

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CÂMPUS CORNÉLIO PROCÓPIO  
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
MESTRADO EM ENGENHARIA ELÉTRICA**

**AVYNER LORRAN DE OLIVEIRA VITOR**

**DETECÇÃO DE FALHAS DE ESTATOR EM MOTORES DE INDUÇÃO  
TRIFÁSICOS UTILIZANDO TRANSFORMADA WAVELET, MEDIDA  
RMS E POTÊNCIA DE PREVISÃO**

**DISSERTAÇÃO DE MESTRADO**

**CORNÉLIO PROCÓPIO**

**2015**

**AVYNER LORRAN DE OLIVEIRA VITOR**

**DETECÇÃO DE FALHAS DE ESTATOR EM MOTORES DE INDUÇÃO  
TRIFÁSICOS UTILIZANDO TRANSFORMADA WAVELET, MEDIDA  
RMS E POTÊNCIA DE PREVISÃO**

Dissertação de mestrado apresentada ao Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Mestre em Engenharia Elétrica”.

Orientador: Prof. Dr. Paulo Rogério Scalassara

Co-orientador: Prof. Dr. Fábio Durand

**CORNÉLIO PROCÓPIO**

**2015**

---

Dados Internacionais de Catalogação na Publicação

---

- V845 Vitor, Avyner Lorrان de Oliveira  
Detecção de falhas de estator em motores de indução trifásicos utilizando transformada wavelet, medida rms e potência de previsão / Avyner Lorrان de Oliveira Vitor. –2015.  
131 f. : il. ; 30 cm
- Orientador: Paulo Rogério Scalassara.  
Coorientador: Fábio Durand.  
Dissertação (Mestrado) –Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. Cornélio Procópio, 2015.  
Bibliografia: p. 128 -131.
1. Motores elétricos de indução. 2. Entropia. 3. Redes neurais (Computação). 4. Wavelets (Matemática) 5. Engenharia elétrica - Dissertações. I. Scalassara, Paulo Rogério, orient. II. Durand, Fábio, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. IV. Título.

CDD (22. ed.) 621.3



---

## TERMO DE APROVAÇÃO

DETECÇÃO DE FALHAS DE ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS  
UTILIZANDO TRANSFORMADA WAVELET, ERRO MÉDIO QUADRÁTICO E POTÊNCIA  
DE PREVISÃO

Por

Avyner Lorrán de Oliveira Vitor

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Engenharia Elétrica” e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 26/10/2015.

---

Paulo Rogério Scalassara, Prof. Dr  
Coordenadora do Curso

### Banca Examinadora:

---

Paulo Rogério Scalassara, Prof. Dr  
Orientador

---

Taufik Abrão, Prof. Dr  
Universidade Estadual de Londrina

---

Alessandro Goedel, Prof. Dr  
Universidade Tecnológica Federal do Paraná

“A Folha de Aprovação assinada encontra-se na Coordenação do Curso do Programa”

Dedico esta obra a minha família, namorada e amigos, pelo apoio oferecido em todos os momentos da minha vida.

## **AGRADECIMENTOS**

Antes de mais nada, agradeço a Deus a graça da vida e a Seu filho Jesus Cristo os seus ensinamentos. Agradeço aos meus pais e avós a fé depositada em meus propósitos e a renúncia de suas vontades em função de minhas necessidades. Agradeço à minha tia Alaide, para com quem eu tenho afeto de avó, a sua dedicação e carinho. À minha namorada, por entender os momentos que tive que ficar ausente.

À Universidade Tecnológica Federal do Paraná, Campus Cornélio Procópio, que disponibilizou ensino de excelência por meio de seu corpo docente e instalações altamente qualificados.

Ao Prof Dr. Paulo Scalassara e Fabio Durand, o auxílio e orientação oferecidos, sem os quais não seria possível a realização deste trabalho. Aos professores membros da comissão examinadora Dr. Alessandro Goedel e Dr. Taufik Abrão as sugestões e correções que foram de extrema relevância para a continuidade deste trabalho. À toda equipe dos laboratórios do PPGEE, pelo apoio e companheirismo.

"Tudo aquilo que o homem ignora, não existe para ele. Por isso, o universo de cada um, se resume no tamanho de seu saber."  
*(Albert Einstein)*

## RESUMO

Vitor, A. L. de O.. **DETECÇÃO DE FALHAS DE ESTATOR EM MOTORES DE INDUÇÃO TRIFÁSICOS UTILIZANDO TRANSFORMADA WAVELET, MEDIDA RMS E POTÊNCIA DE PREVISÃO.** . 131 f. Dissertação de mestrado – Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

O Motor de Indução Trifásico é a máquina elétrica mais utilizada no ambiente industrial. Trata-se de um equipamento que apresenta construção robusta, facilidade de manutenção, baixo custo de aquisição e confiabilidade. Contudo, em ambiente fabril, o mesmo está exposto a esforços térmicos, elétricos e mecânicos indesejáveis, os quais, com o passar do tempo, resultam em uma falha. A presente pesquisa consiste em analisar a falha de curto-circuito de estator, uma das falhas mais recorrentes em motores de indução. Para tanto, são investigadas as peculiaridades refletidas nos sinais de corrente estatórica, a fim de correlacionar as características do sinal à falha em questão. Para tanto, os sinais de corrente são processados por meio das transformadas de Fourier e *Wavelet*, buscando-se isolar frequências características de uma falha de curto-circuito, as quais possam auxiliar na detecção de uma falha. Posteriormente, a classificação a partir das informações extraídas é efetuado por meio de Redes Neurais Artificiais, especificamente, a *perceptron* multicamadas e a *Radial Basis Function*.

**Palavras-chave:** Motor de Indução Trifásico, falha de estator, detecção de falhas, Transformada Wavelet, entropia, Redes Neurais Artificiais



## ABSTRACT

Vitor, A. L. de O.. **STATOR FAULT DETECTION IN THREE PHASE INDUCTION MOTORS USING WAVELET TRANSFORM, RMS AND PREDICTION POWER** . . 131 f. Dissertação de mestrado – Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

The Three-Phase Induction Motor is the most utilized electrical machine in industrial environments. It is an equipment that shows robust construction, ease maintenance, low cost and reliability. However, frequently, machines are exposed to thermal, electrical and mechanical efforts, which, over time, result in a failure. This work aims to analyze the stator short circuit fault, one of the most frequent induction motor failures. Therefore, the peculiarities of the signals that are reflected in stator current are investigated, in order to correlate the signal characteristics to the failure in question. Current signals are processed through the Fourier and Wavelet transform in order to analyse short-circuit specific frequencies. Subsequently, the classification is performed through two artificial neural networks, the multilayer perceptron and the Radial Basis Function.

**Keywords:** Three Phase Induction Motors, stator fault, fault diagnosis, Wavelet Transform, entropy, Artificial Neural Networks

## LISTA DE FIGURAS

FIGURA 1	– Prognóstico e diagnóstico durante um processo de degradação. ....	18
FIGURA 2	– Procedimento para monitoramento do MIT. ....	19
FIGURA 3	– Espectro de frequência de corrente de estator indicando valores hipotéticos para $f_{CC}$ de acordo com o escorregamento. ....	21
FIGURA 4	– Filtro wavelet delimitando um intervalo de frequências nas quais podem ocorrer falhas de curto-circuito. ....	22
FIGURA 5	– Metodologia proposta. ....	24
FIGURA 6	– Filtros discretos para geração da decomposição <i>wavelet</i> . ....	29
FIGURA 7	– WPR do primeiro nível de decomposição. ....	30
FIGURA 8	– Estrutura de árvore formada pela decomposição <i>wavelet-packet</i> ; abaixo, encontram-se as representações dos filtros resultantes após o processo. ....	30
FIGURA 9	– Esquema geral para ensaios, Laboratório de Sistemas Inteligentes. ...	38
FIGURA 10	– Esquema geral para ensaios, Laboratório de Automação Inteligente de Processos e Sistemas. ....	39
FIGURA 11	– <i>Taps</i> do enrolamento de estator para realização de ensaios de curto-circuito. ....	40
FIGURA 12	– MIT 3 e suas derivações para ensaios de até 20% de espiras curto circuitadas. ....	41
FIGURA 13	– Organização das amostras, aquisição 1. ....	41
FIGURA 14	– Organização das amostras, aquisição 2. ....	42
FIGURA 15	– Representação gráfica das diversas falhas de estator. ....	47
FIGURA 16	– Correntes trifásicas, motor normal à vazio, sem desbalanço. ....	50
FIGURA 17	– Espectro de frequência referentes às correntes trifásicas, motor normal à vazio, sem desbalanço. ....	51
FIGURA 18	– Correntes trifásicas, motor com curto-circuito de 1% das espiras, à vazio, sem desbalanço. ....	52
FIGURA 19	– Espectro de frequência referentes às correntes trifásicas, motor com curto-circuito de 1% das espiras, à vazio, sem desbalanço. ....	53
FIGURA 20	– Espectro de frequência referentes à fase A, motor normal e com diversos níveis de curto-circuito, à vazio, sem desbalanço. ....	53
FIGURA 21	– Valor RMS das componentes do nível 8 da decomposição <i>wavelet-packet</i> para os sinais com variação de curto-circuito de até 20%. ....	56
FIGURA 22	– Valor RMS das componentes do nível 8 da decomposição <i>wavelet-packet</i> para os sinais sem falha e sem desequilíbrio, considerando variação de carregamento. ....	57
FIGURA 23	– Valor RMS das componentes do nível 8 da decomposição <i>wavelet-packet</i> para os sinais do motor à vazio sem falha, considerando variação de desequilíbrio entre fases. ....	59
FIGURA 24	– Valor RMS das componentes do nível 8 da decomposição <i>wavelet-packet</i> para os sinais do motor à vazio sem falha, considerando variação de sobretensão na fase B. ....	61
FIGURA 25	– Padrão de curto-circuito das primeiras componentes de decomposição <i>wavelet</i> para os dados dos 3 motores analisados. ....	62
FIGURA 26	– TF aplicada na componente <i>wavelet</i> (8,6) reconstruída. ....	63

FIGURA 27 – Localização estimada das frequências 150 Hz e 210 Hz até o décimo nível de decomposição <i>wavelet-packet</i> . . . . .	64
FIGURA 28 – Potência de Previsão das componentes da WPD do MIT 1, sinais sem falha, com falha e relativo. . . . .	66
FIGURA 29 – Potência de Previsão das componentes da WPD do MIT 2, sinais sem falha, com falha e relativo. . . . .	67
FIGURA 30 – Potência de Previsão das componentes da WPD do MIT 3, sinais sem falha, com falha e relativo. . . . .	68
FIGURA 31 – Arquitetura <i>Perceptron</i> multicamadas (PMC). . . . .	71
FIGURA 32 – Organização das amostras, exibindo os subconjuntos de treinamento e validação das entradas e saídas da rede. . . . .	73
FIGURA 33 – Gráfico de $RMS(C(8,8)) \times RMS(C(8,6))$ , para diversas intensidades de curto-circuito. . . . .	74
FIGURA 34 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por curto-circuito. . . . .	82
FIGURA 35 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por curto-circuito. . . . .	83
FIGURA 36 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por curto-circuito. . . . .	84
FIGURA 37 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por desequilíbrio entre fases. . . . .	88
FIGURA 38 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por desequilíbrio entre fases. . . . .	88
FIGURA 39 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por desequilíbrio entre fases. . . . .	89
FIGURA 40 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de curto-circuito utilizando coeficientes PP. . . . .	92
FIGURA 41 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de curto-circuito utilizando coeficientes PP. . . . .	93
FIGURA 42 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de curto-circuito utilizando coeficientes PP. . . . .	93
FIGURA 43 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por desequilíbrio utilizando coeficientes PP. . . . .	96
FIGURA 44 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por desequilíbrio utilizando coeficientes PP. . . . .	96
FIGURA 45 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por desequilíbrio utilizando coeficientes PP. . . . .	97
FIGURA 46 – Arquitetura <i>Radial Basis Function</i> (RBF). . . . .	98
FIGURA 47 – Disposição do vetor de pesos dos neurônios da camada escondida após convergência para o centro das amostras. . . . .	98
FIGURA 48 – a) Campos receptivos hiperesféricos referentes aos dois neurônios da camada escondida. b) Fronteira delimitadora de separação produzida. . . . .	100
FIGURA 49 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de curto-circuito utilizando RMS. . . . .	104
FIGURA 50 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de curto-circuito utilizando RMS. . . . .	104
FIGURA 51 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de curto-circuito utilizando RMS. . . . .	105

FIGURA 52 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de desequilíbrio utilizando RMS. ....	107
FIGURA 53 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de desequilíbrio utilizando RMS. ....	108
FIGURA 54 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de desequilíbrio utilizando RMS. ....	108
FIGURA 55 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de curto-circuito utilizando coeficientes PP. ....	112
FIGURA 56 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de curto-circuito utilizando coeficientes PP. ....	112
FIGURA 57 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de curto-circuito utilizando coeficientes PP. ....	113
FIGURA 58 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de desequilíbrio utilizando coeficientes PP. ....	115
FIGURA 59 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de desequilíbrio utilizando coeficientes PP. ....	116
FIGURA 60 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de desequilíbrio utilizando coeficientes PP. ....	116

## LISTA DE TABELAS

TABELA 1	– Dados dos motores. ....	40
TABELA 2	– Porcentual de falhas de componentes do MIT .....	44
TABELA 3	– Frequências características de curto-circuito ( $f_{cc}$ ), $k = 1$ , $f = 60Hz$ , $p = 2$ .....	49
TABELA 4	– Tabela resumo ds componentes de frequência e suas possíveis causas. ....	54
TABELA 5	– Valor RMS das componentes reconstruídas do nível 8 da decomposição <i>wavelet-packet</i> para os sinais com variação de curto-circuito de até 20%. ....	55
TABELA 6	– Valor RMS das componentes reconstruídas do nível 8 da decomposição <i>wavelet-packet</i> para os sinais variação de carregamento. ....	57
TABELA 7	– Valor RMS das componentes reconstruídas do nível 8 da decomposição <i>wavelet-packet</i> para os sinais do motor à vazio sem falha, considerando variação de desequilíbrio entre fases. ....	59
TABELA 8	– Valor RMS das componentes reconstruídas do nível 8 da decomposição <i>wavelet-packet</i> para os sinais do motor à vazio sem falha, considerando sobretensão na fase B e subtensão na fase C. ....	60
TABELA 9	– Topologias testadas .....	71
TABELA 10	– Organização de amostras de treinamento e validação. ....	72
TABELA 11	– Matriz de confusão $2 \times 2$ genérica. ....	75
TABELA 12	– Interpretação dos valores do índice Kappa. ....	75
TABELA 13	– Resultados de validação, para amostras com 7% e 10% de curto-circuito. ....	76
TABELA 14	– Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 13. ....	76
TABELA 15	– Resultados de validação, para amostras com 5% de curto-circuito. ..	77
TABELA 16	– Matriz de confusão para o experimento com maior taxa de acertos da Tabela 15. ....	77
TABELA 17	– Resultados de validação, para amostras com 3% de curto-circuito. ..	77
TABELA 18	– Matriz de confusão para o experimento com maior taxa de acertos da Tabela 17. ....	77
TABELA 19	– Resultados de validação, para amostras com 1% de curto-circuito. ..	78
TABELA 20	– Matriz de confusão para o experimento com maior taxa de acertos da Tabela 19. ....	78
TABELA 21	– Resultados de validação, para amostras com 7% e 10% de curto-circuito. ....	79
TABELA 22	– Matriz de confusão para o experimento com maior taxa de acertos da Tabela 21. ....	79
TABELA 23	– Resultados de validação, para amostras com 5% de curto-circuito. ..	80
TABELA 24	– Matriz de confusão para o experimento com maior taxa de acertos da Tabela 23. ....	80
TABELA 25	– Resultados de validação, para amostras com 3% de curto-circuito. ..	80
TABELA 26	– Matriz de confusão para o experimento com maior taxa de acertos da Tabela 25. ....	81

TABELA 27 – Resultados de validação, para amostras com 1% de curto-circuito. . .	81
TABELA 28 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 27. . . . .	81
TABELA 29 – Organização de amostras de treinamento e validação para os testes sem desequilíbrio de tensão. . . . .	85
TABELA 30 – Resultados de validação para amostras com curto-circuito de até 7%, MIT 1, e 20%, MITs 2 e 3, amostras sem desequilíbrio. . . . .	85
TABELA 31 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 30. . . . .	85
TABELA 32 – Organização de amostras de treinamento e validação para os testes com desequilíbrio de tensão de até 2%. . . . .	86
TABELA 33 – Resultados de validação, para amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 2%. . . . .	86
TABELA 34 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 33. . . . .	86
TABELA 35 – Organização de amostras de treinamento e validação para os testes com desequilíbrio de até 4%. . . . .	87
TABELA 36 – Resultados de validação, para amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 4%. . . . .	87
TABELA 37 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 36. . . . .	87
TABELA 38 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 7% e 10% das espiras. . . . .	90
TABELA 39 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 38. . . . .	90
TABELA 40 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 5% das espiras. . . . .	90
TABELA 41 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 40. . . . .	91
TABELA 42 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito 3% das espiras. . . . .	91
TABELA 43 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 42. . . . .	91
TABELA 44 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito 1% das espiras. . . . .	92
TABELA 45 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 44. . . . .	92
TABELA 46 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito de até 7% e 20%, amostras sem desequilíbrio. . . . .	94
TABELA 47 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 46. . . . .	94
TABELA 48 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 2%. . . . .	95
TABELA 49 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 48. . . . .	95
TABELA 50 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até	

4%.	95
TABELA 51 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 50.	95
TABELA 52 – Topologias RBF utilizadas nos experimentos.	99
TABELA 53 – Resultados de validação, para amostras com 7% e 10% de curto-circuito.	101
TABELA 54 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 53.	101
TABELA 55 – Resultados de validação, para amostras com 5% de curto-circuito.	102
TABELA 56 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 55.	102
TABELA 57 – Resultados de validação, para amostras com 3% de curto-circuito.	102
TABELA 58 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 57.	103
TABELA 59 – Resultados de validação, para amostras com 1% de curto-circuito.	103
TABELA 60 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras sem desequilíbrio.	105
TABELA 61 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 60.	106
TABELA 62 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 2%.	106
TABELA 63 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 62.	106
TABELA 64 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 4%.	107
TABELA 65 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 64.	107
TABELA 66 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 7% e 10% das espiras.	109
TABELA 67 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 66.	109
TABELA 68 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 5% das espiras.	110
TABELA 69 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 68.	110
TABELA 70 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 3% das espiras.	111
TABELA 71 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 1% das espiras.	111
TABELA 72 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras sem desequilíbrio.	113
TABELA 73 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 72.	114
TABELA 74 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 2%.	114
TABELA 75 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 74.	114
TABELA 76 – Resultados de validação para amostras com curto-circuito de até 7%	

e 20%, amostras com desequilíbrio de até 4%. . . . .	115
TABELA 77 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 76. . . . .	115
TABELA 78 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 2 para validação. . . . .	117
TABELA 79 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 3 para validação . . . . .	118
TABELA 80 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 1 para validação . . . . .	118
TABELA 81 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 3 para validação . . . . .	119
TABELA 82 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 1 para validação . . . . .	119
TABELA 83 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 2 para validação . . . . .	119
TABELA 84 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 2 para validação, com coeficientes PP. . . . .	120
TABELA 85 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 3 para validação, com coeficientes PP. . . . .	120
TABELA 86 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 1 para validação, com coeficientes PP. . . . .	121
TABELA 87 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 3 para validação, com coeficientes PP. . . . .	121
TABELA 88 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 1 para validação, com coeficientes PP. . . . .	121
TABELA 89 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 2 para validação, com coeficientes PP. . . . .	122
TABELA 90 – Resultado geral, considerando todas as condições de operação, incluindo desequilíbrios, carregamentos e curto-circuito. . . . .	122
TABELA 91 – Resultados de validação considerando as fases B e C. . . . .	123



## LISTA DE SIGLAS E ABREVIATURAS

Aneel Agência Nacional de Energia Elétrica.  
AR *Autoregressive*.  
ARMA *Autoregressive Moving Average*.  
CWT Continuous Wavelet Transform.  
DFT *Discrete Fourier Transform*.  
DWT Discrete Wavelet Transform.  
EPRI *Electric Power Research Institute*.  
EPVA *Extended Park's Vector Approach*.  
FFT Fast Fourier Transform.  
IC Inteligência Computacional.  
IEEE *Institute of Electrical and Electronics Engineers*.  
LAIPS Laboratório de Automação Inteligente de Processos e Sistemas.  
LSI Laboratório de Sistemas Inteligentes.  
MCSA *Motor Current Signature Analysis*.  
MIT Motores de Indução Trifásicos.  
PCA *Principal Component Analysis*.  
PDF *Probability Distribution Functions*.  
PMC *Perceptron* Multicamadas.  
PP Potência de Previsão.  
PP Potência de Previsão.  
PrCA *Predictable Component Analysis*.  
QMF *Quadrature Mirror Filters*.  
RBF *Radial Basis Function*.  
RMS *Root Mean Square*.  
RNA Redes Neurais Artificiais.  
SDP *Symmetrised Dot Pattern*.  
SOM Mapas Auto-Organizáveis de Kohonen.  
STFT *Short-Time Fourier Transform*.  
TF Transformada de Fourier.  
TSA *Time Synchronous Average*.  
TW Transformada Wavelet.  
WPD *wavelet-packet decomposition*.  
WPR *wavelet-packet reconstruction*.

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>17</b>
1.1 PROBLEMA	20
1.2 JUSTIFICATIVA	22
1.3 OBJETIVOS	23
1.3.1 Objetivo geral	23
1.3.2 Objetivos específicos	23
1.4 METODOLOGIA	23
1.5 ESTRUTURA DO TRABALHO	25
<b>2 ESTADO DA ARTE DE DETECÇÃO DE FALHAS</b>	<b>26</b>
2.1 ANÁLISE NO DOMÍNIO DO TEMPO	26
2.2 ANÁLISE NO DOMÍNIO DA FREQUÊNCIA	27
2.3 TRANSFORMADA <i>WAVELET</i>	28
2.4 MEDIDAS DE PREVISIBILIDADE	32
2.4.1 Entropia	33
2.4.2 Potência de Previsão	34
2.5 MÉTODOS DE DETECÇÃO DA FALHA	34
2.5.1 Modelos Determinísticos	34
2.5.1.1 Lógica Fuzzy	35
2.5.1.2 Redes Neurais Artificiais	35
2.6 CONCLUSÃO	36
<b>3 MATERIAIS E MÉTODOS</b>	<b>38</b>
3.1 SISTEMA DE AQUISIÇÃO DE DADOS	38
3.2 FALHA DE CURTO-CIRCUITO RECRIADA EM LABORATÓRIO	40
<b>4 FALHAS DE ESTATOR DE MIT</b>	<b>43</b>
4.1 FALHAS EM MOTORES DE INDUÇÃO	44
4.2 ESTUDO DA FALHA DE ESTATOR	45
4.3 ANÁLISE DOS DADOS ATRAVÉS DA TRANSFORMADA DE FOURIER	49
4.3.1 Motor normal, sem carga, sem desbalanço	50
4.3.2 Motor com curto-circuito na fase A, sem carga, sem desbalanço	52
4.4 ANÁLISE DOS DADOS ATRAVÉS DA TRANSFORMADA <i>WAVELET</i>	54
4.4.1 Variação do curto-circuito na fase A, sem carga, sem desbalanço	54
4.4.2 Variação do carregamento no eixo, motor normal, sem desbalanço	56
4.4.3 Subtensão na fase A, motor normal a vazio	58
4.4.4 Sobretenção na fase B e subtensão na fase C, motor normal a vazio	60
4.4.5 A falha de curto-circuito na árvore de decomposição	63
4.5 POTÊNCIA DE PREVISÃO NA ANÁLISE DE CURTO-CIRCUITO	65
4.6 CONCLUSÃO	69
<b>5 RESULTADOS EXPERIMENTAIS</b>	<b>70</b>
5.1 <i>CLASSIFICAÇÃO UTILIZANDO REDES PERCEPTRON MULTICAMADAS</i>	70
5.1.1 RMS das componentes 6 e 8 como entradas	73
5.1.2 RMS das componentes 2, 4, 6, 8, 14 e 16 como entradas	78
5.1.3 Classificação utilizando Potência de Previsão	89
5.2 <i>CLASSIFICAÇÃO UTILIZANDO RADIAL BASIS FUNCTION</i>	97
5.2.1 Classificação utilizando Potência de Previsão	109

5.3 TESTES DE ROBUSTEZ .....	117
5.4 CONCLUSÃO .....	123
<b>6 CONSIDERAÇÕES FINAIS .....</b>	<b>125</b>
6.1 AGRADECIMENTOS .....	127
6.2 PUBLICAÇÃO ASSOCIADA AO TRABALHO .....	127
<b>REFERÊNCIAS .....</b>	<b>128</b>

## 1 INTRODUÇÃO

Motores de Indução Trifásicos (MIT) são as máquinas elétricas mais utilizadas no ambiente industrial, consumindo em torno de 40% da energia elétrica no mundo (FERREIRA; ALMEIDA, 2012). Trata-se de um dispositivo que apresenta princípio de funcionamento simples, construção robusta, facilidade de manutenção, baixo custo de aquisição e confiabilidade (FITZGERALD; KINGSLEY; UMANS, 2008). Contudo, os MIT são frequentemente expostos aos mais diversos tipos de ambientes operacionais prejudiciais. Isso significa que o equipamento está normalmente sujeito a esforços térmicos, elétricos e mecânicos indesejáveis, os quais podem originar uma falha. Portanto, o prognóstico antecipado de falhas é importante para garantir condições operacionais seguras e minimizar custos.

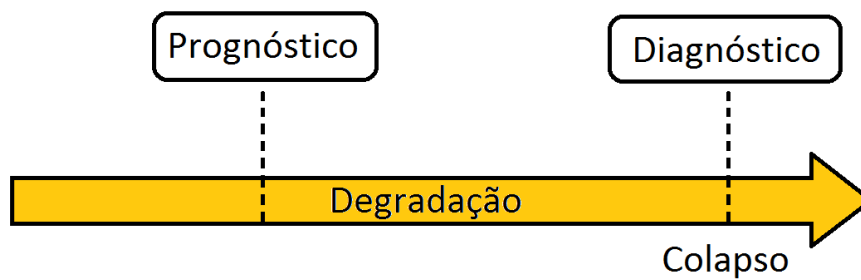
Neste ponto, torna-se necessário diferenciar os conceitos de prognóstico e diagnóstico. Ambos os termos são oriundos do campo da medicina, contudo, à medida que a manutenção preditiva foi se desenvolvendo, tornou-se de muito interesse o conhecimento a respeito da condição dos equipamentos e maquinários. Em função dessa similaridade, tais termos começaram a ser amplamente utilizados no campo da engenharia.

