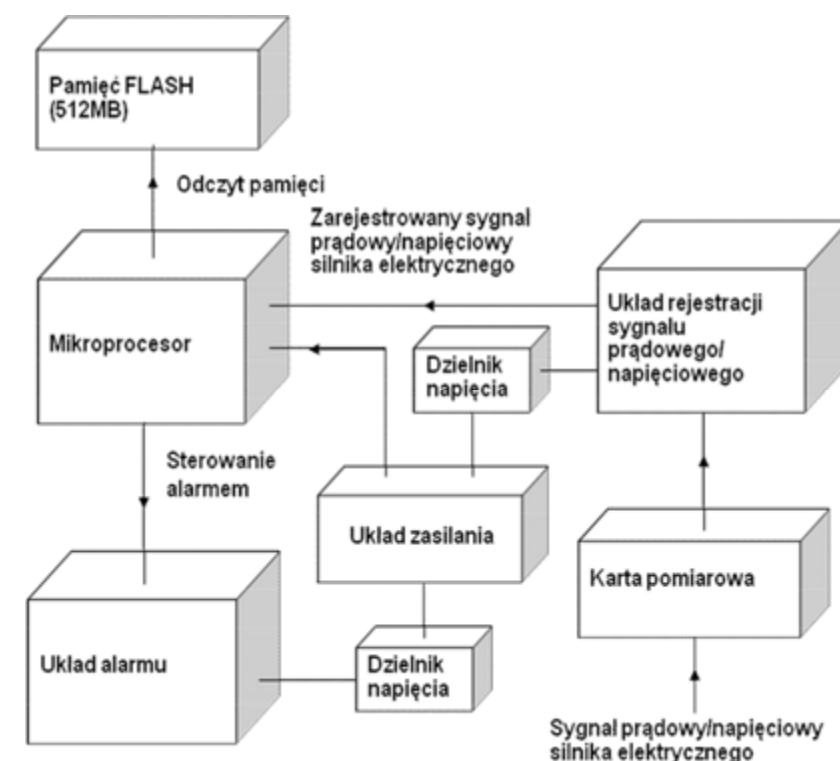


Rys. 5.1. Schemat połączeń sprzętu dla urządzenia monitorującego maszynę elektryczną


5. PROJEKT URZĄDZENIA MONITORUJĄCEGO SILNIK ELEKTRYCZNY

5.1. Opis projektu

W rozdziale tym zaproponowano projekt urządzenia monitorującego maszynę elektryczną w ruchu. Projekt ten zawierał propozycję powiązania opracowanych (i opisanych w poprzednich rozdziałach) algorytmów ze sprzętem właściwym do prowadzenia diagnostyki maszyny. W dalszym ciągu umożliwi to budowę urządzenia, które sprawi, że diagnostyka maszyn oparta na badaniu sygnałów prądowych i napięciowych stanie się bardziej opłacalna. Urządzenie takie będzie: małe, tanie, bezprzewodowe oraz przenośne. Podobnie jak w przypadku stanowiska diagnostycznego w projekcie urządzenia należy uwzględnić wyposażenie informatyczne i sprzętowe. Pierwsze zostanie omówione wyposażenie sprzętowe. Wyposażenie to powinno zawierać: układ rejestracji sygnału prądowego/napięciowego, układ alarmu, układ zasilania, pamięć FLASH oraz mikroprocesor. Schemat połączeń sprzętu dla urządzenia monitorującego maszynę elektryczną został przedstawiony na rysunku 5.1. Mikroprocesor zostanie podłączony do układu rejestracji sygnału prądowego/napięciowego, układu alarmu oraz pamięci FLASH (4GB). Mikroprocesor ten powinien mieć moc obliczeniową [20-40] GFLOPS, aby móc przetwarzać kolejne próbki prądu/napięcia.



Rys. 5.1. Schemat połączeń sprzętu dla urządzenia monitorującego silnik elektryczny



Rys. 5.3. Przykład skanowania [127]

Układ rejestracji sygnału akustycznego powinien rejestrować dźwięki z odpowiednimi parametrami (zobacz podrozdział 2.1), dlatego będzie on zintegrowany z mikrofonem OLYMPUS TP-7. Urządzenie monitorujące maszynę elektryczną będzie rejestrować pięciosekundowe próbki dźwięku, ponieważ próbki o tej długości dawały najlepszą skuteczność rozpoznawania sygnału akustycznego. Próbki będą tworzyć zbiory uczące i testowe. Zbiory te zapisywane będą w pamięci FLASH.

Urządzenie do monitorowania maszyny elektrycznej będzie zawierać układ alarmowy, który będzie odpowiadał różnym rodzajom rozpoznawanych kategorii dźwięków. Sygnał akustyczny klaksonu samochodowego będzie oznaczać, że maszyna pracuje dobrze, natomiast sygnał akustyczny karetki pogotowia będzie sygnalizować określone uszkodzenie.

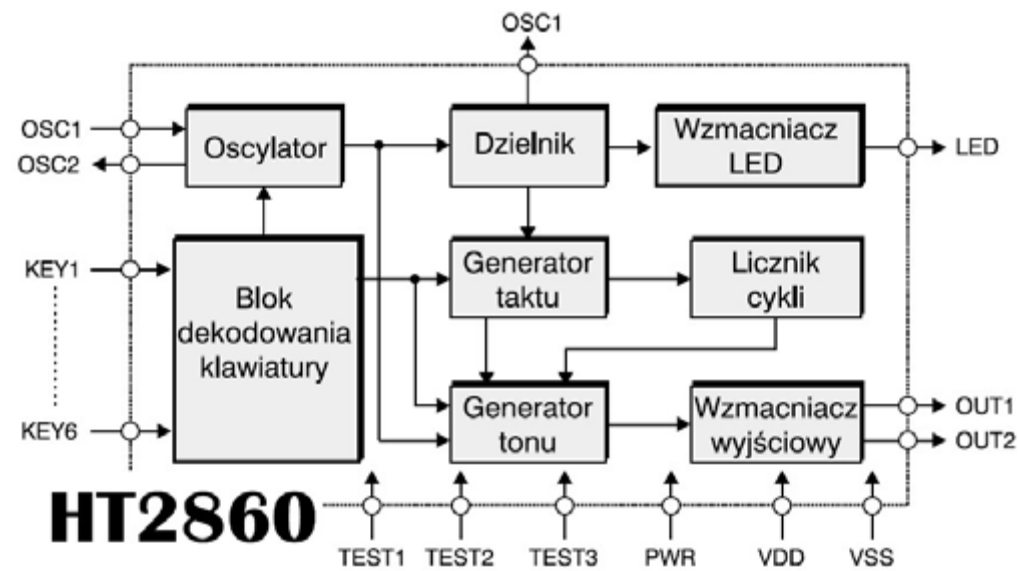
Odgłos alarmu będzie sygnalizować poprawnie przeprowadzony proces tworzenia wzorców do rozpoznawania.

Obecnie znany jest układ HT2860, który generuje sześć różnych sygnałów akustycznych, w tym sygnał zbliżony do klaksonu samochodowego i karetki pogotowia. Dzięki niskiemu kosztowi układ ten można zastosować jako generator sygnałów akustycznych w małym urządzeniu monitorującym. Schemat blokowy układu HT2860 został przedstawiony na rysunku 5.4.

Układ rejestracji sygnału prądowego/napięciowego powinien rejestrować prądy/napięcia z odpowiednimi parametrami. Urządzenie monitorujące maszynę elektryczną będzie rejestrować pięciosekundowe próbki prądu/napięcia, ponieważ próbki o tej długości dawały najlepszą skuteczność rozpoznawania sygnału prądowego/napięciowego. Próbki będą tworzyć zbiory uczące i testowe. Zbiory te zapisywane będą w pamięci FLASH.

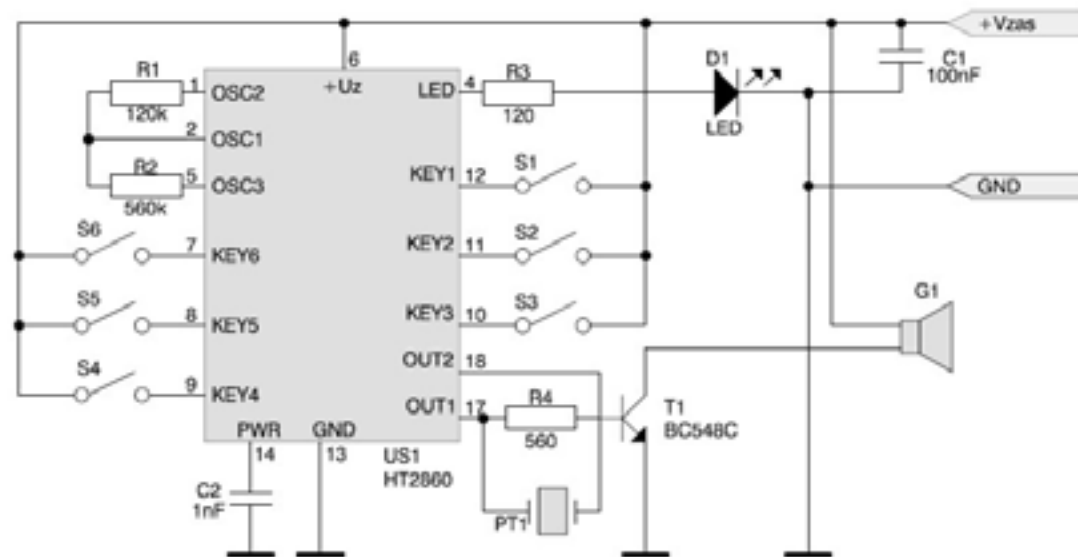
Urządzenie do monitorowania maszyny elektrycznej będzie zawierać układ przetwarzania tekstu na mowę, który będzie informował o rodzaju rozpoznawanych kategorii prądów/napięć i sygnalizował określone uszkodzenie.

Obecnie znany jest układ ISD9160. Schemat blokowy układu ISD9160 został przedstawiony na rysunku 5.4.



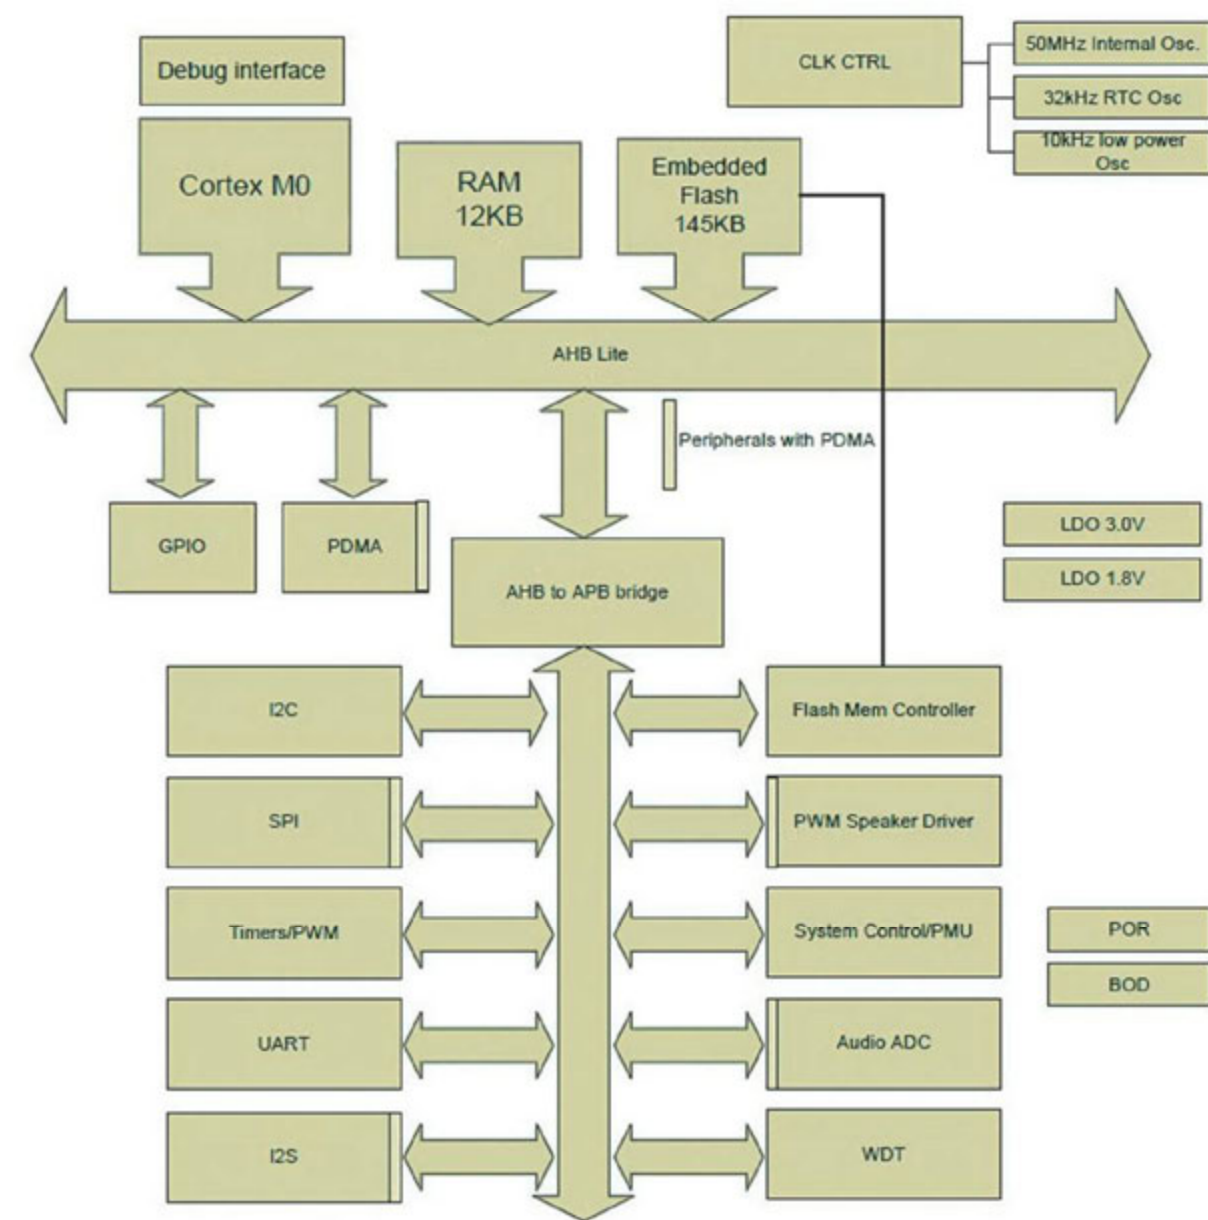
Rys. 5.4. Schemat blokowy układu HT2860 [28]

Schemat elektryczny generatora sygnałów akustycznych HT2860 został przedstawiony na rysunku 5.5. Układ ten jest szczegółowo omówiony w literaturze [28].




Rys. 5.5. Schemat elektryczny generatora sygnałów akustycznych [28]

Układ zasilania urządzenia monitorującego maszynę elektryczną został zaprojektowany na baterię 12 V. Przedstawiony jest on na rysunku 5.6.



Rys. 5.4. Schemat blokowy układu ISD9160 [125]

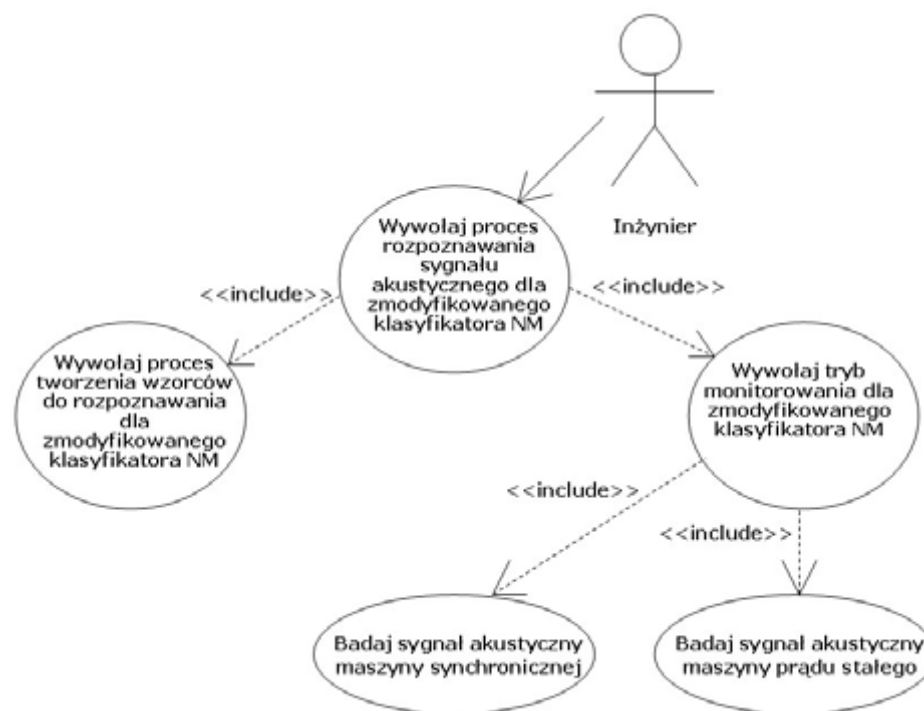
Układ ten jest opisany w literaturze [125]. Dzięki niskiemu kosztowi można go zastosować w małym urządzeniu monitorującym.



Rys. 5.6. Układ zasilania urządzenia monitorującego maszynę elektryczną

Na podstawie prowadzonych badań (zobacz rozdział 4) przyjęto, że wyposażenie informatyczne urządzenia powinno zawierać SARSA z wybranymi algorytmami przetwarzania danych. Proponowane są następujące algorytmy: normalizacja amplitudy, segmentacja, okienkowanie, FFT, wyboru amplitud dla częstotliwości oraz zmodyfikowany klasyfikator NM z metryką Euklidesa.

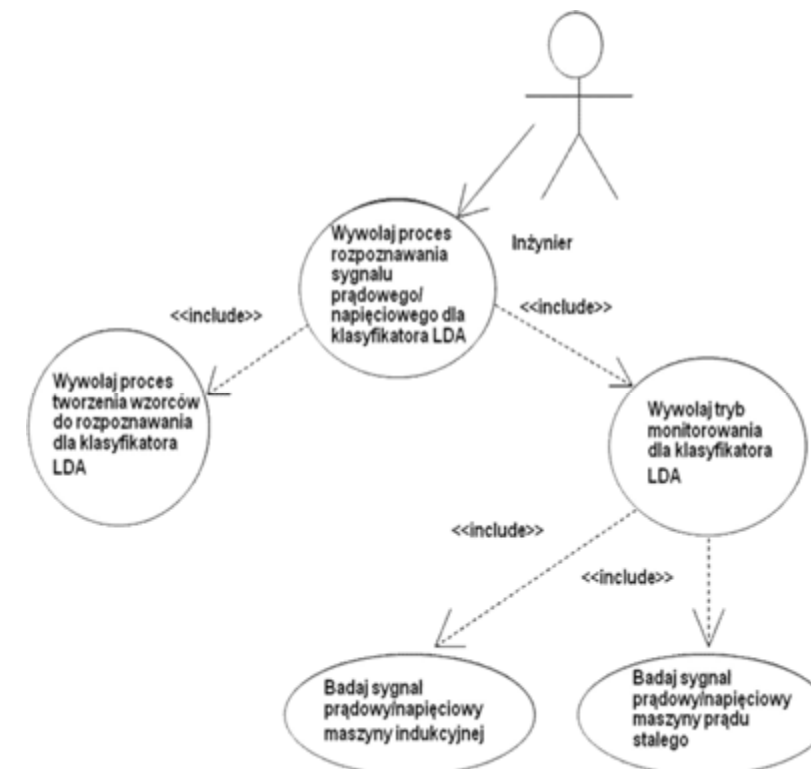
Dla takiej techniki (wariantu metod) rozpoznawania sygnału akustycznego przypadki użycia urządzenia monitorującego maszynę elektryczną zostały przedstawione na rysunku 5.7. Przypadek użycia „Wywołaj proces rozpoznawania sygnału akustycznego dla zmodyfikowanego klasyfikatora NM” składa się z dwóch przypadków użycia „Wywołaj proces tworzenia wzorców do rozpoznawania dla zmodyfikowanego klasyfikatora NM” oraz „Wywołaj tryb monitorowania dla zmodyfikowanego klasyfikatora NM”.



Rys. 5.7. Diagram przypadków użycia urządzenia monitorującego maszynę elektryczną

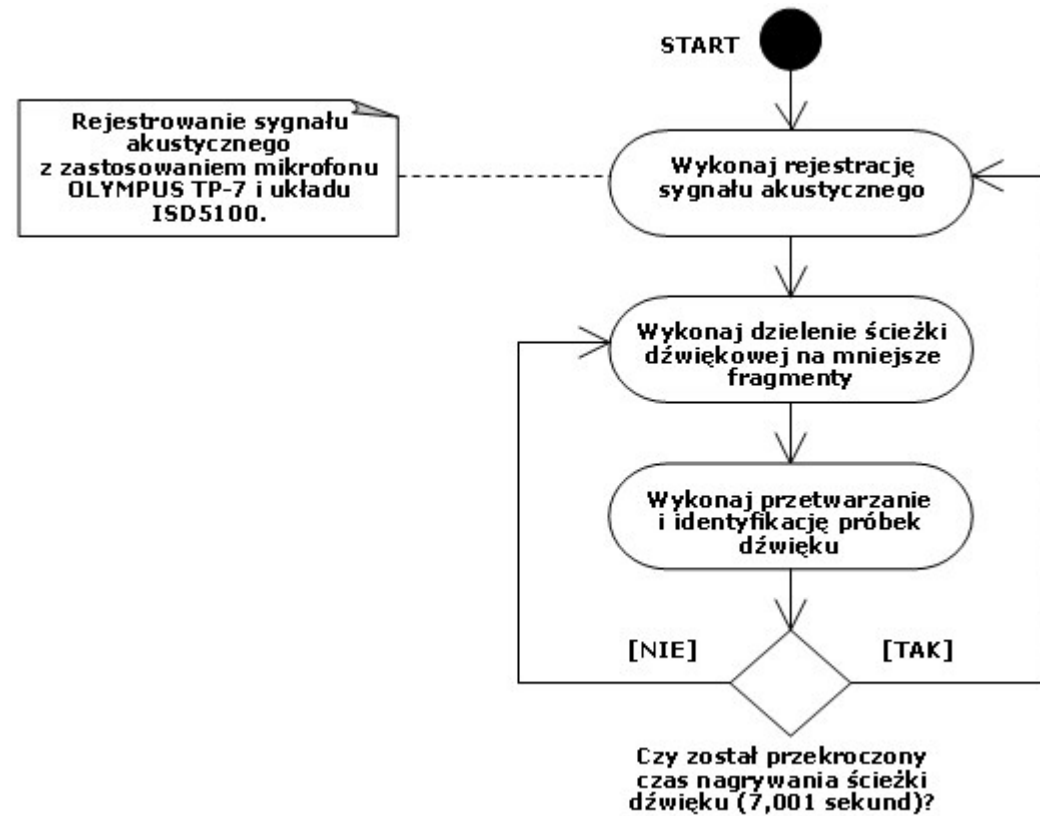
Na podstawie prowadzonych badań przyjęto, że wyposażenie informatyczne urządzenia powinno zawierać SARSA z wybranymi algorytmami przetwarzania danych. Proponowane są następujące algorytmy: normalizacja amplitudy, segmentacja, okienkowanie, FFT, wyboru amplitud dla częstotliwości oraz klasyfikator LDA.

Dla takiej techniki (wariantu metod) rozpoznawania sygnału prądowego/napięciowego przypadki użycia urządzenia monitorującego maszynę elektryczną zostały przedstawione na rysunku 5.5. Przypadek użycia „Wywołaj proces rozpoznawania sygnału prądowego/napięciowego dla klasyfikatora LDA” składa się z dwóch przypadków użycia „Wywołaj proces tworzenia wzorców do rozpoznawania dla klasyfikatora LDA” oraz „Wywołaj tryb monitorowania dla klasyfikatora LDA”.



Rys. 5.5. Diagram przypadków użycia urządzenia monitorującego silnik elektryczny

Diagram czynności trybu monitorowania dla zmodyfikowanego klasyfikatora NM został przedstawiony na rysunku 5.8.



Rys. 5.8. Diagram czynności trybu monitorowania dla zmodyfikowanego klasyfikatora NM

Jest on bardzo podobny do diagramu czynności stanowiska diagnostycznego podczas trybu monitorowania (zobacz rysunek 3.9). Różnica polega tu na zastosowaniu odpowiednich układów elektronicznych i wybranych algorytmów przetwarzania danych.

5.1. Podsumowanie

W rozdziale tym zaproponowano projekt urządzenia monitorującego maszynę elektryczną w ruchu. Projekt ten zawierał propozycję powiązania opracowanych algorytmów ze sprzętem właściwym do prowadzenia diagnostyki maszyny. W dalszym ciągu umożliwi to budowę urządzenia, które sprawi, że diagnostyka maszyn oparta na badaniu sygnałów akustycznych stanie się bardziej opłacalna. Urządzenie takie będzie: małe, tanie, bezprzewodowe oraz przenośne. Podobnie jak w przypadku stanowiska diagnostycznego w projekcie urządzenia uwzględniono wyposażenie informatyczne i sprzętowe. Różnica pomiędzy małym urządzeniem a stanowiskiem polegała na zastosowaniu odpowiednich układów elektronicznych i wybranych algorytmów przetwarzania danych.

5.2. Podsumowanie

W rozdziale tym zaproponowano projekt urządzenia monitorującego maszynę elektryczną w ruchu. Projekt ten zawierał propozycję powiązania opracowanych algorytmów ze sprzętem właściwym do prowadzenia diagnostyki maszyny. W dalszym ciągu umożliwi to budowę urządzenia, które sprawi, że diagnostyka maszyn oparta na badaniu sygnałów prądowych i napięciowych stanie się bardziej opłacalna. Urządzenie takie będzie: małe, tanie, bezprzewodowe oraz przenośne. Podobnie jak w przypadku stanowiska diagnostycznego w projekcie urządzenia uwzględniono wyposażenie informatyczne i sprzętowe. Różnica pomiędzy małym urządzeniem a stanowiskiem polegała na zastosowaniu odpowiednich układów elektronicznych i wybranych algorytmów przetwarzania danych.

6. PODSUMOWANIE I KIERUNKI DALSZYCH PRAC

Celem pracy doktorskiej było przeprowadzenie tezy, że zastosowanie algorytmów rozpoznawania umożliwia użycie metod analizy sygnału akustycznego do efektywnej diagnostyki stanów przedawaryjnych maszyn elektrycznych. Aby osiągnąć ten cel, zrealizowano następujące zadania badawcze: przeanalizowano problemy rozpoznawania stanów przedawaryjnych maszyn elektrycznych, przedyskutowano możliwości zastosowania wybranych metod przetwarzania i analizy sygnału akustycznego, dokonano implementacji poszczególnych metod, opracowano projekt stanowiska diagnostycznego do badania sygnałów akustycznych maszyn elektrycznych, przeprowadzono badania sygnałów akustycznych zmierzające do skonfigurowania metod przetwarzania i analizy w celu uzyskania najlepszej metody rozpoznawania dla wybranych typów maszyn elektrycznych, przeprowadzono weryfikację wyników rozpoznawania sygnałów akustycznych oraz przedstawiono projekt urządzenia monitorującego maszynę elektryczną w trakcie jej eksploatacji.

Rozważania prowadzone w pracy doktorskiej dotyczyły dwóch wybranych maszyn elektrycznych. Przeprowadzone badania pokazały, że stany pracy maszyn testowych znajdowały odbicie w sygnałach akustycznych przez nie generowanych w stopniu wystarczającym, aby metody rozpoznające z zadawalającą precyzją wskazywały pojawianie się monitorowanych uszkodzeń.

Istotnym czynnikiem wpływającym na uzyskanie wysokiej skuteczności rozpoznawania sygnału akustycznego była długość próbki dźwięku stosowana do rozpoznawania. Wykazano również, iż zmodyfikowany klasyfikator NM z metrykami Manhattan, Euklidesa i Minkowskiego działał najlepiej przy wypracowanych metodach obróbki. Dobre wyniki zostały otrzymane dla przypadku z klasyfikatorem opartym na słowach. Sieć neuronowa z algorytmem wstecznej propagacji błędów miała niższą skuteczność rozpoznawania niż pozostałe klasyfikatory. Spośród algorytmów FFT, LPCC, LPC najlepszą skuteczność rozpoznawania sygnału akustycznego dawały FFT i LPCC. Podsumowując wyniki eksperymentów, można stwierdzić, że teza dysertacji została przeprowadzona.

Oryginalnymi elementami przedstawionej pracy doktorskiej są zdaniem autora:

- 1) Opracowanie technik analizy informacji zawartej w sygnałach akustycznych maszyn elektrycznych dla stanów przedawaryjnych. Techniki te zostały zrealizowane w następujących etapach obróbki sygnału: rejestracji sygnału akustycznego, filtracji, normalizacji amplitudy, segmentacji, okienkowania, ekstrakcji cech i klasyfikacji.
- 2) Opracowanie i implementacja metody wyboru amplitud dla częstotliwości, klasyfikatora opartego na słowach, klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji.

6. PODSUMOWANIE I KIERUNKI DALSZYCH PRAC

Celem niniejszej rozprawy było udowodnienie tezy, że zastosowanie algorytmów rozpoznawania umożliwia użycie metod analizy sygnałów prądowych lub napięciowych do efektywnej diagnostyki stanów przedawaryjnych silników elektrycznych. Aby osiągnąć ten cel w pracy zrealizowano następujące zadania badawcze: omówiono problemy rozpoznawania stanów przedawaryjnych silników elektrycznych, przedstawiono wybrane metody przetwarzania, analizy i rozpoznawania sygnału prądowego/napięciowego, dokonano implementacji poszczególnych metod, opracowano projekt stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych maszyn elektrycznych, przeprowadzono badania sygnałów prądowych i napięciowych zmierzające do skonfigurowania metod przetwarzania, analizy i rozpoznawania dla danego silnika elektrycznego, przeprowadzono weryfikację wyników rozpoznawania sygnałów prądowych i napięciowych oraz przedstawiono projekt urządzenia monitorującego silnik elektryczny w ruchu.

[Fragment przestawiony dalej]

Oryginalnymi elementami w pracy doktorskiej są:

- 1) Opracowanie technik analizy informacji zawartej w sygnałach prądowych i napięciowych silników elektrycznych dla stanów przedawaryjnych. Techniki te zostały zrealizowane w następujących etapach: rejestracji sygnału prądowego/napięciowego, filtracji, normalizacji amplitudy, segmentacji, okienkowania, ekstrakcji cech i klasyfikacji .
- 2) Opracowanie i implementacja metody wyboru amplitud dla częstotliwości, klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów, na metodzie najbliższego sąsiada NN, Bayesa i liniowej analizie dyskryminacyjnej LDA.

3) Zaprojektowanie i zbudowanie stanowiska diagnostycznego do badania sygnałów akustycznych maszyn elektrycznych.

4) Przeprowadzenie analizy sygnałów akustycznych zmierzającej do skonfigurowania metod przetwarzania i analizy w celu uzyskania jak najlepszej metody rozpoznawania dla danej maszyny elektrycznej.

5) Przedstawienie projektu urządzenia monitorującego maszynę elektryczną w ruchu. Projekt zawierał propozycję powiązania opracowanych algorytmów ze sprzętem właściwym do prowadzenia diagnostyki maszyny w ruchu.

[Przestawiony fragment pracy poniżej]

Rozważania prowadzone w pracy doktorskiej dotyczyły dwóch wybranych maszyn elektrycznych. Przeprowadzone badania pokazały, że stany pracy maszyn testowych znajdowały odbicie w sygnałach akustycznych przez nie generowanych w stopniu wystarczającym, aby metody rozpoznające z zadawalającą precyzją wskazywały pojawianie się monitorowanych uszkodzeń.

Istotnym czynnikiem wpływającym na uzyskanie wysokiej skuteczności rozpoznawania sygnału akustycznego była długość próbki dźwięku stosowana do rozpoznawania. Wykazano również, iż zmodyfikowany klasyfikator NM z metrykami Manhattan, Euklidesa i Minkowskiego działał najlepiej przy

3) Zbudowanie stanowiska diagnostycznego do badania sygnałów prądowych i napięciowych maszyn elektrycznych.

Opracowane zostały: warunki zastosowania stanowiska, projekt stanowiska, diagramy UML (diagramy wdrożenia, diagramy przypadków użycia, diagram pakietów, diagramy czynności, diagramy sekwencji). Zaprojektowano wyposażenie techniczne i informatyczne stanowiska. Zaimplementowano system automatycznego rozpoznawania sygnałów prądowych i napięciowych (SARSP/SARSN), który zawierał wybrane algorytmy przetwarzania danych. Przygotowane zostały odpowiednie stany przedawaryjne wybranych maszyn elektrycznych. Przeprowadzono rejestrację sygnałów prądowych i napięciowych dla stanów przedawaryjnych silnika indukcyjnego i silnika prądu stałego. Omówione zostały stosowane algorytmy oraz łączenie sprzętu z oprogramowaniem. Parametry i strukturę algorytmów dostosowano do charakteru rozważanych sygnałów prądowych i napięciowych. Wprowadzona została możliwość podglądu danych w kolejnych krokach przetwarzania i analizy sygnału prądowego/napięciowego. Uwzględniona została możliwość porównywania wyników rozpoznawania sygnałów prądowych i napięciowych z innymi metodami, np. opartymi na analizie sygnałów akustycznych.

4) Przeprowadzenie analizy sygnałów prądowych i napięciowych zmierzającej do skonfigurowania metod przetwarzania i analizy w celu uzyskania jak najlepszej metody rozpoznawania dla danej maszyny elektrycznej. Przeprowadzone badania potwierdziły skuteczność proponowanego podejścia (działania systemu i algorytmów).

Badania potwierdziły również, że stanowisko zostało zbudowane właściwie.

5) Przedstawienie projektu urządzenia monitorującego maszynę elektryczną w ruchu. Projekt zawiera propozycję powiązania opracowanych algorytmów ze sprzętem właściwym do prowadzenia diagnostyki maszyny w ruchu.

Rozważania prowadzone w rozprawie doktorskiej dotyczyły dwóch wybranych maszyn elektrycznych, które generowały sygnały prądowe i napięciowe. Po przeprowadzonych badaniach można było stwierdzić, że stany pracy wybranych maszyn elektrycznych wpływały na generowane przez nie sygnały.

Istotnym czynnikiem wpływającym na uzyskanie wysokiej skuteczności rozpoznawania sygnału prądowego/napięciowego była długość próbki prądu/napięcia do rozpoznawania. Analiza opracowanych algorytmów wskazuje, iż klasyfikator LDA najlepiej rozpoznawał sygnały prądowe i

wypracowanych metodach obróbki. Dobre wyniki zostały otrzymane dla przypadku z klasyfikatorem opartym na słowach. Sieć neuronowa z algorytmem wstecznej propagacji błędów miała niższą skuteczność rozpoznawania niż pozostałe klasyfikatory. Spośród algorytmów FFT, LPCC, LPC najlepszą skuteczność rozpoznawania sygnału akustycznego dawały FFT i LPCC. Podsumowując wyniki eksperymentów, można stwierdzić, że teza dysertacji została przeprowadzona.

Należy jednak zauważyć, że proponowane podejście ma swoje ograniczenia. Istotnym ograniczeniem jest to, że budowanie wzorców do późniejszego rozpoznawania za pomocą zbudowanego środowiska musi być w zasadzie powtarzane dla każdego typu maszyny wyróżniającej się wymiarami, konstrukcją, masą, materiałami z których jest wykonana, czy też parametrami znamionowymi. Nie ma też pewności, nim nie zostanie to potwierdzone eksperymentalnie, że proponowane techniki okażą się skuteczne dla dowolnych typów maszyn generujących podczas pracy sygnał dźwiękowy. Innym problemem, który może mieć wpływ na stosowalność podejścia jest zapewnienie odpowiednich (tych samych dla testów i eksploatacji) warunków rejestracji sygnału akustycznego. W praktyce użytkownika proponowanego stanowiska odbicia, nakładania się fal akustycznych i szumy spowodowane pracą wielu maszyn elektrycznych mogą doprowadzić do znacznego zdeformowania sygnału i w konsekwencji nie dotrzymania założonej skuteczności rozpoznawania.

Wypracowane w dysertacji podejście może być, pomimo wskazanych ograniczeń, stosowane również w przypadku innych obiektów technicznych generujących sygnały akustyczne. Można przyjąć, że środowisko do badania będzie w stanie wypracować użyteczne wyniki dla szerokiego wachlarza urządzeń mechanicznych, hydraulicznych czy pneumatycznych.

Kierunki dalszych prac nad rozwijaniem zaproponowanego podejścia będą związane z opracowywaniem nowych technik analizy informacji zawartej w sygnałach akustycznych maszyn. Badania będą prowadzone w kierunku integracji technik rozpoznawania sygnałów akustycznych, elektrycznych i cieplnych. Połączenie takich badań może przyczynić się do rozwoju bardziej niezawodnych systemów diagnostycznych. Innym kierunkiem badań będzie dążenie do zbudowania małych urządzeń pozwalających szybko i tanio zbadać maszynę elektryczną. W przyszłości urządzenia takie mogą być zastosowane w przemyśle energetycznym i hutniczym. Jeszcze inne kierunki to: używanie wielu mikrofonów do rozpoznawania stanu przedawaryjnego, rozwiązanie problemu zmiany warunków środowiska, w którym

napięciowe maszyn elektrycznych. Podobnie bardzo dobre wyniki zostały otrzymane z zastosowaniem klasyfikatora NN. Klasyfikator oparty na sieci neuronowej z algorytmem wstecznej propagacji błędów i klasyfikator Bayesa miały niższą skuteczność rozpoznawania sygnału prądowego/napięciowego, niż pozostałe klasyfikatory. Spośród algorytmów FFT, LPC, LPCC najlepszą skuteczność rozpoznawania sygnału prądowego/napięciowego miały FFT, szczególnie MSAF, następnie LPCC. Na podstawie przedstawionych technik i ich wyników otrzymanych dla wybranych maszyn elektrycznych można stwierdzić, że teza naukowa rozprawy doktorskiej została udowodniona.

Należy zauważyć, że proponowane techniki są ograniczone warunkami zastosowania. Istotnym ograniczeniem jest to, że maszyny elektryczne muszą mieć wymiary, konstrukcje, masę, materiały, z których są wykonane, parametry znamionowe takie same jak te, na których przeprowadzany został proces tworzenia wzorców do rozpoznawania. Skutkuje to tym, że proponowane techniki dla pewnej grupy maszyn mogą dawać dobre wyniki, a dla innej grupy już nie. Z drugiej strony różnorodność maszyn elektrycznych jest tak duża, że prowadzenie badań nad wszystkimi rodzajami maszyn i rodzajami stanów przedawaryjnych może trwać latami. Innym problemem, który został poruszony w warunkach zastosowania stanowiska jest posiadanie takiego samego środowiska do rejestracji sygnału prądowego/napięciowego. W praktyce użytkownika proponowanego stanowiska szumy spowodowane pracą wielu maszyn elektrycznych mogą doprowadzić do znacznego utrudnienia diagnostyki. Taką sytuację można jednak częściowo rozwiązać weryfikując metody oparte na badaniu sygnałów prądowych i napięciowych za pomocą innych metod.