A palavra prognóstico está semanticamente relacionada à predição, prenúncio, previsão (HOUAISS, 2011). Tais conceitos estão em consonância com os fundamentos da manutenção preditiva. Logo, conclui-se que realizar o prognóstico de uma máquina elétrica é, de fato, o âmago da manutenção preditiva. A palavra diagnóstico, por sua vez, têm o mesmo valor semântico de investigação, pesquisa, identificação, parecer (HOUAISS, 2011). Portanto, o diagnóstico é considerado uma reação a uma falha, com a finalidade de investigar os motivos que levaram à disruptura e interrupção de um sistema ou equipamento.

De fato, segundo Lee et al. (2014), o diagnóstico é o processo que contempla aquisição de dados, processamento de sinal e extração de características, além do conhecimento a respeito de falhas, modelos físicos e informação de eventos passados. Logo, por si só não é uma medida a qual previne o chamado *downtime* - termo utilizado para indicar o tempo no qual o equipamento está inoperante para manutenção. Ainda, afirma que o prognóstico pode ser interpretado como o processo que inclui a detecção de falhas incipientes e estima a vida útil restante do motor e seus componentes.

As principais perguntas que um prognóstico procura responder são: "como a máquina está operando agora?", "quando a máquina entrará em colapso?", "quais serão os primeiros indícios de falha?" e "por que a falha ocorre?" (LEE et al., 2014). A Figura 1 ilustra essa percepção, diferenciando prognóstico de diagnóstico, ao longo do processo de degradação de um sistema.

Aliados, prognóstico e diagnóstico, auxiliam a tomadas de decisões relativas ao MIT dentro do processo industrial, formando a base para o desenvolvimento de uma metodologia de acompanhamento contínuo das variáveis de processo que indiquem a evolução do processo de degradação do equipamento com o intuito de reduzir a incidência de falhas. Em uma situação ideal, uma falha seria detectada em seu estágio inicial, o que alertaria para o desenvolvimento de uma falha crítica, que por sua vez demandaria a ação de uma manutenção corretiva. Assim, o cronograma de manutenção é otimizado, o tempo de provisionamento para peças reservas pode ser reduzido e o tempo no qual a máquina estaria



**Figura 1 – Prognóstico e diagnóstico durante um processo de degradação.**

Fonte: Adaptado de Lee et al. (2014)

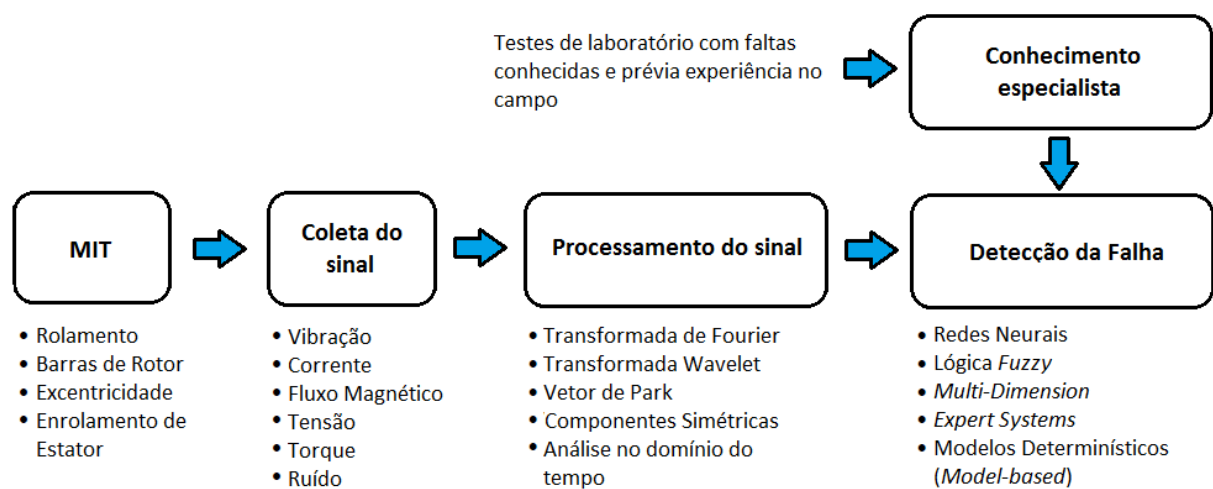
inoperante seria próximo de zero (BELLINI et al., 2008). Logo, diante da política de maximização de lucros, o período de *downtime* é inaceitável. Em razão disso, esforços devem ser realizados no intuito de migrar a estratégia de manutenção da metodologia corretiva para a preditiva. Para que isso seja possível, o monitoramento do MIT em tempo real e em campo se fazem necessários.

A base para qualquer método de monitoramento de motores de indução trifásicos é o entendimento de seu comportamento elétrico, magnético e mecânico quando em funcionamento normal e perante alguma condição de falha (FISER; FERKOLJ, 2001). Os MIT são máquinas altamente simétricas, o que significa que qualquer tipo de falha modifica suas propriedades causando algum tipo de assimetria (SIN; SOONG; ERTUGRUL, 2003; BELLINI et al., 2008). Portanto, quando é desenvolvida uma falha, os indícios de defeitos surgem de várias formas, tais como mudanças nos sinais de vibrações, variação na temperatura, ruídos, alterações no fluxo magnético e na corrente de estator (THOMSON, 2001). Assim sendo, procura-se encontrar a correlação entre o tipo de falha e a respectiva perturbação causada em uma ou mais dessas variáveis. Acompanhar a variável em questão consiste em realizar o monitoramento da evolução de uma possível falha.

A Figura 2 exhibe, em um diagrama de blocos, as etapas necessárias para se realizar o monitoramento da condição de um motor trifásico. O primeiro bloco lista componentes do MIT submetidos à falha. Seguindo, sensores devem ser conectados à máquina a fim de coletar dados de acordo com a variável que se deseja monitorar.

Em seguida, utiliza-se alguma técnica de processamento de sinais para extrair características relativas às falhas. O processamento normalmente possibilita uma interpretação dos dados por outro ponto de vista. A Transformada de Fourier (TF), por exemplo, permite a análise do sinal no domínio da frequência, no qual são evidenciadas características que de outra forma estariam ocultas ou de difícil percepção. Nesse sentido, muitas vezes é possível obter dados mais expressivos para um dada situação. Demais métodos de processamento promovem a análise por uma nova perspectiva de maneiras distintas, cada qual com suas vantagens e desvantagens. A Transformada Wavelet (TW) e a Potência de Previsão (PP) estão entre as ferramentas utilizadas neste trabalho, portanto, têm seus fundamentos teóricos aprofundados no Capítulo 2.

Por fim, aliado ao conhecimento de um especialista, é tomada a decisão a respeito da existência ou não da falha com auxílio de um dos métodos utilizados na detecção de falha listados no último bloco. O diagnóstico baseado em técnicas computadorizadas convencionais tem, recentemente, entrado em desuso. Os sistemas baseados em Inteligência Computacional (IC), por sua vez, vem sendo utilizados com maior frequência. Dentro desse meio, as Redes Neurais Artificiais (RNA) são conhecidas por sua capacidade de aprendizado e generalização, sendo portanto, amplamente empregadas para classificação de padrões. A *Perceptron* Multicamadas (PMC) e a *Radial Basis Function* (RBF) são duas arquiteturas de RNA utilizadas no presente trabalho. Detalhes a respeito podem ser verificados na Seção 2.5.



**Figura 2 – Procedimento para monitoramento do MIT.**

Fonte: Adaptado de Siddiqui, Sahay e Giri (2014)

Diversos aspectos das máquinas sofrem alterações perante uma determinada falha. Grandezas operacionais tais como vibração, temperatura, torque, velocidade, medidas elétricas e magnéticas podem ser utilizadas para a determinação de uma condição anormal de operação. Para a implementação de técnicas de monitoramento é necessário realizar procedimentos para coleta de tais dados. A seguir são expostas as metodologias mais utilizadas para o monitoramento e coleta de sinais da máquina, elencando algumas vantagens e desvantagens de cada método.

O uso de sinais de vibração consiste em uma técnica extensivamente utilizada com sucesso para diagnosticar falhas em motores de indução. De fato, segundo Siddiqui, Sahay e Giri (2014), o monitoramento da vibração é o melhor método quando se trata de falhas mecânicas, contudo, demanda instrumentos de custo elevado. Além disso, para uma medição precisa muitas vezes é preciso ter acesso interno ao MIT, pois os sensores devem ser instalados firmemente ao equipamento. Essas características limitam seu uso a casos específicos.

O monitoramento da temperatura é baseado no princípio de que determinados defeitos geram calor anormal em certos pontos da máquina. A temperatura elevada em

razão de curto-circuito nas espiras do estator ou a fricção exagerada dos rolamentos com a pista possibilita a detecção de falhas de estator e rolamento. A desvantagem dessa técnica é que o aquecimento das regiões mencionadas pode ocorrer de forma gradativa e lenta, impossibilitando muitas vezes o diagnóstico de uma falha incipiente (MEHALA, 2010). Ademais, seu uso fica limitado basicamente aos dois tipos de falhas mencionadas.

Em relação ao monitoramento do fluxo magnético, o mesmo é baseado no fato que qualquer alteração na densidade de fluxo no entreferro estabelece um fluxo axial no eixo (SIDDQUI; SAHAY; GIRI, 2014). Esse, por sua vez, pode ser mensurado por espiras localizadas na região traseira do motor. Dessa forma, o fluxo disperso é concatenado pelas espiras externas, fazendo surgir uma tensão proporcional em seus terminais, a qual pode ser mensurada. Essa técnica pode ser usada para detectar defeitos no estator, contudo é mais usualmente empregada para estimar a velocidade do MIT (SIN; SOONG; ERTUGRUL, 2003).

O monitoramento da corrente de linha do estator destaca-se entre as demais pelo fato de possibilitar a coleta de dados de maneira não invasiva, permitindo a coleta do sinal remotamente, sem a necessidade de se ter acesso ao MIT (BENBOUZID, 2000). Sendo assim, a ligação pode ser realizada em qualquer ponto da alimentação sem comprometer sua performance. Outro ponto a considerar é o fato de não haver necessidade de conexão física entre o sistema de acionamento e o sensor, o que garante segurança no procedimento. Em virtude dos motivos supracitados, Bellini et al. (2008) e Thomson e Fenger (2001) asseguram que, dentre as variáveis possíveis de serem mensuradas no processo industrial, o monitoramento via corrente de estator é aceito pela indústria como o mais apropriado. Técnicas de monitoramento da corrente de estator são usualmente empregadas para detectar vários tipos de falhas em motores de indução, tais como falha de rotor (SUETAKE, 2012), de curto-circuito entre espiras (SANTOS, 2013; THOMSON, 2001), de excentricidade (THOMSON; FENGER, 2001; DORRELL; THOMSON; ROACH, 1995) e de rolamento (GONGORA, 2013; SCHMITT, 2013; SCHMITT et al., 2015).


Portanto, diante dos aspectos mencionados, o diagnóstico fundamentado nas correntes trifásicas do estator apresenta-se como a estratégia utilizada no presente trabalho. Técnicas, ferramentas e algoritmos de processamento de sinais são aplicados aos sinais de corrente a fim de investigar os indícios de determinada falha, possibilitando, por fim, a instalação de uma metodologia para realização do monitoramento das condições do MIT.

## 1.1 PROBLEMA

Tradicionalmente, a análise da corrente estatórica para detecção de falhas é realizada em conjunto com a TF, com a finalidade de examinar as frequências características de determinada falha no espectro da corrente. No caso da falha de estator, a Equação (1) determina as componentes de frequência da corrente de estator que tem seu módulo modificado quando da ocorrência dessa falha (THOMSON, 2001; THOMSON; FENGER, 2001).

$$f_{cc} = f_1 \left[ \frac{n}{p}(1-s) \pm k \right] \quad (1)$$

A frequência da componente fundamental da alimentação é representada por  $f_1$ ,  $p$  é o número de pares de polos do MIT,  $s$  é o escorregamento do rotor,  $k$  é um número inteiro ímpar e  $n$  é um número inteiro positivo. Percebe-se que o resultado dessa equação modifica-se de acordo com o escorregamento do MIT. Isso significa que a frequência característica da falha de estator se modifica conforme variações de torque no eixo da máquina. A Figura 3 exemplifica essa situação, ilustrando o espectro de frequências genérico e simplificado da corrente de um motor de indução trifásico com falha de estator. A frequência de curto-circuito aparece no gráfico, indicada por  $f_{CC}$ . Caso o escorregamento do motor se modifique, a frequência na qual ocorre a falha se altera, conforme verificado na Equação 1. Dessa forma, podemos assumir, hipoteticamente, que os componentes de frequência da falha ocorrem dentro do intervalo  $f_{CC1}$  a  $f_{CC2}$ .



**Figura 3 – Espectro de frequência de corrente de estator indicando valores hipotéticos para  $f_{CC}$  de acordo com o escorregamento.**

Fonte: Autoria própria

Como visto, o uso desse método é baseado na decomposição do sinal de corrente em um espectro de frequências. Um curto-circuito provoca o surgimento de uma componente harmônica na frequência característica dessa falha. Para que se possa determinar essa frequência é indispensável que se saiba o escorregamento do MIT (CASTELLI; FOS-SATTI; TERRA, 2012). A complicação se deve ao fato de que esse parâmetro se modifica em virtude da carga aplicada no eixo da máquina.


Diante do exposto, verifica-se que a detecção da frequência característica por meio da TF é realizada de forma pontual. Portanto, para o correto funcionamento de um sistema de detecção de falha baseado na TF, o mesmo deve estar preparado para lidar com situações de alteração do escorregamento. Uma das alternativas envolve garantir que o carregamento no eixo da máquina seja constante, o que nem sempre é possível no ambiente industrial.



## 1.2 JUSTIFICATIVA

As *wavelets* são funções capazes de decompor e representar uma série de dados originalmente descrita no domínio do tempo. Essa decomposição recebe o nome de TW. Devido à possibilidade de análise de um sinal em diferentes escalas de frequência e tempo, as funções *wavelet* são ferramentas poderosas de processamento de sinais, muito aplicadas, por exemplo, na compressão de dados, eliminação de ruído e separação de componentes no sinal. Essa última aplicação, em particular, se torna uma opção extremamente interessante para sobrepor o problema em questão. A capacidade da TW de separar componentes de um sinal, dentro de determinado intervalo de frequências, possibilita a eliminação da preocupação com variações no torque imposto ao eixo da máquina.

Dessa forma, basta encontrar o intervalo de frequências possível para a frequência característica da falha de estator. Conforme ilustrado na Figura 4, a TW funciona como um filtro, no qual é possível isolar e analisar as frequências no entorno da  $f_{CC}$ . Tem-se assim, a segurança de observar todo o intervalo  $f_{CC1}$  a  $f_{CC2}$  no qual há possibilidade de ocorrência de um pico em razão do curto-circuito.



**Figura 4 – Filtro wavelet delimitando um intervalo de frequências nas quais podem ocorrer falhas de curto-circuito.**

Fonte: Autoria própria

A forma de onda abaixo do espectro de Fourier na Figura 4 representa a resposta em frequência do filtro gerado a partir da TW. Percebe-se que, dessa forma, a análise não se resume ao acompanhamento de um único valor no espectro de frequência, o qual é instável em razão da sua vinculação com o carregamento aplicado à máquina. Ao contrário, a componente obtida a partir da TW indicará uma perturbação qualquer que seja o valor

do escorregamento, desde que  $f_{cc}$  se mantenha dentro dos limites de corte do filtro.

Em suma, a utilização da Transformada *Wavelet* permite a análise dentro de um determinado intervalo de frequências. Dessa forma, o problema referente às alterações no escorregamento do MIT pode ser minimizado ou até mesmo superado.

### 1.3 OBJETIVOS

Esta seção se dedica a expor os objetivos geral e específicos, deixando claro o que se espera conseguir ao fim do estudo.

#### 1.3.1 Objetivo geral

O escopo do presente trabalho consiste em desenvolver uma estratégia alternativa para a detecção de curto-circuito em motores de indução. Dessa forma, procura-se uma metodologia para o monitoramento do estado dos enrolamentos de estator de maneira que seja independente às variações de carregamento. São levados em consideração também variações nas intensidades de curto-circuito e de desequilíbrio entre fases da alimentação.

Em outras palavras, busca-se possibilitar a utilização do método para a implementação do prognóstico das condições das bobinas da máquina, investigando sua viabilidade para tanto.

#### 1.3.2 Objetivos específicos

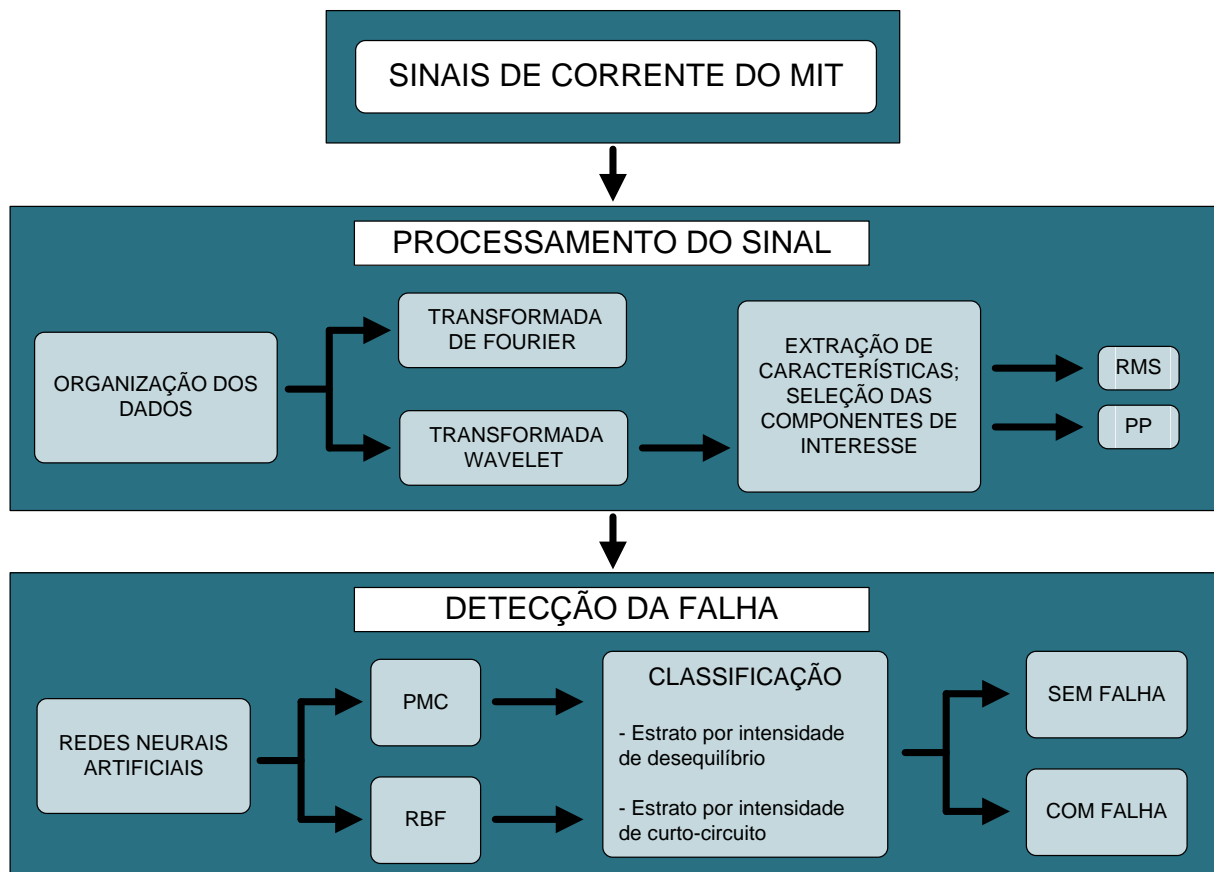
Dentre os objetivos específicos, elencam-se os seguintes:

- Realizar o estudo das frequências associadas ao curto-circuito;
- Analisar as frequências de interesse aplicando a TF nas correntes estatóricas;
- Isolar as componentes associadas ao curto-circuito por meio da TW e analisá-las em busca de padrões, perante variações de desequilíbrios e intensidades de curto-circuitos;
- Investigar a viabilidade de se utilizar o valor RMS e PP das componentes *wavelets* de interesse como entradas para a RNA;
- Testar duas RNA distintas como classificadoras de padrões, PMC e RBF;
- Testar a confiabilidade do método frente às amostras provenientes de motores diferentes.

### 1.4 METODOLOGIA

A metodologia empregada no trabalho envolve o processamento dos sinais de corrente do MIT, com falha e sem falha, e da detecção da falha por meio de um algoritmo específico aliado ao conhecimento especialista adquirido por meio de testes em laboratório.

O diagrama da Figura 5 ilustra a metodologia e auxilia no entendimento da proposta do trabalho. O primeiro passo consiste na organização dos sinais de corrente do MIT para análise dos componentes de frequência específicos do curto-circuito. A partir do banco de dados, promove-se a análise dessas componentes, primeiramente, com auxílio do espectro de Fourier. Em seguida, aplica-se TW para realizar a investigação de padrões. Nessa etapa, o valor RMS é utilizado para mensurar as alterações provocadas pelas frequências específicas nas componentes da TW. Na sequência, o próprio valor RMS será usado como entrada para as RNA, bem como os valores de Potência de Previsão. São realizados testes com as redes PMC e RBF, submetidas a amostras estratificadas por intensidade de curto-circuito e desequilíbrio com a finalidade de elevar a confiabilidade e facilitar a análise dos resultados. Por fim, avalia-se o desempenho de cada arquitetura de acordo com a taxa de acerto na classificação. Assim sendo, as simulações indicam a viabilidade do método, emulando o comportamento do sistema de detecção de falhas em uma situação real.



**Figura 5 – Metodologia proposta.**

**Fonte: Autoria própria**

Trata-se da realização do diagnóstico do MIT, pois busca-se entender o comportamento da falha a partir dos dados do motor com falha, ou seja, após um eventual colapso.

Portanto, de acordo com a análise realizada, criam-se bases para a instalação de um sistema de monitoramento. Espera-se que, desse modo, ao final do trabalho, seja desenvolvida uma estratégia para a detecção de falhas nos enrolamentos de motores de

indução, especificamente, curto-circuitos de estator. A seguir, apresenta-se a estrutura do trabalho e a forma como este é organizado, sintetizando o que será encontrado em cada capítulo.

## 1.5 ESTRUTURA DO TRABALHO

No Capítulo 2 são apresentadas técnicas de processamento de sinais utilizadas para a identificação de falhas, bem como técnicas de reconhecimento de padrões. De forma geral, esse capítulo foca na apresentação dos conceitos teóricos utilizados na posterior apreciação dos dados. São estudadas mais detalhadamente as Transformadas de Fourier e *Wavelet*, as Medidas de Previsibilidade, Entropia, Potência de Previsão e RNA.

No Capítulo 3, são apresentados os procedimentos, materiais e métodos empregados para a aquisição dos sinais que compuseram o banco de dados utilizado no trabalho. É realizada a descrição dos principais componentes da estrutura que compreende o sistema de aquisição de sinais para operação em diversos níveis de curto-circuito, desequilíbrios e carregamentos.

No Capítulo 4 é apresentada uma revisão dos conceitos sobre motores de indução trifásicos, suas propriedades, características básicas e as falhas mais comuns, com destaque para a falha de curto-circuito entre espiras no estator. São realizadas análises utilizando FT e TW, efetuando-se o reconhecimento de padrões dos dados de forma manual. Por fim, são organizadas as conclusões obtidas por meio dessas duas abordagens.

No Capítulo 5 é investigada a viabilidade do emprego de Redes Neurais Artificiais para a realização do mapeamento de padrões efetuado de forma manual no capítulo anterior. As redes PMC e RBF são submetidas a diversos treinamentos, diante de uma variedade de situações de falha, desequilíbrios e carregamento.

Por fim, no capítulo 6 são apresentadas as considerações finais do trabalho.

## 2 ESTADO DA ARTE DE DETECÇÃO DE FALHAS

Uma grande variedade de modelos, algoritmos e ferramentas podem ser utilizados no intuito de interpretar os sinais coletados e extrair características para o posterior diagnóstico ou prognóstico. Este capítulo exhibe os métodos de processamento de sinais convencionais aplicados à identificação de falhas de estator através do processamento do sinal da corrente de estator, expondo métodos fundamentados na análise no domínio do tempo e da frequência. São expostos embasamentos teóricos a respeito de medidas de informação, entropia e Potência de Previsão. Por fim, são analisadas as técnicas de detecção de falhas tradicionalmente empregadas para a classificação de sinais.

### 2.1 ANÁLISE NO DOMÍNIO DO TEMPO

Na análise no domínio do tempo, compara-se diretamente as formas de onda de dois ou mais sinais, o que pode imediatamente mostrar suas semelhanças ou disparidades. Normalmente, a extração de características ocorre através de cálculos de parâmetros estatísticos, os quais podem ser simples medidas da estatística descritiva, como por exemplo, média, valor de pico, desvio padrão, *Root Mean Square* (RMS). Esse último pode ser calculado conforme a Equação (2), considerando um conjunto discreto de  $N$  valores  $\{x_1, x_2, \dots, x_n\}$ . Dentre as medidas de estatística avançada, cita-se *skewness* e *kurtosis*.

$$RMS(X) = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2)$$

As medidas de correlação são outro exemplo de ferramentas comumente utilizadas. Tais medidas são usadas quando se deseja avaliar o grau de relacionamento entre duas ou mais variáveis. Neste sentido, existem vários métodos de mensurar a correlação, cada um adaptado à natureza dos dados utilizados. O mais conhecido é o coeficiente de correlação de Pearson, o qual é obtido dividindo a covariância de duas variáveis pelo produto de seus desvios padrão (BENESTY et al., 2009).

Segundo Jardine, Lin e Banjevic (2006), além dos métodos supracitados, outras ferramentas comuns para análise no tempo incluem: *Time Synchronous Average* (TSA), *Autoregressive* (AR) *model*, *Autoregressive Moving Average* (ARMA) *model*, *Principal Component Analysis* (PCA).