Proponowane stanowisko diagnostyczne do badania sygnałów prądowych i napięciowych, techniki oraz ich wyniki eksperymentalne są istotne dla nauk technicznych, w tym informatyki. Wyniki badań potwierdzają, że stanowisko może być przydatne do wykrywania uszkodzeń i zabezpieczania maszyn elektrycznych. Maszyny te występowały tutaj jako obiekty. Zatem zastosowane podejście może być stosowane w innych obiektach generujących sygnały elektryczne.

Kierunki dalszych prac będą związane z opracowywaniem nowych technik analizy informacji zawartej w sygnałach prądowych i napięciowych maszyn. Badania będą prowadzone w kierunku integracji technik rozpoznawania sygnałów prądowych i napięciowych, elektrycznych i cieplnych. Połączenie takich badań może przyczynić się do rozwoju bardziej niezawodnych systemów diagnostycznych. Innym kierunkiem badań będzie dążenie do zbudowania małych urządzeń pozwalających szybko zbadać maszynę elektryczną. W przyszłości urządzenia takie mogą być zastosowane w przemyśle energetycznym oraz hutniczym. Jeszcze innymi kierunkami badań mogą

rejestrwany jest sygnał akustyczny, zaproponowanie uniwersalnej techniki analizy informacji zawartej w sygnałach akustycznych wielu rodzajów maszyn, różniących się wymiarami, konstrukcją, masą, materiałami, z których są wykonane, parametrami znamionowymi.

być problemy nierozpatrywane w pracy doktorskiej: rozwiązanie problemu zmiany warunków środowiska, w którym rejestrwany jest sygnał prądowy/napięciowy, zaproponowanie uniwersalnej techniki analizy informacji zawartej w sygnałach prądowych i napięciowych wielu rodzajów maszyn, różniących się wymiarami, konstrukcją, masą, materiałami, z których są wykonane, parametrami znamionowymi.

Bibliografia

- [1] Alexandre E., Cuadra L., Álvarez L., Rosa-Zurera M., López-Ferreras F.: Two-layer automatic sound classification system for conversation enhancement in hearing aids. *Integrated Computer-Aided Engineering*, Vol. 15, No. 1, 2008, 85–94.
- [2] Antoniol G., Rollo F., Venturi G.: Linear Predictive Coding and Cepstrum Coefficients for mining time variant information from software repositories. *Second International Workshop on Mining Software Repositories*, St. Louis, USA, 17 May 2005, 74–78.
- [3] Benetos E., Kotti M., Kotropoulos C., Burred J., Eisenberg G., Haller M., Sikora T.: Comparison of subspace analysis-based and statistical model-based algorithms for musical instrument classification. *Second Workshop on Immersive Communication and Broadcast Systems (ICOB)*, October 2005.
- [4] Benetos E., Kotropoulos C., Lidy T., Rauber A.: Testing supervised classifiers based on non-negative matrix factorization to musical instrument classification. *Proceedings of XIV European Signal Processing Conference*, Florence, Italy, 4–8 September 2006.
- [5] Bieniek J., Banasiak J., Komarnicki P.: Zastosowanie termowizji w badaniach eksploatacyjnych maszyn rolniczych. *Inżynieria Rolnicza*, Tom 87, Nr 12, 2006, 17–24.
- [6] Boryczko K., Kurdziel M.: Recognition of subtle microcalcifications in high-resolution mammograms. *Computer Recognition Systems, Advances in Soft Computing*, Berlin, Heidelberg: Springer-Verlag, 2005, 485–492.
- [7] Buchanan C. R.: Semantic-based audio recognition and retrieval. *Master's thesis*, School of Informatics, University of Edinburgh, 2005.
- [8] Burred J. J., Lerch A.: A hierarchical approach to automatic musical genre classification. *Proceedings of the sixth International Conference on Digital Audio Effects (DAFX)*, London, UK, 8–11 September 2003, 308–311.
- [9] Campbell J.: Speaker recognition: a tutorial. *Proceedings of the IEEE* 85, 9/1997, 1437–1462.
- [10] Carey M. J., Parris E. S., Lloyd-Thomas H.: A comparison of features for speech, music discrimination. *Proceedings of International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, Vol. 1, March 1999, 149–152.
- [11] Casagrande N., Eck D., Kegl B.: Geometry in sound: A speech/music audio classifier inspired by an image classifier. *Proceedings of the International Computer Music Conference (ICMC)*, 2005, 207–210.

Literatura

- [1] Andonova A. V., Hinov N. L.: Thermographic Analysis of a Bridge Power Converter. *Journal of Electrical Engineering-Elektrotechnicky Casopis*, 65, 6 (2014), pp. 371-375.
- [2] Antoniol G., Rollo F., Venturi G.: Linear Predictive Coding and Cepstrum Coefficients for mining time variant information from software repositories. *Second International Workshop on Mining Software Repositories*, St. Louis, USA, 17 May 2005, 74–78.
- [3] Augustyniak P., Czopek K.: Wykorzystanie sieci neuronowych do przetwarzania sygnałów bioelektrycznych na przykładzie EKG. *Wyd. Inżynieria biomedyczna - podstawy i zastosowania*. T. 9, Sieci neuronowe w inżynierii biomedycznej, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2013, s. 53–93.
- [4] Augustyniak P., Smoleń M., Mikrut Z., Kańtoch E.: Seamless Tracing of Human Behavior Using Complementary Wearable and House-Embedded Sensors. *Sensors*, 14, 5 (2014), pp. 7831-7856.
- [5] Ayaz E.: Autoregressive modeling approach of vibration data for bearing fault diagnosis in electric motors, *Journal of Vibroengineering*, 16, 5, 2014, 2130-2138.
- [6] Barański M., Decner A., Polak A.: Selected Diagnostic Methods of Electrical Machines Operating in Industrial Conditions. *IEEE Transactions on Dielectrics and Electrical Insulation*, 21, 5 (2014), pp. 2047-2054.
- [7] Będkowski B., Madej J.: The innovative design concept of thermal model for the calculation of the electromagnetic circuit of rotating electrical machines. *Eksploatacja i Niezawodność – Maintenance and Reliability*, 17, 4 (2015), pp. 481–486.
- [8] Bieniek J., Banasiak J., Komarnicki P.: Zastosowanie termowizji w badaniach eksploatacyjnych maszyn rolniczych. *Inżynieria Rolnicza*, Tom 87, Nr 12, 2006, 17–24.
- [9] Boryczko K., Kurdziel M.: Recognition of subtle microcalcifications in high-resolution mammograms. *Computer Recognition Systems, Advances in Soft Computing*, Berlin, Heidelberg: Springer-Verlag, 2005, 485–492.
- [10] Cempel C.: *Diagnostyka wibroakustyczna maszyn*. Państwowe Wydawnictwo Naukowe, Warszawa, 1989.
- [11] Cieśla A., Kraszewski W., Tadeusiewicz R.: Visualization of magnetic field generated by portable coil designed for magnetotherapy. *Przegląd Elektrotechniczny*, R. 88, Nr 10a, 2012, s. 127–131.
- [12] Cieśla A.: Dependence of a superconductor magnetic filter effectiveness on magnetic

- [12] Cempel C.: Diagnostyka wibroakustyczna maszyn. Państwowe Wydawnictwo Naukowe, Warszawa, 1989.
- [13] Cetnarowicz K.: Algorithm, agent and robots in cyberspace. *Recent advances in Intelligent Information Systems*, Academic Publishing House EXIT, Warsaw, 2009, 699–710.
- [14] Corneliu M., Costinescu B.: Implementing the Levinson-Durbin algorithm on the StarCore™ SC140/SC1400 Cores. Application Note Freescale Semiconductor AN2197, Rev. 1 1/2005.
- [15] Cowling M.: Non-speech environmental sound classification system for autonomous surveillance. *Ph.D. Thesis*, Griffith University, School of Information Technology, 2004.
- [16] Cruz S., Gaspar F.: A new method to diagnose rotor faults in 3-phase induction motors coupled to time-varying loads. *Przegląd Elektrotechniczny*, 01a/2012, 202-206.
- [17] Davis S. B., Mermelstein P.: Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Trans. on Acoustic, Speech and Signal Processing*, Vol. 28, Issue 4, 1980, 357–366.
- [18] Dittmar C.: Drum detection from polyphonic audio via detailed analysis of the time frequency domain. *First Music Information Retrieval Evaluation exchange (MIREX)*, London, Great Britain, 11–15 September 2005.
- [19] Dobrowolski G., Nawarecki E.: Baza wiedzy jako element sterujący modulem interfejsowym złożonego systemu informacyjnego. *Computer Methods in Materials Science*, Vol. 6, No. 2, 2006, 94–99.
- [20] Dobrowolski G., Marcjan R.: Platforma komunikacyjna integrująca różnorodne źródła informacji w procesie diagnostycznym. *KomPlasTech, Informatyka w technologii metali, materiały ósmej konferencji*, Korbielów, 14–17 stycznia 2001, 11–18.
- [21] Dudek-Dyduch E., Tadeusiewicz R., Horzyk A.: Neural network adaptation process effectiveness dependent of constant training data availability. *Neurocomputing*, Vol. 72, 2009, 3138–3149.
- [22] Dudek K., Banasiak J., Bieniek J.: Diagnostyka węzłów kinematycznych w kosiarkach rotacyjnych. *Eksplatacja i Niezawodność*, Nr 4, 2003, 17–21.
- [23] Dufaux A., Besacier L., Ansorge M., Pellandini F.: Automatic sound detection and recognition for noisy environment. *Proceedings of European Signal Processing Conference*, Tampere, Finland, 4–8 September 2000, 1033–1036.
- [24] Dustor A., Izydorczyk J.: Rozpoznawanie mówców. *Przegląd Telekomunikacyjny i wiadomości telekomunikacyjne*, Nr 2–3, 2003, 71-76.
- [25] Fan K.-C., Wang Y.-K.: A Genetic Sparse Distributed Memory approach to the application of induction, *COMPEL – International Journal for Computation Mathematics in Electrical and Electronics Engineering*, Vol. 19, No. 2, 2000, pp. 706–711.
- [13] Ciszewski T., Swędrowski L.: Diagnostyka łożysk silnika indukcyjnego na podstawie prądu zasilającego przy użyciu sztucznych sieci neuronowych. *Pomiary, Automatyka, Kontrola*, R. 59. Nr 4, 2013, s. 316-318.
- [14] Corneliu M., Costinescu B.: Implementing the Levinson-Durbin algorithm on the StarCore™ SC140/SC1400 Cores. Application Note Freescale Semiconductor AN2197, Rev. 1 1/2005.
- [15] Cowling M.: *Non-speech environmental sound classification system for autonomous surveillance*. Ph.D. Thesis, Griffith University, School of Information Technology, 2004.
- [16] Cruz S., Gaspar F.: A new method to diagnose rotor faults in 3-phase induction motors coupled to time-varying loads. *Przegląd Elektrotechniczny*, Vol. 88, No. 1a, 2012, 202206.
- [17] Czech P., Wojnar G., Burdzik R., Konieczny L., Warczek J.: Application of the discrete wavelet transform and probabilistic neural networks in IC engine fault diagnostics. *Journal of Vibroengineering*, 16, 4 (2014), pp. 1619-1639.
- [18] Dach M., Werewka J.: Analiza czasów reakcji w systemie kontrolno-diagnostycznym. W: *Systemy Czasu Rzeczywistego, materiały X Konferencji SCR'03*, Ustroń, 15–18 września 2003.
- [19] Dobrowolski G., Nawarecki E.: Baza wiedzy jako element sterujący modulem interfejsowym złożonego systemu informacyjnego. *Computer Methods in Materials Science*, Vol. 6, No. 2, 2006, s. 94–99.
- [20] Dobrowolski G., Marcjan R.: Platforma komunikacyjna integrująca różnorodne źródła informacji w procesie diagnostycznym. *KomPlasTech, Informatyka w technologii metali, materiały ósmej konferencji*, Korbielów, 14–17 stycznia 2001, s. 11–18.
- [21] Dudek-Dyduch E., Tadeusiewicz R., Horzyk A.: Neural network adaptation process effectiveness dependent of constant training data availability. *Neurocomputing*, Vol. 72, 2009, 3138–3149.
- [22] Dudek K., Banasiak J., Bieniek J.: Diagnostyka węzłów kinematycznych w kosiarkach rotacyjnych. *Eksplatacja i Niezawodność – Maintenance and Reliability*, nr 4, 2003, s. 17–21.
- [23] Dufaux A., Besacier L., Ansorge M., Pellandini F.: Automatic sound detection and recognition for noisy environment. *Proceedings of European Signal Processing Conference*, Tampere, Finland, 4–8 September 2000, 1033–1036.
- [24] Dustor A., Izydorczyk J.: Rozpoznawanie mówców. *Przegląd Telekomunikacyjny i wiadomości telekomunikacyjne*, Nr 2–3, 2003, 71-76.

- handwritten character recognition. *Pattern Recognition*, Vol. 30, No. 12, December 1997, 2015–2022.
- [26] Florkowski M.: Signal and image processing in diagnostics of electrical power equipment. *Rozprawa habilitacyjna, Rozprawy Monografie*, AGH Uczelniane Wydawnictwo Naukowo-Dydaktyczne, Kraków, 2007, 168 stron.
- [27] Ganchev T., Fakotakis N., Kokkinakis G.: Comparative evaluation of various MFCC implementations on the speaker verification task. *Proceedings of SPECOM*, Patras, Greece, Vol. 1, 17–19 October 2005, 191–194.
- [28] Generator sygnałów akustycznych alarmowych. *Elektronika Praktyczna*, Nr 2, 1998, 65–66.
- [29] Glinka T.: Degradation of electrical machines windings insulation in time. *Przegląd Elektrotechniczny*, Vol. 84, No. 7, 2008, 8–11.
- [30] Głowacz A., Dobrowolski G.: Oprogramowanie i integracja stanowiska do badania sygnałów akustycznych stanów przedawaryjnych maszyn elektrycznych. *XVIII Międzynarodowe sympozjum – Zastosowania Teorii Systemów*, Zakopane 27–29 września 2009, *Półrocznik Automatyka AGH*, Tom 13, Zeszyt 2, Uczelniane Wydawnictwo Naukowo-Dydaktyczne, Kraków, 2009, 267–274.
- [31] Głowacz A.: Diagnostyka silnika indukcyjnego oparta na analizie sygnałów akustycznych z użyciem dyskretnej transformaty falkowej Haara i klasyfikatora najbliższej średniej z metryką Euklidesa, XIV Krajowa konferencja elektryki górniczej : Zakopane, 10–12 października 2012, s. 51–59.
- [32] Głowacz A., Głowacz W.: New approach to diagnostics of DC machines by sound recognition using Linear Predictive Coding. *Human-Computer Systems Interaction. Advances in Soft Computing*, Springer Berlin/Heidelberg, Vol. 60, 13 October 2009, 529–540.
- [33] Głowacz A., Głowacz W.: Diagnostyka silnika prądu stałego oparta na rozpoznawaniu prądu wzbudzenia z zastosowaniem FFT i algorytmu wstecznej propagacji błędów, *Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie*, 2010 nr 2 s. 22–26.
- [34] Głowacz A., Głowacz Z.: Diagnostics of DC machine based on analysis of acoustic signals with application of MFCC and classifier based on words. *Archives of Metallurgy and Materials*, Vol. 57 Issue 1, 2012, 179–183.
- [35] Głowacz Z.: Modele matematyczne układów elektromechanicznych z elementami półprzewodnikowymi dla analizy stanów awaryjnych. *Rozprawy i monografie*, Wydawnictwo AGH, 1997, 140 stron.
- [36] Głowacz Z., Kozik J.: Selekcja symptomów zwarć uzwojeń twornika silnika synchronicznego z
- [25] Ebrahimi B. M., Faiz J.: Diagnosis and performance analysis of three-phase permanent magnet synchronous motors with static, dynamic and mixed eccentricity. *IET Electric Power Applications*, 4, 1 (2010), pp. 53-66.
- [26] El-Thalji I., Jantunen E.: A summary of fault modelling and predictive health monitoring of rolling element bearings. *Mechanical Systems and Signal Processing*, 6061, (2015), pp. 252-272.
- [27] Fan K.-C., Wang Y.-K.: A Genetic Sparse Distributed Memory approach to the application of handwritten character recognition. *Pattern Recognition*, Vol. 30, No. 12, December 1997, 2015–2022.
- [28] Flasiński M.: *Wstęp do sztucznej inteligencji*. Wydawnictwo Naukowe PWN, Warszawa 2011.
- [29] Florkowska B., Florkowski M., Furgał J., Pająk P., Roehrich J., Zydroń P.: Influence of fast switching phenomena on electrical insulation systems. *Przegląd Elektrotechniczny*, 2010, R. 86, nr 4, s. 158–161.
- [30] Florkowski M.: *Signal and image processing in diagnostics of electrical power equipment*. Rozprawa habilitacyjna, Rozprawy Monografie, AGH Uczelniane Wydawnictwo Naukowo-Dydaktyczne, Kraków, 2007, 168 stron.
- [31] Ganchev T., Fakotakis N., Kokkinakis G.: Comparative evaluation of various MFCC implementations on the speaker verification task. *Proceedings of SPECOM*, Patras, Greece, Vol. 1, 17–19 October 2005, 191–194.
- [32] Glinka T.: *Badania diagnostyczne maszyn elektrycznych w przemyśle*. Wyd. BOBRME KOMEL, Katowice. Wyd. I 1998, wyd. II 2002.
- [33] Glinka T.: Degradation of electrical machines windings insulation in time. *Przegląd Elektrotechniczny*, Vol. 84, No. 7, 2008, pp. 8–11.
- [34] Głowacz A.: *Komputerowe techniki analizy informacji zawartej w sygnałach akustycznych maszyn elektrycznych dla celów diagnostyki stanów przedawaryjnych*. Rozprawa doktorska, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej, Akademia Górniczo-Hutnicza im. Stanisława Staszica, Kraków, 2013.
- [35] Głowacz A.: Diagnostyka silnika indukcyjnego oparta na analizie sygnałów akustycznych z użyciem dyskretnej transformaty falkowej Haara i klasyfikatora najbliższej średniej z metryką Euklidesa, XIV Krajowa Konferencja Elektryki Górniczej, Zakopane, 10–12 października 2012, s. 51–59.
- [36] Głowacz A., Dobrowolski G.: Oprogramowanie i integracja stanowiska do badania sygnałów akustycznych stanów przedawaryjnych maszyn elektrycznych. *XVIII Międzynarodowe*

- wykorzystaniem algorytmu genetycznego i odległości Mahalanobisa. *Przegląd Elektrotechniczny* 2/2012, 204-207.
- [37] Głowacz Z., Kozik J.: Faulty states detection of synchronous motor using neural network. *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały*, Tom 62, Nr 28, 2008, 466–473.
- [38] Hao Z., Han J.: Identification of diesel front sound source based on continuous wavelet transform. *Journal of Zhejiang University SCIENCE*, Vol. 5, No. 9, 2004, 1069–1075.
- [39] Hermansky H.: Perceptual linear prediction (PLP) analysis for speech. *Journal of the Acoustic Society of America*, Vol. 87, 1990, 1738–1752.
- [40] Hermansky H., Morgan N., Bayya A., Kohn P.: Rasta-PLP Speech Analysis. *International Computer Science Institute Technical Report TR-91-069*, Berkeley, California, 1991.
- [41] Hermansky H., Morgan N.: RASTA processing of speech. *IEEE Transactions on Speech and Audio Processing*, Vol. 2, No. 4, 1994, 578–589.
- [42] Hyoung-Gook K., Berdahl E., Moreau N., Sikora T.: Speaker recognition using MPEG7 descriptors. *Proceedings of Eurospeech*, Geneva, Switzerland 2003, 489–492.
- [43] ITU-T Study Group 15: ITU-T Recommendation G.729 – Coding of speech at 8 kbit/s using conjugate structure algebraic code excited linear prediction (CS-ACELP). 01/2007.
- [44] ITU-T Study Group 15: ITU-T Recommendation G.723.1 – Dual rate speech coder for multimedia communications transmitting at 5.3 and 6.3 kbit/s. 05/2006.
- [45] Kercel S. W., Tucker R. W., Brown-VanHoozer S. A.: Speaker recognition through NLP and CWT modeling. *Fifteenth Annual Security Technology Symposium SecurityRelated Research and Methodology Session*, Norfolk, Virginia, 16 June 1999.
- [46] Kinnunen T.: Spectral features for automatic text-independent speaker recognition. *Ph. Lic. thesis*, Department of Computer Science, University of Joensuu, 2004, 144 pages.
- [47] Kluska-Nawarecka S., Nawarecki E., Dobrowolski G., Marcjan R.: Hybrydowy system ekspertowy dla diagnostyki wad odlewniczych. *Materiały szóstej konferencji KomPlasTech'99, Zastosowanie komputerów w zakładach przetwórstwa metali*, Szczyrk 17–20 stycznia 1999, 189–196.
- [48] Kozik J.: Diagnostyka maszyny synchronicznej z zastosowaniem metod sztucznej inteligencji. *Rozprawa doktorska*, Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków, Akademia Górniczo-Hutnicza im. Stanisława Staszica, 2011.
- [49] Kraus P., Dzwinel W.: Nearest neighbor search by using Partial KD-tree method. *Theoretical and Applied Informatics*, Vol. 20, No. 3, 2008, 149–165.
- Symposium – Zastosowania Teorii Systemów*, Zakopane 27–29 września 2009, Półrocznik Automatyka AGH, Tom 13, Zeszyt 2, Uczelniane Wydawnictwo Naukowo-Dydaktyczne, Kraków, 2009, s. 267–274.
- [37] Głowacz A., Głowacz A., Głowacz Z.: Diagnostics of Direct Current generator based on analysis of monochrome infrared images with the application of cross-sectional image and nearest neighbor classifier with Euclidean distance. *Przegląd Elektrotechniczny*, Vol. 88, No. 6, 2012, pp. 154-157.
- [38] Głowacz A., Głowacz A., Głowacz Z.: Recognition of Monochrome Thermal Images of Synchronous Motor with the Application of Skeletonization and Classifier Based on Words. *Archives of Metallurgy and Materials*. 60, 1 (2015), pp. 27-32.
- [39] Głowacz A., Głowacz A., Korohoda P.: Recognition of Monochrome Thermal Images of Synchronous Motor with the Application of Binarization and Nearest Mean Classifier. *Archives of Metallurgy and Materials*. 59, 1 (2014), pp. 31-34.
- [40] Głowacz A., Głowacz W.: New approach to diagnostics of DC machines by sound recognition using Linear Predictive Coding. *Human-computer systems interaction: backgrounds and applications. Advances in Intelligent and Soft Computing*. SpringerVerlag, Berlin/Heidelberg, Vol. 60, 2009, pp. 529–540.
- [41] Głowacz A., Głowacz W.: Shape recognition of film sequence with application of Sobel filter and backpropagation neural network. *Human-computer systems interaction: backgrounds and applications. Advances in Intelligent and Soft Computing*. Springer Verlag, Berlin/Heidelberg, Vol. 60, 2009, 505–516.
- [42] Głowacz A., Głowacz W.: Diagnostics of synchronous motor based on analysis of acoustic signals with application of LPCC and Nearest Mean classifier with cosine distance, *Archives of Metallurgy and Materials*, vol. 55, iss. 2, 2010, 565-571.
- [43] Głowacz A., Głowacz W.: Diagnostics of DC machine based on sound recognition with application of FFT and Jacquard distance, *Przegląd Elektrotechniczny*, Vol. 86, No. 4, 2010, 292-295.
- [44] Głowacz A., Głowacz W.: Diagnostyka silnika prądu stałego oparta na rozpoznawaniu prądu wzbudzenia z zastosowaniem FFT i algorytmu wstecznej propagacji błędów, *Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie*, 2010 nr 2 s. 22–26.
- [45] Głowacz A., Głowacz W., Głowacz Z.: Recognition of armature current of DC generator depending on rotor speed using FFT, MSAF-1 and LDA. *Eksploatacja i Niezawodność – Maintenance and Reliability*, Vol. 17, No. 1, 2015, pp. 64–69.

- [50] Kurek J., Osowski S.: Diagnostic feature selection for efficient recognition of different faults of rotor bars in the induction machine. *Przegląd Elektrotechniczny*, Vol. 86, No. 1, 2010, 121–123.
- [51] Kurth F., Gehrmann T., Müller M.: The Cyclic Beat Spectrum: Tempo-Related audio features for time-scale invariant audio identification. *Proceedings of the seventh International Conference on Music Information Retrieval (ISMIR)*, Victoria, Canada, October 2006, 35–40.
- [52] Kuta M., Wójcik W., Wrzeszcz M., Kitowski J.: Application of stacked methods to part-of-speech tagging of Polish. *Parallel Processing and Applied Mathematics, Lecture Notes in Computer Science*, Berlin, Heidelberg: Springer-Verlag, Vol. 6067, 2010, 340–349.
- [53] Kuta S.: Elementy i układy elektroniczne. Część I-II, Wydawnictwa AGH 2000.
- [54] Lee K., Estivill-Castro V.: Feature extraction and gating techniques for ultrasonic shaft signal classification. *Applied Soft Computing*, Vol. 7, Issue 1, January 2007, Elsevier, 156–165.
- [55] Lee K.: Effective approaches to extract features and classify echoes in long ultrasound signals from metal shafts. *Ph. D. dissertation*, Brisbane, Australia, 2006.
- [56] Ligęza A., Nalepa G. J.: A study of methodological issues in design and development of rule-based systems: proposal of a new approach. *Data Mining and Knowledge Discovery*, Vol. 1 Issue 2 March/April, 2011, 117–137.
- [57] Liu C.-S., Huang C.-S., Lin M.-T., Wang H.-C.: Automatic speaker recognition based upon various distances of LSP frequencies. *Proceedings of twenty-fifth IEEE International Carnahan Conference on Security Technology*, 1–3 October 1991, 104–109.
- [58] Liu C.-S., Wang W.-J., Lin M.-T., Wang H.-C.: Study of line spectrum pair frequencies for speaker recognition. *Proceedings of the IEEE Acoustics, Speech, and Signal Processing (ICASSP)*, Albuquerque, New Mexico, USA, 1990, 277–280.
- [59] Liu Z., Wang Y., Chen T.: Audio feature extraction and analysis for scene segmentation and classification. *Journal of VLSI Signal Processing System*, Vol. 20, Issue 1, June 1998, 61–79.
- [60] Lu L., Zhang H.-J., Jiang H.: Content analysis for audio classification and segmentation. *IEEE Transactions on Speech and Audio Processing*, Vol. 10, No. 7, October 2002, 504–516.
- [61] Lyons R. G.: Wprowadzenie do cyfrowego przetwarzania sygnałów. Wydawnictwo Komunikacji i Łączności, Warszawa, 1999.
- [62] Makhoul J.: Linear Prediction: A tutorial review. *Proceedings of the IEEE*, Vol. 63, No. 4, April 1975, 561–580.
- [63] Meng A., Ahrendt P., Larsen J.: Improving music genre classification by short-time feature integration. *Proceedings of ICASSP*, 18–23 March 2005, 1293–1296.
- [46] Głowacz A., Głowacz W., Głowacz Z.: Diagnostyka generatora prądu stałego oparta na analizie sygnałów akustycznych z użyciem transformaty falkowej biortogonalnej i klasyfikatora najbliższej średniej. *Przegląd Elektrotechniczny*, R. 90, nr 11, 2014, s. 185–188.
- [47] Głowacz A., Głowacz W., Głowacz Z.: Diagnostyka silnika synchronicznego oparta na analizie sygnałów akustycznych z zastosowaniem MFCC i GSDM. *Zeszyty Problemowe - Maszyny Elektryczne*, nr 87, 2010, Wyd. BOBRME KOMEL, Katowice, s. 185-190.
- [48] Głowacz A., Głowacz Z.: Diagnostics of DC machine based on analysis of acoustic signals with application of MFCC and classifier based on words. *Archives of Metallurgy and Materials*, Vol. 57, No. 1, 2012, pp. 179–183.
- [49] Głowacz W.: Diagnostics of induction motor based on Spectral Analysis of Stator Current with Application of Backpropagation Neural Network. *Archives of Metallurgy and Materials*, Vol. 58, No. 2, 2013, pp. 561-564.
- [50] Głowacz W.: Diagnostyka silnika indukcyjnego klatkowego oparta na analizie i rozpoznawaniu sygnałów z zastosowaniem FFT i klasyfikatora LDA. *XV Krajowa Konferencja Elektryki Górniczej*, Szczyrk, 24–26 września 2014, s. 183–190.
- [51] Głowacz W.: Diagnostyka silnika obcowzbudnego prądu stałego oparta na analizie i rozpoznawaniu sygnałów napięciowych z zastosowaniem FFT i klasyfikatora Bayesa. *XL Konferencja Sekcji Cybernetyki w Górnictwie KG PAN, Automatyka, Telekomunikacja, Informatyka, ATI 2015*, 24-26 czerwca 2015, s. 207-214.
- [52] Głowacz W., Głowacz Z.: Diagnostics of separately excited DC motor based on analysis and recognition of signals using FFT and Bayes classifier. *Archives of Electrical Engineering*, Vol. 64, No. 1, 2015, pp. 29-35.
- [53] Głowacz, Z., Kozik, J.: Detection of synchronous motor inter-turn faults based on spectral analysis of park's vector. *Archives of Metallurgy and Materials*. Vol. 58, No. 1, 2013, pp. 19-23.
- [54] Głowacz Z., Zdrojewski A.: Diagnostics of Commutator DC Motor Basing on Spectral Analysis of Signals, *Proc. of 6th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)*, IEEE, Cracow 2007, 497-500.
- [55] Hippe Z.S., Paja W., Piątek L., Wrzesień M.: Melanoma diagnosis and classification web center system, Information Technology, 2008. IT 2008. 1st International Conference on 18-21 May 2008, *IEEE Conference Proceeding*, pp. 1–4.
- [56] Idziak P., Rawicki S.: Analysis of stator deformations of a three-phase squirrel-cage induction

- [64] Milner B., Shao Xu: Prediction of fundamental frequency and voicing from MelFrequency Cepstral Coefficients for unconstrained speech reconstruction. *IEEE Transactions on Audio, Speech and Language Processing*, Vol. 15, Issue 1, 2007, 24–33.
- [65] Mitrovic D., Zeppelzauer M., Eidenberger H.: Towards an optimal feature set for environmental sound recognition. *Technical Report TR-188-2-2006-03*, 2006.
- [66] Mitrovic D., Zeppelzauer M., Eidenberger H.: Analysis of the data quality of audio features of environmental sounds. *Journal of Universal Knowledge Management*, Vol. 1, No. 1, 2006, 4–17.
- [67] Moorer J. A.: The use of Linear Prediction of speech in computer music applications. *Journal of the AES*, Vol. 27, No. 3, March 1979, 134–140.
- [68] Mrówka P.: Algorytmy kompensacji warunków transmisyjnych i cech osobniczych mówcy w systemach automatycznego rozpoznawania mowy. *Rozprawa doktorska*, Politechnika Wrocławska, Wrocław, 2007.
- [69] Mrówka R., Szmuc T.: UML Statecharts compositional semantics in LOTOS. *Proceedings of the seventh International Symposium on Parallel and Distributed Computing*, 1–5 July 2008, Krakow, Poland, 459–463.
- [70] Muralishankar R., Sangwan A., O’Shaughnessy D.: Warped discrete cosine transform cepstrum: A new feature for speech processing. *Proceedings of EUSIPCO*, Antalya, Turkey, 2005.
- [71] Nawarecki E., Dobrowolski G., Kisiel-Dorohinicki M., Kluska-Nawarecka S.: Zarządzanie wiedzą w systemie wspomagania wieloaspektowych ekspertyz przemysłowych. *Rozdział w Zastosowanie teorii systemów Nr 3*, Wydział Inżynierii Mechanicznej i Robotyki AGH, Kraków 2005, 213–222.
- [72] Neumayer R., Rauber A.: Integration of text and audio features for genre classification in music information retrieval. *Proceedings of the twenty-ninth European Conference on Information Retrieval (ECIR)*, Rome, Italy, 2–5 April 2007, 724–727.
- [73] Neumayer R.: Musical genre classification using a multi layer perceptron. *Proceedings of the fifth Workshop on Data Analysis (WDA)*, Elfa Academic Press, June 24–27 2004, 51–66.
- [74] New T. L., Li H.: Exploring vibrato-motivated acoustic features for singer identification. *IEEE Transactions on Audio, Speech and Language Processing*, Vol. 15, Issue 2, 2007, 519–530.
- [75] Openshaw J., Sun Z., Mason J.: A comparison of composite features under degraded speech in speaker recognition. *Proceedings of International Conference on Acoustics, Speech, and Signal Processing*, Minneapolis, Minnesota, USA, 1993, Vol. 2, 371–374.
- motor, *Przegląd Elektrotechniczny*, 2010, 86, 4, 184-187.
- [57] Jaffery Z.A., Dubey, A.K.: Design of early fault detection technique for electrical assets using infrared thermograms. *International Journal of Electrical Power & Energy Systems*, 63, (2014), pp. 753-759.
- [58] Jedlinski L., Caban J., Krzywonos L., Wierzbicki S., Brumerick F.: Application of vibration signal in the diagnosis of IC engine valve clearance. *Journal of Vibroengineering*, 17, 1, 2015, pp. 175-187.
- [59] Kang M., Kim J., Kim J.M., Tan A.C.C., Kim E.Y., Choi B.K.: Reliable Fault Diagnosis for Low-Speed Bearings Using Individually Trained Support Vector Machines With Kernel Discriminative Feature Analysis. *IEEE Transactions on Power Electronics*, 30, 5, (2015), pp. 2786-2797.
- [60] Kluska-Nawarecka S., Nawarecki E., Dobrowolski G., Marcjan R.: Hybrydowy system ekspertowy dla diagnostyki wad odlewniczych. *Materiały szóstej konferencji KomPlasTech'99, Zastosowanie komputerów w zakładach przetwórstwa metali*, Szczyrk 17–20 stycznia 1999, s. 189–196.
- [61] Kościelny J. M., Syfert M.: Application properties of methods for fault detection and isolation in the diagnosis of complex large-scale processes. *Bulletin of the Polish Academy of Sciences-Technical Sciences*, Vol. 62, No. 3, 2014, pp. 571-582.
- [62] Kotulski L.: *Rozproszone transformacje grafowe. Teoria i zastosowania*. Wydawnictwa AGH, Kraków 2013.
- [63] Kowalski Cz.T.: Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych. *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej nr 57, Seria: Monografie nr 18*, Wrocław 2005.
- [64] Kozik J.: Diagnostyka maszyny synchronicznej z zastosowaniem metod sztucznej inteligencji. *Rozprawa doktorska*, Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Akademia Górniczo-Hutnicza im. Stanisława Staszica, Kraków 2011.
- [65] Kraus P., Dzwinel W.: Nearest neighbor search by using Partial KD-tree method. *Theoretical and Applied Informatics*, Vol. 20, No. 3, 2008, pp. 149–165.
- [66] Kurek J., Osowski S.: Diagnostic feature selection for efficient recognition of different faults of rotor bars in the induction machine. *Przegląd Elektrotechniczny*, Vol. 86, No. 1, 2010, 121–123.
- [67] Kuta S.: *Elementy i układy elektroniczne. Część I-II*, Wydawnictwa AGH 2000.
- [68] Lee K.: *Effective approaches to extract features and classify echoes in long ultrasound signals*

- [76] Pampalk E., Dixon S., Widmer G.: On the evaluation of perceptual similarity measures for music. *Proceedings of sixth Conference on Digital Audio Effects (DAFX)*, London, UK, 8–11 September 2003, 7–12.
- [77] Pasko M., Walczak J.: Teoria sygnałów. Wydawnictwo Politechniki Śląskiej, 2007.
- [78] Peeters G., Rodet X.: Hierarchical Gaussian tree with inertia ratio maximization for the classification of large musical instrument databases. *Sixth International Conference on Digital Audio Effects*, London, UK, 8–11 September 2003.
- [79] Pietrowski W.: Application of Radial Basis Neural Network to diagnostics of induction motor stator faults using axial flux. *Przegląd Elektrotechniczny (Electrical Review)*. Vol. 87, n. 6, 2011, 190-192.
- [80] Puschel M., Moura J. M. F.: Algebraic signal processing theory: 1-D space. *IEEE Transactions on Signal Processing*, Vol. 56, Issue 8, Part 1, 2008, 3586–3599.
- [81] Reynolds D.: Experimental evaluation of features for robust speaker identification. *IEEE Transactions on Speech and Audio Processing*, Vol. 2, Issue 4, 1994, 639–643.
- [82] Rutkowska D., Rutkowski L., Piliński M.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwo Naukowe PWN, Warszawa, 1999.
- [83] Said S., Le Bihan N., Sangwine S. J.: Fast Complexified Quaternion Fourier Transform. *IEEE Transactions on Signal Processing*, Vol. 56, Issue 4, 2008, 1522–1531.
- [84] Sandryhaila A., Kovacevic J., Puschel M.: Algebraic Signal Processing Theory: 1-D Nearest Neighbor Models. *IEEE Transactions on Signal Processing*, Vol. 60, No. 4, 2012, 2247-2259.
- [85] Sarilaya R., Hansen J. H. L.: Analysis of the Root-Cepstrum for acoustic modeling and fast decoding in speech recognition. *Proceedings of European Conference on Speech Communication and Technology (Eurospeech)*, Aalborg, Denmark, 2001, 687–690.
- [86] Schaefer R.: Foundations of global genetic optimization. *Studies in Computational Intelligence*, Vol. 74, Berlin, Heidelberg, Springer-Verlag, 2007, 222 pages.
- [87] Scheirer E., Slaney M.: Construction and evaluation of a robust multifeatures speech/music discriminator. *IEEE Transactions on Acoustics, Speech, and Signal Processing (ICASSP)*, 1997, 1331–1334.
- [88] Skomorowski M.: Syntactic recognition of distorted patterns by means of random graph parsing. *Pattern Recognition Letters*, Vol. 28, Issue 5, 2007, 572–581.
- [89] Skwarczyński J., Matras A., Drabek T.: Siły i naprężenia zębowe w maszynach elektrycznych. *Elektrotechnika i Elektronika: półrocznik Akademii Górniczo-Hutniczej im. Stanisława Staszica w* from metal shafts. Ph. D. dissertation, Brisbane, Australia, 2006.
- [69] Ligęza A.: Models and tools for improving efficiency in constraint logic programming. *Decision Making in Manufacturing and Services*, 2011, Vol. 5, No. 1–2, pp. 69–78.
- [70] Ligęza A., Nalepa G. J.: A study of methodological issues in design and development of rule-based systems: proposal of a new approach. *Data Mining and Knowledge Discovery*, Vol. 1 Issue 2 March/April, 2011, 117–137.
- [71] Lim G. M., Bae D. M., Kim J. H.: Fault diagnosis of rotating machine by thermography method on support vector machine. *Journal of Mechanical Science and Technology*, 28, 8, 2014, pp. 2947-2952.
- [72] Lyons R. G.: Wprowadzenie do cyfrowego przetwarzania sygnałów. *Wydawnictwo Komunikacji i Łączności*, Warszawa, 1999.
- [73] Łukaniszyn M., Jaszczyk B.: *Podstawy elektromagnetyzmu*. Oficyna Wydawnicza PO, Opole 2003.
- [74] Makhoul J.: Linear Prediction: A tutorial review. *Proceedings of the IEEE*, Vol. 63, No. 4, April 1975, 561–580.
- [75] Martinez A.M., Kak A.C.: PCA versus LDA. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 2, 2001, pp. 228-233.
- [76] Michalak M., Sikora M., Sobczyk, J.: Analysis of the longwall conveyor chain based on a harmonic analysis. *Eksploatacja i Niezawodność – Maintenance and Reliability*, 15, 4, 2013, pp. 332-336.
- [77] Mrówka R., Szmuc T.: UML Statecharts compositional semantics in LOTOS. *Proceedings of the seventh International Symposium on Parallel and Distributed Computing*, 1–5 July 2008, Krakow, Poland, 459–463.
- [78] Nawarecki E., Dobrowolski G., Kisiel-Dorohinicki M., Kluska-Nawarecka S.: Zarządzanie wiedzą w systemie wspomagania wieloaspektowych ekspertyz przemysłowych. *W: Zastosowanie teorii systemów*, Nr 3, Wydział Inżynierii Mechanicznej i Robotyki AGH, Kraków 2005, 213–222.
- [79] Neumayer R.: Musical genre classification using a multi layer perceptron. *Proceedings of the fifth Workshop on Data Analysis (WDA)*, Elfa Academic Press, June 24–27 2004, pp. 51–66.
- [80] Oprędkiewicz K., Głowacz W., Zaczyk M., Teneta J., Więckowski Ł.: Identyfikacja modelu przedziałowego kąta elewacji orientowanego ogniwa słonecznego. *Przegląd Elektrotechniczny*, 2014, R. 90, nr 8, s. 243–247.
- [81] Oprędkiewicz K.: *Praktyczne sterowanie systemami dynamicznymi z widmem punktowym i*