Utilizando apenas amostras de amplitude da forma de onda original de corrente, em Broniera et al. (2013), identificam-se falhas de curto-circuito entre espiras de estator de uma mesma fase. As amostras mencionadas serviram diretamente como entrada para três arquiteturas de redes neurais embarcadas em DSP, a fim de comparação. Destaca-se, neste ponto, uma grande vantagem desse método, haja vista que evita o processamento via TF, o qual acarretaria maior esforço computacional. Outro exemplo é Gongora (2013), no qual é proposto um sistema inteligente para detecção de falhas em tempo real empregando somente sinais de tensão e corrente no tempo e redes neurais artificiais. O algoritmo foi embarcado em DSP e validado em testes de bancada.

## 2.2 ANÁLISE NO DOMÍNIO DA FREQUÊNCIA

A análise no domínio da frequência proporcionada pela aplicação da Transformada de Fourier é o método de processamento de sinais mais comum quando se trata de monitoração das condições do MIT (SIDDIQUI; SAHAY; GIRI, 2014). Isso se deve ao fato de que nessa análise é possível identificar e isolar determinados componentes de interesse no espectro de frequência. Por utilizar-se desse princípio, a técnica *Motor Current Signature Analysis* (MCSA) tornou-se muito utilizada para a detecção de falhas. Embora alguns autores, como Benbouzid (2000), Sin, Soong e Ertugrul (2003), Mehala (2010), Siddiqui, Sahay e Giri (2014), considerem que analisar a corrente de estator por meio da TW é uma maneira de realizar MCSA, a grande maioria dos trabalhos associam MCSA exclusivamente à TF.

Para a aplicação da TF aos sinais coletados é necessária a utilização de sua versão discreta, a Transformada Discreta de Fourier, do inglês, *Discrete Fourier Transform* (DFT). Contudo, a complexidade computacional da DFT é bastante elevada. Em vista disso, um algoritmo particularmente eficiente para implementação computacional da DFT denomina-se Fast Fourier Transform (FFT), a Transformada Rápida de Fourier (CASTELLI; FOSSATTI; TERRA, 2012). A FFT constitui-se de uma ferramenta viável e efetiva para extração de características de sinais discretos. Suetake (2012) utilizou a FFT em conjunto com RNA com a finalidade de detectar falhas incipientes de barras quebradas nos rotores. Para tanto, foi utilizado o sinal de corrente de linha de uma das fases do MIT ligado em delta. O sinal foi transformado do domínio do tempo para o domínio da frequência e, em seguida, normalizou-se em amplitude e frequência em torno da componente fundamental. Antes de ser encaminhado para a rede neural, o vetor normalizado teve suas dimensões reduzidas aplicando-se a técnica de PCA. Utilizando essa metodologia foi possível o projeto de uma única ferramenta a qual, a partir de ensaios experimentais do MIT acionado diretamente pela rede elétrica, generaliza seus resultados para detectar falhas perante o acionamento por inversores de frequência. Nos experimentos, foram consideradas a análise do sinal processado pela FFT em termos de variação do carregamento e do número de barras quebradas.

A TF desempenha um papel importante na análise de sinais estacionários (LEE et al., 2014; PENG; CHU, 2004; HAMBABA; HUFF, 2000), uma vez que a aplicação dessa transformada conduz a uma abordagem no domínio da frequência em detrimento de informações temporais. Para que possa ser calculada a DFT é condição necessária que o sinal seja de duração finita. Portanto, o comprimento do sinal precisa ser limitado, procedimento conhecido como janelamento. Ainda que um aumento no comprimento da janela seja benéfico na análise de espectro de dados estacionários, quando se trata de dados variantes no tempo, é preferível estabelecer um comprimento de janela o mais curto possível (OPPENHEIM; SCHAFER, 2012). Isso leva ao conceito da TF dependente do tempo, a denominada *Short-Time Fourier Transform* (STFT).

Segundo Lee et al. (2014), a STFT exige alto desempenho computacional e sua resolução é constante para todas as frequências, uma vez que usa o mesmo tamanho de janela para analisar o sinal inteiro (HAMBABA; HUFF, 2000; PENG; CHU, 2004). A análise espectral de sinais não estacionários implica na escolha entre resolução no tempo

e na frequência (PROAKIS; MANOLAKIS, 2006). Isso significa que é possível obter uma boa resolução de frequência usando janelas maiores, contudo, em detrimento de uma boa resolução para o tempo (janela estreita). Por outro lado, como será visto na seção seguinte, por meio da TW, torna-se praticável a decomposição do sinal em diversas resoluções de tempo e frequência de forma apropriada (MALLAT, 2009).

### 2.3 TRANSFORMADA WAVELET

A TW gera uma representação do sinal por meio de versões escalonadas e deslocadas de uma mesma função *wavelet*, de modo similar à TF que utiliza senoides para a decomposição. Contudo, diferentemente da TF, a qual cria um espectro de frequência para o sinal como um todo, TW possibilita representar o sinal em diferentes resoluções de tempo e frequência, criando um conteúdo espectral que se modifica com o tempo. Em vista disso, a TW permite detectar uma alteração transitória no sinal. Tal fato é considerado uma característica apreciável quando se trata da detecção de falhas em MIT, haja vista que a corrente de estator consiste em um sinal dinâmico variante no tempo (BELLINI et al., 2008; BENBOUZID, 2000).

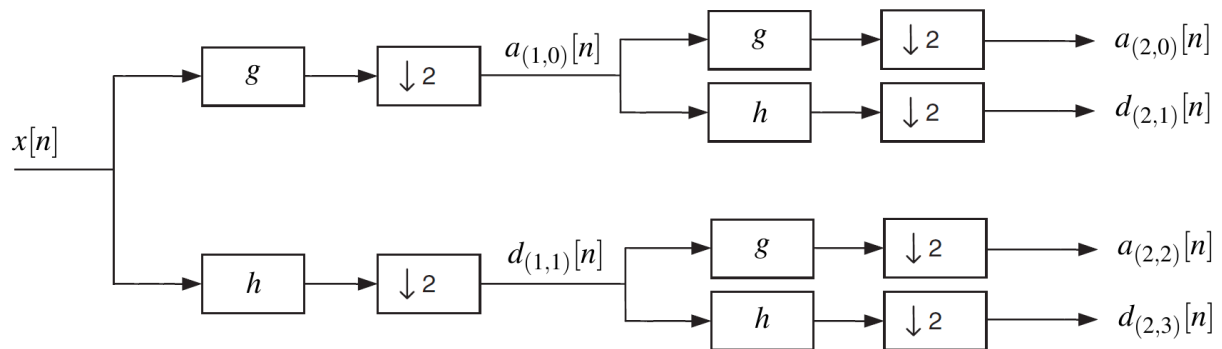
De acordo com Mallat (2009), ao contrário da DFT, a qual consiste em uma versão discreta da TF, a Transformada Wavelet Discreta, ou Discrete Wavelet Transform (DWT), não é a rigor uma versão discreta da Transformada Wavelet Contínua, ou Continuous Wavelet Transform (CWT). De fato, a implementação da DWT por meio da aplicação de um banco de filtros discretos passa-altas e passa-baixas consiste em um procedimento prático, convencional e eficiente para tal. Conforme as Equações (3) e (4), a concepção dos filtros consiste na convolução do sinal, sendo que  $h[n]$  consiste na resposta impulsiva de um filtro de decomposição passa-alta, enquanto que  $g[n]$  consiste em um filtro de decomposição passa-baixa, e  $N$  é o tamanho do sinal (GUIDO R.C.; SLAETS, 2006).

$$a[n] = x[n] * g[n] = \sum_{k=0}^{N-1} g[k] \cdot x[2n - k] \quad (3)$$

$$d[n] = x[n] * h[n] = \sum_{k=0}^{N-1} h[k] \cdot x[2n - k] \quad (4)$$

A Figura 6 ilustra uma maneira de utilização dos filtros: primeiramente, o sinal  $x[n]$  é filtrado pelo banco composto pelos filtros passa-alta,  $h[n]$ , e passa-baixa,  $g[n]$ . O filtro passa-baixa remove as componentes de alta frequência do sinal, resultando numa representação mais suave do sinal original. Por sua vez, o filtro passa-alta remove o conteúdo de baixa frequência, expondo os componentes de alta frequência. Em seguida, o operador  $\downarrow 2$  implica uma subamostragem por um fator igual a 2. O processo de subamostragem equivale a reamostrar o sinal com uma taxa de amostragem menor, nesse caso, descartando metade das amostras. Tem-se, como resultado dessas operações, duas saídas,  $a_{(1,0)}[n]$  e  $d_{(1,1)}[n]$ , as quais correspondem, respectivamente, aos coeficientes de aproximação e de detalhes relativos ao primeiro nível. Decomposições em níveis posteriores são obtidas

realizando-se o mesmo processo em cascata, ou seja, submetendo  $a_{(1,0)}[n]$  e  $d_{(1,1)}[n]$  novamente a um banco de filtros como dois novos sinais de entrada, gerando  $a_{(2,0)}[n]$ ,  $d_{(2,1)}[n]$ ,  $a_{(2,2)}[n]$  e  $d_{(2,3)}[n]$ , e assim por diante. O procedimento descrito é conhecido como decomposição *wavelet-packet*, ou *wavelet-packet decomposition* (WPD), e resulta na chamada *decomposition tree*. Isso significa que a *wavelet-packet* é uma generalização do conceito de DWT (WEEKS, 2012).



**Figura 6 – Filtros discretos para geração da decomposição *wavelet*.**

Fonte: Adaptado de Weeks (2012)

Conforme Mallat (2009), os operadores  $h[n]$  e  $g[n]$  satisfazem as condições de ortogonalidade, Equações (5) e (6), sendo que  $I$  representa a matriz identidade e  $(T)$  denota o operador transposto, e, portanto, se enquadram como filtros espelhados em quadratura, do inglês *Quadrature Mirror Filters* (QMF). Tal fato permite a reconstrução do sinal através dos coeficientes *wavelets*, pois, uma vez que os operadores são do tipo QMF, admite-se a inversão perfeita do processo. Entretanto, a subamostragem das componentes na fase de decomposição pode provocar uma distorção chamada *aliasing* (VARANIS; PEDERIVA, 2013). A viabilidade da reconstrução é uma característica essencial para a abordagem desse trabalho, como será visto na Seção 4.4.

$$hg^T = gh^T \quad (5)$$

$$hh^T = gg^T = I \quad (6)$$

A reconstrução do sinal decomposto é conhecida como *wavelet-packet reconstruction* (WPR). A Figura 7 exhibe a reconstrução dos coeficientes do primeiro nível de decomposição. Os coeficientes de aproximação e detalhes são submetidos aos filtros  $h_R[n]$  e  $g_R[n]$  para se obter o sinal reconstruído  $x_R[n]$ . Como pode ser visto, o procedimento de reconstrução consiste no processo inverso da decomposição. Além disso, o erro de reconstrução ( $e_R$ ) é entendido como a diferença entre o sinal original e o sinal reconstruído e pode ser calculado realizando-se  $e_R[n] = x[n] - x_R[n]$ .






Figura 7 – WPR do primeiro nível de decomposição.

A Figura 8 exemplifica uma árvore gerada por uma decomposição até o 3º nível. Na imagem,  $f$  representa a frequência máxima do sinal, a qual vai se dividindo pela metade a cada nível em função dos filtros específicos. Também pode ser observado nesta figura a representação de resposta em frequência dos filtros para cada uma das componentes encontradas no terceiro nível.

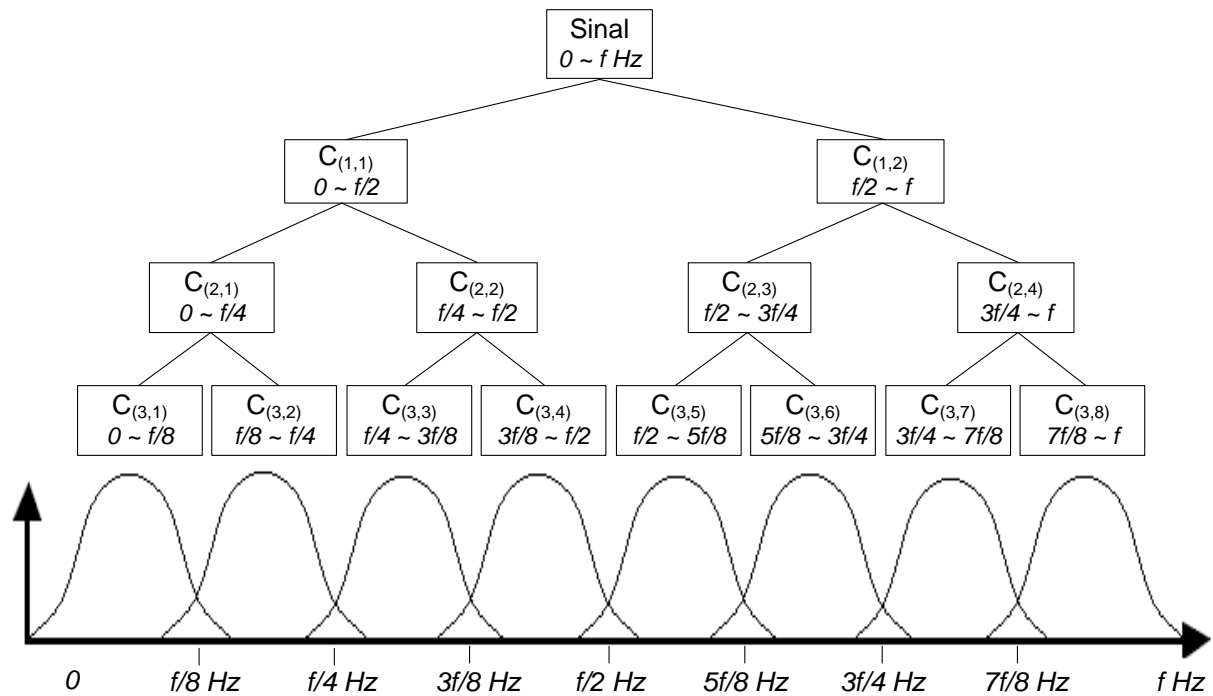


Figura 8 – Estrutura de árvore formada pela decomposição *wavelet-packet*; abaixo, encontram-se as representações dos filtros resultantes após o processo.

Fonte: Autoria própria

Do ponto de vista da detecção de falhas, a abordagem por meio da WPD permite o exame apurado das componentes de frequência pertinentes perante determinado tipo de falha. Isso possibilita a remoção de elementos inexpressivos, ou seja, a eliminação de bandas de frequências as quais não contenham informações de interesse. De fato, segundo Benbouzid (2000), a viabilidade de proceder essa análise localizada é uma das características mais interessantes das *wavelets*, o que a torna uma ferramenta singular para detecção de falhas em motores de indução.

Diversos pesquisadores perceberam o potencial da WPD na execução de diagnósticos. Liu, Ling e Meng (1997) propuseram um método baseado na WPD para tratar sinais de vibração com conteúdo não-estacionários e assim diagnosticar falhas mecânicas em maquinários industriais. Os autores encontraram padrões nos coeficientes de detalhes com os quais foi possível detectar falha de rolamento. Yen e Lin (1999) aplicaram WPD aliado a RNA no diagnóstico de falhas. Nesta ocasião, os autores validaram a técnica proposta com simulações realizadas com dados do *benchmark* conhecido como *Westland Data Set*, o qual consiste em sinais de vibração das engrenagens do sistema de transmissão de um helicóptero. Ye, Wu e Zargari (2000) extraíram características de sinais de corrente do estator de um motor de indução tipo gaiola de esquilo com auxílio da WPD. Uma rede neural com duas camadas escondidas foi utilizada para diagnosticar falhas nas barras de rotor a partir da assinatura de corrente encontrada. Uma abordagem diferente foi utilizada por Shibata, Takahashi e Shirai (2000) para analisar falhas de rolamento em máquina rotativas. Os pesquisadores perceberam que ocorriam mudanças sonoras entre máquinas em perfeitas condições e máquinas com defeito no rolamento. Aproveitando-se desse fato, utilizaram a TW e *Symmetrised Dot Pattern* (SDP), método que possibilita visualizar os ruídos sonoros da máquina em forma de diagrama, e assim, distinguir entre a condição normal de operação daquelas com falhas.

Hambaba e Huff (2000) inovaram ao utilizar DWT aliada à Função Distribuição de Probabilidade, ou *Probability Distribution Functions* (PDF). Os autores diagnosticaram rupturas em um sistema de engrenagens com auxílio do banco de dados da *Westland*. Foram avaliados dados de engrenagens em perfeito estado e outro com rupturas em diversos dentes. Comparando-se os histogramas de ambos os sinais até o sexto nível da WPD, verificou-se que, para o primeiro caso estes apresentavam aspecto normalmente distribuído, enquanto que, para o segundo caso, seu aspecto se contrastava de uma distribuição normal.

Em Schmitt et al. (2013) e Schmitt (2013), apresentou-se um estudo baseado em sinais de corrente de estator simulados com e sem falha de rolamento. A partir de um sinal de corrente de um motor trifásico em perfeito estado de funcionamento, foram adicionados sinais gerados com falhas específicas nas pistas interna, externa e na gaiola. Uma vez aplicada DWT, a entropia relativa entre o sinal original e o erro de previsão foi avaliada. A avaliação das características dos sinais foi realizada com base em medidas de distâncias estatísticas entre o sinal original e os sinais de erro das previsões através de reconstruções de componentes da DWP. Concluiu-se que, nas frequências relacionadas aos distúrbios, o sinal comportou-se de maneira mais imprevisível quando comparado ao sinal do motor normal. Os autores utilizaram três diferentes topologias de redes neurais a fim de classificar os sinais: PMC, RBF e Mapas Auto-Organizáveis de Kohonen (SOM). Como entrada para a rede, foi utilizado o vetor de entropia relativa gerado a partir das três fases e, pela análise dos resultados, percebeu-se que a PMC apresentou maior taxa de acerto entre as redes estudadas.

Santos (2013) apresentou uma metodologia para diagnóstico da condição do MIT, considerando falhas por barras quebradas e curto-circuito no enrolamento de estator. Os dados utilizados contemplam motores acionados diretamente da rede e por inversores de frequência. Para os sinais referentes ao motor acionado pela rede elétrica, foi aplicada a

DWT até o terceiro nível. Para o caso da utilização do inversor, o processo se deu até o quarto nível. Os coeficientes de detalhes do último nível analisado em cada caso foram utilizados como entradas para três redes neurais distintas, a saber: PMC, rede de Elman e RBF. Concluiu-se que a rede de Elman exibiu melhor desempenho para classificação das falhas analisadas.

Das et al. (2014) apresentaram um método de classificação da severidade da falha de isolamento do enrolamento de estator em um MIT. Para tanto, *Extended Park's Vector Approach* (EPVA) foi empregado para tratamento dos sinais de corrente sob diversos níveis de falha de curto circuito e carregamento. Em seguida, os autores aplicaram CWT nas formas de onda obtidas e concluíram que a posição no tempo e frequência do coeficiente de maior pico varia de acordo com o número de espiras curto circuitadas.

Silva (2014), da mesma forma, utiliza modelos *wavelets* e RNA, contudo, desenvolve um método baseado em medidas de previsibilidade, especificamente Potência de Previsão (PP) e um método de decomposição chamado *Predictable Component Analysis* (PrCA). Após realizar a WPD, todas as componentes da decomposição foram reconstruídas individualmente avaliando-se os respectivos erros de reconstrução. Posteriormente, foram comparados os resultados obtidos empregando-se PP e PrCA. Uma vez que no presente trabalho são empregadas medidas de previsibilidade, a seção seguinte é dedicada ao estudo dessas ferramentas.

## 2.4 MEDIDAS DE PREVISIBILIDADE

Conforme (DESOLE, 2004), a previsibilidade é o estudo da extensão com o qual os eventos podem ser antecipados. A palavra previsibilidade por muitas vezes é relacionada a previsões climatológicas, contudo, as teorias e medidas da previsibilidade, ou medidas de informação, têm sido recentemente aplicadas a uma gama de campos distintos. Um exemplo é a pesquisa apresentada em Scalassara (2009), no qual são empregadas medidas de previsibilidade na análise de sistemas biológicos, com a finalidade de diferenciar sinais de voz saudáveis daqueles com patologias de laringe. Outro exemplo, no campo da engenharia e manutenção, é o trabalho de Schmitt (2013), no qual tais ferramentas são utilizadas conforme citadas anteriormente.

A aplicabilidade em diferentes esferas de pesquisa além do clima tornou-se possível em razão de trabalhos tais como Schneider e Griffies (1999), DeSole (2004) e Chang et al. (2006), os quais acrescentaram princípios da teoria da informação aos métodos tradicionais de previsibilidade, introduzindo uma nova abordagem para a análise da previsibilidade de sistemas.

Dentre as medidas de informação, o erro quadrático médio é a mais comumente utilizada em função de sua simplicidade (DESOLE, 2004). Entretanto, outras medidas tais como entropia e potência de previsão possibilitam cálculo baseado na incerteza de um evento, podendo contribuir de forma mais efetiva. Portanto, tais medidas são o foco desta seção.

### 2.4.1 Entropia

A ideia de entropia, originalmente, é definida dentro do contexto da termodinâmica, no qual pode ser entendida como uma grandeza que mensura o grau de irreversibilidade de um sistema (HALLIDAY; RESNICK; WALKER, ) e é muitas vezes associada semanticamente ao termo "desordem". No entanto, Shannon (1948), introduziu o conceito de entropia no campo da teoria da informação, definindo a entropia  $H$  de uma distribuição de probabilidades  $p_1, \dots, p_N$ :

$$H = - \sum_i^N p_i \log_2(p_i) \quad (7)$$

Neste ponto, destaca-se que, no contexto da teoria da informação, é convencional medir-se a informação em bits, portanto, utiliza-se logaritmos na base 2. Além disso, considera-se  $0 \log_2 0 = 0$  (COVER; THOMAS, 2006). No caso particular de uma variável aleatória, a qual pode assumir 2 valores com probabilidades  $p$  e  $q = 1 - p$ , a Equação 7 toma a forma  $H = -(p \log_2 p + q \log_2 q)$ . Ademais, quando os resultados possíveis têm a mesma probabilidade,  $p = q = 1/2$ , a entropia atinge o valor de pico, ou seja, incerteza do resultado será máxima.

A partir do exposto, constata-se que a entropia é medida da incerteza em relação a um determinado evento, e, assim sendo, está intimamente relacionada aos estudos de previsibilidade, na qual é aplicada com a finalidade de avaliar a capacidade de previsão de um sistema (SCALASSARA, 2009).

Outra medida de previsibilidade derivada da entropia de Shannon é a entropia relativa, a qual foi primeiramente definida por Kullback como uma medida de divergência de informação entre duas PDF (CHANG et al., 2006). Matematicamente, a entropia relativa  $D$  entre duas PDF  $p_1, \dots, p_N$  e  $q_1, \dots, q_N$  pode ser descrita de acordo com a Equação (8), sendo  $N$  o tamanho do alfabeto de eventos. Verifica-se através do exame da Equação (8) que a entropia  $D$  será sempre positiva ou igual a zero, característica em consonância com o conceito de mensuração de distância. Em razão disso, a entropia relativa é muitas vezes relacionada a distância entre distribuições de probabilidade. Todavia, uma análise mais rigorosa pode evidenciar que  $D(p||q) \neq D(q||p)$ , assim sendo, a entropia relativa não se trata realmente de uma medida de distância (COVER; THOMAS, 2006).

$$D(p||q) = \sum_{i=0}^{N-1} p_i \log_2\left(\frac{p_i}{q_i}\right) \quad (8)$$

A Equação (8) implica que, quanto menor a entropia relativa, menor é a discrepância entre  $p$  e  $q$ , logo, as funções probabilidade são mais compatíveis. Além disso, os valores de  $D$  podem variar entre 0 e infinito, sendo, portanto, sempre positiva qualquer que seja o domínio. Caso  $D = 0$ , as PDF são iguais, não havendo discriminação entre elas.

### 2.4.2 Potência de Previsão

A Potência de Previsão é uma medida de previsibilidade baseada na entropia relativa, introduzida por Schneider e Griffies (1999). Para o cálculo da PP, os autores basearam-se na grandeza chamada informação previsível, que por sua vez é calculada pela diferença das incertezas de estado e do erro de previsão.

Contudo, também é possível calcular a PP utilizando-se a entropia relativa como substituto da informação previsível (SCALASSARA, 2009), resultando na Equação 9. Essas duas medidas de previsibilidade apresentam similaridades, tais como o fato de tenderem a zero sempre que as duas PDF forem iguais, e a possibilidade de decomposição em componentes previsíveis (DESOLE, 2004). Contudo, a entropia relativa se iguala a zero somente no caso de PDF iguais, ao contrário da informação previsível, a qual pode assumir o valor nulo em outros casos (SCALASSARA, 2009).

$$PP = 1 - e^{-D(p||q)} \quad (9)$$

Uma vantagem apresentada pelo cálculo da PP através da Equação (9) é que, dessa forma, resulta somente valores entre zero e 1, ao contrário da PP calculada utilizando-se informação previsível, as quais podem apresentar PP negativa (SCALASSARA, 2009).

## 2.5 MÉTODOS DE DETECÇÃO DA FALHA

As ferramentas e métodos listados nessa subseção são utilizadas como suporte para a tomada de decisão, sendo esse o último passo do monitoramento baseado nas condições do motor, conforme Figura 2. Nesse ponto, torna-se necessário mapear as informações e características extraídas no passo anterior, o processamento do sinal, a fim de realizar uma classificação de padrões. Tradicionalmente, o reconhecimento mencionado é feito manualmente, ou seja, a partir do conhecimento e experiência de profissionais mediante análise visual de um gráfico, espectrograma, tabelas, entre outros. Portanto, percebe-se que o reconhecimento de padrões feito de modo manual é um procedimento que requer um conhecimento especialista na área em questão.

Em razão do exposto, a classificação de padrões automático mostra-se conveniente para a detecção da falha, uma vez que, na maioria dos casos, atribui maior confiabilidade, impessoalidade e precisão ao processo. Desse modo, as abordagens mencionadas em seguida se tornam responsáveis por identificar a existência da falha e/ou classificá-la, o que pode auxiliar os operadores e gestores do processo quanto à necessidade ou não de uma intervenção. Nas subseções a seguir são esboçadas algumas técnicas comumente apresentadas na literatura nesta etapa do monitoramento dos motores de indução.