- Krakowie, Tom 25, Zeszyt 2, 2006, 197–201.
- [90] Sutowski P.: Wykorzystanie wartości skutecznej sygnału emisji akustycznej oraz metod sztucznej inteligencji do oceny zużycia ściernicy. *Pomiary Automatyka Kontrola*, Tom. 55, Nr 4, 2009, 255–258.
- [91] Tadeusiewicz R.: Sieci Neuronowe. Akademicka Oficyna Wydawnicza. Warszawa 1993.
- [92] Tadeusiewicz R., Ogiela M. R.: USG – bezpieczna i wygodna technika obrazowania. *Podstawy inżynierii biomedycznej*, T. 1, Wydawnictwa AGH, Kraków, 2009, 513–526.
- [93] The MARF Development Group: Modular Audio Recognition Framework v.0.3.0devel-20050606 and its Applications. *Application note*, Montreal, Quebec, Canada, 2005.
- [94] Tzanetakis G., Essl G., Cook P.: Automatic musical genre classification of audio signals. *Proceedings of International Symposium on Music Information Retrieval (ISMIR)*, Bloomington, Indiana, USA, October 2001, 205–210.
- [95] Uhl T.: Współczesne metody monitorowania i diagnozowania konstrukcji. Wyd. Fundacja im. Wojciecha Świątosławskiego na Rzecz Wspierania Nauki i Rozwoju Potencjału Naukowego w Polsce, Gliwice, 2010, 193–254.
- [96] Umaphy K., Krishnan S., Rao R. K.: Audio signal feature extraction and classification using Local Discriminant Bases. *IEEE Transactions on Audio, Speech and Language Processing*, Vol. 15, Issue 4, 2007, 1236–1246.
- [97] Van Steelant D., Tanghe K., Degroeve S., De Baets B., Leman M., Martens J.-P.: Classification of percussive sounds using Support Vector Machines. *Proceedings of the annual machine learning conference of Belgium and The Netherlands*, Brussels, Belgium, 2004, 146–152.
- [98] Van Steelant D., Tanghe K., Degroeve S., De Baets B., Leman M., Martens J.-P.: Support Vector Machines for bass and snare drum recognition. *Classification – the Ubiquitous Challenge: Proceedings of the twenty-eighth Annual Conference of the Gesellschaft für Klassifikation*, Springer-Verlag, 2005, 616–623.
- [99] Ververidis D., Kotropoulos C.: Emotional speech recognition: Resources, features and methods. *Elsevier Speech communication*, Vol. 48, No. 9, September, 2006, 1162–1181.
- [100] Ververidis D., Kotropoulos C.: Emotional speech classification using Gaussian mixture models. *Proceedings of International Symposium on Circuits and Systems (ISCAS)*, Kobe, Japan, 2005, 2871–2874.
- [101] Vuuren S.: Comparison of text-independent speaker recognition methods on telephone speech with acoustic mismatch. *Proceedings of the fourth International Conference on Spoken Language* parametrą przedziałowymi. Rozprawy i monografie, Wydawnictwa AGH, 2008, 176 stron.
- [82] Pasko M., Walczak J.: *Teoria sygnałów*. Wydawnictwo Politechniki Śląskiej, 2007.
- [83] Pietrowski W.: Application of Radial Basis Neural Network to diagnostics of induction motor stator faults using axial flux. *Przegląd Elektrotechniczny (Electrical Review)*. Vol. 87, n. 6, 2011, pp. 190-192.
- [84] Pięciak T., Jaworek-Korjakowska J., Gorgoń M.: Sieci neuronowe w przetwarzaniu obrazów medycznych. *Wyd. Inżynieria biomedyczna - podstawy i zastosowania*, T. 9, Sieci neuronowe w inżynierii biomedycznej, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2013, s. 105–127.
- [85] Piłat A.: *Systemy aktywnej lewitacji magnetycznej*. Rozprawy i monografie, Wydawnictwa AGH, Kraków 2013, 166 stron.
- [86] Puschel M., Moura J. M. F.: Algebraic signal processing theory: 1-D space. *IEEE Transactions on Signal Processing*, Vol. 56, Issue 8, Part 1, 2008, 3586–3599.
- [87] Rad M.: *Diagnostyka wirnika maszyn indukcyjnych z wykorzystaniem analizy falkowej i układów uczących się*. Rozprawa doktorska, Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków, Akademia Górniczo-Hutnicza im. Stanisława Staszica, 2009.
- [88] Rutkowska D., Rutkowski L., Piliński M.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Wydawnictwo Naukowe PWN, Warszawa, 1999.
- [89] Said S., Le Bihan N., Sangwine S. J.: Fast Complexified Quaternion Fourier Transform. *IEEE Transactions on Signal Processing*, Vol. 56, Issue 4, 2008, 1522–1531.
- [90] Sandryhaila A., Kovacevic J., Puschel M.: Algebraic Signal Processing Theory: 1-D Nearest Neighbor Models. *IEEE Transactions on Signal Processing*, Vol. 60, No. 4, 2012, 2247-2259.
- [91] Sarilaya R., Hansen J. H. L.: Analysis of the Root-Cepstrum for acoustic modeling and fast decoding in speech recognition. *Proceedings of European Conference on Speech Communication and Technology (Eurospeech)*, Aalborg, Denmark, 2001, 687–690.
- [92] Schaefer R.: *Foundations of global genetic optimization. Studies in Computational Intelligence*, Vol. 74, Berlin, Heidelberg, Springer-Verlag, 2007, 222 pages.
- [93] Scheirer E., Slaney M.: Construction and evaluation of a robust multifeatures speech/music discriminator. *IEEE Transactions on Acoustics, Speech, and Signal Processing (ICASSP)*, 1997, 1331–1334.
- [94] Skomorowski M.: *Wybrane zagadnienia rozpoznawania obrazów*. Wydawnictwo Uniwersytetu Jagiellońskiego, Kraków 2013.

- Processing (ICSLP)*, Philadelphia, Pennsylvania, USA, 1996, 1788–1791.
- [102] Wajs W., Stoch P., Kruczek P.: Radial basis networks and logistic regression method for prediction of bronchopulmonary dysplasia. (*ISDA*), *Seventh international conference on Intelligent Systems Design and Applications*, Rio de Janeiro, Brazil, 22–24 October 2007, 551–555.
- [103] Walendowski P.: Zastosowanie sieci neuronowych typu SVM do rozpoznawania mowy. *Praca doktorska*, Politechnika Wroclawska, 2008.
- [104] Wei Chu, Champagne B.: A Noise-Robust FFT-Based auditory spectrum with application in audio classification. *IEEE Transactions on Audio, Speech and Language Processing*, Vol. 16, Issue 1, 2008, 137–150.
- [105] Wiatr K., Chwiej P.: Implementacja sieci neuronowych w układach programowalnych FPGA dla potrzeb przetwarzania obrazów w czasie rzeczywistym. *Kwartalnik Elektroniki i Telekomunikacji*, 2006, Tom 52, Zeszyt 1, 115–128.
- [106] Wiązania M.: Analizator widma sygnału audio z wyświetlaczem graficznym. *Elektronika Praktyczna*, Nr 11, 2009, 49–51.
- [107] Wielgat R., Zieliński T., Hołda Ł., Król D., Woźniak T., Grabias S.: HFCC based pathological speech recognition. *Advances in quantitative laryngology, voice and speech research: Seventh international conference*, Groningen, Netherlands, 6–7 October 2006, 1–17.
- [108] Wierzbicki R., Kowalski C.: Diagnostyka uszkodzeń stojana i wirnika silnika indukcyjnego pracującego w zamkniętej wektorowej strukturze sterowania prędkością. *Przegląd Elektrotechniczny* 4b/2012, 265-269.
- [109] Williams G., Ellis D.: Speech/music discrimination based on posterior probability features. *Proceedings of Eurospeech, Budapest*, September 1999, 687–690.
- [110] Winbond: Isd5100 series single-chip 1 to 16 minutes duration voice record/playback devices with digital storage capability. *Datasheet, Revision 1.4*, May 16 2007.
- [111] Wolkiewicz M., Kowalski C., Kamiński M.: Wykrywanie zwarć zwojowych silnika indukcyjnego z wykorzystaniem składowych symetrycznych oraz sieci neuronowych. *Przegląd Elektrotechniczny* 4b/2012, 276-281.
- [112] Wolkiewicz M., Kowalski C.: Neuronowy detektor zwarć zwojowych stojana silnika indukcyjnego wykorzystujący analizę PCA wektora prądu. *Przegląd Elektrotechniczny* 4b/2012, 288-293.
- [113] Xiong Ziyu, Radhakrishnan R., Divakaran A., Huang T. S.: Comparing MFCC and MPEG-7 audio features for feature extraction, maximum likelihood HMM and entropic prior HMM for sports audio classification. *Proceedings of International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, Philadelphia, Pennsylvania, USA, 2000, 1788–1791.
- [95] Skomorowski M.: Syntactic recognition of distorted patterns by means of random graph parsing. *Pattern Recognition Letters*, Vol. 28, Issue 5, 2007, 572–581.
- [96] Skwarczyński J., Matras A., Drabek T.: Siły i naprężenia zębowe w maszynach elektrycznych. *Elektrotechnika i Elektronika: półrocznik Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie*, Tom 25, Zeszyt 2, 2006, 197–201.
- [97] Sułowicz M., Borkowski D., Węgiel T., Weinreb K.: Specialized diagnostic system for induction motors. *Przegląd Elektrotechniczny* 2010, 86 (4), pp. 285-291.
- [98] Sutowski P.: Wykorzystanie wartości skutecznej sygnału emisji akustycznej oraz metod sztucznej inteligencji do oceny zużycia ściernicy. *Pomiary Automatyka Kontrola*, Tom. 55, Nr 4, 2009, 255–258.
- [99] Swędrowski L., Duzinkiewicz K., Grochowski M., Rutkowski T.: *Use of neural networks in diagnostics of rolling-element bearing of the induction motor*. Smart Diagnostics V, Book Series: Key Engineering Materials; 588 (2014), pp. 333-342.
- [100] Szmuc T.: *Modele i metody inżynierii oprogramowania systemów czasu rzeczywistego*, Wydawnictwa AGH, Kraków 2001, s. 279.
- [101] Szymański Z.: Application of the Magnetic Field Distribution in Diagnostic Method of Special Construction Wheel Traction Motors. *Studies in Applied Electromagnetics and Mechanics, Advanced Computer Techniques in Applied Electromagnetics*, 2008, 30, pp. 449-456.
- [102] Tadeusiewicz R.: *Sieci Neuronowe*. Akademicka Oficyna Wydawnicza. Warszawa 1993.
- [103] Tadeusiewicz R., Ogiela M. R.: *USG – bezpieczna i wygodna technika obrazowania. Podstawy inżynierii biomedycznej*, T. 1, Wydawnictwa AGH, Kraków, 2009, s. 513–526.
- [104] Uhl T.: Współczesne metody monitorowania i diagnozowania konstrukcji. *Wyd. Fundacja im. Wojciecha Świątosławskiego na Rzecz Wspierania Nauki i Rozwoju Potencjału Naukowego w Polsce*, Gliwice, 2010, 193–254.
- [105] Van Steelant D., Tanghe K., Degroeve S., De Baets B., Leman M., Martens J.-P.: Support Vector Machines for bass and snare drum recognition. *Classification – the Ubiquitous Challenge: Proceedings of the twenty-eighth Annual Conference of the Gesellschaft für Klassifikation*, Springer-Verlag, 2005, 616–623.
- [106] Wajs W., Stoch P., Kruczek P.: Radial basis networks and logistic regression method for prediction of bronchopulmonary dysplasia. *ISDA, Seventh international conference on Intelligent Systems Design and Applications*, Rio de Janeiro, Brazil, 22–24 October 2007, pp. 551–555.
- [107] Walendowski P.: *Zastosowanie sieci neuronowych typu SVM do rozpoznawania mowy*.

- Processing*, Vol. 5, April 2003, 628–631.
- [114]Zdrojewski A.: Diagnostyka maszyny komutatorowej prądu stałego bazująca na analizie spektralnej pomiarowo dostępnych sygnałów. *Rozprawa doktorska*, Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków, Akademia GórniczoHutnicza im. Stanisława Staszica, 2007.
- [115]Zeppelzauer M.: Discrimination and retrieval of animal sounds. *Diploma Thesis*, Vienna, 2005.
- [116]Zieliński K.: Zagadnienia konstrukcji oprogramowania komponentowego. *Problemy i metody inżynierii oprogramowania*, Warszawa, Wydawnictwa Naukowo-Techniczne, 2003, 327–343.
- [117]Zieliński T., Gajda P., Stachura M.: Application of Human Factor Cepstral Coefficients to robust recognition of pathological pronunciation in noisy environment. *International Conference on Signals and Electronic Systems*, Łódź, Poland, 17–20 September 2006, 241–244.
- [118]Zieliński T. P.: Od teorii do cyfrowego przetwarzania sygnałów. Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków, Akademia GórniczoHutnicza im. Stanisława Staszica, 2002.
- [119]Ziółko M., Samborski R., Gałka J., Ziółko B.: Wavelet-Fourier analysis for speaker recognition. *Proceedings of the seventeenth national conference on Applications of mathematics in biology and medicine*, Zakopane–Kościelisko, 1–6 September 2011, 129–134.
- [120]Zhu X., Wyse L.: Sound texture modeling and Time-Frequency LPC. *Proceedings of seventh International Conference on Digital Audio Effects*, Naples, Italy, 2004, 345– 349.
- [121]MPlayer – The Movie Player. <http://www.mplayerhq.hu/design7/news.html>
- [122]WAVE. <http://www.digitalpreservation.gov/formats/fdd/fdd000001.shtml>
- Praca doktorska, Politechnika Wroclawska, 2008.
- [108]Wiatr K., Chwiej P.: Implementacja sieci neuronowych w układach programowalnych FPGA dla potrzeb przetwarzania obrazów w czasie rzeczywistym. *Kwartalnik Elektroniki i Telekomunikacji*, 2006, Tom 52, Zeszyt 1, 115–128.
- [109]Wielgat R., Zieliński T., Hołda Ł., Król D., Woźniak T., Grabias S.: HFCC based pathological speech recognition. *Advances in quantitative laryngology, voice and speech research: Seventh international conference*, Groningen, Netherlands, 6–7 October 2006, 1–17.
- [110]Wierzbiński R., Kowalski C.: Diagnostyka uszkodzeń stojana i wirnika silnika indukcyjnego pracującego w zamkniętej wektorowej strukturze sterowania prędkością. *Przegląd Elektrotechniczny*, 4b/2012, s. 265-269.
- [111]Więckowski Ł.: *Analiza metod sterowania i zarządzania energią w autonomicznym robocie mobilnym zasilanym ogniwami słonecznymi*. Rozprawa doktorska, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej, Akademia Górniczo-Hutnicza im. Stanisława Staszica, Kraków 2014.
- [112]Williams G., Ellis D.: Speech/music discrimination based on posterior probability features. *Proceedings of Eurospeech*, Budapest, September 1999, 687–690.
- [113]Wolkiewicz M., Kowalski C., Kamiński M.: Wykrywanie zwarć zwojowych silnika indukcyjnego z wykorzystaniem składowych symetrycznych oraz sieci neuronowych. *Przegląd Elektrotechniczny*, R. 88, Nr 4b, 2012, s. 276-281.
- [114]Wolkiewicz M., Kowalski C.: Neuronowy detektor zwarć zwojowych stojana silnika indukcyjnego wykorzystujący analizę PCA wektora prądu. *Przegląd Elektrotechniczny*, R. 88, Nr 4b, 2012, s. 288-293.
- [115]Zadrozny S., Kacprzyk J., Gajewski M.: Multiaspect Text Categorization Problem Solving: A Nearest Neighbours Classifier Based Approaches and Beyond. *Journal of Automation, Mobile Robotics & Intelligent Systems*, Vol. 8, No. 4, 2015, pp. 58-70.
- [116]Zakrzewski K., Tomczuk B., Koterka D.: Simulation of forces and 3D field arising during power autotransformer fault due to electric arc in HV winding, *IEEE Transactions on Magnetics*, Vol. 38, No. 2, 2002, pp. 1153-1156.
- [117]Zdrojewski A.: Diagnostyka maszyny komutatorowej prądu stałego bazująca na analizie spektralnej pomiarowo dostępnych sygnałów. *Rozprawa doktorska*, Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków, Akademia GórniczoHutnicza im. Stanisława Staszica, 2007.
- [118]Zhao Z., Wang C., Zhang Y.G., Sun Y.: Latest progress of fault detection and localization in

complex Electrical Engineering. *Journal of Electrical Engineering/Elektrotechnicky Casopis*, 65, 1 (2014), pp. 55-59.

[119]Zhu X., Wyse L.: Sound texture modeling and Time-Frequency LPC. *Proceedings of seventh International Conference on Digital Audio Effects*, Naples, Italy, 2004, pp. 345– 349.

[120]Zieliński K.: Zagadnienia konstrukcji oprogramowania komponentowego. *Problemy i metody inżynierii oprogramowania*, Warszawa, Wydawnictwa Naukowo-Techniczne, 2003, s. 327–343.

[121]Zieliński T., Gajda P., Stachura M.: Application of Human Factor Cepstral Coefficients to robust recognition of pathological pronunciation in noisy environment. *International Conference on Signals and Electronic Systems*, Łódź, Poland, 17–20 September 2006, 241–244.

[122]Zieliński T. P.: *Od teorii do cyfrowego przetwarzania sygnałów*. Wydział Elektrotechniki, Automatyki, Informatyki i Elektroniki, Kraków, Akademia GórniczoHutnicza im. Stanisława Staszica, 2002.

[123]Ziółko M., Samborski R., Gałka J., Ziółko B.: Wavelet-Fourier analysis for speaker recognition. *Proceedings of the seventeenth national conference on Applications of mathematics in biology and medicine*, Zakopane–Kościelisko, 1–6 September 2011, 129–134.

[124]Zydroń P.: Przekształcenie falkowe w pomiarach wysokonapięciowych. *Przegląd Elektrotechniczny*, R. 78, nr 10s z. spec., 2002, s. 319–322.

[125]ISD9160 - system audio w pojedynczym chipie. *Elektronika Praktyczna*, Nr 6, 2014, 74–75.

[126]"3.397 Text File". IEEE Std 1003.1, 2013 Edition. *IEEE Computer Society*. Retrieved 2015-12-15.

[127]IOtex. Inc. - *DaqLab/2000 Series User's Manual*, 2016, www.iotech.com.

[128]MathWorks – *MATLAB and SimuLink for Technical Computing*, 2016; www.mathworks.com.

DODATEK A – WYKAZ WAŻNIEJSZYCH SKRÓTÓW W TEKŚCIE

A/C	<i>Analogowo-Cyfrowy</i>
FFT	<i>Fast Fourier Transform</i>
IFFT	<i>Inverse Fast Fourier Transform</i>

DODATEK A - Wykaz ważniejszych skrótów w tekście

A/C	<i>analogowo-cyfrowy</i>
BA	<i>klasyfikator Bayesa</i>

LPC	<i>Linear Predictive Coding</i>		BIAS	<i>wejście bias w sieciach nfouriera neuronowych</i>
LPCC	<i>Linear Predictive Cepstrum Coefficients</i>		DAQ	<i>akwizycja danych</i>
MAD	<i>Moduł automatycznego działania</i>		DFT	<i>dyskretna transformacja Fouriera</i>
MARF	<i>Modular Audio Recognition Framework</i>		DWT	<i>dyskretna transformacja falkowa</i>
MDŚD	<i>Moduł dzielenia ścieżki dźwiękowej</i>		FFT	<i>szybka transformacja Fouriera</i>
MRSA	<i>Moduł rozpoznawania sygnału akustycznego</i>		GDSM	<i>genetyczna rozrzedzona pamięć rozproszona</i>
MR	<i>Moduł rejestracji sygnału akustycznego</i>		IFFT	<i>odwrotna szybka transformacja Fouriera</i>
NM	<i>Nearest Mean</i>		k-NN	<i>k-najbliższych sąsiadów</i>
SARSA	<i>System automatycznego rozpoznawania sygnału akustycznego</i>		LDA	<i>liniowa analiza dyskryminacyjna</i>
SARP	<i>System automatycznego rozpoznawania prądu</i>		LPC	<i>liniowe kodowanie predykcyjne</i>
WAVE PCM	<i>Waveform audio format pulse-code modulation</i>		LPCC	<i>liniowe kodowanie predykcyjne cepstrum</i>
			MAD	<i>moduł automatycznego działania</i>
			MDŚN	<i>moduł dzielenia ścieżki napięciowej</i>
			MDŚP	<i>moduł dzielenia ścieżki prądowej</i>
			MR	<i>moduł rozpoznawania</i>
			MRSN	<i>moduł rozpoznawania sygnału napięciowego</i>
			MRSP	<i>moduł rozpoznawania sygnału prądowego</i>
			NM	<i>najbliższa odległość</i>

NN	<i>najbliższy sąsiad</i>
SARSI	<i>system automatycznego rozpoznawania sygnału innego</i>
SARSN	<i>system automatycznego rozpoznawania sygnału napięciowego</i>
SARSP	<i>system automatycznego rozpoznawania sygnału prądowego</i>
SI	<i>silnik indukcyjny</i>
SN	<i>sieć neuronowa</i>
SOA	<i>analiza spektralna oleju</i>
SPS	<i>silnik prądu stałego</i>

DODATEK B – WYNIKI ROZPOZNAWANIA SYGNAŁÓW AKUSTYCZNYCH DLA WYBRANYCH MASZYN ELEKTRYCZNYCH

W tabelach rodzaje sygnału akustycznego maszyn elektrycznych oznaczono następującymi skrótami:

bez uszkodzeń – sygnał akustyczny maszyny prądu stałego (synchronicznej) bez uszkodzeń, **zwarcia** – sygnał akustyczny maszyny prądu stałego ze zwartymi zezwojami wirnika (synchronicznej ze zwartymi zezwojami stojana),

1 przerwa – sygnał akustyczny maszyny synchronicznej z jedną przerwą w obwodzie stojana, **3 przerwy** – sygnał akustyczny maszyny synchronicznej z trzema przerwami w obwodzie stojana.

Tab. 4.1. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

DODATEK B - WYNIKI ROZPOZNAWANIA SYGNAŁÓW PRĄDOWYCH I NAPIĘCIOWYCH DLA WYBRANYCH SILNIKÓW ELEKTRYCZNYCH

W tabelach rodzaje sygnałów prądowych i napięciowych silników elektrycznych oznaczono następującymi skrótami:

bez uszkodzeń – sygnały prądowe i napięciowe silnika indukcyjnego i silnika prądu stałego bez uszkodzeń,

uszkodzenie pierścienia / przerwa zezwoju – sygnały prądowe i napięciowe silnika indukcyjnego z uszkodzonym pierścieniem i silnika prądu stałego z przerwą w zezwoju,

uszkodzenie 1 pręta / zwarcie 3 zezwojów – sygnały prądowe i napięciowe silnika indukcyjnego z uszkodzonym jednym prętem i silnika prądu stałego z trzema zwartymi zezwojami, **uszkodzenie 2 prętów / zwarcie 6 zezwojów** – sygnały prądowe i napięciowe silnika indukcyjnego z uszkodzonymi dwoma prętami i silnika prądu stałego z sześcioma zwartymi zezwojami.

Tab. 4.25. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Manhattan

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.2. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Euklidesa

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.3. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100

dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	87,5	uszkodzenie 1 pręta	1	100
bez uszkodzeń	2	75	uszkodzenie 1 pręta	2	100
bez uszkodzeń	3	66,6	uszkodzenie 1 pręta	3	100
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	100
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	100
uszkodzenie pierścienia	1	100	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	100	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	100	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	100	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	100	uszkodzenie 2 prętów	5	100

Tab. 4.26. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	100
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	100
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	100
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	100
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	100
uszkodzenie pierścienia	1	100	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	100	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	100	uszkodzenie 2 prętów	3	100

bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.4. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.5. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.6. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$

uszkodzenie pierścienia	4	100	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	100	uszkodzenie 2 prętów	5	100

Tab. 4.27. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	100
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	100
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	100
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	100
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	100
uszkodzenie pierścienia	1	100	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	100	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	100	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	100	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	100	uszkodzenie 2 prętów	5	100

Tab. 4.28. Wyniki rozpoznawania sygnału prądowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	100
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	100
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	100
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	100

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.7. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką kosinusową

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	99,16
bez uszkodzeń	2	100	1 przerwa	2	98,33
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	93,33
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	99,16	3 przerwy	1	99,16
zwarcia	2	100	3 przerwy	2	96,66
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	96,66
zwarcia	5	100	3 przerwy	5	100

Tab. 4.8. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Jacquarda

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	100
bez uszkodzeń	2	100	1 przerwa	2	98,33
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	96,66

bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	100
uszkodzenie pierścienia	1	100	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	100	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	100	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	100	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	100	uszkodzenie 2 prętów	5	100

Tab. 4.29. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	62,5
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	75
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	66,6
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	50
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	50
uszkodzenie pierścienia	1	62,5	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	75	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	66,6	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	50	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	50	uszkodzenie 2 prętów	5	100

Tab. 4.30. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	62,5
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	75
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	66,6
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	50
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	50
uszkodzenie pierścienia	1	62,5	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	75	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	66,6	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	50	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	50	uszkodzenie 2 prętów	5	100

bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	100	3 przerwy	1	95,83
zwarcia	2	100	3 przerwy	2	98,33
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.9. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, FFT i klasyfikatora opartego na słowach

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	99,16	1 przerwa	1	82,5
bez uszkodzeń	2	100	1 przerwa	2	96,66
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	96,66
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	98,33	3 przerwy	1	94,16
zwarcia	2	100	3 przerwy	2	98,33
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.10. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, FFT i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	69,16	1 przerwa	1	82,5
bez uszkodzeń	2	78,33	1 przerwa	2	71,66
bez uszkodzeń	3	90	1 przerwa	3	87,5
bez uszkodzeń	4	83,33	1 przerwa	4	80
bez uszkodzeń	5	95,83	1 przerwa	5	91,66
zwarcia	1	78,33	3 przerwy	1	57,5
zwarcia	2	88,33	3 przerwy	2	63,33
zwarcia	3	95	3 przerwy	3	80
zwarcia	4	100	3 przerwy	4	83,33
zwarcia	5	95,83	3 przerwy	5	95,83

bez uszkodzeń	1	62,5	uszkodzenie 1 pręta	1	100
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	75
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	66,6
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	50
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	50
uszkodzenie pierścienia	1	100	uszkodzenie 2 prętów	1	62,5
uszkodzenie pierścienia	2	62,5	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	66,6	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	50	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	50	uszkodzenie 2 prętów	5	100

Tab. 4.31. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	62,5
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	75
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	66,6
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	50
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	50
uszkodzenie pierścienia	1	62,5	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	62,5	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	66,6	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	50	uszkodzenie 2 prętów	4	100

uszkodzenie pierścienia	5	50	uszkodzenie 2 prętów	5	100
-------------------------	---	----	----------------------	---	-----

Tab. 4.32. Wyniki rozpoznawania sygnału napięciowego silnika indukcyjnego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	uszkodzenie 1 pręta	1	62,5
bez uszkodzeń	2	100	uszkodzenie 1 pręta	2	75
bez uszkodzeń	3	100	uszkodzenie 1 pręta	3	66,6
bez uszkodzeń	4	100	uszkodzenie 1 pręta	4	50
bez uszkodzeń	5	100	uszkodzenie 1 pręta	5	50
uszkodzenie pierścienia	1	62,5	uszkodzenie 2 prętów	1	100
uszkodzenie pierścienia	2	75	uszkodzenie 2 prętów	2	100
uszkodzenie pierścienia	3	66,6	uszkodzenie 2 prętów	3	100
uszkodzenie pierścienia	4	50	uszkodzenie 2 prętów	4	100
uszkodzenie pierścienia	5	100	uszkodzenie 2 prętów	5	100

Tab. 4.11. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Manhattan

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	74,16	1 przerwa	1	82,5
bez uszkodzeń	2	85	1 przerwa	2	91,66
bez uszkodzeń	3	90	1 przerwa	3	92,5
bez uszkodzeń	4	86,66	1 przerwa	4	93,33
bez uszkodzeń	5	95,83	1 przerwa	5	95,83
zwarcia	1	60	3 przerwy	1	57,5

zwarcia	2	73,33	3 przerwy	2	80
zwarcia	3	80	3 przerwy	3	92,5
zwarcia	4	86,66	3 przerwy	4	86,66
zwarcia	5	87,5	3 przerwy	5	91,66

Tab. 4.12. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	74,16	1 przerwa	1	82,5
bez uszkodzeń	2	85	1 przerwa	2	91,66
bez uszkodzeń	3	90	1 przerwa	3	92,5
bez uszkodzeń	4	86,66	1 przerwa	4	93,33
bez uszkodzeń	5	95,83	1 przerwa	5	95,83
zwarcia	1	60	3 przerwy	1	57,5
zwarcia	2	73,33	3 przerwy	2	80
zwarcia	3	80	3 przerwy	3	92,5
zwarcia	4	86,66	3 przerwy	4	86,66
zwarcia	5	87,5	3 przerwy	5	91,66

Tab. 4.13. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	74,16	1 przerwa	1	82,5
bez uszkodzeń	2	85	1 przerwa	2	91,66
bez uszkodzeń	3	90	1 przerwa	3	92,5
bez uszkodzeń	4	86,66	1 przerwa	4	93,33
bez uszkodzeń	5	95,83	1 przerwa	5	95,83
zwarcia	1	60	3 przerwy	1	57,5
zwarcia	2	73,33	3 przerwy	2	80
zwarcia	3	80	3 przerwy	3	92,5
zwarcia	4	86,66	3 przerwy	4	86,66
zwarcia	5	87,5	3 przerwy	5	91,66

Tab. 4.14. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	74,16	1 przerwa	1	82,5
bez uszkodzeń	2	85	1 przerwa	2	91,66
bez uszkodzeń	3	90	1 przerwa	3	92,5
bez uszkodzeń	4	86,66	1 przerwa	4	93,33
bez uszkodzeń	5	95,83	1 przerwa	5	95,83
zwarcia	1	60	3 przerwy	1	57,5
zwarcia	2	73,33	3 przerwy	2	80
zwarcia	3	80	3 przerwy	3	92,5
zwarcia	4	86,66	3 przerwy	4	86,66
zwarcia	5	87,5	3 przerwy	5	91,66

Tab. 4.15. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	74,16	1 przerwa	1	82,5
bez uszkodzeń	2	85	1 przerwa	2	91,66
bez uszkodzeń	3	90	1 przerwa	3	92,5
bez uszkodzeń	4	86,66	1 przerwa	4	93,33
bez uszkodzeń	5	95,83	1 przerwa	5	95,83
zwarcia	1	60	3 przerwy	1	57,5
zwarcia	2	73,33	3 przerwy	2	80
zwarcia	3	80	3 przerwy	3	92,5
zwarcia	4	86,66	3 przerwy	4	86,66
zwarcia	5	87,5	3 przerwy	5	91,66

Tab. 4.16. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	74,16	1 przerwa	1	82,5
bez uszkodzeń	2	85	1 przerwa	2	91,66
bez uszkodzeń	3	90	1 przerwa	3	92,5
bez uszkodzeń	4	86,66	1 przerwa	4	93,33
bez uszkodzeń	5	95,83	1 przerwa	5	95,83

zwarcia	1	60	3 przerwy	1	57,5
zwarcia	2	73,33	3 przerwy	2	80
zwarcia	3	80	3 przerwy	3	92,5
zwarcia	4	86,66	3 przerwy	4	86,66
zwarcia	5	87,5	3 przerwy	5	91,66

Tab. 4.17. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką kosinusową

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	65	1 przerwa	1	54,16
bez uszkodzeń	2	71,66	1 przerwa	2	81,66
bez uszkodzeń	3	82,5	1 przerwa	3	80
bez uszkodzeń	4	76,66	1 przerwa	4	86,66
bez uszkodzeń	5	70,83	1 przerwa	5	95,83
zwarcia	1	52,5	3 przerwy	1	53,33
zwarcia	2	63,33	3 przerwy	2	71,66
zwarcia	3	67,5	3 przerwy	3	87,5
zwarcia	4	76,66	3 przerwy	4	80
zwarcia	5	66,66	3 przerwy	5	91,66

Tab. 4.18. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu, algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	61,66	1 przerwa	1	70
bez uszkodzeń	2	68,33	1 przerwa	2	80
bez uszkodzeń	3	82,5	1 przerwa	3	80
bez uszkodzeń	4	80	1 przerwa	4	86,66
bez uszkodzeń	5	70,83	1 przerwa	5	95,83
zwarcia	1	52,5	3 przerwy	1	53,33
zwarcia	2	65	3 przerwy	2	71,66
zwarcia	3	70	3 przerwy	3	87,5
zwarcia	4	76,66	3 przerwy	4	80
zwarcia	5	70,83	3 przerwy	5	91,66

Tab. 4.19. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPC i klasyfikatora opartego na słowach

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	70,83	1 przerwa	1	78,33
bez uszkodzeń	2	96,66	1 przerwa	2	88,33
bez uszkodzeń	3	100	1 przerwa	3	92,5
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	69,16	3 przerwy	1	71,66
zwarcia	2	81,66	3 przerwy	2	93,33
zwarcia	3	82,5	3 przerwy	3	100
zwarcia	4	90	3 przerwy	4	100
zwarcia	5	95,83	3 przerwy	5	100

Tab. 4.20. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPC i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	60	1 przerwa	1	74,16
bez uszkodzeń	2	73,33	1 przerwa	2	80
bez uszkodzeń	3	82,5	1 przerwa	3	92,5
bez uszkodzeń	4	76,66	1 przerwa	4	93,33
bez uszkodzeń	5	87,5	1 przerwa	5	91,66
zwarcia	1	60	3 przerwy	1	74,16
zwarcia	2	73,33	3 przerwy	2	71,66
zwarcia	3	80	3 przerwy	3	87,5
zwarcia	4	93,33	3 przerwy	4	80
zwarcia	5	100	3 przerwy	5	91,66

Tab. 4.21. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Manhattan

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100

bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	97,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.22. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	97,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.23. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	97,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100

zwarcia	5	100	3 przerwy	5	100
---------	---	-----	-----------	---	-----

Tab. 4.24. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	97,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.25. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	97,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.26. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	97,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.27. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką kosinusową

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,5	1 przerwa	1	97,5
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	93,33	3 przerwy	1	93,33
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.28. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	90	1 przerwa	1	97,5
bez uszkodzeń	2	93,33	1 przerwa	2	100
bez uszkodzeń	3	97,5	1 przerwa	3	100
bez uszkodzeń	4	96,66	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100

zwarcia	1	93,33	3 przerwy	1	92,5
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.29. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na słowach

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	1 przerwa	1	95,83
bez uszkodzeń	2	100	1 przerwa	2	100
bez uszkodzeń	3	100	1 przerwa	3	100
bez uszkodzeń	4	100	1 przerwa	4	100
bez uszkodzeń	5	100	1 przerwa	5	100
zwarcia	1	97,5	3 przerwy	1	95,83
zwarcia	2	100	3 przerwy	2	100
zwarcia	3	100	3 przerwy	3	100
zwarcia	4	100	3 przerwy	4	100
zwarcia	5	100	3 przerwy	5	100

Tab. 4.30. Wyniki rozpoznawania sygnałów akustycznych maszyny synchronicznej przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 75, 100, 125, 150, 175, 250 Hz, LPCC i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	70,83	1 przerwa	1	70,83
bez uszkodzeń	2	76,66	1 przerwa	2	81,66
bez uszkodzeń	3	77,5	1 przerwa	3	87,5
bez uszkodzeń	4	86,66	1 przerwa	4	90
bez uszkodzeń	5	91,66	1 przerwa	5	95,83
zwarcia	1	70,83	3 przerwy	1	74,16
zwarcia	2	73,33	3 przerwy	2	71,66
zwarcia	3	80	3 przerwy	3	87,5
zwarcia	4	93,33	3 przerwy	4	90
zwarcia	5	95,83	3 przerwy	5	91,66

Tab. 4.31. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i

Tab. 4.33. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego

zmodyfikowanego klasyfikatora NM z metryką Manhattan

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.32. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Euklidesa

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.33. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.34. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100

na sieci neuronowej

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	62,5	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	75	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	66,6	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	50	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	50	zwarcie 6 zezwojów	5	100

Tab. 4.34. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	62,5	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	75	zwarcie 6 zezwojów	2	100

bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.35. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.36. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.37. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką kosinusową

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	91,3
bez uszkodzeń	2	100	zwarcia	2	86,95
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.38. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, FFT i zmodyfikowanego klasyfikatora NM z metryką Jacquarda

przerwa zezwoju	3	66,6	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	50	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.35. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	62,5	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	75	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	66,6	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	50	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.36. Wyniki rozpoznawania sygnału prądu wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	86,95	zwarcia	1	100
bez uszkodzeń	2	100	zwarcia	2	100
bez uszkodzeń	3	100	zwarcia	3	100
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.39. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na słowach