### 2.5.1 Modelos Determinísticos

Os métodos tradicionais para detecção falhas são fundamentados em modelos determinísticos, do inglês *model-based systems*. De acordo com IEEE (1989), um modelo é uma aproximação, representação ou idealização de determinados aspectos de uma estrutura, comportamento, operação, entre outras características de sistemas do mundo

real. O modelo eletromagnético detalhado do motor de indução trifásico pode fornecer diagnósticos precisos, partindo do princípio que as falhas causam efeitos típicos em parâmetros da máquina, os quais podem ser incluídos na modelagem (SIN; SOONG; ERTU-GRUL, 2003). Tais efeitos podem ser previstos utilizando uma simulação computadorizada baseada em modelos matemáticos, conhecida como *finite-element modelling*. Conforme (FISER; FERKOLJ, 2001), essa abordagem permite o estudo da influência de diferentes falhas em um motor de indução de forma efetiva e com baixo custo, pois evita a necessidade de gastos com laboratórios e tempo despendido com medições.

Dentre as desvantagens, cita-se a necessidade de elaboração de programas complexos, pois devem ser consideradas as não-linearidades da máquina, o que dificulta o gerenciamento e manutenção do processo. Além disso, é necessário o conhecimento de diversos parâmetros da máquina estudada para a concepção do modelo. Em vista disso, a supervisão de equipamentos elétricos baseado em modelos determinísticos tem sido substituída por sistemas baseados em inteligência computacional (BELLINI et al., 2008). Esse termo engloba diversas técnicas, dentre elas redes neurais e lógica fuzzy.

#### 2.5.1.1 Lógica Fuzzy

Na lógica binária clássica, as proposições assumem unicamente valores "verdadeiro" ou "falso", porém, na Lógica Fuzzy possibilita-se a existência de valores intermediários. Em outras palavras, a Lógica Fuzzy consiste em modelos matemáticos dedicados ao tratamento de incertezas e falta de informação, e permite representar as imprecisões inerentes aos processos e sistemas, expressando o conhecimento de forma mais natural. Portanto, aplicada ao monitoramento da condição do motor de indução, permite determinar a seriedade de uma falha, ao invés de decidir somente entre a existência ou não de uma falha.

A incorporação da Lógica Fuzzy em simulações computacionais é especialmente útil em situações que envolvem processos complexos ou de compreensão limitada e sistemas nos quais a percepção e o processo de decisão humano estão intrinsecamente envolvidos (SANTOS, 2013).

#### 2.5.1.2 Redes Neurais Artificiais

Uma RNA é um método computacional que apresenta um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma RNA é composta por diversas unidades de processamento (neurônios), cujo funcionamento é bastante simples (SILVA; SPATTI; FLAUZINO, 2010). Essas unidades, geralmente são conectadas por canais de comunicação que estão associados a determinado peso sináptico. As unidades de processamento fazem operações somente sobre seus dados locais, ou seja, entradas recebidas pelas suas conexões.

O comportamento inteligente de uma RNA é devido às interações entre tais unidades de processamento, ajustando continuamente o valor dos pesos sinápticos de acordo com os valores de entrada e saída (HAYKIN, 2001). A capacidade de aprendizado através de dados fornecidos durante a fase de treinamento, e, dessa forma, generalizar para situações não apresentadas nessa fase, é um dos aspectos que torna redes neurais interessan-

tes para diversas aplicações. Para tanto, produzem resultados limitados a determinados sistemas, aos quais foram treinadas (SUETAKE, 2012). Em vista disso, percebe-se que a escolha do domínio na fase de treinamento da rede é crítica.

Uma das razões pelas qual as RNA têm sido aplicada extensivamente na área de monitoramento de falhas é que essa técnica mostra-se eficiente, confiável e simples, desde que seja fornecida uma base de dados confiável à rede. Além disso, existem inúmeras topologias e modos de treinamentos de redes neurais, sendo que cada uma se adapta melhor a diferentes situações. Dentre as arquiteturas as quais possibilitam o reconhecimento e classificação de padrões, cita-se a *perceptron* de camada simples, a *adaline*, a PMC, as redes de Kohonen e a RBF. A *perceptron* simples é considerada a mais elementar rede neural, sendo capaz de classificar padrões desde que linearmente separáveis. A rede *adaline* sofre dessa mesma limitação.

Para um mapeamento otimizado, deve-se considerar o conceito de várias camadas interagindo e adaptando seus pesos. As camadas intermediárias da PMC permitem que a rede crie mais de um hiperplano separador, possibilitando uma representação mais rica e complexa do sistema. Portanto, essas redes são, a princípio, capazes de solucionar problemas não-linearmente separáveis (HAYKIN, 2001).

Contudo, possuir várias camadas não é critério imprescindível para classificar padrões complexos. A exemplo disso pode-se citar a rede de Kohonen, a qual é constituída de uma única camada, e, ainda assim, possui a capacidade de detectar correlações entre os padrões do conjunto de entrada, agrupando-os em classes (*clusters*), mesmo sem qualquer informação a respeito das saídas desejadas (SILVA; SPATTI; FLAUZINO, 2010).

No caso da RBF, sua construção envolve três camadas as quais têm funções específicas. Na camada de entrada estão os neurônios que irão conectar a rede a seu ambiente. A camada intermediária realiza uma transformação não-linear do espaço de entrada para o espaço intermediário. As ativações das funções de base radial da camada intermediária são criadas pelos neurônios não-lineares os quais tem ativação local e os neurônios da camada de saída formam uma combinação linear das funções de base radial calculadas na camada intermediária.

Em vista do mencionado, verifica-se que as topologias PMC, RBF e Kohonen viabilizam a classificação em situações mais complexas, como é o caso da identificação de falhas.

## 2.6 CONCLUSÃO

Neste Capítulo, foram revisadas as ferramentas tradicionalmente utilizadas para a extração de características de sinais de corrente para fins de identificação de falha no estator. Verificou-se que a análise no domínio do tempo evita esforço computacional, sendo esta uma ótima característica quando se trata de implementação em dispositivos microprocessados, os quais possuem poder de processamento limitado.

Contudo, a ferramenta mais utilizada é sem dúvida a TF, que extrai as características no domínio da frequência, perdendo por completo a informação temporal do sinal. Essa deficiência temporal verificada após a TF pode inviabilizar o diagnóstico de falhas em determinados casos. A fim de contornar esse tipo de inconveniente, surgiu a STFT, a qual proporciona informação relativa a tempo e frequência simultaneamente. Em contraposição às vantagens oferecidas, a STFT exige um desempenho computacional elevado e fornece uma resolução constante para todas as frequências.


Por outro lado, ao utilizar a TW, é possível analisar o sinal em diversas resoluções de tempo e frequência, permitindo a decomposição do sinal em versão deslocadas e escalonadas de uma função *wavelet*-mãe. Já a análise por meio de componentes previsíveis surgiu com o intuito principal de realizar a previsão climática. No entanto, uma vez que essa ferramenta foi utilizada com êxito nesse campo, o poder de previsão da mesma motivou pesquisas bem sucedidas para o auxílio na detecção de falhas em motores de indução.

Como método de detecção de falhas, as RNA mostram-se como uma boa opção, uma vez que sua simplicidade e confiabilidade sustentam resultados em diversas pesquisas correlatas, como as mencionadas. Dentre as topologias, destaca-se principalmente a PMC, pois trata-se de uma rede utilizada com bastante frequência para diversas finalidades.



### 3 MATERIAIS E MÉTODOS

Para a realização do presente trabalho, foi utilizado um banco de dados constituído a partir da coleta de corrente de estator de MIT em laboratório. Os ensaios envolvem motores com enrolamentos de estator normais e com diversos níveis de curto-circuito, da ordem de 20%, 15%, 10%, 7%, 5%, 3% e 1% das espiras danificadas. Para cada ensaio, as máquinas foram submetidas a diferentes condições de operação, contemplando variações de carregamento e desequilíbrio na rede elétrica da alimentação. Todas as condições de falhas que proporcionaram as aquisições foram produzidas no Laboratório de Sistemas Inteligentes (LSI) da UTFPR - Campus Cornélio Procópio (UTFPR/CP), Figura 9, em parceria com o Laboratório de Automação Inteligente de Processos e Sistemas (LAIPS) da Escola de Engenharia de São Carlos da USP (USP/SC), Figura 10, dentro do escopo do projeto Casadinho/Procad. As seções seguintes possuem a finalidade de descrever os procedimentos, materiais e métodos empregados para aquisição dos sinais e o modo como foram emuladas as falhas.



**Figura 9 – Esquema geral para ensaios, Laboratório de Sistemas Inteligentes.**

**Fonte: Autoria própria.**

#### 3.1 SISTEMA DE AQUISIÇÃO DE DADOS

Como citado, os dados coletados têm origem no LSI e no LAIPS. Genericamente, a bancada de ensaios em ambos laboratórios é composta por um MIT, uma máquina de Corrente Contínua (CC), um banco de resistência variável, um torquímetro girante e um

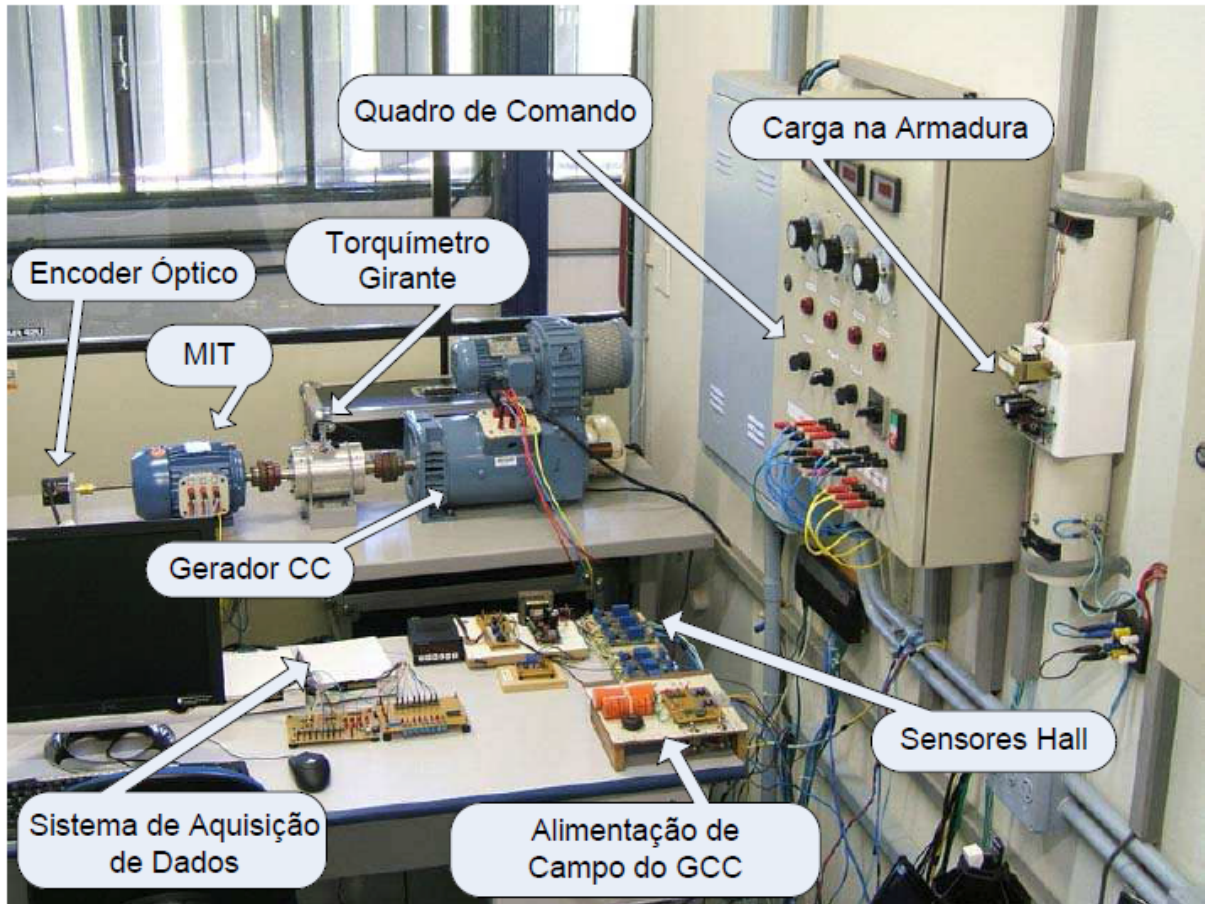


Figura 10 – Esquema geral para ensaios, Laboratório de Automação Inteligente de Processos e Sistemas.

Fonte: Suetake (2012).

sistema de aquisição de dados. A máquina CC atua como gerador, tendo seu eixo acoplado ao MIT por intermédio do torquímetro girante e o banco de resistores conectado aos terminais do enrolamento de armadura. Dessa forma, tem-se um sistema que possibilita simular várias condições de carregamento aplicado ao eixo do MIT. O torque eletromagnético resistente no eixo pode ser modificado de duas formas distintas: variando-se a corrente de excitação do campo do gerador CC ou alterando o valor da resistência do banco de resistências.

A medição das correntes trifásicas no estator foi realizada por meio de sensores de efeito Hall de corrente. É preciso um sistema de condicionamento de sinal para que o dispositivo de aquisição de dados efetue a medição de forma eficaz e exata. A placa de aquisição DAQ6221 promove a comunicação via USB com um microcomputador, onde são armazenados os dados com auxílio do software Matlab.

Os dados coletados são oriundos de três motores de indução diferentes, descritos na Tabela 1. Desse modo, forma-se um banco de dados contemplando MIT distintos, o que aumenta a confiabilidade do estudo.

Tabela 1 – Dados dos motores.

Parâmetro	MIT 1	MIT 2	MIT 3
Potência	1 CV	1 CV	2 CV
Origem	LAIPS	LSI	LSI
Fabricante	WEG	WEG	WEG
Linha	<i>Standard</i>	Alto Rendimento	Alto Rendimento
Rendimento	79,5%	80,5%	84,2%
Fator de Potência	0,82	0,81	0,78
Par de polos	2	2	2
Tensão nominal	220/380 V	220/380 V	220/380 V
Frequência	60Hz	60Hz	60Hz
Velocidade Nominal	1720 rpm	1730 rpm	1750 rpm
Torque Nominal	4,1Nm	4,06Nm	8,02Nm

### 3.2 FALHA DE CURTO-CIRCUITO RECRIADA EM LABORATÓRIO

Com o passar do tempo, a esmalte das bobinas tende a ressecar, podendo ter sua propriedade isolante prejudicada. A temperatura na qual o motor está operando é um fator de grande influência na determinação do tempo de vida útil dessa isolação. Uma vez danificada a proteção dos fios de cobre das bobinas de estator, podem ocorrer curto-circuitos, colocando em risco o próprio motor e o operador da máquina. Quanto maior o número de espiras avariadas, maior a corrente de curto-circuito circulando na bobina. O procedimento utilizado para emular um curto-circuito entre as espiras devido à degradação dos isolantes térmicos envolve a execução do rebobinamento do enrolamento de estator do MIT (SUE-TAKE, 2012). Conforme Figura 11, a metodologia consiste em projetar derivações (*taps*) em pontos estratégicos dos enrolamentos. Cada fase é representada por seis bobinas alocadas em seis ranhuras, sendo que as derivações intermediárias e nas extremidades das bobinas possibilitam diversas combinações de falhas.




Figura 11 – *Taps* do enrolamento de estator para realização de ensaios de curto-circuito.

Fonte: Suetake (2012).

Contudo, para simular curto-circuitos entre espiras não é necessário o rebobinamento e execução das derivações para todas as fases. Nesse caso, basta realizar esse procedimento para apenas uma das fases. Dito isso, o MIT 1 possui apenas uma fase rebobinada com derivações adicionais. Os MIT 2 e 3 possuem as três fases rebobinadas com os devidos *taps*. A Figura 12 exibe o MIT 3, com destaque para os terminais de suas derivações.



Figura 12 – MIT 3 e suas derivações para ensaios de até 20% de espiras curto circuitadas.

Fonte: Autoria própria.

O banco de dados utilizado compreende ensaios com 60 e 110 aquisições de correntes trifásicas para cada intensidade de curto-circuito e para o motor normal, conforme Figuras 13 e 14. A taxa de amostragem utilizada foi 15,5 kHz para todos os casos. Os ensaios para o MIT 1 contemplam falhas de 1%, 3%, 5% e 7%, enquanto os ensaios para os MIT 2 e 3 contemplam falhas de 1%, 3%, 5%, 10%, 15% e 20%.

		Redução da tensão na fase A						Elevação da tensão na fase B Redução da tensão na fase C					
		Porcentagem de desequilíbrio											
				Fase A-				Fase B+/Fase C-					
		MITs 1 e 2	MIT 3	0%	2%	4%	6%	8%	10%	2%	4%	6%	8%
Elevação do carregamento	a vazio	a vazio	a vazio	1	7	13	19	25	31	37	43	49	55
	1Nm	2Nm	2Nm	2	8	14	20	26	32	38	44	50	56
	2Nm	4Nm	3Nm	3	9	15	21	27	33	39	45	51	57
	3Nm	6Nm	4Nm	4	10	16	22	28	34	40	46	52	58
	4Nm	8Nm	5Nm	5	11	17	23	29	35	41	47	53	59
	5Nm	9Nm	6Nm	6	12	18	24	30	36	42	48	54	60

Figura 13 – Organização das amostras, aquisição 1.

Fonte: Autoria própria.



MIT	Porcentagem de desequilíbrio				
	0%	Fase A -		Fase B + / Fase C -	
		2%	4%	2%	4%
0,7	1	23	45	67	89
0,9	2	24	46	68	90
1,1	3	25	47	69	91
1,3	4	26	48	70	92
1,5	5	27	49	71	93
1,7	6	28	50	72	94
1,9	7	29	51	73	95
2,1	8	30	52	74	96
2,3	9	31	53	75	97
2,5	10	32	54	76	98
2,7	11	33	55	77	99
2,9	12	34	56	78	100
3,1	13	35	57	79	101
3,3	14	36	58	80	102
3,5	15	37	59	81	103
3,7	16	38	60	82	104
3,9	17	39	61	83	105
4,1	18	40	62	84	106
4,3	19	41	63	85	107
4,5	20	42	64	86	108
4,7	21	43	65	87	109
4,9	22	44	66	88	110

**Figura 14 – Organização das amostras, aquisição 2.**

Fonte: Autoria própria.

Os desbalanços são caracterizados nos ensaios mediante subtensões na fase A, conforme observado nas figuras, bem como sobretensões na fase B simultaneamente a subtensões na fase C. As amostras contemplam ensaios com variações de carga aplicada ao eixo.

Destaca-se que, nas Figuras 13 e 14 e no decorrer do trabalho, o termo *a vazio* é utilizado para caracterizar os ensaios nos quais nenhum carregamento intencional foi aplicado, ou seja, o único conjugado que o motor deve exercer é aquele intrínseco ao sistema, devido ao próprio peso do conjunto eixo/rotor, ao atrito nos mancais, à ventilação e ao acoplamento mecânico existente entre os equipamentos da bancada. Portanto, o conjugado do motor operando a vazio é de aproximadamente 0,5Nm.

Nesse capítulo, apresentou-se a descrição dos principais componentes da estrutura que compreende o sistema de aquisição de sinais para a formação de um banco de dados contemplando MIT operando em condições de diversos níveis de curto-circuito, desequilíbrios de tensão e carregamentos.

## 4 FALHAS DE ESTATOR DE MIT

Neste capítulo, apresentam-se aspectos básicos do funcionamento do motor de indução trifásico, suas partes integrantes e falhas típicas. Na Seção 4.2, é realizado o estudo da falha de estator. Os dados são analisados por meio da Transformada de Fourier, seção 4.3, e por meio da Transformada *Wavelet*, seção 4.4.

O motor de indução trifásico é definido como uma máquina assíncrona que tem essencialmente a função de converter energia elétrica em motriz. O princípio de funcionamento do MIT foi desenvolvido na década de 1880 por Nicola Tesla, o qual também apresentou os fundamentos básicos do motor síncrono e do motor de relutância. No período de 1888 - ano em que foi de fato patenteado - a 1895, o motor tomou a forma reconhecida nos dias de hoje. Inicialmente, as melhorias de projeto visavam a redução do custo de fabricação em detrimento de sua eficiência, haja vista o baixo custo da eletricidade naquela época (CHAPMAN, 2012).

No contexto atual, porém, a maioria das aplicações demanda equilíbrio entre custo de produção e operação, sendo que, na maioria das vezes, a eficiência da máquina é preferível. De fato, avalia-se que o custo gerado pelo consumo de energia elétrica é correspondente à aproximadamente 97% dos custos totais durante o ciclo de vida de um motor elétrico, sendo os 3% restantes referentes à custos de aquisição, instalação e manutenção (SUETAKE, 2012). No cenário nacional, esses dados tornam-se ainda mais relevantes, tendo em vista o recente aumento das tarifas de energia elétrica aprovado pela Agência Nacional de Energia Elétrica (Aneel) para as distribuidoras de todo o país (BORBA, 2015).

O processo de conversão de energia em motores elétricos envolve a presença do enrolamento de campo e o enrolamento da armadura. Num motor de indução trifásico, o enrolamento de armadura aloja-se na parte estacionária, chamada estator. Em operação normal, aplica-se tensão trifásica senoidal nos enrolamentos de estator, fazendo com que a corrente de magnetização circule em cada uma das três fases em conjunto, criando um campo magnético girante (FITZGERALD; KINGSLEY; UMANS, 2008). Esse campo produzido no estator faz com que sejam induzidas correntes no rotor ( $e = \frac{Nd\sigma}{dt}$ ), ou seja, no enrolamento de campo. As correntes que circulam no rotor reagem com o campo resultando em um torque eletromagnético (DEL TORO, 2011). À vista disso, o MIT opera sempre em velocidades inferiores a velocidade mecânica síncrona - determinada pelo número de polos do estator e pela frequência da tensão de alimentação. Há, portanto, uma diferença de velocidade do rotor em relação ao fluxo da armadura denominada escorregamento.

Apesar de ser usualmente chamado de enrolamento de rotor, o mesmo não é necessariamente de fato uma bobina. O aspecto construtivo do rotor pode contemplar uma estrutura que se assemelha à uma gaiola de esquilo, com barras sólidas de alumínio ou cobre curto-circuitadas por anéis nas extremidades. Caso a máquina possua rotor bobinado, existe a possibilidade de controle da velocidade mecânica a partir de um resistor externo, o que não se verifica possível no caso do rotor tipo gaiola de esquilo. Todavia, as máquinas bobinadas estão se tornando cada vez mais incomuns. Com o desenvolvimento da eletrônica de potência, os motores de gaiola de esquilo passaram a garantir toda a flexibilidade dos motores de rotor bobinado (FITZGERALD; KINGSLEY; UMANS, 2008), com a vantagem de proporcionar um custo reduzido e elevada confiabilidade em função

de sua estrutura simples e robusta. Tais fatores contribuem para sua ampla aplicação no meio industrial, sendo utilizados em bombas, ventiladores, compressores e esteiras.

Mesmo sendo robustos, condições desfavoráveis podem prejudicar o desempenho do MIT, podendo resultar em uma falha. A seguir, apresentam-se as falhas mais comuns que ocorrem nesses equipamentos.

#### 4.1 FALHAS EM MOTORES DE INDUÇÃO

Circunstâncias internas e externas ao MIT, tais como sobrecarga, erro na construção ou montagem, falta de lubrificação de peças móveis, regime de partidas severo durante o ciclo de trabalho, refrigeração inadequada, problemas de qualidade de energia da rede, entre outros, comprometem seu funcionamento e podem promover o surgimento de uma falha. O termo falha pode ser entendido como uma diminuição, seja total ou parcial, da capacidade de desempenho do motor ou algum de seus componentes no atendimento da função para a qual foi empregado.

Quando a situação envolve defeitos tais como desalinhamento, desgaste de acoplamento, mancais, excentricidade e rolamento, tem-se uma falha do tipo mecânica. Caso o defeito seja nos enrolamentos de rotor/estator, conexões, anéis ou barras quebradas, a falha é do tipo elétrica (BONNETT; SOUKUP, 1992). Segundo Bellini et al. (2008), entre 40% e 50% das falhas em motores de indução são do tipo mecânica. Pesquisas conduzidas pela *Institute of Electrical and Electronics Engineers* (IEEE) e pelo *Electric Power Research Institute* (EPRI) demonstram que o rolamento, o estator e o rotor são os componentes mais suscetíveis a falhas, nessa ordem. A Tabela 2 exhibe as porcentagens correspondentes.

**Tabela 2 – Porcentual de falhas de componentes do MIT**

	Falha de rolamento	Falha de estator	Falha de rotor	Outros
EPRI	40%	38%	10%	12%
IEEE	42%	28%	8%	22%

Diante dos diversos tipos de falhas, existe a necessidade de conhecer aquelas mais relevantes, ou seja, aquelas que têm maior probabilidade de ocorrer. De acordo com a Tabela 2, ambas as fontes, EPRI e IEEE, concordam que a falha de rolamento é a que possui maior probabilidade de ocorrência. Conclui-se, portanto, que o rolamento é o componente mais susceptível à falha em motores de indução.

Rolamentos são componentes presentes em praticamente todos os tipos de máquinas girantes. Sua principal função é evitar o desgaste devido ao atrito entre as partes móveis (rotor, eixo) e as fixas (estator, carcaça) (BONNETT; SOUKUP, 1992). Os rolamentos são compostos de esferas confinadas entre dois anéis, conhecidos como pista interna e externa, além da gaiola, a qual tem a função de mantê-las a uma distância constante. Bellini et al. (2008) afirma que, mesmo em uma operação normal com bom alinhamento do eixo, os rolamentos são fatigados continuamente. Entretanto, o processo de degradação desse componente é acelerado por condições tais como corrosão, instalação incorreta,

falta de lubrificação, contaminação por poeira e detritos. Esse tipo de situação resulta na geração de ruídos e vibrações excessivas, além da elevação da temperatura local. Em vista disso, a detecção desse tipo de falha pode ser realizada por inspeção visual do elemento durante o funcionamento. Contudo, uma vez que os efeitos citados se tornaram perceptíveis o rolamento já está em fase avançada de deterioração (GONGORA, 2013). Percebe-se que, desse modo, não está assegurada a identificação da existência da falha antes que o componente atinja o nível de inutilização.

Em busca da detecção de falhas de rolamento em seus estágios iniciais, a análise da vibração é o método convencionalmente utilizado. Todavia, o uso de sinais elétricos é preferido em diversas situações. Apesar de ser uma falha do tipo mecânica, um defeito no rolamento pode ser percebido pela análise da corrente de estator, tal qual as falhas de estator e rotor. Falhas de rolamentos dão origem a bandas laterais à frequência fundamental (BELLINI et al., 2008). De acordo a localização da falha - na pista interna, externa, esferas ou gaiola - as bandas de frequências que surgem são distintas, possibilitando a classificação das falhas.

Outra falha que figura na Tabela 2 é a de rotor. Em motores do tipo gaiola de esquilo, esse componente girante é composto por um conjunto de barras curto-circuitadas por anéis nas extremidades. Quando é exigido um carregamento excessivo, ou ainda sob condições de vibração, excentricidade e desalinhamento, pode ocorrer a ruptura das barras do rotor (GONGORA, 2013). Conforme Mehala (2010), barras quebradas não levam o motor trifásico a um colapso imediato, contudo, podem gerar efeitos secundários e comprometer o funcionamento normal do motor. O campo girante produzido pelos enrolamentos de estator induz tensão no circuito de rotor, e, em consequência, correntes circulam na frequência do escorregamento. Essas correntes, por sua vez, criam um campo magnético trifásico, o qual induz tensão e corrente, na respectiva frequência de escorregamento no enrolamento de estator. Quando da existência de trincas ou rupturas nas barras, o campo magnético produzido pelo rotor deixa de ser uniforme. Em virtude dessa assimetria no rotor, um componente de determinada frequência no espectro da corrente de estator é gerado, possibilitando a análise do espectro da corrente com o intuito de identificar a existência da falha.

Por fim, o estator é notado como o segundo maior causador de falhas no MIT. Tendo em vista que o presente trabalho objetiva somente as falhas de estator, a seguinte seção é dedicada inteiramente ao estudo das falhas desse componente, especificamente, do curto-circuito entre espiras no estator.

## 4.2 ESTUDO DA FALHA DE ESTATOR

O enrolamento de estator consiste de espiras de cobre isoladas eletricamente e alocadas em ranhuras especialmente projetadas para essa finalidade. A camada isolante que envolve os fios de cobre tem como função impedir o contato entre as espiras, promovendo uma proteção contra estresses dielétricos, mecânicos e químicos. Quando, por algum motivo, a isolação tem sua integridade física comprometida a mesma deixa de cumprir seu papel.



A temperatura de operação do motor é um fator de grande influência na determinação do tempo de vida útil do material utilizado na isolação elétrica das bobinas. O sobreaquecimento deteriora o esmalte dos enrolamentos, em decorrência disso, o mesmo tende a ressecar e tem sua propriedade isolante prejudicada com o passar do tempo. Dentre os fatores que promovem o aquecimento excessivo dos enrolamentos, podem-se citar: defeito no sistema de refrigeração da máquina, grande número de partidas num ciclo de trabalho, estresse mecânico, sobretensões transitórias e sobrecarregamento.


Além do sobreaquecimento, outros fatores promovem a degradação do isolamento, tais como excentricidade do rotor, vibrações, barras quebradas, rolamentos desgastados, movimentação das bobinas dentro das ranhuras em função de defeitos de fabricação (BONNETT; SOUKUP, 1992).

A partir da análise do sinal da corrente estatórica, alguns princípios podem ser aplicados para investigar as falhas de estator. O método tradicional se baseia no espectro de frequência obtido pela aplicação da TF. Uma falha no motor provoca alterações nas correntes de estator, alterando a magnitude de certas frequências de acordo com o tipo de falha. No caso específico de uma falha no enrolamento estator não é produzida nenhuma nova frequência no espectro da corrente, somente a magnitude de frequências já existentes é alterada (SANTOS, 2013).

Siddiqui, Sahay e Giri (2014) destacam que as falhas no estator são divididas em cinco categorias:

1. Falha de circuito aberto, caracterizada pela ausência de continuidade elétrica em um enrolamento, possivelmente pelo rompimento de uma espira;
2. Curto-circuito entre espiras, caracterizado pelo contato entre duas ou mais espiras de uma mesma bobina;
3. Curto-circuito entre bobinas, quando ocorre o contato entre espiras de bobinas distintas de uma mesma fase;
4. Curto-circuito entre fases, caracterizado pelo contato entre espiras de fases diferentes;
5. Curto-circuito fase-terra, ocorre quando a corrente encontra um caminho de baixa impedância à terra, geralmente em virtude do contato direto do enrolamento com a carcaça, a qual deve ser apropriadamente aterrada.

A análise da Figura 15 ilustra a distinção entre os tipos de falhas listados. Bellini et al. (2008) afirmam que o motor de indução é capaz de continuar em operação mesmo após uma falha do tipo circuito aberto, ainda que o torque disponível no eixo seja reduzido substancialmente. A assimetria originada por esse tipo de falha é facilmente detectada pelo equipamento de proteção, que remove o MIT da rede elétrica. Por outro lado, as demais falhas podem conduzir a máquina a um colapso, pois, dependendo do caso, não são facilmente detectáveis.



**Figura 15 – Representação gráfica das diversas falhas de estator.**

Fonte: Adaptado de Siddiqui, Sahay e Giri (2014)

Bonnett e Soukup (1992) descrevem a evolução de uma falha de curto-circuito da seguinte forma: uma vez que ocorre uma falha do tipo 2, curto-circuito entre espiras, o calor excessivo gerado resulta na deterioração da isolamento adjacente. Dependendo do tipo de proteção utilizado, o motor continua em operação. À medida que a isolamento se deteriora a corrente e o calor se elevam, num ciclo vicioso, até culminar numa falha do tipo 3, 4 ou 5. Normalmente, nesse nível, a proteção, se bem dimensionada, deve agir, desconectando o motor da rede elétrica e paralisando o processo.

Em vista da descrição acima, fica evidente que os curtos-circuitos entre espiras podem ser qualificadas como incipientes, haja vista que as demais são normalmente consequência dessa. Portanto, o curto-circuito entre espiras demanda atenção no processo de monitoramento do MIT. Uma vez que esse tipo de curto-circuito ocasiona a retirada de uma ou mais espiras do circuito, é estabelecida uma força magnetomotriz (FMM) negativa, a qual reduz a FMM da fase em questão (BONNETT; SOUKUP, 1992). Em decorrência disso, a forma de onda do fluxo magnético no entreferro é distorcida, induzindo frequências harmônicas na corrente do estator (PENMAN et al., 1994). Estas frequências são dadas pela Equação (1), exibida no Capítulo 1.

Como já mencionado, as harmônicas do campo do entreferro induzidas na corrente de estator apresentam-se na mesma frequência daquelas produzidas num motor normal (SANTOS, 2013). O que se busca através a análise da Equação (1) é averiguar as variações em amplitude de componentes já existentes. Ademais, deve-se observar também que outros tipos de falhas podem causar confusão na leitura do espectrograma, pois as demais falhas podem produzir alterações em componentes comuns às falhas de estator.

Segundo Thomson (2001), quando se deseja avaliar falhas de curto-circuito nos enrolamentos estatóricos, deve-se prestar atenção também às componentes de frequência relativas às falhas de excentricidade. A inobservância das mesmas pode conduzir a equívocos na interpretação.

Sabe-se que as frequências relativas à excentricidade ( $f_{exc1}$ ) ocorrem de acordo com a Equação (10) (NANDI; AHMED; TOLIYAT, 2001). Considera-se  $n_d$  um número inteiro maior ou igual a zero,  $\nu$  um número inteiro maior que zero,  $R$  o número de barras/fendas do rotor,  $p$  o número de pares de polos,  $s$  o escorregamento do rotor e  $k$  é um número inteiro ímpar.

$$f_{exc1} = f_1 \left[ (\nu R \pm n_d) \left( \frac{(1-s)}{p} \right) \pm k \right] \quad (10)$$

Contudo, o uso dessa equação requer informações à respeito do número de barras ou fendas do rotor, o que muitas vezes não está explícita nas placas de identificação do motor. Entretanto, Dorrell, Thomson e Roach (1995) mostraram, por meio de resultados teóricos e experimentais, que é possível identificar as frequências relacionadas a excentricidade do rotor em um motor de indução trifásico sem o uso da Equação (10). Os autores explicam que a excentricidade estática e dinâmica devem ser consideradas simultaneamente (excentricidade mista), uma vez que é muito provável que existam sempre ambos os tipos de excentricidade mesmo que em reduzido grau de intensidade. Posteriormente, demais pesquisadores corroboraram com os resultados de Dorrell, Thomson e Roach (1995), como foi o caso de Bangura e Demerdash (2000), que comprovaram através de modelos determinísticos que a excentricidade no entreferro pode ser observada mediante monitoramento das componentes de baixa frequência em detrimento daquelas de elevada frequência dada Equação (10).

Em vista disso, uma vez que se apresenta excentricidade mista, frequências adicionais dadas pela Equação (11) estarão presentes na corrente de estator em qualquer das 3 fases da máquina, independente de valores de  $R$  (NANDI; AHMED; TOLIYAT, 2001).

$$f_{exc2} = |f_1 \pm m f_r| \quad (11)$$

Considera-se que  $f_1$  representa a frequência da componente fundamental da alimentação,  $f_r$  a frequência rotacional do motor e  $m$  um número inteiro positivo.

Os fatos mencionados, do ponto de vista da análise espectral, tornam a investigação de curto-circuitos incipientes uma tarefa de maior complexidade. Como destacam Joksimovic e Penman (1998), Bellini et al. (2008) e Mehala (2010), a falha do tipo 2 é

reconhecida como uma das mais difíceis de serem detectadas em estágios iniciais. Em razão disso, muitas metodologias têm sido desenvolvidas para solucionar essa dificuldade, sendo este tipo de falha o foco do presente trabalho.

Sintetizando, a importância da detecção de um curto-circuito prematuro se verifica em razão da possibilidade de evitar que o dano se propague para espiras e bobinas em sua proximidade.

#### 4.3 ANÁLISE DOS DADOS ATRAVÉS DA TRANSFORMADA DE FOURIER

Nesta seção, descreve-se a análise dos sinais de corrente por intermédio da TF, a qual proporciona a identificação das frequências presentes no sinal e revela qual o grau de interferência dessas componentes na forma de onda do sinal original. Em vista disso, o diagnóstico mediante TF visa detectar as frequências características de curto-circuito no espectrograma da corrente de estator.

A Tabela 3 exhibe os valores correspondentes de frequências as quais têm relação com curto-circuito, considerando o intervalo  $1 \leq n \leq 7$ . Os valores da tabela foram calculados por meio da Equação (1), para  $f = 60\text{Hz}$ , e  $p = 2$ , valores nominais dos MITs (Tabela 1). O valor de  $k$  foi mantido em 1 para analisar as componentes de baixa frequência. Os valores de  $s$  utilizados foram 0; 0,027; 0,038 e 0,044, correspondem, respectivamente, ao escorregamento de um motor ideal operando a vazio (referência) e aos escorregamentos dos MIT 3, 2 e 1 operando a plena carga. Destaca-se que a aplicação da Equação (1), em virtude do sinal  $\pm$ , resulta sempre em dois valores distintos, sendo um deles correspondente a Banda Inferior (B.I.) e o outro a Banda Superior (B.S.).


**Tabela 3 – Frequências características de curto-circuito ( $f_{cc}$ ),  $k = 1$ ,  $f = 60\text{Hz}$ ,  $p = 2$**

n	s = 0		s = 0,027		s = 0,038		s = 0,044	
	B.I.	B.S.	B.I.	B.S.	B.I.	B.S.	B.I.	B.S.
1	30	90	30,81	89,19	31,14	88,86	31,32	88,68
2	0	120	1,62	118,38	2,28	117,72	2,64	117,36
3	60	150	27,57	147,57	26,58	146,58	26,04	146,04
4	90	180	56,76	176,76	55,44	175,44	54,72	174,72
5	120	210	85,95	205,95	84,30	204,30	83,40	203,40
6	150	240	115,14	235,14	113,16	233,16	112,08	232,08
7	180	270	144,33	264,33	142,02	262,02	140,76	260,76

Nas subseções seguintes, serão comparados os ensaios relacionados ao MIT normal e com falha de curto-circuito no estator, assim como as implicações do ponto de vista do domínio da frequência proporcionado mediante TF.

#### 4.3.1 Motor normal, sem carga, sem desbalanço

Para uma primeira análise, considere o motor operando a vazio, sem qualquer tipo de falha ou desbalanço na alimentação trifásica. A Figura 16 exibe as correntes trifásicas,  $I_a$ ,  $I_b$  e  $I_c$  para esse caso. Uma breve análise das formas de onda no tempo revela que, mesmo em condições normais de operação, as correntes não se apresentam como senoides perfeitas, uma vez que se verificam deformidades na forma de onda. Isso ocorre principalmente devido a problemas de qualidade de energia na rede elétrica à qual o equipamento está conectado. Tais condições são comuns no ambiente industrial e são impossíveis de serem eliminadas completamente. À vista disso, não podem ser desconsideradas no presente estudo.




**Figura 16 – Correntes trifásicas, motor normal à vazio, sem desbalanço.**

**Fonte: Autoria própria**

Para averiguar com exatidão quais componentes de frequência são responsáveis pelas perturbações na forma de onda, faz-se necessária a análise no domínio da frequência, a partir do espectro gerado com TF, Figura 17.

Observando-se a Figura 17, é possível identificar as frequências existentes nos sinais mencionados. Considerando a faixa de 0 Hz a 350 Hz apresentada, conclui-se que os valores de maior magnitude ocorrem nas frequências 60 Hz, 180 Hz e 300 Hz, as quais são correspondentes à componente fundamental e suas harmônicas de terceira e quinta ordem, respectivamente.

Destacam-se, também, os picos nas frequências 30 Hz e 90 Hz, as quais se intensificam na presença de excentricidade no eixo, como será visto a seguir. Conforme Equação (11), a frequência rotacional ( $f_r$ ) pode ser calculada como  $f_r = f_1(1 - s)/p$  ou  $f_r = N_r/60$ , sendo  $N_r$  a velocidade do rotor, em rpm (SAMAGA; VITTAL, 2014).



**Figura 17 – Espectro de frequência referentes às correntes trifásicas, motor normal à vazio, sem des-balanço.**

**Fonte: Autoria própria**


Assim sendo, considerando-se escorregamento nulo e  $m = 1$ , tem-se  $f_{exc} = 60 \pm 30$ , ou seja, as componentes de 30 Hz e 90 Hz encontradas no espectro. Conclui-se que o motor utilizado nos ensaios não apresenta o perfeito alinhamento do eixo do rotor, e, portanto, a excentricidade contribui para a intensificação dessas componentes. De fato, esse resultado é previsto por Nandi, Ahmed e Toliyat (2001), quando afirma que, devido a características intrínsecas de construção, as componentes oriundas de  $\pm f_r$  podem ser vistas mesmo em um motor de indução saudável. Em outras palavras, o perfeito alinhamento é impossível (THOMSON, 2001).

Em relação as componentes em 120, 240 e 270 Hz, verificadas no espectro da Figura 17, percebe-se que estas também podem ser associadas a falha de excentricidade, fazendo  $k = 2$ ,  $k = 6$  e  $k = 7$ , respectivamente, na Equação (11). Além disso, segundo Thomson (2001), a elevação na componentes de 120 Hz pode existir devido à assimetria inerente ao posicionamento dos enrolamentos de estator e o campo girante originado.

Em suma, o espectrograma de frequência do sinal de corrente de um motor normal operando em condições normais apresentou picos em determinados componentes, a saber, 30 Hz, 60 Hz, 90 Hz, 120 Hz, 180 Hz, 240 Hz, 270 Hz e 300 Hz. Na Tabela 3, verifica-se que estas componentes são todas associadas às frequências de curto-circuito no estator. Assim sendo, uma vez que tais componentes podem ser encontradas mesmo que o motor analisado esteja operando em condições normais, entende-se que exista outra fonte para geração dessas frequências. Portanto, fica claro que uma análise mais cautelosa deve ser considerada a respeito do uso das frequências de curto-circuito. Além disso, constatou-se que os sinais das três fases apresentam componentes de magnitude semelhante no domínio da frequência.

#### 4.3.2 Motor com curto-circuito na fase A, sem carga, sem desbalanço

O ensaio considerado nesta subseção apresenta as mesmas condições da situação anterior, com exceção do curto-circuito provocado na fase A. A Figura 18 ilustra as formas de onda das correntes trifásicas no tempo. Percebe-se que mesmo um curto-circuito incipiente de 1% das espiras é capaz de causar elevação na amplitude e alterações na forma de onda, principalmente na fase A. A análise espectral, Figura 19, pode ser utilizada para investigar quais alterações a falha produziu no domínio da frequência.




**Figura 18 – Correntes trifásicas, motor com curto-circuito de 1% das espiras, à vazio, sem desbalanço.**

Fonte: Autoria própria

Observa-se, na Figura 19, a presença de duas novas componentes, em 150 Hz e 210 Hz, em todas as fases. Por meio da Tabela 3 constata-se que essas componentes correspondem a  $n = 3$  e  $n = 5$  na Equação (1), ou seja, estão presentes dentre aquelas citadas como típicas de curto-circuito. Além disso, 150 Hz e 210 Hz não são múltiplas inteiras da frequência fundamental, isso significa que não podem ser confundidas com harmônicas da rede. Em vista disso, pode-se afirmar que somente o curto-circuito aplicado pode ter sido o responsável pela modificação da magnitude dessas frequências. Destacam-se as diferenças expressivas entre as magnitudes sem falha, em torno de  $-80$  dB, e com falha, em torno de  $-60$  dB. Em escala linear, essa diferença representa uma magnitude aproximadamente 10 vezes maior para essas componentes. As demais componentes não revelam alterações comparáveis.


Como pode-se perceber nas Figuras 17 e 19, as três fases so comportam de maneira semelhante, mesmo com falha em somente uma das fases. Diante desse fato, na Figura 20 são exibidos somente os espectrogramas da fase A.



**Figura 19 – Espectro de frequência referentes às correntes trifásicas, motor com curto-circuito de 1% das espiras, à vazio, sem desbalanço.**

**Fonte: Autoria própria**

A fim de comparação, podem ser conferidos na Figura 20 os espectros de frequência para o motor normal, com 3% e com 7% de espiras curto-circuitadas. O domínio (abszissas) foi limitado entre 140 Hz e 220 Hz a fim de concentrar a atenção nas componentes 150 Hz e 210 Hz.



**Figura 20 – Espectro de frequência referentes à fase A, motor normal e com diversos níveis de curto-circuito, à vazio, sem desbalanço.**

**Fonte: Autoria própria**



O principal objetivo dessa subseção foi verificar os efeitos no domínio da frequência de um curto-circuito entre espiras. Constatou-se a manifestação de duas novas componentes de frequência, 150 Hz e 210 Hz, em todas as fases, indicando sua correlação com a falha. A Tabela 4 resume as informações verificadas nesta seção.

**Tabela 4 – Tabela resumo ds componentes de frequência e suas possíveis causas.**

Componentes	Fatores geradores
60Hz, 180Hz e 300Hz	Fundamental e harmônicas de terceira e quinta ordem, curto-circuito
30Hz e 90Hz	Excentricidade no eixo, curto-circuito
120Hz, 250Hz e 270Hz	Assimetria enrolamentos/campo girante, excentricidade, curto-circuito
150Hz e 210Hz	Curto-circuito e excentricidade

#### 4.4 ANÁLISE DOS DADOS ATRAVÉS DA TRANSFORMADA WAVELET

Esta seção visa, mediante decomposição *wavelet-packet*, realizar o estudo detalhado das frequências ressaltadas na seção anterior. Os bancos de filtros *Daubechies* com comprimento 10 utilizados nessa transformada permitem isolar as bandas de frequência desejadas, promovendo a investigação de cada componente separadamente. Por simplificação, são utilizados somente os dados referentes ao MIT 2. Para esse tem-se sinais de curtos-circuitos de intensidade até 20%, possibilitando um exame mais apurado.

A subseção seguinte expõe a análise dos sinais sem desequilíbrio de tensão e sem carregamento no eixo. Contudo, considera-se variação da intensidade de curto-circuito, a fim de conferir isoladamente as modificações causadas pela falha.

##### 4.4.1 Variação do curto-circuito na fase A, sem carga, sem desbalanço

Com a finalidade de discriminar as componentes 150 Hz e 210 Hz das demais frequências foi utilizada a WPD em 8 níveis. Nesse nível, o sinal é dividido em  $2^8$  (256) bandas de frequência, sendo que a largura das bandas encontra-se estreita o bastante para a análise das frequências 150 Hz e 210 Hz com pouca interferência de outras frequências indesejadas. Uma vez que o estudo proposto intenciona o exame das componentes


de baixa frequência, do total de 256 componentes, foram selecionadas as primeiras 17 (0 - 515 Hz), excluindo as bandas de frequência elevada que não são de interesse para o estudo.

Para mensurar relevância de cada componente foi adotado o valor RMS dos componentes, calculado conforme (2). Uma vez que consiste em uma medida estatística da magnitude de uma quantidade variável, sendo, portanto, adequada para representar o sinal. A Tabela 5 exibe os valores RMS dos componentes *wavelet* reconstruídos das componentes 1 a 17 do oitavo nível.

São analisados os sinais da fase A, considerando as condições sem falha e com curto-circuito de até 20% das espiras na fase A, sem carregamento ou desequilíbrio entre fases. As componentes destacadas (2, 4, 6, 8, 14 e 16) exibem um valor RMS superior em relação às demais. A Figura 21 exibe o gráfico de barras correspondente, para melhor visualização dos dados apresentados. Destacam-se as componentes 2, 4, 6 e 8, as quais apresentam modificação mais expressiva à medida que o nível da falha aumenta. A partir dessa verificação, entende-se que as componentes de frequência 150 Hz e 210 Hz devem contribuir para a elevação no valor RMS em uma ou mais dessas componentes WPD.

**Tabela 5 – Valor RMS das componentes reconstruídas do nível 8 da decomposição *wavelet-packet* para os sinais com variação de curto-circuito de até 20%.**

Comp.	Valor RMS (A)						
	Sem falha	c.c. de 1%	c.c. de 3%	c.c. de 5%	c.c. de 10%	c.c. de 15%	c.c. de 20%
1	0,00552	0,01228	0,01702	0,00733	0,00544	0,02771	0,13694
<b>2</b>	<b>1,59019</b>	<b>1,60923</b>	<b>1,78525</b>	<b>2,25330</b>	<b>3,52163</b>	<b>4,03106</b>	<b>4,86736</b>
3	0,00911	0,01001	0,01581	0,02033	0,02212	0,02468	0,03118
<b>4</b>	<b>1,72842</b>	<b>1,70802</b>	<b>1,97759</b>	<b>2,28647</b>	<b>2,83615</b>	<b>4,32541</b>	<b>5,16627</b>
5	0,00204	0,00260	0,00363	0,00498	0,00726	0,00535	0,00725
<b>6</b>	<b>0,06658</b>	<b>0,05757</b>	<b>0,07526</b>	<b>0,09059</b>	<b>1,17278</b>	<b>0,33148</b>	<b>0,33769</b>
7	0,00556	0,00620	0,00800	0,01273	0,01194	0,00532	0,00577
<b>8</b>	<b>0,07088</b>	<b>0,07377</b>	<b>0,08940</b>	<b>0,10516</b>	<b>0,19139</b>	<b>0,39554</b>	<b>0,41590</b>
9	0,00066	0,00056	0,00155	0,00107	0,00195	0,00167	0,00229
10	0,01767	0,02756	0,03206	0,03295	0,02148	0,03007	0,04095
11	0,00130	0,00125	0,00227	0,00169	0,00334	0,00412	0,00413
12	0,02544	0,03870	0,04652	0,04496	0,02992	0,04212	0,04527
13	0,00207	0,00232	0,00320	0,00540	0,00852	0,01013	0,01071
<b>14</b>	<b>0,08303</b>	<b>0,10305</b>	<b>0,11364</b>	<b>0,08398</b>	<b>0,08036</b>	<b>0,13716</b>	<b>0,12767</b>
15	0,00081	0,00121	0,00213	0,00270	0,00356	0,00355	0,00457
<b>16</b>	<b>0,06278</b>	<b>0,08038</b>	<b>0,0873</b>	<b>0,06815</b>	<b>0,06066</b>	<b>0,13432</b>	<b>0,10736</b>
17	0,00054	0,00061	0,00060	0,00064	0,00091	0,00151	0,00343



**Figura 21 – Valor RMS das componentes do nível 8 da decomposição *wavelet-packet* para os sinais com variação de curto-circuito de até 20%.**

**Fonte: Autoria própria**

#### 4.4.2 Variação do carregamento no eixo, motor normal, sem desbalanço

Com interesse de investigar as implicações de uma elevação de carga nos componentes da WPD, faz-se necessária a análise da Tabela 6 e da Figura 22. Neste experimento, foram utilizados somente sinais de corrente da fase A, sem falha e sem desequilíbrio, contudo, variando o carregamento no eixo até o valor de 5 Nm.

Percebe-se que as componentes 2 e 4 sofreram elevação em seus valores RMS proporcionalmente à elevação do carregamento, revelando-se indicadores questionáveis para detecção de falhas de curto-circuito, uma vez que comportam-se de maneiras semelhantes perante uma elevação de carga e uma falha desse tipo. Todavia, o exame das componentes 6 e 8 revelam pouca modificação em seus valores RMS à medida que a carga no eixo se eleva, mostrando-se imunes a variação de carga. Tal fato indica que não houveram alterações significativas na magnitude das bandas de frequência correspondentes, o que, por sua vez, sugere que os componentes 6 e 8 estejam associados às frequências 150 Hz e 210 Hz.

Tabela 6 – Valor RMS das componentes reconstruídas do nível 8 da decomposição *wavelet-packet* para os sinais variação de carregamento.

Componente	Valor RMS (A)					
	A vazio	1Nm	2Nm	3Nm	4Nm	5Nm
1	0,00552	0,00564	0,00364	0,00378	0,00544	0,00349
2	1,59019	1,72710	1,78145	2,25119	2,23871	2,89167
3	0,00911	0,00770	0,00615	0,00667	0,00486	0,00413
4	1,72842	1,7238	1,93530	1,93315	2,49839	2,58577
5	0,00204	0,00143	0,00097	0,00132	0,00180	0,00202
<b>6</b>	<b>0,06658</b>	<b>0,07097</b>	<b>0,06550</b>	<b>0,06493</b>	<b>0,06279</b>	<b>0,05442</b>
7	0,00556	0,00511	0,00470	0,00483	0,00373	0,00264
<b>8</b>	<b>0,07088</b>	<b>0,08307</b>	<b>0,08032</b>	<b>0,06731</b>	<b>0,06901</b>	<b>0,06557</b>
9	0,00066	0,00073	0,00067	0,00103	0,00121	0,00083
10	0,01767	0,02426	0,03010	0,04057	0,04832	0,05838
11	0,00130	0,00148	0,00113	0,00185	0,00308	0,00312
12	0,02544	0,03276	0,04337	0,05616	0,07161	0,08206
13	0,00207	0,00142	0,00112	0,00149	0,00211	0,00225
14	0,08303	0,08355	0,07341	0,05342	0,03353	0,01963
15	0,00081	0,00078	0,00067	0,00010	0,00176	0,00293
16	0,06278	0,06488	0,05799	0,04353	0,02974	0,01551
17	0,00054	0,00051	0,00091	0,00202	0,00330	0,00368




Figura 22 – Valor RMS das componentes do nível 8 da decomposição *wavelet-packet* para os sinais sem falha e sem desequilíbrio, considerando variação de carregamento.