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	95,65	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	82,6
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	81,81
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.40. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, FFT i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	89,13	zwarcia	1	47,82
bez uszkodzeń	2	100	zwarcia	2	43,47
bez uszkodzeń	3	86,66	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	45,45
bez uszkodzeń	5	100	zwarcia	5	66,66

bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	62,5	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	75	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	66,6	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	50	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	50	zwarcie 6 zezwojów	5	100

Tab. 4.37. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.38. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud

dla częstotliwości MSAF i klasyfikatora NN

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.39. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	75	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	75	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	66,6	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa	2	100	zwarcie 6	2	100

zezwoju			zezwojów		
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.40. Wyniki rozpoznawania sygnału prądu twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA

Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału prądowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.41. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100

bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.42. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.43. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	62,5	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	50	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	66,6	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	50	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	50	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.44. Wyniki rozpoznawania sygnału napięcia wzbudzenia silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	62,5	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100

przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.45. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.46. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora NN

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100

bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.47. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora Bayesa

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	62,5	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	50	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	66,6	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	50	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	50	zwarcie 6 zezwojów	5	100

Tab. 4.48. Wyniki rozpoznawania sygnału napięcia twornika silnika prądu stałego przy zastosowaniu algorytmu wyboru amplitud dla częstotliwości MSAF i klasyfikatora LDA

Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału napięciowego	Długość próbki [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	100	zwarcie 3 zezwojów	1	100
bez uszkodzeń	2	100	zwarcie 3 zezwojów	2	100
bez uszkodzeń	3	100	zwarcie 3 zezwojów	3	100
bez uszkodzeń	4	100	zwarcie 3 zezwojów	4	100
bez uszkodzeń	5	100	zwarcie 3 zezwojów	5	100
przerwa zezwoju	1	100	zwarcie 6 zezwojów	1	100
przerwa zezwoju	2	100	zwarcie 6 zezwojów	2	100
przerwa zezwoju	3	100	zwarcie 6 zezwojów	3	100
przerwa zezwoju	4	100	zwarcie 6 zezwojów	4	100
przerwa zezwoju	5	100	zwarcie 6 zezwojów	5	100

Tab. 4.41. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Manhattan

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	73,91
bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.42. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	73,91

bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.43. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	73,91
bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.44. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	73,91
bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.45. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	73,91
bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.46. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	76,08
bez uszkodzeń	2	95,65	zwarcia	2	73,91
bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.47. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką kosinusową

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	89,13	zwarcia	1	71,17
bez uszkodzeń	2	91,3	zwarcia	2	69,56
bez uszkodzeń	3	100	zwarcia	3	66,66
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.48. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	71,73
bez uszkodzeń	2	95,65	zwarcia	2	69,56
bez uszkodzeń	3	73,33	zwarcia	3	66,66
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.49. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPC i klasyfikatora opartego na słowach

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	73,91

bez uszkodzeń	2	86,95	zwarcia	2	82,6
bez uszkodzeń	3	93,33	zwarcia	3	86,66
bez uszkodzeń	4	90,9	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.50. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPC i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	95,65	zwarcia	1	63,04
bez uszkodzeń	2	100	zwarcia	2	65,21
bez uszkodzeń	3	100	zwarcia	3	80
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.51. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Manhattan

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.52. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Euklidesa

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.53. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu

algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 3$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.54. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu

algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 4$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.55. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 5$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.56. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu

algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Minkowskiego dla $r = 6$

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

bez uszkodzeń	1	97,82	zwarcia	1	71,73
bez uszkodzeń	2	100	zwarcia	2	78,26
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.57. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką kosinusową

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	95,65	zwarcia	1	58,69
bez uszkodzeń	2	95,65	zwarcia	2	69,56
bez uszkodzeń	3	100	zwarcia	3	73,33
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.58. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i zmodyfikowanego klasyfikatora NM z metryką Jacquarda

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	93,47	zwarcia	1	67,39
bez uszkodzeń	2	95,65	zwarcia	2	69,56
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

Tab. 4.59. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566 Hz, LPCC i klasyfikatora opartego na słowach

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	91,3	zwarcia	1	73,91
bez uszkodzeń	2	86,95	zwarcia	2	82,6
bez uszkodzeń	3	100	zwarcia	3	86,66
bez uszkodzeń	4	100	zwarcia	4	100
bez uszkodzeń	5	100	zwarcia	5	100

Tab. 4.60. Wyniki rozpoznawania sygnałów akustycznych maszyny prądu stałego przy zastosowaniu algorytmu wybierania amplitud dla częstotliwości 233, 887, 1260, 2286, 2566

Hz, LPCC i klasyfikatora opartego na sieci neuronowej

Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]	Rodzaj sygnału akustycznego	Długość próbki dźwięku [s]	Skuteczność rozpoznawania [%]
bez uszkodzeń	1	95,65	zwarcia	1	67,39
bez uszkodzeń	2	95,65	zwarcia	2	69,56
bez uszkodzeń	3	100	zwarcia	3	80
bez uszkodzeń	4	100	zwarcia	4	90,9
bez uszkodzeń	5	100	zwarcia	5	88,88

DODATEK C – OPIS BADANYCH STANÓW MASZYN ELEKTRYCZNYCH

Przeprowadzono badania dla dwóch typów maszyn elektrycznych. Pierwszym typem była maszyna synchroniczna ze wzbudzeniem elektromagnetycznym, drugim maszyna prądu stałego obcowzbudna. Maszyny generowały różne sygnały akustyczne.

Maszyna synchroniczna ze wzbudzeniem elektromagnetycznym

Maszyna synchroniczna pracowała jako silnik. Maszyna ta wytwarzała następujące sygnały akustyczne: maszyny synchronicznej bez uszkodzeń, maszyny synchronicznej ze zwartymi zewojami stojana (zwarło 4 zewoje z 16 zewojów jednej fazy R), maszyny synchronicznej z jedną przerwą w obwodzie stojana (w uzwojeniu jednej fazy stojana) oraz maszyny synchronicznej z trzema przerwami w obwodzie stojana (w uzwojeniach trzech faz stojana). Maszyna miała następujące parametry operacyjne:

-stan pracy maszyny synchronicznej bez uszkodzeń, $U_{RS} = 100 \text{ V}$, $I_R = 30,9 \text{ A}$, $n_N = 1500 \text{ obr/min}$, $I_w \approx 0 \text{ A}$,

-stan pracy maszyny synchronicznej ze zwartymi zewojami stojana, $U_{RS} = 100 \text{ V}$,

$I_R = 31,2 \text{ A}$, $n_N = 1500 \text{ obr/min}$, $I_w \approx 0 \text{ A}$, $R_z = 2,5 \Omega$,

-stan pracy maszyny synchronicznej z jedną przerwą w obwodzie stojana, $U_{RS} = 100 \text{ V}$, $I_R = 24 \text{ A}$, $n_N = 1500 \text{ obr/min}$, $I_w \approx 0,3 \text{ A}$,

-stan pracy maszyny synchronicznej z trzema przerwami w obwodzie stojana, $U_{RS} = 100 \text{ V}$, $I_R = 36 \text{ A}$, $n_N = 1500 \text{ obr/min}$, $I_w \approx 0,245 \text{ A}$,

DODATEK C - BADANE SILNIKI ELEKTRYCZNE

Przeprowadzono badania dla dwóch typów silników elektrycznych. Pierwszym typem był silnik indukcyjny klatkowy, drugim silnik prądu stałego obcowzbudny. Silniki generowały różne sygnały prądowe i napięciowe.

Maszyna indukcyjna klatkowa

Maszyna indukcyjna klatkowa pracowała jako silnik. Maszyna ta wytwarzała sygnały prądowe i napięciowe w czterech stanach pracy: bez uszkodzeń, uszkodzenia pierścienia klatki, uszkodzenia jednego pręta klatki, uszkodzenia dwóch prętów klatki. Maszyna miała następujące dane:

-stan pracy maszyny indukcyjnej bez uszkodzeń, $U_{RS} = 400 \text{ V}$, $I_R = 2,77 \text{ A}$, $n_N = 1500 \text{ obr/min}$,

-stan pracy maszyny indukcyjnej z uszkodzonym pierścieniem klatki, $U_{RS} = 400 \text{ V}$,

$I_R = 2,65 \text{ A}$, $n_N = 1500 \text{ obr/min}$,

-stan pracy maszyny indukcyjnej z uszkodzonym jednym prętem klatki, $U_{RS} = 400 \text{ V}$,


$I_R = 2,82 \text{ A}$, $n_N = 1500 \text{ obr/min}$,

- stan pracy maszyny indukcyjnej z uszkodzonymi dwoma prętami klatki, $U_{RS} = 400 \text{ V}$, $I_R = 2,51 \text{ A}$, $n_N = 1500 \text{ obr/min}$,

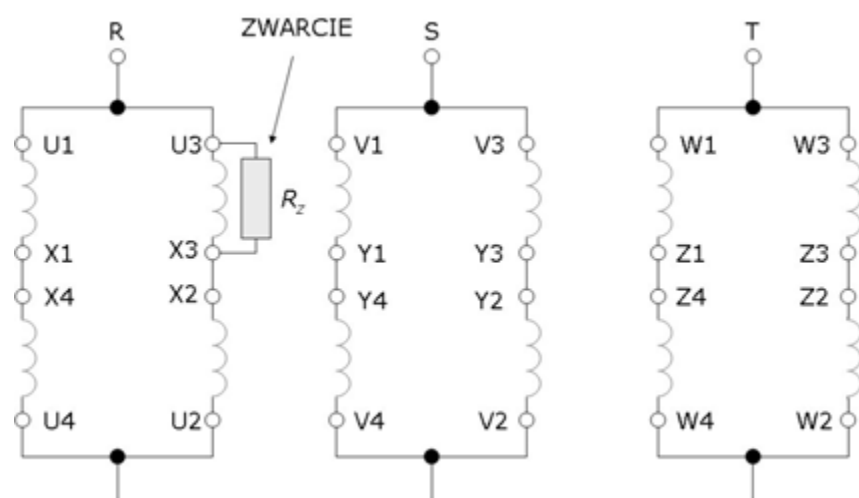
gdzie: U_{RS} – napięcie przewodowe pomiędzy fazami L1 i L2 (znamionowe stojana), I_R – prąd fazy L1, n_N – liczba obrotów wirnika na minutę.

gdzie: U_{RS} – napięcie międzyprzewodowe faz R i S, znamionowe stojana, I_R – prąd fazy R, I_W – prąd wzbudzenia, n_N – ilość obrotów wirnika na minutę, R_z – rezystancja zwierająca (U3-X3).


Schematy układu stojana maszyny synchronicznej dla czterech różnych stanów pracy zostały przedstawione na rysunkach C1, C2, C3, C4. Zwarcie i przerwy zostały zlokalizowane w obwodzie stojana. W przypadku maszyny bez uszkodzeń, układ stojana nie zawierał żadnych modyfikacji. W przypadku maszyny synchronicznej ze zwartymi zewojami stojana, zwarto cewkę w fazie R (U3-X3). Dla maszyny z jedną przerwą w obwodzie stojana, przerwa została zlokalizowana w fazie R (X1-X4). Natomiast w przypadku maszyny z trzema przerwami w obwodzie stojana, przerwy zostały zlokalizowane w fazach R, S i T (X1-X4, Y1-Y4, Z1-Z4).




Rys. C1. Schemat uzwojeń stojana dla maszyny synchronicznej bez uszkodzeń



Rys. C2. Schemat uzwojeń stojana dla maszyny synchronicznej ze zwartymi zewojami (U3-X3)




Rys. C3. Schemat uzwojeń stojana dla pracy maszyny synchronicznej z jedną przerwą (X1-X4)



Rys. C4. Schemat uzwojeń stojana dla pracy maszyny synchronicznej z trzema przerwami (X1-X4, Y1-Y4, Z1-Z4)

Maszyna synchroniczna ze wzbudzeniem elektromagnetycznym została przedstawiona na rysunku C5.



Rys. C5. Badana maszyna synchroniczna ze wzbudzeniem elektromagnetycznym

Maszyna prądu stałego obcowzbudna

Maszyna prądu stałego pracowała jako generator. Maszyna wytwarzała określony sygnał akustyczny przy pracy normalnej (bez uszkodzeń maszyny) i inny charakterystyczny sygnał akustyczny przy zwarciu zezwojów wirnika (3 zwarte zezwoje z 126 zezwojów). Zwarcie zostało zlokalizowane w obwodzie wirnika przy prądzie wzbudzenia generatora 0,22 A. Maszyna miała następujące parametry operacyjne:

$P_N = 13 \text{ kW}$, $U_N = 75 \text{ V}$, $I_N = 200 \text{ A}$, $U_{fN} = 220 \text{ V}$, $I_{fN} = 4 \text{ A}$, $n_N = 700 \text{ obr/min}$, $R_{bz} = 7,7 \text{ m}\Omega$, gdzie: P_N – moc czynna na wirniku, U_N – napięcie znamionowe twornika, I_N – prąd znamionowy twornika, U_{fN} – napięcie znamionowe wzbudzenia, I_{fN} – prąd znamionowy wzbudzenia, n_N – ilość obrotów wirnika na minutę.

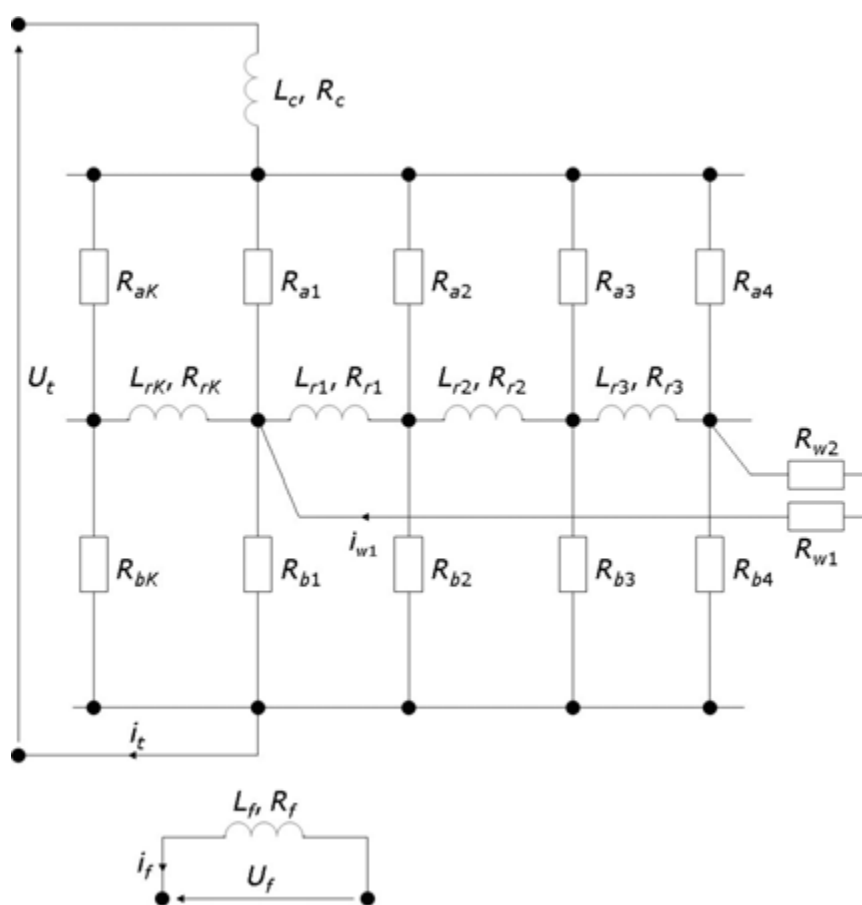
Schemat badanych uzwojeń wirnika dla maszyny prądu stałego bez uszkodzeń został przedstawiony na rysunku C6. Schemat badanych uzwojeń wirnika dla maszyny prądu stałego ze zwartymi zezwojami wirnika został pokazany na rysunku C7,

Maszyna prądu stałego obcowzbudna

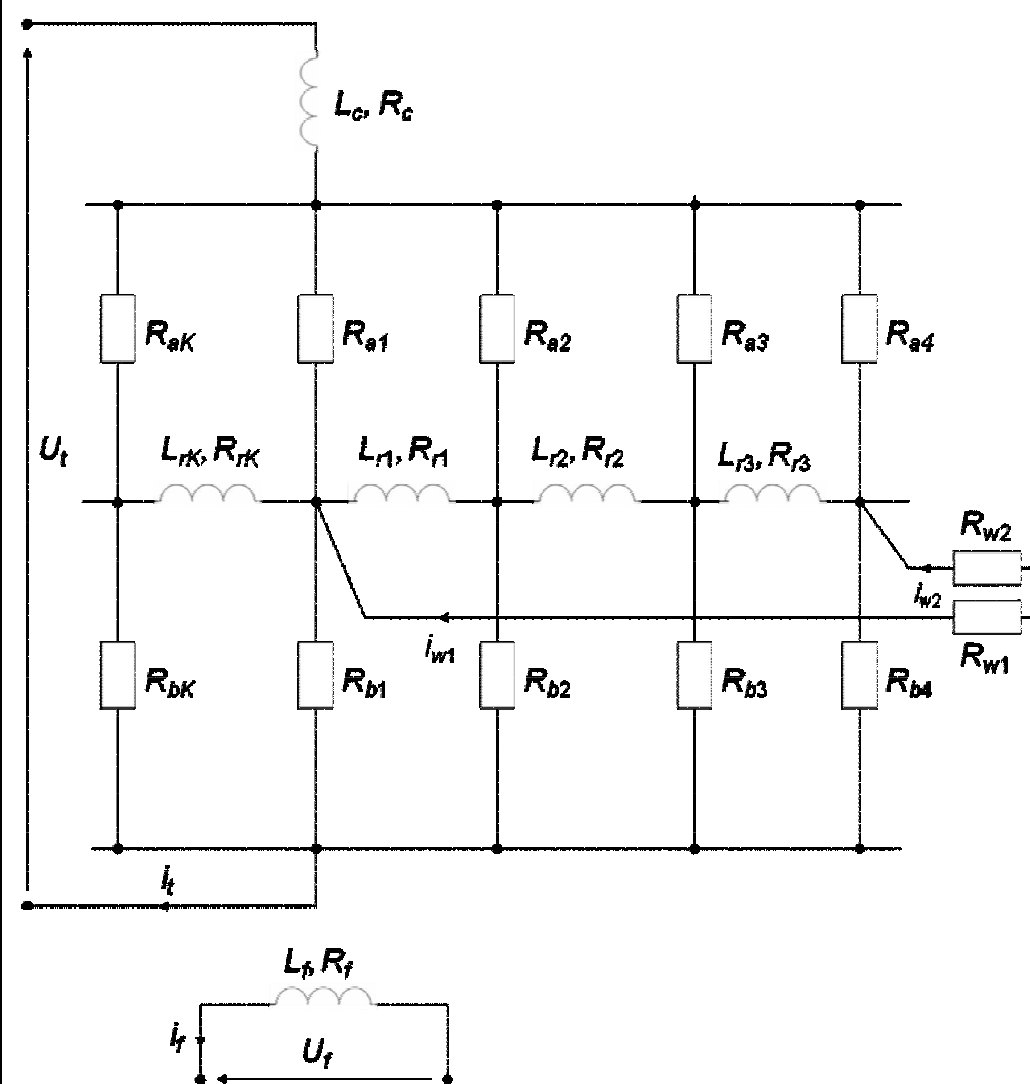
Maszyna prądu stałego obcowzbudna pracowała jako silnik. Maszyna wytwarzała określone sygnały prądowe i napięciowe w czterech stanach pracy: bez uszkodzeń, przerwy zezwojów wirnika, zwarcia trzech zezwojów wirnika oraz zwarcia sześciu zezwojów wirnika. Zwarcie zostało zlokalizowane w obwodzie wirnika przy prądzie wzbudzenia silnika 2,5 A. Maszyna miała następujące dane:

$P_N = 13 \text{ kW}$, $U_N = 75 \text{ V}$, $I_N = 200 \text{ A}$, $U_{fN} = 220 \text{ V}$, $I_{fN} = 4 \text{ A}$, $n_N = 700 \text{ obr/min}$, $R_{bz} = 7,7 \text{ m}\Omega$, gdzie: P_N – moc czynna na wirniku, U_N – napięcie znamionowe twornika, I_N – prąd znamionowy twornika, U_{fN} – napięcie znamionowe wzbudzenia, I_{fN} – prąd znamionowy wzbudzenia, n_N – liczba obrotów wirnika na minutę.