Fonte: Autoria própria

Outro ponto a ressaltar é a manifestação dos componentes 10 e 12, quase imperceptíveis no ensaio anterior, revelam-se agora sensíveis à variações de carga. Aponta-se ainda a variação das componentes 14 e 16, cujos valores RMS se mostraram inversamente proporcionais à elevação de carregamento.

Conclui-se que o valor RMS das componentes 2 e 4 sofrem modificações proporcionais aos valores da componente fundamental, o que sugere a contribuição da componente 60 Hz nesses resultados. Segundo, a análise de Fourier permitiu concluir que as componentes 150 Hz e 210 Hz não apresentavam valores significativos para a condição do motor sem curto-circuito, enquanto que a WPD mostrou dois componentes sensíveis ao curto-circuito e independente do carregamento aplicado no eixo. Tal fato sugere correlação entre as componentes 6 e 8 da transformada *wavelet* e as frequências citadas. Terceiro, as componentes 10, 12, 14 e 16 produziram resultados potencialmente interessantes, demandando mais ensaios para conclusões seguras.

#### 4.4.3 Subtensão na fase A, motor normal a vazio


A análise que segue leva em consideração dados do motor normal operando à vazio e submetido a diferentes níveis de desbalanços, proporcionando o estudo relativo às alterações provocadas por desequilíbrio de tensão entre as fases da alimentação. Os desbalanços foram provocados mantendo-se as tensões das fases B e C constantes em 127 V e reduzindo-se a tensão da fase A na ordem de 2%, 4%, 6%, 8% e 10%.

A Tabela 7 apresenta os valores RMS dos componentes *wavelet* reconstruídos da fase A, enquanto que a Figura 23 ilustra os dados apresentados na forma gráfica. Ao observar os componentes 2 e 4, percebe-se que os mesmos tem seu valor RMS reduzido à medida que o desequilíbrio aumenta. Tal resultado corrobora com a ideia de que tais componentes possuem correlação com a frequência fundamental, uma vez que a tensão na fase A também decresce. Logo, a tendência é que uma variação no valor eficaz da fase analisada provoque uma variação proporcional nos componentes 2 e 4.

Quanto aos componentes de interesse, 6 e 8, percebe-se um aumento do seu valor RMS conforme a elevação do desequilíbrio, embora relativamente inferior ao aumento causado pelo curto-circuito dentro do domínio de abordagem dos ensaios. Olhando somente para os componentes 6 e 8 das Tabelas 4 e 6, pode-se confundir um desbalanço de 10% com um curto-circuito de 5%, por exemplo, haja vista que apresentam valores muito próximos. Todavia, ao observar simultaneamente os componentes 2, 4, 6, 8, 14 e 16, a distinção pode se tornar mais clara. Isso significa que, embora somente alguns componentes expressam correlação com a falha, a observação de outros pode auxiliar na classificação do sinal perante desequilíbrios.

**Tabela 7 – Valor RMS das componentes reconstruídas do nível 8 da decomposição *wavelet-packet* para os sinais do motor à vazio sem falha, considerando variação de desequilíbrio entre fases.**

Componente	Valor RMS (A)					
	Sem des. (127V)	2% (124,5V)	4% (121,9V)	6% (119,4V)	8% (116,8V)	10% (114,3V)
1	0,00552	0,00459	0,00677	0,00443	0,01126	0,01092
2	1,59019	1,69705	1,38038	1,33828	1,34183	1,04150
3	0,00911	0,00873	0,00707	0,00644	0,00752	0,00723
4	1,72842	1,42748	1,48791	1,38281	1,05567	1,14533
5	0,00204	0,00112	0,00302	0,00211	0,00306	0,00237
<b>6</b>	<b>0,06658</b>	<b>0,06681</b>	<b>0,06931</b>	<b>0,07434</b>	<b>0,07750</b>	<b>0,09179</b>
<b>8</b>	<b>0,07088</b>	<b>0,07543</b>	<b>0,08507</b>	<b>0,09212</b>	<b>0,09243</b>	<b>0,09722</b>
9	0,00066	0,00086	0,00101	0,00086	0,00094	0,00100
10	0,01767	0,01584	0,01308	0,01391	0,02273	0,02317
11	0,00130	0,00114	0,00146	0,00128	0,00236	0,00147
12	0,02544	0,02087	0,01863	0,01883	0,03224	0,03401
13	0,00207	0,00106	0,00288	0,00272	0,00262	0,00254
14	0,08303	0,07833	0,07932	0,07584	0,09947	0,09626
15	0,00081	0,00098	0,00158	0,00155	0,00120	0,00110
16	0,06278	0,06677	0,06125	0,05996	0,08170	0,07342
17	0,00054	0,00047	0,00050	0,00049	0,00041	0,00051



**Figura 23 – Valor RMS das componentes do nível 8 da decomposição *wavelet-packet* para os sinais do motor à vazio sem falha, considerando variação de desequilíbrio entre fases.**

Fonte: Autoria própria


#### 4.4.4 Sobretensão na fase B e subtensão na fase C, motor normal a vazio

Os testes dessa subseção levam em consideração condições de desequilíbrio provocadas pela elevação da tensão na fase B simultaneamente a diminuição na fase C na ordem de 2%, 4%, 6% e 8%, mantendo constante a tensão na fase A. Busca-se descobrir quais alterações são provocadas nos componentes do oitavo nível perante esse tipo de falha no sistema de alimentação.

A Tabela 8 e a Figura 24 exibem os resultados do ensaio. Analisando as medidas RMS das componentes reconstruídas referentes aos sinais de corrente da fase A, constata-se que, para os diversos níveis de desequilíbrios provocados nesse experimento, todas as componentes exibiram modificações irrelevantes em seus valores, à exceção das componentes 2 e 4. Essas demonstraram uma tendência de crescimento conforme o incremento do desbalanço a partir de 4%.

**Tabela 8 – Valor RMS das componentes reconstruídas do nível 8 da decomposição *wavelet-packet* para os sinais do motor à vazio sem falha, considerando sobretensão na fase B e subtensão na fase C.**

Componente	Valor RMS (A)				
	Sem desb. (127V)	2% (129,54V)	4% (132,08V)	6% (134,62V)	8% (137,16V)
1	0,00552	0,00579	0,01046	0,00443	0,01231
2	1,59019	1,57530	1,67838	1,33828	1,86409
3	0,00911	0,00912	0,00652	0,00644	0,00401
4	1,72842	1,72104	1,79378	1,38281	2,03500
5	0,00204	0,00270	0,00227	0,00211	0,00349
<b>6</b>	<b>0,06658</b>	<b>0,07278</b>	<b>0,08494</b>	<b>0,07434</b>	<b>0,08136</b>
7	0,00556	0,00444	0,00385	0,00304	0,00268
<b>8</b>	<b>0,07088</b>	<b>0,07573</b>	<b>0,08931</b>	<b>0,09212</b>	<b>0,08694</b>
9	0,00066	0,001157	0,00065	0,00086	0,00111
10	0,01767	0,02427	0,02279	0,01391	0,02113
11	0,00130	0,00154	0,00094	0,00128	0,00173
12	0,02544	0,03584	0,03233	0,01883	0,03001
13	0,00207	0,00279	0,00279	0,00272	0,00285
14	0,08303	0,10175	0,09067	0,07584	0,09910
15	0,00081	0,00141	0,00140	0,00155	0,00144
16	0,06278	0,07822	0,07195	0,05996	0,07562
17	0,00054	0,00049	0,00050	0,00049	0,00073

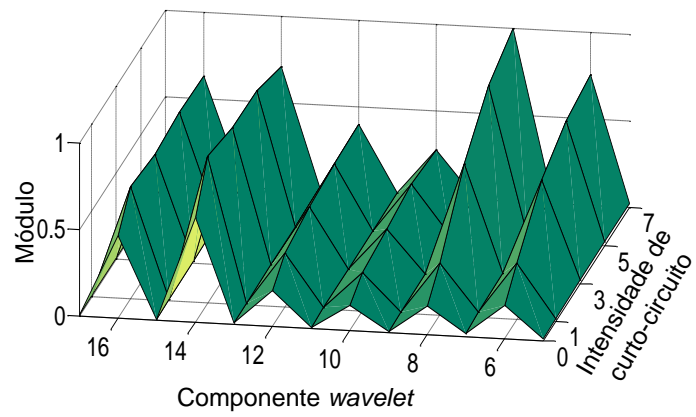


**Figura 24 – Valor RMS das componentes do nível 8 da decomposição *wavelet-packet* para os sinais do motor à vazio sem falha, considerando variação de sobretensão na fase B.**

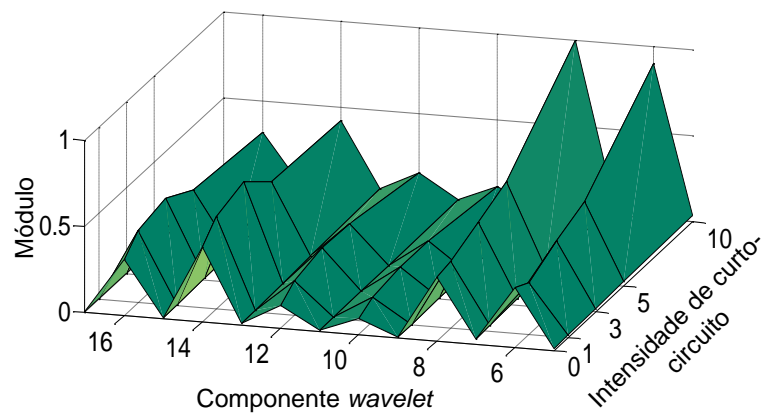
**Fonte: Autoria própria**

Na análise realizada nesta seção considerou-se, até então, somente o MIT 2. Contudo, como verificado na Figura 25, o padrão para as componentes 6 e 8 do oitavo nível da WPD se mantêm para os demais motores quando do aumento gradual do curto-circuito.

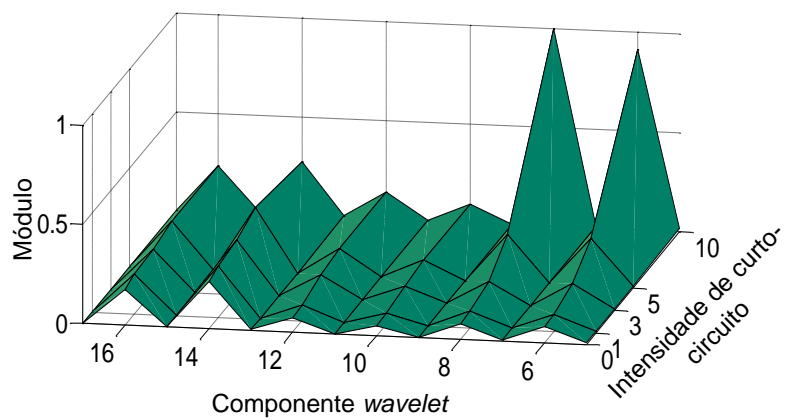




a) MIT 1



b) MIT 2



c) MIT 3

**Figura 25 – Padrão de curto-circuito das primeiras componentes de decomposição *wavelet* para os dados dos 3 motores analisados.**

**Fonte: Autoria própria**

#### 4.4.5 A falha de curto-circuito na árvore de decomposição

A *wavelet-packet* divide o eixo de frequências em intervalos distintos de vários tamanhos. A contínua utilização de filtros tanto nos componentes de aproximação quanto nos detalhes define a estrutura de árvore, conhecida como árvore binária ou árvore de decomposição. Nas subseções anteriores foram exibidos resultados detalhados de ensaios realizados em 8 níveis da WDP. A Figura 26 exhibe o resultado da TF aplicada na componente *wavelet* (8,6) reconstruída. Percebe-se que as frequências de 150 Hz estão presentes, enquanto frequências mais distantes são atenuadas pelos filtros. Frente às conclusões realizadas, fica estabelecido que as frequências relacionadas à falha de estator se localizam na sexta e oitava componentes da decomposição no nível 8.

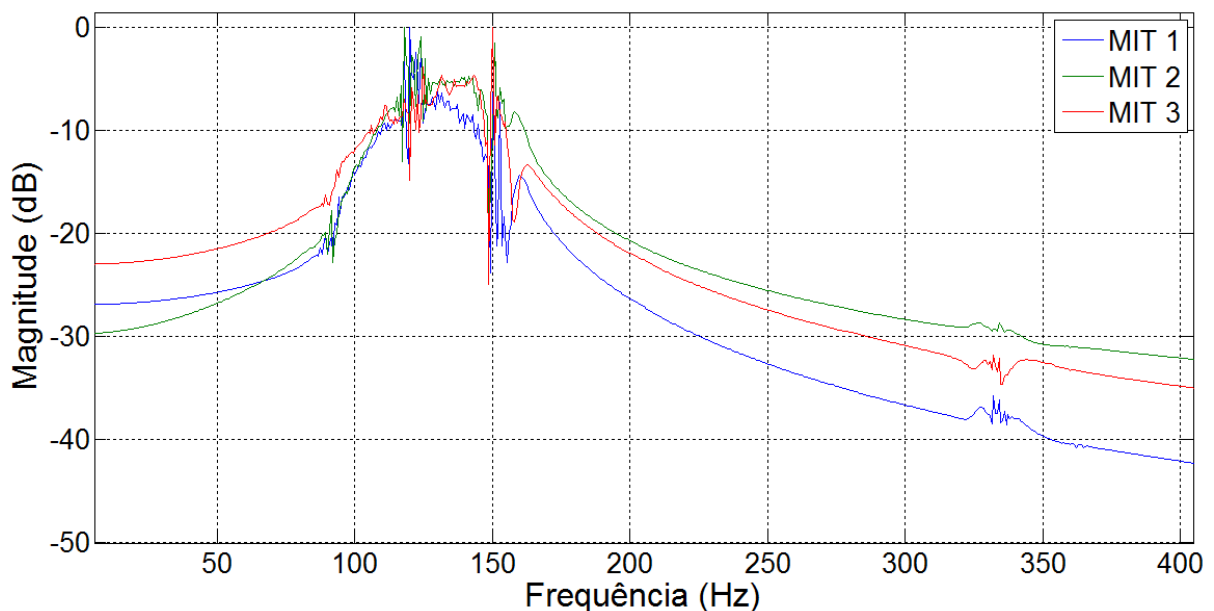
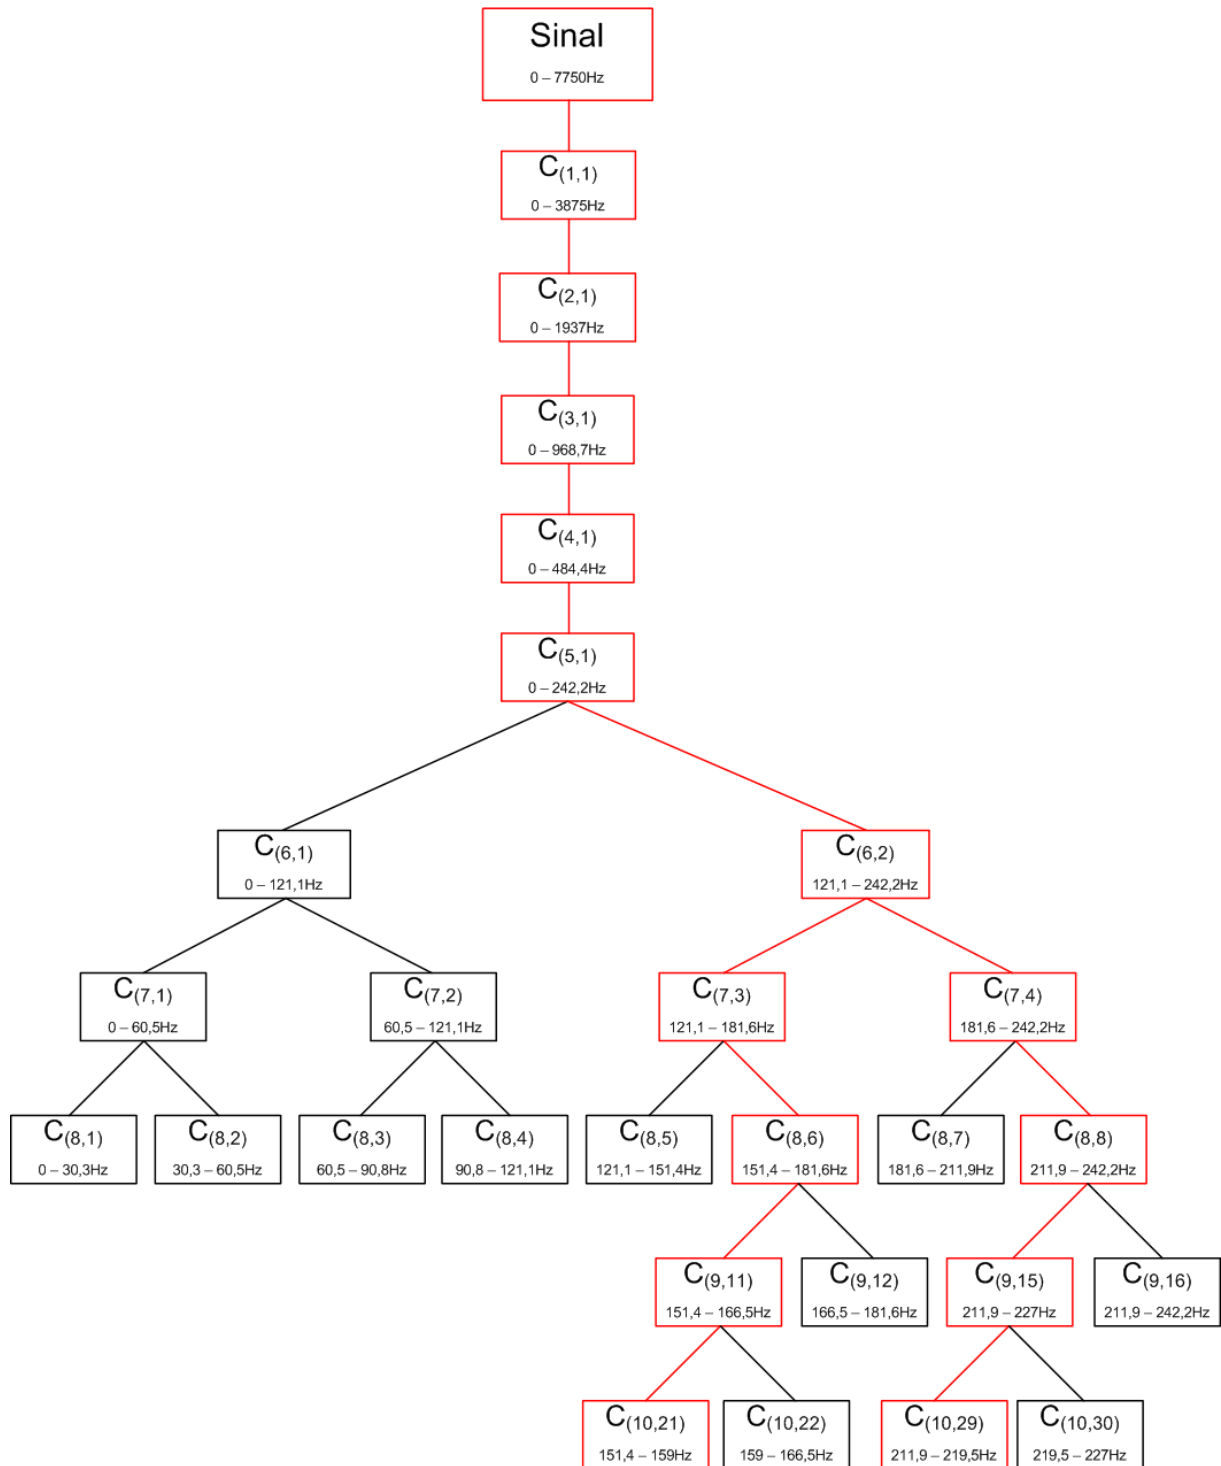


Figura 26 – TF aplicada na componente *wavelet* (8,6) reconstruída.

Fonte: Autoria própria

Para os demais níveis, a Figura 27 exhibe a estrutura da árvore até o décimo nível. O caminho foi traçado com base em resultados experimentais, ou seja, analisando os padrões da mesma forma como foi feito para o nível 8 na Seção 4.4.1, em cada um dos níveis até o décimo, com a finalidade de encontrar as componentes mais sensíveis às falhas de curto-circuito. Dessa forma, verificou-se que a frequência de 150 Hz segue de C(8,6) para C(9,11) e em seguida para C(10,21), enquanto que aquela de 210 Hz continua de C(8,8) para C(9,15) e depois para C(10,29). Ressalta-se que foram omitidos os demais nós dos níveis 9 e 10, assim com os ramos de detalhes até o nível 5, com a finalidade de aproveitar o espaço disponível de forma mais eficiente.

Percebe-se que cada componente tem seu intervalo de frequências correspondente grafado, a fim de facilitar a compreensão da árvore. Observa-se que o sinal original é composto por frequências de 0 a 7,75 kHz. Isso se dá pois a frequência de amostragem é de 15,5 kHz, como mencionado no Capítulo 3.



**Figura 27 – Localização estimada das frequências 150 Hz e 210 Hz até o décimo nível de decomposição wavelet-packet.**

Fonte: Autoria própria

Ao analisar o nó  $C_{(8,6)}$  na Figura 27, verifica-se que a banda de frequência dessa componente tem seus limites em 151,4 Hz e 181,6 Hz, o que contradiz os resultados aferidos até então. De fato, respeitando a disposição da decomposição tal qual ilustrada na árvore, a componente  $C_{(8,5)}$ , cujos limites são 121,1 Hz e 151,4 Hz, deveria ser aquela

que contém a frequência 150 Hz. Entretanto, como visto experimentalmente, a componente C(8,5) mostra-se insensível ao curto-circuito. O mesmo pode ser dito em relação às componentes C(8,8), C(9,11), C(10,21), C(9,15) e C(10,29).

Frente a tais constatações, entende-se que houve um deslocamento da frequência de interesse para a componente adjacente. Destaca-se que os filtros utilizados para realização da decomposição não realizam um corte abrupto das frequências, o que promove a mistura de alguns componentes. Esse fenômeno foi conferido por Schmitt (2013), no qual a componente esperado não apresentava as características desejadas, compelindo o autor a utilizar as componentes contíguas em relação aquelas que se apresentavam associadas à falha de rolamento. O mesmo ocorre neste trabalho.

#### 4.5 POTÊNCIA DE PREVISÃO NA ANÁLISE DE CURTO-CIRCUITO

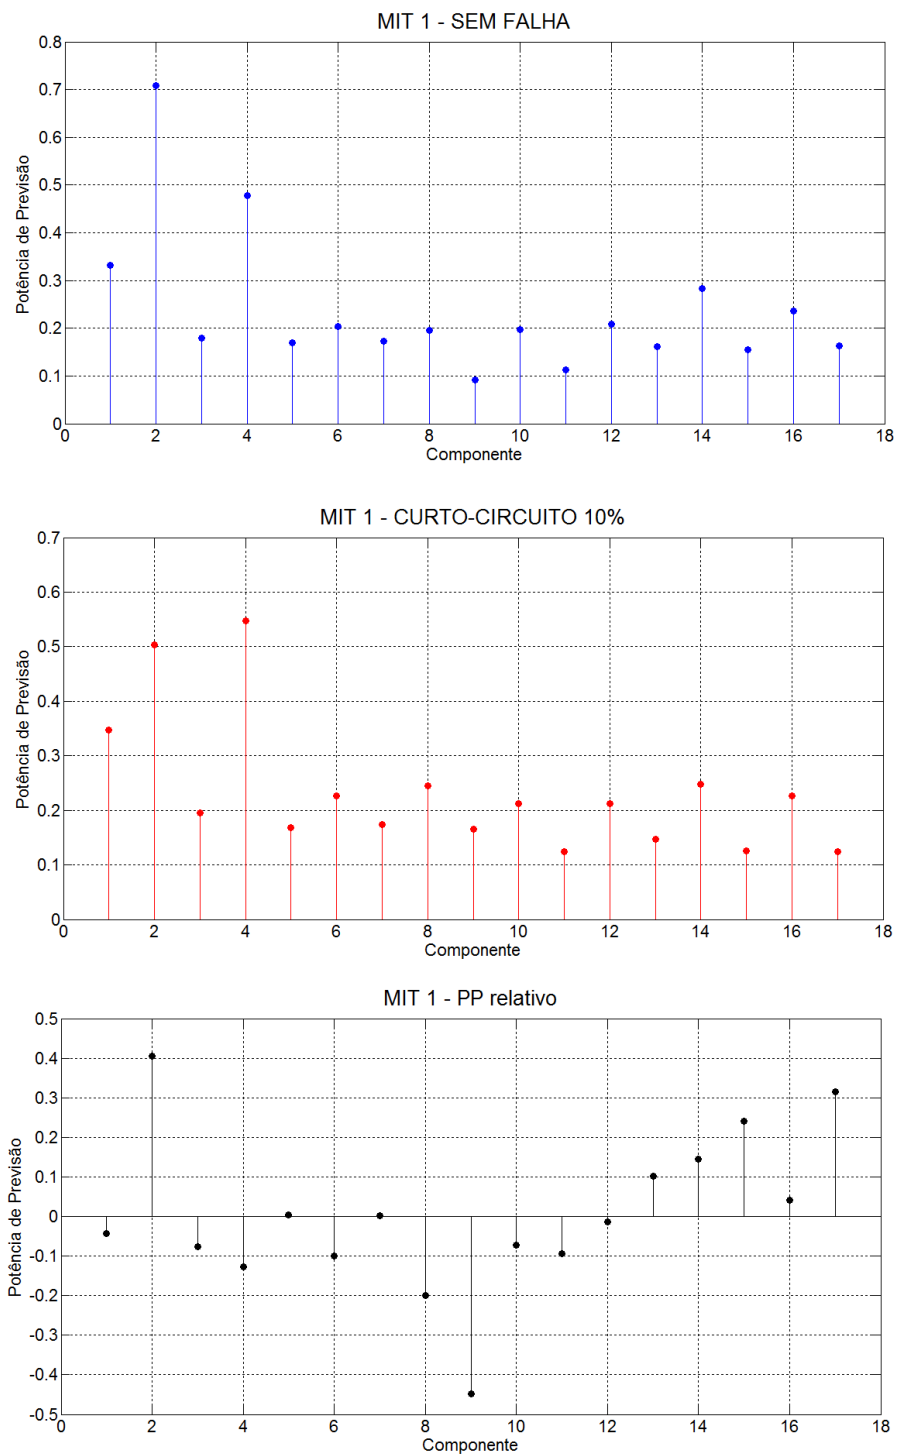
Esta seção se dedica a análise do curto-circuito de estator sob o ponto de vista da Potência de Previsão. As Figuras 28, 29 e 30 ilustram o valor PP dos 17 primeiros componentes da WPD em oitavo nível, considerando sinais dos motores normal ( $PP_{SF}$ ) e com curto-circuito ( $PP_{CC}$ ) de 7%, MIT 1, e 10%, MIT 2 e 3. Ilustra, ainda, a diferença relativa ( $PP_{RELATIVO}$ ) entre os dois anteriores, calculada de acordo com a equação (12).

$$PP_{RELATIVO} = \frac{PP_{CC} - PP_{SF}}{PP_{SF}} \quad (12)$$

O sinais são referentes ao MIT operando a vazio e sem desequilíbrio de tensão entre fases. Os gráficos apresentam valores de PP entre zero e a unidade, uma vez que a PP pode ser vista como uma normalização da entropia relativa. Quanto maior a PP, mais previsível é a componente em questão.

Como visto na Seção 2.4, a entropia relativa é uma medida de divergência entre duas distribuições de probabilidades. Para o cálculo da entropia relativa são utilizadas as PDF do sinal original e do erro de reconstrução de cada componente da WPD. Pela análise da Equação (9), percebe-se que a previsibilidade é maior quanto menor for o valor apresentado pelo erro de reconstrução. Logo, o valor PP do componente é maior quando o sinal original e o reconstruído são similares.

Observando-se as Figuras 28, 29 e 30, percebe-se que o curto-circuito provoca uma pequena elevação no valor da PP na maioria das componentes apresentadas. Ambas as componentes 6 e 8 são exemplo, mantendo o padrão para os sinais dos 3 MIT. Portanto, de modo geral, essas componentes se tornam mais previsíveis diante da falha. Contudo, não se pode constatar um padrão para todas as componentes. Tomando com exemplo a componente 2, verifica-se que seu valor é maior sem falha e decresce quando a ocorrência da falha, para os MIT 1 e 3. Já para o MIT 2, seu valor PP sem falha é menor.



**Figura 28 – Potência de Previsão das componentes da WPD do MIT 1, sinais sem falha, com falha e relativo.**

**Fonte: Autoria própria**

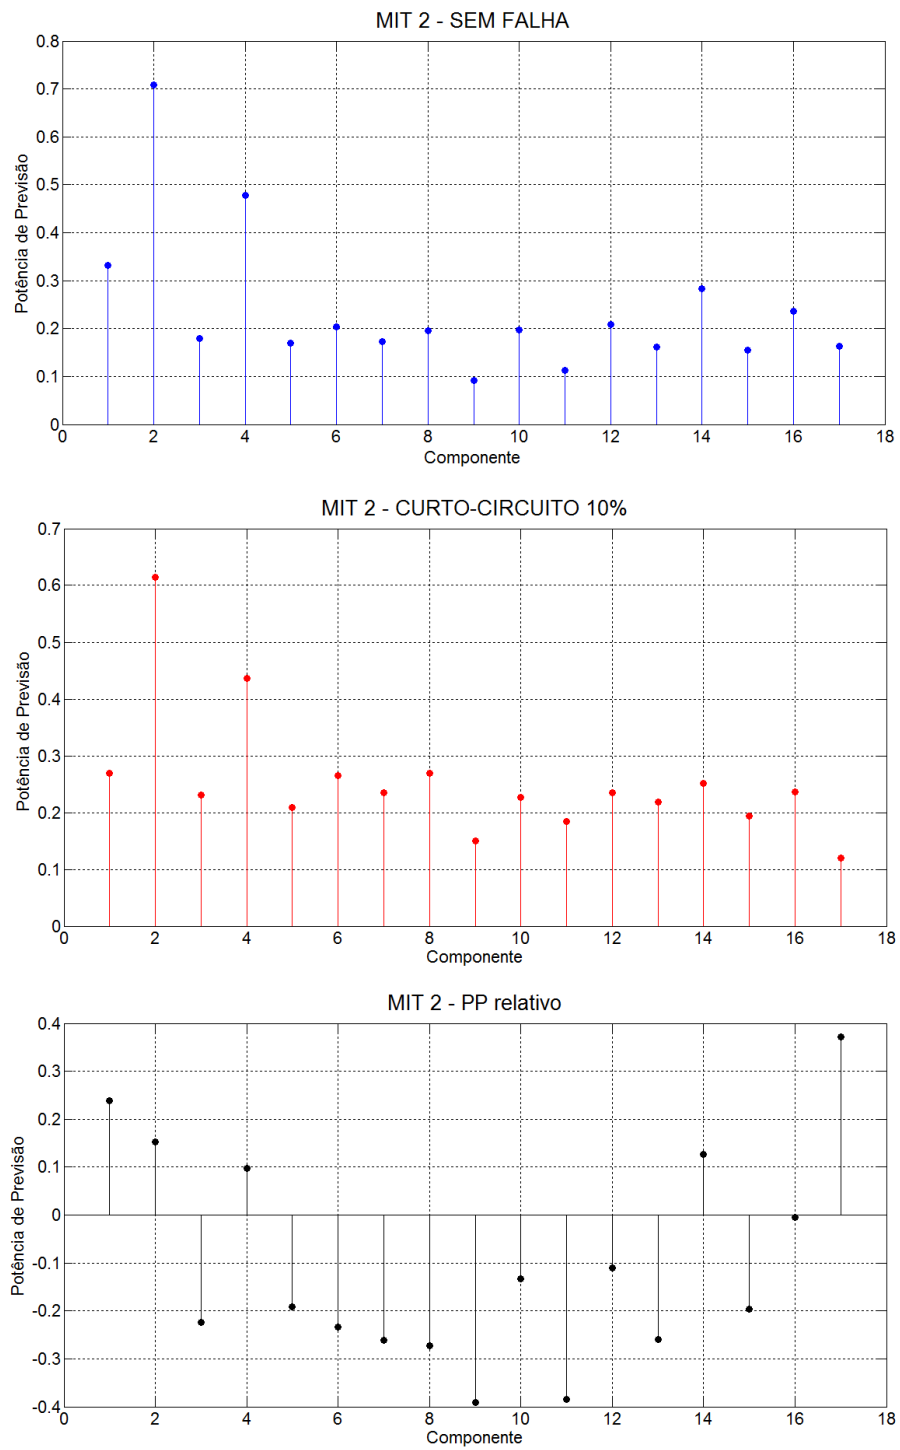
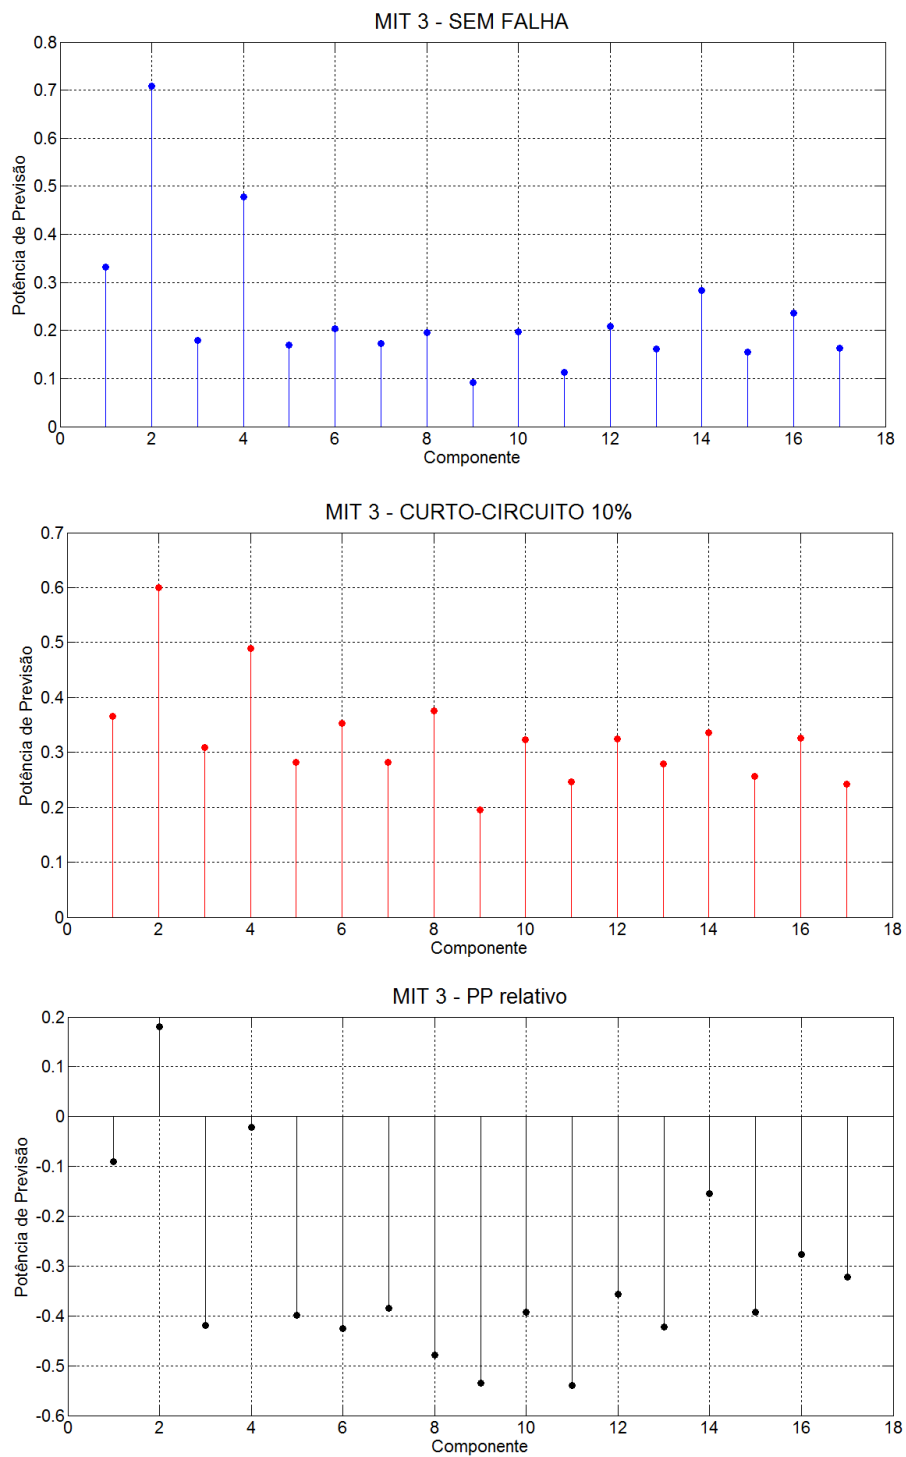


Figura 29 – Potência de Previsão das componentes da WPD do MIT 2, sinais sem falha, com falha e relativo.

Fonte: Autoria própria



**Figura 30 – Potência de Previsão das componentes da WPD do MIT 3, sinais sem falha, com falha e relativo.**

**Fonte: Autoria própria**

## 4.6 CONCLUSÃO

Em suma, nesse capítulo foi visto que, dentre as falhas de curto-circuito de enrolamento de estator, aquelas do tipo 2 são as mais difíceis de serem detectadas e podem evoluir para curto-circuitos do tipo 3, 4 e 5. Destaca-se, portanto, a importância de serem detectadas rapidamente. A análise por TF sugeriu uma forte correlação entre as frequências 150 Hz e 210 Hz e a falha de curto-circuito. Destaca-se que todas as fases manifestaram alterações nessas frequências diante de um curto-circuito em somente uma das fases. Na análise mediante WPD, buscou-se isolar as várias condições de funcionamento do MIT em questão, ou seja, o curto-circuito, o carregamento e o desequilíbrio, a fim investigar que tipo de alterações essas condições de operação implicam nas componentes *wavelet* examinadas. Os padrões obtidos corroboraram os resultados anteriores, associando as componentes C(8,6) e C(8,8) com as frequências indicadas por Fourier. Além disso, os testes mostraram a indiferença dessas componentes perante uma elevação de carga no eixo. As variações perante o desequilíbrio não são muito expressivas, mas podem gerar confusão na classificação. Concluindo, ainda que essas componentes sejam as únicas claramente ligadas às frequências de curto-circuito, pode ser necessário o uso de outras componentes para se realizar um reconhecimento de padrões confiável. No próximo capítulo serão realizados experimentos com redes neurais a fim de avaliar a sua aplicabilidade para classificar os padrões encontrados.



## 5 RESULTADOS EXPERIMENTAIS

No capítulo anterior, foi realizado o estudo da falha de curto-circuito no estator do MIT, no qual foi exibida a análise dos sinais coletados em laboratório. Com base na fundamentação teórica apresentada, foi efetuado o reconhecimento de padrões dos dados, de forma manual, com auxílio de gráficos e tabelas. Assim, foi possível constatar algumas regularidades manifestadas pelo curto-circuito, perante situações de desbalanço e carregamento variados.

Com a finalidade de tornar o reconhecimento de padrões um processo automático, encontra-se na abordagem neural uma alternativa para o reconhecimento manual de padrões. Tem-se, assim, um procedimento impessoal, uma vez que é eliminado o fator humano. Isso se traduz em uma maior confiabilidade e exatidão para a detecção de uma falha em MIT. Além disso, possibilita a implementação de um sistema *on-line* para o monitoramento do motor.


Diante das pesquisas apresentadas nos Capítulos 1 e 2, verifica-se que as redes *Perceptron* multicamadas e *Radial Basis Function* proporcionam resultados satisfatórios para diversas situações às quais foram aplicadas. Foram, portanto, as redes selecionadas para realizar a classificação de padrões. No decorrer deste capítulo, é investigada a viabilidade do emprego da PMC e RBF para a realização do mapeamento de padrões efetuado de forma manual no capítulo anterior. As redes em questão são submetidas à diversos treinamentos, perante uma variedade de situações de falha, incluindo testes com as amostras estratificadas por intensidade de curto-circuito e por intensidade de desequilíbrio. Além disso, a fim de comparação, são realizados experimentos utilizando os valores RMS e Potência de Previsão dos coeficientes *wavelet* selecionados. A partir dos resultados obtidos é possível avaliar a aplicabilidade da metodologia para a detecção da falha de curto-circuito no estator de um motor de indução trifásico.

### 5.1 CLASSIFICAÇÃO UTILIZANDO REDES PERCEPTRON MULTICAMADAS

Existem diversos parâmetros que influenciam no desempenho de uma PMC, tais como o algoritmo de aprendizado utilizado, os valores dos pesos iniciais e a forma como os mesmos foram iniciados, a complexidade do problema a ser mapeado, a qualidade do conjunto de dados disponível na fase de treinamento, entre outros (SILVA; SPATTI; FLAUZINO, 2010). Portanto, a especificação da topologia mais apropriada para uma situação específica é normalmente efetuada de forma empírica. Diante disso, uma metodologia para auxiliar a seleção da melhor topologia consiste em aplicar o algoritmo de treinamento em um conjunto de topologias pré-escolhidas. Finalizada a fase de treinamento para cada rede, avalia-se o potencial de generalização aplicando-se os subconjuntos de validação em cada topologia candidata, e, com isso, seleciona-se aquela que obtiver o melhor desempenho.

As topologias candidatas para o experimento estão discriminadas na Tabela 9. A Figura 31 exhibe a arquitetura genérica de uma rede *Perceptron* com 3 camadas escondidas. As Redes 1, 2 e 3 possuem duas camadas escondidas,  $L1$  e  $L2$ , e a Rede 4, por sua vez, possui três camadas escondidas. Além disso,  $n_1$ ,  $n_2$  e  $n_3$  representam o número de

neurônios em cada uma das camadas.



**Figura 31 – Arquitetura *Perceptron* multicamadas (PMC).**

Fonte: Modificado de Silva, Spatti e Flauzino (2010).

Com a finalidade de aumentar a rapidez do treinamento da PMC foi utilizado o algoritmo *resilient-propagation*, em todos os casos. A justificativa de escolha desse algoritmo reside no fato de que se trata de um problema envolvendo classificação de padrões. Conforme Silva, Spatti e Flauzino (2010), a utilização do método *resilient-propagation* se mostra normalmente mais eficiente nessa situação, pois há o tratamento direto dos sinais das derivadas do gradiente. Como função de ativação foi adotada a tangente hiperbólica, uma vez que esta contribui para melhorar o processo de convergência da rede pelo fato de ser uma função ímpar. Além disso, a taxa de aprendizado,  $\eta$ , exprime o quão rápido o processo de treinamento está sendo conduzido à convergência, atentando-se que taxas inadequadas podem levar à instabilidade do sistema. Costuma-se adotar valores entre 0 e 1 para esse parâmetro, sendo  $\eta = 10^{-3}$  especificado empiricamente. A função de ativação utilizada é a tangente hiperbólica.

**Tabela 9 – Topologias testadas**

	Rede 1	Rede 2	Rede 3	Rede 4
Nº de camadas escondidas	2	2	2	3
Nº de neurônios na camada L1	5	10	15	10
Nº de neurônios na camada L2	5	10	15	10
Nº de neurônios na camada L3	0	0	0	5
Nº de neurônios na camada de saída	1	1	1	1

Na fase de treinamento, são apresentadas à rede os subconjuntos selecionados para esta finalidade e as respectivas saídas desejadas. A cada iteração (época), os pesos

de cada neurônio são ajustados, a fim de adequar a saída produzida conforme a saída desejada. Por esse motivo, tal tipo de treinamento é chamado supervisionado. Durante esse processo de atualização dos pesos sinápticos da PMC, os hiperplanos de separação tendem a se mover continuamente, até que sejam alcançadas fronteiras de separação que permitam a discriminação das duas classes envolvidas.

Em cada caso, são realizados cinco ensaios para cada topologia. A matriz de pesos iniciais é gerada aleatoriamente cada vez que as redes são submetidas ao treinamento, sendo assim, evita-se a convergência da rede para eventuais regiões de mínimos locais. O direcionamento do processo de aprendizagem para pontos de mínimos locais ocorre em virtude da superfície de erro da PMC não ser linear, portanto, a convergência fica condicionada à posição espacial em que a matriz de pesos foi iniciada (SILVA; SPATTI; FLAUZINO, 2010). Ao final, o desempenho global das topologias é avaliado através da média dos desempenhos individuais.

Primeiramente, os experimentos foram estratificados por intensidade de curto-circuito. Para os MIT 1 e 2, em cada teste utilizou-se, na fase treinamento, 110 amostras sem falha mais 110 amostras com um determinado nível de curto, totalizando 220 amostras para treinamento. No caso do MIT 3, são utilizadas 66 amostras sem falha mais 66 amostras com determinado nível de falha na fase de treinamento. Na fase de validação para todos os três MIT, foram utilizadas 60 amostras sem falha mais 60 amostras com determinado nível de curto, totalizando 120 amostras para validar as redes. Para melhor entendimento, recomenda-se a revisão das Figuras 13 e 14.

A Tabela 10 resume como estão organizados os subconjuntos para os ensaios seguintes. Cabe lembrar que as amostras utilizadas para treinamento não têm relação alguma com as amostras de validação, ou seja, são originadas de ensaios distintos.

**Tabela 10 – Organização de amostras de treinamento e validação.**

	Número de Amostras		Total
	Treinamento ( $X_T$ )	Validação ( $X_V$ )	
MIT 1	220	120	340
MIT 2	220	120	340
MIT 3	132	120	252
Total	572	360	932

As subamostras de treinamento,  $X_T$ , e de validação,  $X_V$ , após terem seus dados normalizados, estão prontas para servir de entrada para as redes. A normalização consiste em dividir cada ponto de uma série de termos pelo seu valor máximo, enquadrando os dados entre 0 e 1. Por fim, é necessário atribuir valores para a saída das redes, no caso “1” e “-1”. Dessa forma, Os termos  $D_T$  e  $D_V$  representam, respectivamente, as saídas desejadas para fase de treinamento e validação, de acordo com a Figura 32.

Destaca-se que todas as topologias contemplam apenas um neurônio na camada de saída. Isso porque, para o experimento preliminar em questão, preocupa-se apenas na distinção entre duas classes, ou seja, motores normais e com falha, independente do grau de severidade do curto-circuito. Portanto, um único neurônio apresentando saídas lógicas “1” ou “-1” se verifica suficiente, pois, assim, atribui-se o valor “1” caso a amostra se refira

$$\begin{array}{l}
 \mathbf{X} \left\{ \begin{array}{l}
 \mathbf{X}_T = [ X_T^{(1)} \ X_T^{(2)} \ X_T^{(3)} \ \dots \ X_T^{(98)} \ X_T^{(99)} \ X_T^{(110)} \ | \ X_T^{(1)} \ X_T^{(2)} \ X_T^{(3)} \ \dots \ X_T^{(98)} \ X_T^{(99)} \ X_T^{(110)} ]_{2 \times 220} \\
 \mathbf{X}_V = [ X_V^{(1)} \ X_V^{(2)} \ X_V^{(3)} \ \dots \ X_V^{(58)} \ X_V^{(59)} \ X_V^{(60)} \ | \ X_V^{(1)} \ X_V^{(2)} \ X_V^{(3)} \ \dots \ X_V^{(58)} \ X_V^{(59)} \ X_V^{(60)} ]_{2 \times 120}
 \end{array} \right. \\
 \\
 \mathbf{D} \left\{ \begin{array}{l}
 \mathbf{D}_T = [ 1 \ 1 \ 1 \ \dots \ 1 \ 1 \ 1 \ | \ -1 \ -1 \ -1 \ \dots \ -1 \ -1 \ -1 ]_{1 \times 220} \\
 \mathbf{D}_V = [ 1 \ 1 \ 1 \ \dots \ 1 \ 1 \ 1 \ | \ -1 \ -1 \ -1 \ \dots \ -1 \ -1 \ -1 ]_{1 \times 120}
 \end{array} \right.
 \end{array}$$

**Figura 32 – Organização das amostras, exibindo os subconjuntos de treinamento e validação das entradas e saídas da rede.**

Fonte: Autoria própria.

ao motor normal, e, caso contrário, o neurônio deve revelar o valor “-1” na saída.

O último passo antes de ir para a etapa de validação é o reajuste das saídas da PMC. A função de ativação empregada foi a tangente hiperbólica e a mesma pode produzir números reais, portanto, para correta comparação entre a saída desejada e a saída real da rede, essa última deve ter seus valores aproximados para “1” caso a saída do último neurônio for maior que zero e para “-1” caso contrário. Uma vez realizado esse pós-processamento, a rede estará apta para proceder com a tarefa de classificação frente às amostras desconhecidas. Para tanto é iniciada a fase de validação, na qual o potencial de generalização das redes candidatas será posto à prova.

Com o auxílio da WPD, extraem-se as componentes reconstruídas de interesse, ou seja, aquelas correlacionadas aos curto-circuitos. Conforme averiguado na Seção 4.4, as componentes 6 e 8 do oitavo nível apresentam ligação mais forte com a falha de curto-circuito. Todavia, as demais componentes se comportam de maneiras distintas perante variações de carregamento e desequilíbrio, o que pode auxiliar na classificação. À vista disso, a subseção 5.1.1 exibe os resultados das redes analisadas quando utilizadas como entradas somente os valores RMS das componentes 6 e 8, assim como a subseção 5.1.2 exibe os resultados considerando como entradas as componentes 2, 4, 6, 8, 14 e 16. Dessa forma, é investigada a necessidade ou não de se utilizar um número maior de coeficientes. Caso as redes promovam desempenhos semelhantes para ambos os casos, os demais experimentos devem considerar a apenas a utilização dos coeficientes 6 e 8 caracterizando assim um menor peso computacional.

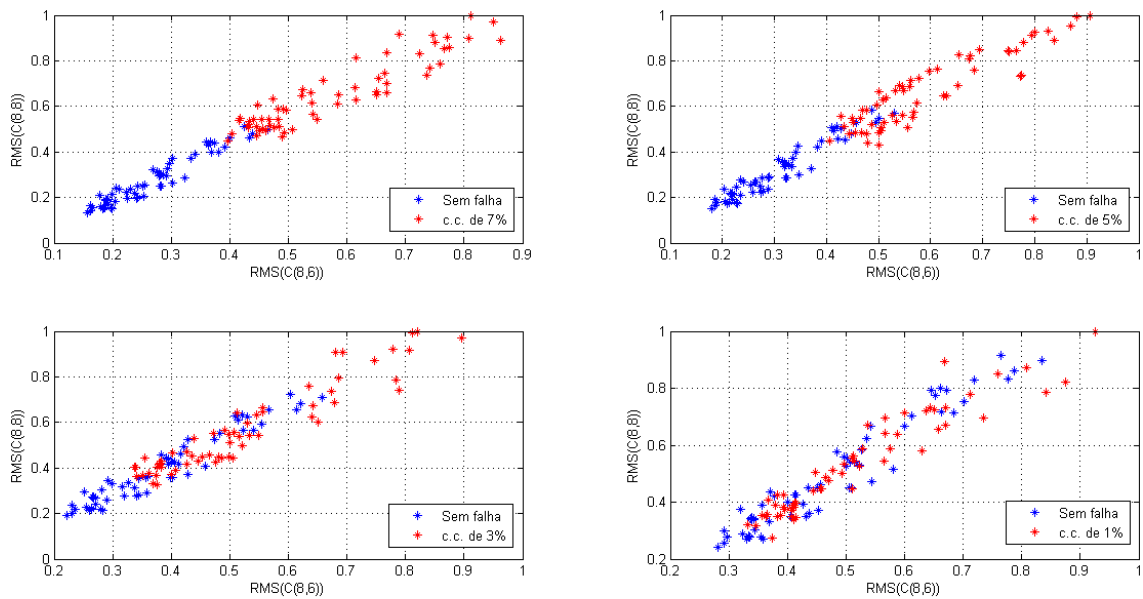
### 5.1.1 RMS das componentes 6 e 8 como entradas

Após submetidas à WPD, realiza-se o pós-processamento dos dados. Nesta etapa é calculada a medida RMS de cada vetor reconstruído, ou seja, cada uma das amostras

agora é retratada por um vetor de 2 entradas, representado na Equação (13) por  $X^{(k)}$ , considerando que  $k$  assumia valores de 1 até o número de amostras.

$$X^{(k)} = \begin{bmatrix} RMS(C_{8,6}) \\ RMS(C_{8,8}) \end{bmatrix} \quad (13)$$

Os vetores  $X^{(k)}$  de dimensão  $2 \times 1$  formam um conjunto de pontos num espaço bidimensional. A Figura 33 exibe esse conjunto de pontos para as amostras sem falha e com falha. O posicionamento dos pontos esboça o grau de complexidade a que as redes serão submetidas a fim de gerar os hiperplanos de separação nos ensaios que seguem.