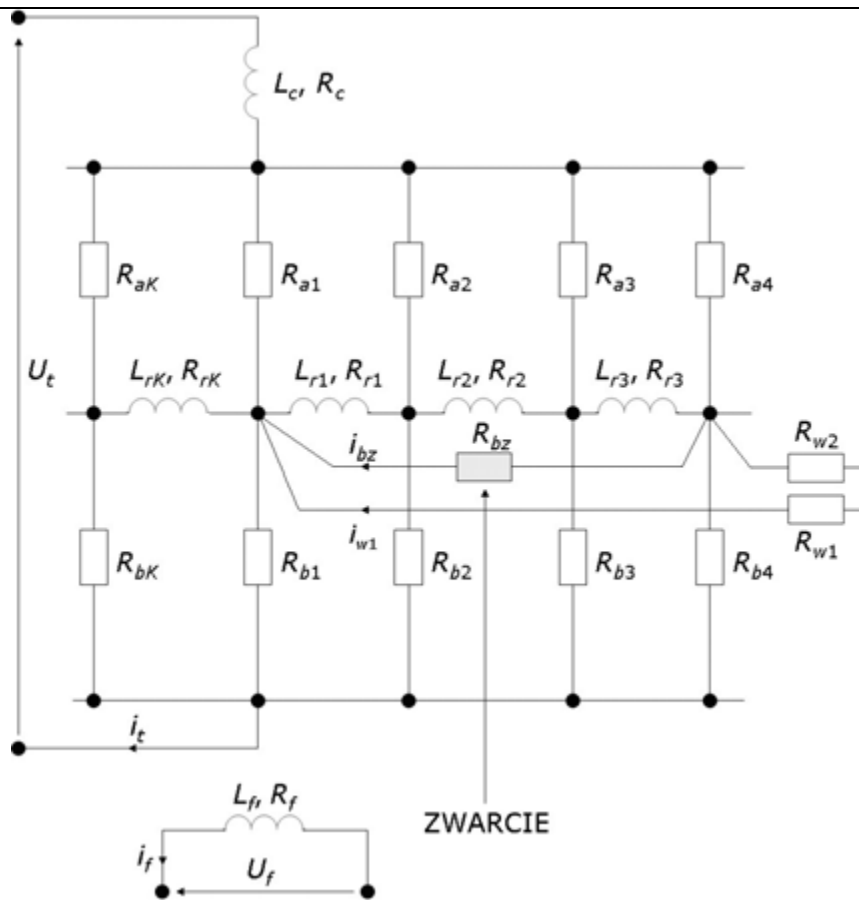
Schemat badanych uzwojeń wirnika dla maszyny prądu stałego bez uszkodzeń został przedstawiony na rysunku C6. Schemat badanych uzwojeń wirnika dla maszyny prądu stałego ze zwartymi zezwojami wirnika został pokazany na rysunku C7,



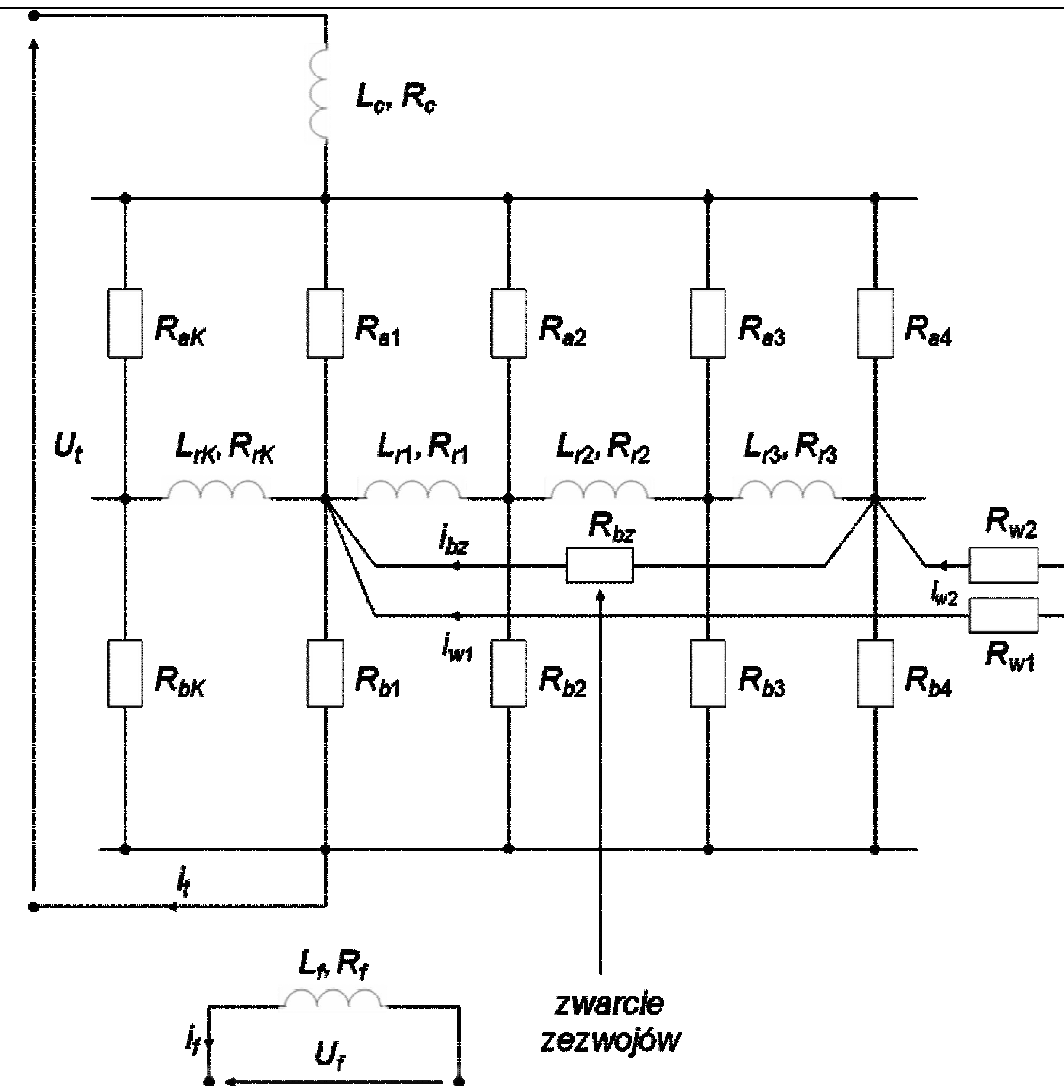
Rys. C6. Schemat uzwojeń wirnika maszyny prądu stałego bez uszkodzeń



Rys. C6. Schemat uzwojeń wirnika silnika prądu stałego bez uszkodzeń



Rys. C7. Schemat uzwojeń wirnika maszyny prądu stałego ze zwartymi zezwojami




Rys. C7. Schemat uzwojeń wirnika silnika prądu stałego ze zwartymi zezwojami

gdzie: $R_{a1}, \dots, R_{aK}, R_{b1}, \dots, R_{bK}$ – rezystancje komutatora, R_{r1}, \dots, R_{rK} – rezystancja zezwojów wirnika, L_{r1}, \dots, L_{rK} – indukcyjność zezwojów wirnika, L_f – indukcyjność uzwojenia wzbudzenia, R_f – rezystancja uzwojenia wzbudzenia, i_f – prąd wzbudzenia, R_{bz} – rezystancja zwierająca, i_{bz} – prąd rezystancji zwierającej, i_{w1} – prąd wyrównawczy w pierwszym połączeniu wyrównawczym, R_{w1} – rezystancja uzwojenia pierwszego połączenia wyrównawczego, R_{w2} – rezystancja uzwojenia drugiego połączenia wyrównawczego, L_c – indukcyjność uzwojenia komutacyjnego, R_c – rezystancja uzwojenia komutacyjnego, U_t – napięcie twornika, i_t – prąd twornika.

Maszyna prądu stałego obcowzbudna została przedstawiona na rysunku C8.

gdzie: $R_{a1}, \dots, R_{aK}, R_{b1}, \dots, R_{bK}$ – rezystancje komutatora, R_{r1}, \dots, R_{rK} – rezystancja zezwojów wirnika, L_{r1}, \dots, L_{rK} – indukcyjności zezwojów wirnika, L_f – indukcyjność uzwojenia wzbudzenia, R_f – rezystancja uzwojenia wzbudzenia, i_f – prąd wzbudzenia, R_{bz} – rezystancja zwierająca, i_{bz} – prąd rezystancji zwierającej, i_{w1} – prąd wyrównawczy w pierwszym połączeniu wyrównawczym, R_{w1} – rezystancja uzwojenia pierwszego połączenia wyrównawczego, R_{w2} – rezystancja uzwojenia drugiego połączenia wyrównawczego, L_c – indukcyjność uzwojenia komutacyjnego, R_c – rezystancja uzwojenia komutacyjnego, U_t – napięcie twornika, i_t – prąd twornika.

Silnik prądu stałego obcowzbudny został przedstawiony na rysunku C8.



Rys. C8. *Badana maszyna prądu stałego obcowzbudna*



Rys. C8. *Badany silnik prądu stałego obcowzbudny*

DODATEK D – INSTALACJA I URUCHAMIANIE SYSTEMU AUTOMATYCZNEGO ROZPOZNAWANIA SYGNAŁU AKUSTYCZNEGO

Do uruchomienia systemu automatycznego rozpoznawania sygnału akustycznego należy zainstalować na komputerze następujące narzędzia: *Windows XP*, *Java Development Kit* w wersji 6, *Active Perl* w wersji 5.6.1.638, *Mplayer* w wersji 6, *SARSA*.

Plik *SARSA_windows.zip* powinien zostać rozpakowany na dysku (D:\). Kolejno należy wybrać jeden wariant algorytmu wstępnej obróbki danych, ekstrakcji cech, klasyfikacji i wykonać proces tworzenia wzorców do rozpoznawania. W tym celu należy wpisać w ścieżce (D:\SARSA\MRSA\) jedną z trzech komend.

Komenda, która wykonuje proces tworzenia wzorców do rozpoznawania dla zmodyfikowanego klasyfikatora NM:

```
java -jar Klient.jar -t <hasło> <algorytm wstępnej obróbki danych> <algorytm ekstrakcji cech>
```

przykładowe użycie: *java -jar Klient.jar -t xx -normalizacja -FFT*

Komenda, która wykonuje proces tworzenia wzorców do rozpoznawania dla

klasyfikatora opartego na słowach: *java -jar KlientSlova.jar -t <hasło> <algorytm wstępnej obróbki danych> <algorytm ekstrakcji cech> <wartość parametru k>*

przykładowe użycie: *java -jar KlientSlova.jar -t xx -normalizacja -FFT 0.0005*

Komenda, która wykonuje proces tworzenia wzorców do rozpoznawania dla

klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów:

```
java -jar KlientNN.jar <algorytm ekstrakcji cech> -train przykładowe użycie:
```

```
java -jar KlientNN.jar -LPC -train
```

Kolejno należy wykonać proces identyfikacji jedną z trzech komend:

Komenda, która wykonuje proces identyfikacji dla zmodyfikowanego klasyfikatora NM:

java -jar Klient.jar -i <próbka dźwięku do identyfikacji> <algorytm wstępnej obróbki danych> <algorytm ekstrakcji cech> <rodzaj metryki>

przykładowe użycie: *java -jar Klient.jar -i z11.wav -normalizacja -FFT -Euklidesa*

Komenda, która wykonuje proces identyfikacji dla klasyfikatora opartego na słowach:

java -jar KlientSlova.jar -i <próbka dźwięku do identyfikacji> <algorytm wstępnej obróbki danych> <algorytm ekstrakcji cech> <wartość parametru k>

przykładowe użycie: *java -jar KlientSlova.jar -i z11.wav -normalizacja -FFT 0.0005*

Komenda, która wykonuje proces identyfikacji dla klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów:

java -jar KlientNN.jar <algorytm ekstrakcji cech> -test przykładowe użycie :

java -jar KlientNN.jar -LPC -test

Tryb niemonitorowania

W trybie niemonitorowania używany jest jeden plik (przykładowo ścieżka dźwiękowa zawierająca zarejestrowany sygnał akustyczny maszyny synchronicznej ze zwartymi zezwojami stojana). W ścieżce (D:\SARSA\MRSA\) w odpowiednim pliku *ident.pl* (dla zmodyfikowanego klasyfikatora NM), *ident_slowa.pl* (dla klasyfikatora opartego na słowach), *runNN.bat* (dla klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów) należy wpisać konfigurację stosowanych algorytmów wstępnej obróbki danych i ekstrakcji cech. Kolejno należy wykonać jedną z trzech komend w określonej ścieżce (D:\SARSA\):

Komenda, która wykonuje tryb niemonitorowania dla zmodyfikowanego klasyfikatora NM:

runMetryki_plik.bat <ścieżka dźwięku do identyfikacji>

przykładowe użycie: *runMetryki_plik.bat zwanieU3-X3Ir104A_ident.wav*

Komenda, która wykonuje tryb niemonitorowania dla klasyfikatora opartego na słowach:

runSlova_plik.bat <ścieżka dźwięku do identyfikacji>

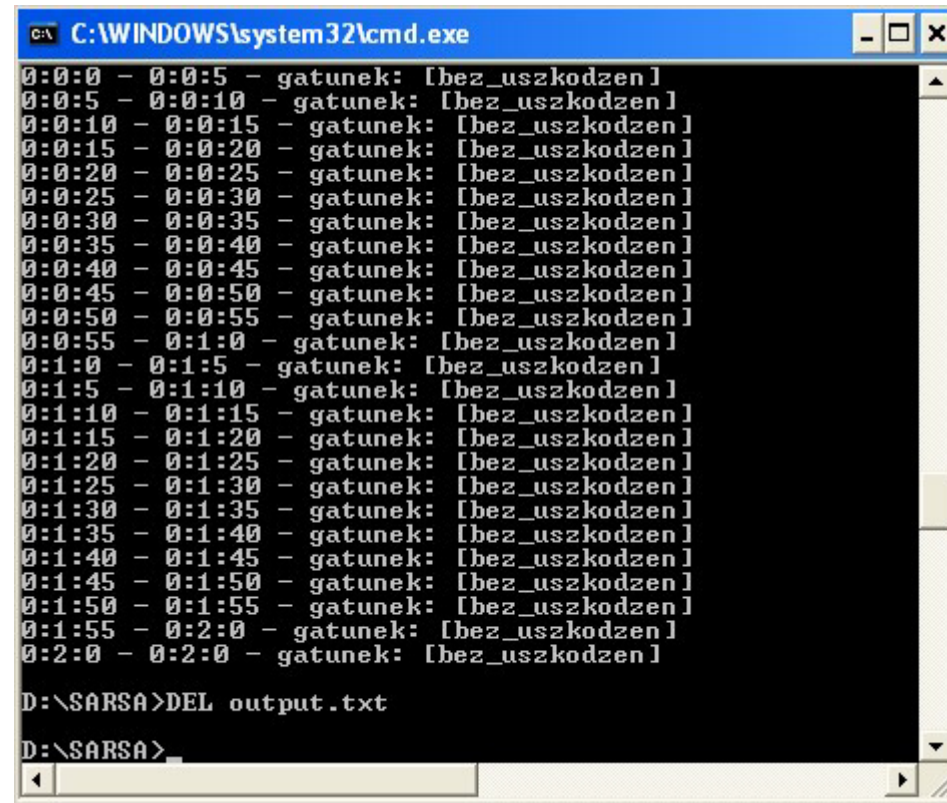
przykładowe użycie: *runSlova_plik.bat zwanieU3-X3Ir104A_ident.wav*

Komenda, która wykonuje tryb niemonitorowania dla klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów:

runNN_plik.bat < ścieżka dźwięku do identyfikacji>

przykładowe użycie: runNN_plik.bat zwanieU3-X3Ir104A_ident.wav

Wyniki rozpoznawania sygnałów akustycznych po uruchomieniu SARSA w trybie niemonitorowania dla próbek pięciosekundowych zostały przedstawione na rysunku D1.



```

C:\WINDOWS\system32\cmd.exe
0:0:0 - 0:0:5 - gatunek: [bez_uszkodzen]
0:0:5 - 0:0:10 - gatunek: [bez_uszkodzen]
0:0:10 - 0:0:15 - gatunek: [bez_uszkodzen]
0:0:15 - 0:0:20 - gatunek: [bez_uszkodzen]
0:0:20 - 0:0:25 - gatunek: [bez_uszkodzen]
0:0:25 - 0:0:30 - gatunek: [bez_uszkodzen]
0:0:30 - 0:0:35 - gatunek: [bez_uszkodzen]
0:0:35 - 0:0:40 - gatunek: [bez_uszkodzen]
0:0:40 - 0:0:45 - gatunek: [bez_uszkodzen]
0:0:45 - 0:0:50 - gatunek: [bez_uszkodzen]
0:0:50 - 0:0:55 - gatunek: [bez_uszkodzen]
0:0:55 - 0:1:0 - gatunek: [bez_uszkodzen]
0:1:0 - 0:1:5 - gatunek: [bez_uszkodzen]
0:1:5 - 0:1:10 - gatunek: [bez_uszkodzen]
0:1:10 - 0:1:15 - gatunek: [bez_uszkodzen]
0:1:15 - 0:1:20 - gatunek: [bez_uszkodzen]
0:1:20 - 0:1:25 - gatunek: [bez_uszkodzen]
0:1:25 - 0:1:30 - gatunek: [bez_uszkodzen]
0:1:30 - 0:1:35 - gatunek: [bez_uszkodzen]
0:1:35 - 0:1:40 - gatunek: [bez_uszkodzen]
0:1:40 - 0:1:45 - gatunek: [bez_uszkodzen]
0:1:45 - 0:1:50 - gatunek: [bez_uszkodzen]
0:1:50 - 0:1:55 - gatunek: [bez_uszkodzen]
0:1:55 - 0:2:0 - gatunek: [bez_uszkodzen]
0:2:0 - 0:2:0 - gatunek: [bez_uszkodzen]

D:\SARSA>DEL output.txt

D:\SARSA>

```

Rys. D1. Wyniki rozpoznawania sygnałów akustycznych po uruchomieniu SARSA w trybie niemonitorowania dla pięciosekundowych próbek dźwięku maszyny synchronicznej bez uszkodzeń

Tryb monitorowania

W trybie monitorowania odbywa się rejestracja sygnału akustycznego z zastosowaniem mikrofonu, karty dźwiękowej i komputera. Odpowiednie programy powinny być wykonane w dwóch konsolach. W pierwszej konsoli należy wykonać polecenie odpowiedzialne za uruchomienie rejestracji sygnału akustycznego:

rec.bat

W drugiej konsoli należy wykonać jedną z trzech komend:

Komenda, która wykonuje tryb monitorowania dla zmodyfikowanego klasyfikatora NM:

runMetryki_monitor.bat

Komenda, która wykonuje tryb monitorowania dla klasyfikatora opartego na słowach

runSłowa_monitor.bat

Komenda, która wykonuje tryb monitorowania dla klasyfikatora opartego na sieci neuronowej z algorytmem wstecznej propagacji błędów:

runNN_monitor.bat