**Figura 33 – Gráfico de  $RMS(C(8,8)) \times RMS(C(8,6))$ , para diversas intensidades de curto-circuito.**

**Fonte: Autoria própria.**

As Tabelas 13 a 20 exibem os resultados das quatro topologias perante os mesmo dados. O grau de precisão  $\varepsilon$  estipulado é  $10^{-6}$ . A precisão é avaliada a cada iteração, calculando-se o erro médio quadrático entre a saída desejada e a saída real da PMC. O algoritmo converge assim que o erro quadrático médio ( $Eqm$ ) entre duas épocas sucessivas for menor que o grau de precisão requerido, ou seja,  $|Eqm_{(atual)} - Eqm_{(anterior)}| \leq \varepsilon$ . Ressalta-se que foi imposta uma quantidade máxima de 2000 épocas como critério complementar de parada do algoritmo, garantindo cessar o treinamento para o caso de uma convergência lenta.

Cada uma das Tabelas exibe, além da taxa média de acertos, o índice Kappa. Avaliados em conjunto, tais valores podem auxiliar a respeito da topologia mais apropriada em cada situação. O índice Kappa, ou estatística Kappa, é uma medida que proporciona uma noção do quanto as observações se afastam daquelas esperadas, levando em consideração o acaso. Portanto, esse índice quantifica a legitimidade das interpretações. Fitzgerald e Lees (1994) recomendam o uso dessa medida para avaliar a precisão da classificação

de diferentes classificadores, pois, segundo os autores, trata-se de uma ferramenta de discernimento com a vantagem de ser estatisticamente testável. O índice Kappa pode ser calculado de acordo com a Equação (14), sendo  $Pr(a)$  a concordância relativa observada entre taxas (nesse caso, trata-se da própria taxa de acertos) e  $Pr(e)$  a concordância esperada (VIERA; GARRETT, 2005).

$$\kappa = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (14)$$

O cálculo de  $Pr(a)$  e  $Pr(e)$  ocorre de acordo com as Equações (15) e (16), respectivamente. A Tabela 11 exibe um exemplo de matriz de confusão com as variáveis necessárias, sendo  $m_1 = a + b$ ,  $m_0 = c + d$ ,  $n_1 = a + c$ ,  $n_0 = b + d$  e  $n = m_1 + m_0 = n_1 + n_0$ .

$$Pr(a) = (a + d)/n \quad (15)$$

$$Pr(e) = [(n_1/n) * (m_1/n)] + [(n_0/n) * (m_0/n)] \quad (16)$$

**Tabela 11 – Matriz de confusão 2x2 genérica.**

	Sim	Não	Total
Sim	a	b	$m_1$
Não	c	d	$m_0$
Total	$n_1$	$n_0$	$n$

Quanto mais próximo de 1 for o resultado da Equação (14), mais confiável é o resultado. Além disso, Landis e Koch (1977) sugerem a interpretação de acordo com a Tabela 12.

**Tabela 12 – Interpretação dos valores do índice Kappa.**

Valores de Kappa	Interpretação
0	Sem concordância
0 - 0,19	Concordância baixa
0,20 - 0,39	Concordância regular
0,40 - 0,59	Concordância moderada
0,60 - 0,79	Concordância alta
0,80 - 1,00	Concordância quase perfeita

Verifica-se que o índice Kappa complementa a informação dada pela taxa média de acertos, haja vista que essa porcentagem não basta para descrever a acurácia da classificação apresentada.

Nesse primeiro momento, são avaliados os resultados alcançados pelas redes considerado treinamentos realizados com apenas determinado nível de curto-circuito (estrato por nível de falha). A Tabela 13 é referente aos motores operando com falha na ordem de 7% (MIT 1) e 10% (MIT 2 e 3) das espiras de estator curto-circuitadas. Considerando os MIT 1 e 3, observa-se que as redes, no geral, obtiveram resultados satisfatórios, como

já era esperado, pois um curto-circuito dessa magnitude já é capaz de provocar alterações significativas na forma de onda, de acordo com a análise efetuada na Seção 4.4 e com a Figura 33. Ao contrário, para o MIT 2, as redes não foram capazes de alcançar o mesmo nível de acertos. A confiabilidade dos resultados, expressa pelo índice Kappa, é considerada satisfatória para os MIT 1 e 3, contudo, os resultados obtidos para o MIT 2 mostram-se pouco confiáveis.

A Tabela 14 exhibe a matriz de confusão para o experimento com maior taxa de acertos do conjunto de testes. Verifica-se que, neste caso, ocorreu apenas 1 erro de classificação, na qual uma amostra com falha foi julgada pela rede como sendo sem falha. Ou seja, trata-se de um falso negativo.

**Tabela 13 – Resultados de validação, para amostras com 7% e 10% de curto-circuito.**

rede	Performance de classificação					
	MIT 1 (7%)		MIT 2 (10%)		MIT 3 (10%)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	92,83%	0,856	68,08%	0,361	97,33%	0,993
2	91,91%	0,838	68,00%	0,360	96,58%	0,971
3	90,33%	0,807	68,83%	0,377	93,33%	0,867
4	93,33%	0,867	68,25%	0,365	96,75%	0,975

**Tabela 14 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 13.**

	Classificado como:	
	Sem falha	c.c. de 10%
Sem falha	60	0
c.c. de 10%	1	59

As Tabelas 15 e 17 avaliam o desempenho das topologias para o caso de 5% e 3% das espiras curto-circuitadas, respectivamente. Verifica-se o gradual decaimento do desempenho das redes, as quais mantêm taxas de acerto semelhantes. Em ambos os casos, os dados provenientes do MIT 1 obtiveram melhor resultado, tanto para a taxa de acertos quanto para o índice Kappa, o qual evidenciou o quão baixo é o grau de confiabilidade dos classificadores, principalmente, para os MIT 2 e 3. Com a diminuição do nível da falha é compreensível que se torne mais complexa a tarefa de separação entre as duas classes, pois as características típicas da falha se tornam cada vez mais inexpressivas.

A Tabela 16 exhibe a matriz de confusão relativa à Tabela 15. Verifica-se que, na classificação que demonstrou melhor desempenho, ocorreram 14 erros de julgamento, sendo quatro falsos negativos e 10 falsos positivos. A Tabela 18 exhibe a matriz de confusão relativa à Tabela 17, exibindo 40 erros de validação, nos quais 10 são falsos negativos e 30 são falsos positivos.

É oportuno ressaltar que, dentre os dois tipos de erro mencionados, o mais grave é o falso negativo, haja vista que, nessa condição, o sistema de detecção de falha indicaria

que o motor está funcionando normalmente mesmo diante de uma falha. No caso de um falso positivo, o único inconveniente seria o transtorno provocado pelo alarme falso. Ainda assim, um sistema de detecção de falha que a todo momento sinaliza um falso alarme teria pouca ou nenhuma confiabilidade no ambiente industrial.

**Tabela 15 – Resultados de validação, para amostras com 5% de curto-circuito.**

		Performance de classificação					
		MIT 1		MIT 2		MIT 3	
		Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
rede							
1	88,50%	0,770	55,67%	0,113	56,25%	0,125	
2	87,83%	0,757	58,17%	0,163	56,67%	0,133	
3	88,75%	0,775	58,08%	0,161	56,67%	0,130	
4	88,67%	0,773	55,50%	0,110	56,17%	0,123	

**Tabela 16 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 15.**

		Classificado como:	
		Sem falha	c.c. de 5%
Sem falha	50	10	
c.c. de 5%	4	56	

**Tabela 17 – Resultados de validação, para amostras com 3% de curto-circuito.**

		Performance de classificação					
		MIT 1		MIT 2		MIT 3	
		Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
rede							
1	67,44%	0,373	48,67%	0,027	45,17%	0,097	
2	67,25%	0,345	46,92%	0,061	46,75%	0,065	
3	68,67%	0,373	41,17%	0,170	45,75%	0,085	
4	68,33%	0,367	44,75%	0,105	46,75%	0,065	

**Tabela 18 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 17.**

		Classificado como:	
		Sem falha	c.c. de 3%
Sem falha	30	30	
c.c. de 3%	10	50	

Na Tabela 19 são encontrados os resultados referentes ao motor operando com falha na ordem de 1% das espiras de estator curto-circuitadas. Constata-se uma diminuição acentuada na taxa de acerto de todas as topologias, quando comparadas aos ensaios



anteriores. Novamente, nenhuma das redes apresenta um desempenho que se sobressai entre as demais. A estatística Kappa indica que nenhum dos resultados obtidos nesse experimento são confiáveis. Além disso, percebeu-se que, durante os ensaios, o grau de precisão alcançado ficou aquém daquele pré-estabelecido. A matriz de confusão, Tabela 20, exibe 25 falsos negativos e 29 falsos positivos.

**Tabela 19 – Resultados de validação, para amostras com 1% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	32,33%	0,353	47,08%	0,056	39,67%	0,207
2	33,50%	0,330	50,67%	0,013	41,25%	0,175
3	37,83%	0,250	54,33%	0,086	40,83%	0,133
4	37,25%	0,255	48,67%	0,027	43,33%	0,133

**Tabela 20 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 19.**

	Classificado como:	
	Sem falha	c.c. de 1%
Sem falha	31	29
c.c. de 1%	25	35

Apesar de conseguir alguns bons resultados, acima de 90% em alguns casos, após a análise realizada conclui-se que a utilização do valor RMS das componentes C(8,6) e C(8,8) apenas não possibilitou para as topologias testadas a convergência para resultados corretos quando o curto-circuito é provocado por menos de 5% das espiras estáticas curto-circuitadas. Na seção seguinte a análise é refeita com número maior de coeficientes, a fim de comparação.

#### 5.1.2 RMS das componentes 2, 4, 6, 8, 14 e 16 como entradas

Esta subseção contempla os experimentos nos quais foram utilizados os valores RMS das componentes reconstruídas C(8,2), C(8,4), C(8,6), C(8,8), C(8,14) e C(8,16). Lembra-se que somente as componentes 6 e 8 demonstraram ligação direta com o curto-circuito, contudo, as demais componentes se mostraram úteis para diferenciar situações de desequilíbrio e carregamento (conforme descrito na Seção 4.2). Dessa forma, a Equação (17) exemplifica a organização dos termos em um vetor genérico  $X^{(k)}$  que constitui o

conjunto de entrada para a rede.

$$X^{(k)} = \begin{bmatrix} RMS(C_{8,2}) \\ RMS(C_{8,4}) \\ RMS(C_{8,6}) \\ RMS(C_{8,8}) \\ RMS(C_{8,14}) \\ RMS(C_{8,16}) \end{bmatrix} \quad (17)$$

Não é possível, nesse caso, ilustrar como as amostras estão distribuídas no espaço, tal qual observado na Figura 33. Isso se deve ao fato de que o vetor de entradas agora é da ordem  $6 \times 1$ , sendo assim, seriam necessárias seis dimensões para contemplar todas as seis coordenadas de cada vetor, e, desse modo, representar a distribuição das amostras. As topologias utilizadas nessa subseção são exatamente as mesmas da subseção anterior. Os resultados obtidos são conferidos a seguir, nos quais são consideradas intensidades de curto-circuito de 10%, 7%, 5%, 3% e 1%.

A Tabela 21 expõe o diagnóstico realizado quando da utilização de apenas as amostras com 7% e 10% de espiras curto-circuitadas. Percebe-se que nenhuma das redes analisadas teve dificuldade para classificar as amostras, exibindo uma taxa média de acertos próxima de 100%. O índice Kappa revela que as elevadas taxas de acerto não foram atingidas por acaso, pois seu valor é próximo da unidade. A matriz de confusão, Tabela 22, mostra que a melhor classificação exibiu 1 falso positivo.

**Tabela 21 – Resultados de validação, para amostras com 7% e 10% de curto-circuito.**

rede	Performance de classificação					
	MIT 1 (7%)		MIT 2 (10%)		MIT 3 (10%)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	97,67%	0,903	98,67%	0,973	99,80%	0,991
2	98,41%	0,928	97,08%	0,941	98,58%	0,971
3	99,33%	0,950	96,86%	0,936	98,95%	0,979
4	99,25%	0,985	99,33%	0,986	97,75%	0,955

**Tabela 22 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 21.**

	Classificado como:	
	Sem falha	c.c. de 1%
Sem falha	59	10
c.c. de 10%	0	60

Na Tabela 23 são encontrados os resultados de validação referentes ao motor operando com falha na ordem de 5% de intensidade. Percebe-se que as redes atingiram um melhor desempenho para classificar os sinais do MIT 1, sendo que a rede 2 quase atinge 90% de acerto. Contudo, para os demais MIT os desempenhos não foram tão

satisfatórios, destacando a rede 4, para o MIT 3, que atingiu a pior taxa de acertos nesse experimento, não chegando a 70%. A confiabilidade dos resultados, no geral, é moderada.

Mesmo diante de uma menor taxa média de acertos, houve pelo menos uma classificação ótima, apresentada na Tabela 24. Como no experimento anterior, apresenta-se apenas 1 falso positivo.

No caso de 3% de espiras curto-circuitadas, Tabela 25, as redes, no geral, foram mais imprecisas, apresentando taxas de acerto variando entre 60 e 70%. A estatística Kappa reflete a incerteza apresentada pelos resultados obtidos.

A matriz de confusão, observada na Figura 26, mostra que não houve nenhum falso negativo, contudo, houveram 35 falsos positivos.

**Tabela 23 – Resultados de validação, para amostras com 5% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	81,67%	0,638	76,66%	0,448	70,20%	0,404
2	89,79%	0,795	74,37%	0,478	78,12%	0,562
3	86,41%	0,728	76,75%	0,525	77,50%	0,550
4	84,79%	0,683	72,08%	0,441	68,95%	0,374

**Tabela 24 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 23.**

	Classificado como:	
	Sem falha	c.c. de 5%
Sem falha	59	1
c.c. de 5%	0	60

**Tabela 25 – Resultados de validação, para amostras com 3% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	67,29%	0,320	57,91%	0,158	66,67%	0,333
2	66,83%	0,316	60,20%	0,204	69,37%	0,383
3	66,04%	0,316	60,62%	0,212	63,12%	0,262
4	67,08%	0,333	60,83%	0,216	63,54%	0,270

**Tabela 26 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 25.**

	Classificado como:	
	Sem falha	c.c. de 3%
Sem falha	25	35
c.c. de 3%	0	60

Em relação ao experimento com 1% de espiras curto-circuitadas, Tabela 27, verifica-se que as taxas de acertos estão um pouco melhor se comparadas ao mesmo experimento da seção anterior. Destaca-se que, inesperadamente, a taxa de acerto das redes para o MIT 3 supera os valores da Tabela 25, apresentando melhores resultados para esse grau de curto-circuito.

A matriz de confusão, Figura 28, apresenta somente dois falsos positivos. Esse resultado ilustra o quão importante é não tomar conclusões baseado apenas na maior taxa de acertos alcançada. O resultado excelente exibido pela matriz de confusão não reflete ou sintetiza todo o experimento.

**Tabela 27 – Resultados de validação, para amostras com 1% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	48,54%	0,029	41,04%	0,337	79,79%	0,679
2	53,54%	0,070	34,87%	0,262	71,87%	0,671
3	41,67%	0,167	33,58%	0,208	82,29%	0,645
4	47,08%	0,058	37,58%	0,208	85,83%	0,716

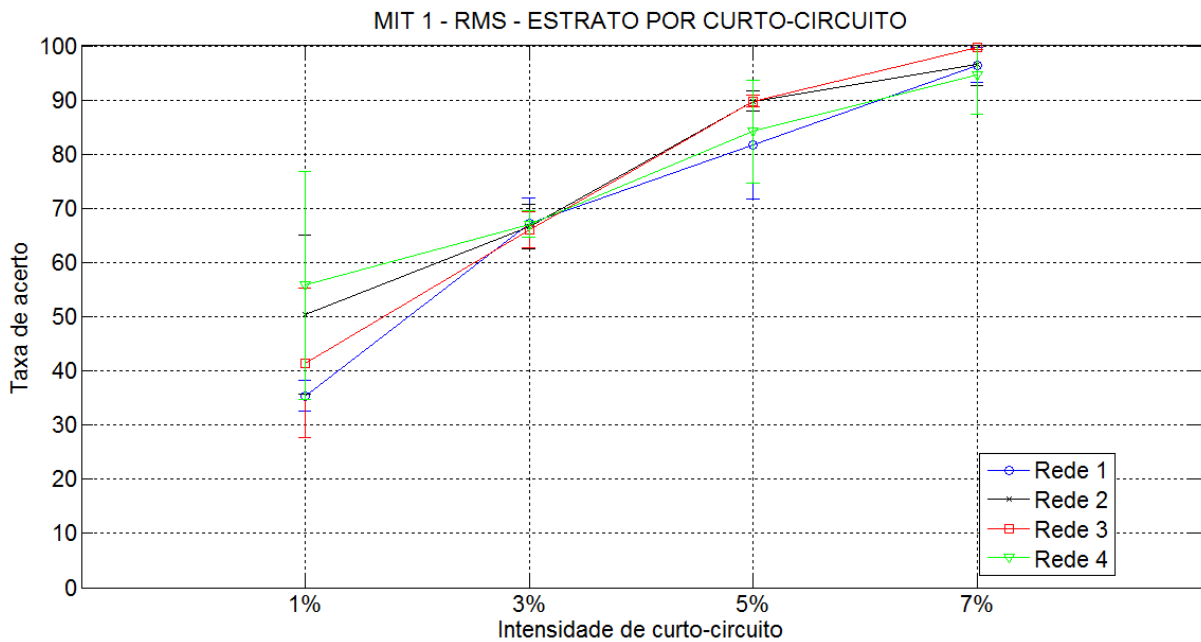
**Tabela 28 – Matriz de confusão para o experimento com maior taxa de acertos da Tabela 27.**

	Classificado como:	
	Sem falha	c.c. de 1%
Sem falha	58	2
c.c. de 1%	0	60

As Figuras 34, 35 e 36 resumem as informações apresentadas nessa seção à respeito da taxa média de acerto para as 4 redes averiguadas. Além disso, apresenta também o desvio padrão das medidas realizadas para cada caso.

Na Figura 34, relativa ao MIT 1, os experimentos com 1% apresentam desvio padrão maior do que com as demais intensidades de curto-circuito, principalmente a rede 4. Considerando 5% de curto-circuito, percebe-se que a dispersão dos dados em torno da média tende a ser menor, e, por fim, com 1% e 7% os dados tendem a se concentrar ainda mais em torno da média.

Para o MIT 2, Figura 35, o desvio padrão para 1% e 3% de intensidade de curto-circuito são bastante semelhantes, assim como para 5% e 10%. Tal qual aconteceu com as




**Figura 34 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por curto-circuito.**

**Fonte: Autoria própria**

taxas de acerto do MIT 1, a tendência é melhora no desempenho das redes na proporção do aumento da intensidade de curto-circuito.


Pode-se concluir que nenhuma das redes mostrou um desempenho global evidentemente superior às demais.

Na Figura 36, referente ao MIT 3, percebe-se que as taxas de acerto seguem a mesma tendência, com exceção das amostras com 1% de curto-circuito, para as quais as redes apresentam taxa de acerto superior ao esperado.



**Figura 35 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por curto-circuito.**

**Fonte: Autoria própria**



**Figura 36 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por curto-circuito.**

**Fonte: Autoria própria**

O melhor desempenho das redes quando usadas como entradas as componentes  $C(8,2)$ ,  $C(8,4)$ ,  $C(8,6)$ ,  $C(8,8)$ ,  $C(8,14)$  e  $C(8,16)$  da decomposição *wavelet* confirmou que é imprescindível a utilização de um número maior de componentes. Portanto, os testes realizados de agora em diante contemplam a utilização dessas componentes da decomposição.

Nos experimentos seguintes, as amostras foram separadas em função da intensidade de desequilíbrio das tensões entre fases, considerando todos os níveis de curto-circuito em cada experimento. Dessa forma é possível avaliar o quanto a taxa de desequilíbrio afeta a classificação das redes.

Primeiramente, foram utilizadas somente amostras sem desequilíbrio (desequilíbrio inferior à 0,5%). Para o treinamento, foram utilizadas 22 amostras sem falha mais 22 amostras para cada nível de curto, totalizando, para o MIT 1, 110 amostras para treinamento, e, para os MIT 2 e MIT 3, 154. Para validação foi utilizado um total 30 amostras para o MIT 1 e 42 para os MITS 2 e 3 (6 amostras para cada nível de curto-circuito), conforme Tabela 29.

A Tabela 30 exhibe a taxa média de acertos e o índice Kappa para as redes considerando as amostras de todos os níveis de curto-circuito referentes a cada motor e desequilíbrio entre fases praticamente nulo. No geral, verifica-se que a taxa de acertos para todas as redes, em cada motor, se manteve semelhante, permanecendo entre 75% e 87%. Já o grau de confiabilidade exibiu valores entre 0,5 e 0,7, indicando uma incerteza moderada nos resultados obtidos. O melhor resultado foi obtido pela rede 1 com amostras referentes ao MIT 3.

A matriz de confusão para o ensaio que apresentou melhor desempenho indica 8 falsos positivos, dentre 42 amostras validadas, de acordo com a Tabela 31.

**Tabela 29 – Organização de amostras de treinamento e validação para os testes sem desequilíbrio de tensão.**

	Número de Amostras		Total
	Treinamento ( $X_T$ )	Validação ( $X_V$ )	
MIT 1	110	30	140
MIT 2	154	42	196
MIT 3	154	42	196
Total	418	104	522

**Tabela 30 – Resultados de validação para amostras com curto-circuito de até 7%, MIT 1, e 20%, MITs 2 e 3, amostras sem desequilíbrio.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	83,33%	0,467	79,17%	0,383	86,90%	0,502
2	84,16%	0,450	75,00%	0,400	79,76%	0,469
3	80,83%	0,416	76,19%	0,323	77,38%	0,413
4	80,00%	0,505	75,59%	0,411	84,52%	0,511

**Tabela 31 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 30.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	6	0
c.c. de até 20%	8	28

Tabela 32 mostra a organização das amostras para desequilíbrios de até 2%. Para o treinamento, foram utilizadas 44 amostras sem falha mais 44 amostras para cada determinado nível de curto, totalizando, para o MIT 1, 220 amostras para treinamento, e, para os MIT 2 e MIT 3, 308. Para validação foi utilizado um total 60 amostras para o MIT 1 e 84 para os MITS 2 e 3 (12 amostras para cada nível de curto circuito). Para melhor entendimento, observe as Tabelas 13 e 14.

A Tabela 33 exhibe o desempenho das redes considerando desequilíbrios de até 2%. À primeira vista, os resultados são semelhantes aos do experimento anterior. Contudo, percebe-se uma pequena melhora na taxa de acerto e no índice de confiabilidade. Entende-se que o maior número de amostras favoreceu o aprendizado das redes. A matriz de confusão, Tabela 34, exhibe 6 falsos positivos e 5 falsos negativos, de um total de 84 amostras.



**Tabela 32 – Organização de amostras de treinamento e validação para os testes com desequilíbrio de tensão de até 2%.**

	Número de Amostras		Total
	Treinamento ( $X_T$ )	Validação ( $X_V$ )	
MIT 1	220	60	280
MIT 2	308	84	392
MIT 3	308	84	392
Total	836	228	1064

**Tabela 33 – Resultados de validação, para amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 2%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	75,83%	0,317	80,05%	0,401	86,90%	0,638
2	82,58%	0,450	79,17%	0,383	84,82%	0,596
3	79,16%	0,483	79,16%	0,383	85,11%	0,502
4	82,50%	0,441	79,76%	0,495	86,01%	0,520

**Tabela 34 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 33.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	6	6
c.c. de até 20%	5	67

O seguinte experimento considera desequilíbrios de até 4%. De acordo com a Tabela 35, foram utilizadas 66 amostras sem falha mais 66 amostras para cada determinado nível de curto, totalizando, para o MIT 1, 330 amostras para treinamento, e, para os MIT 2 e 3, 462. Para validação foi utilizado um total 90 amostras para o MIT 1 e 126 para os MIT 2 e 3 (18 amostras para cada nível de curto circuito).

**Tabela 35 – Organização de amostras de treinamento e validação para os testes com desequilíbrio de até 4%.**

	Número de Amostras		Total
	Treinamento ( $X_T$ )	Validação ( $X_V$ )	
MIT 1	330	90	420
MIT 2	462	126	588
MIT 3	462	126	588
Total	1254	342	1596

A Tabela 36 mostra o desempenho das redes perante desequilíbrios de até 4%. Observa-se que, em comparação ao experimento anterior, em alguns casos, a taxa de acerto melhorou, e, em outros casos diminuiu. O mesmo pode ser dito em relação ao índice Kappa. Contudo, no geral, as alterações não foram muito relevantes.

A matriz de confusão, Tabela 37, exhibe 5 falsos positivos e 2 falsos negativos, dentre 126 amostras.


**Tabela 36 – Resultados de validação, para amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 4%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	78,33%	0,567	74,60%	0,444	89,88%	0,765
2	80,00%	0,600	74,80%	0,484	86,51%	0,710
3	76,11%	0,494	75,19%	0,503	88,69%	0,765
4	78,61%	0,572	72,02%	0,440	86,50%	0,686

**Tabela 37 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 36.**


	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	16	2
c.c. de até 20%	5	103

As Figuras 37, 38 e 39 ilustram, para os MIT 1, 2 e 3, respectivamente, os experimentos desta seção resumidamente. Na figura referente ao MIT 3, percebe-se que as redes atingiram um patamar um pouco mais elevado que para os demais motores. Percebe-se, ainda, que a taxa de acertos se mantém praticamente constante, independente da intensidade de desequilíbrio à que os motores foram submetidos. Isso se explica pelo estudo realizado no Capítulo 4, no qual foi concluído que o desequilíbrio afetava fracamente as componentes estudadas.



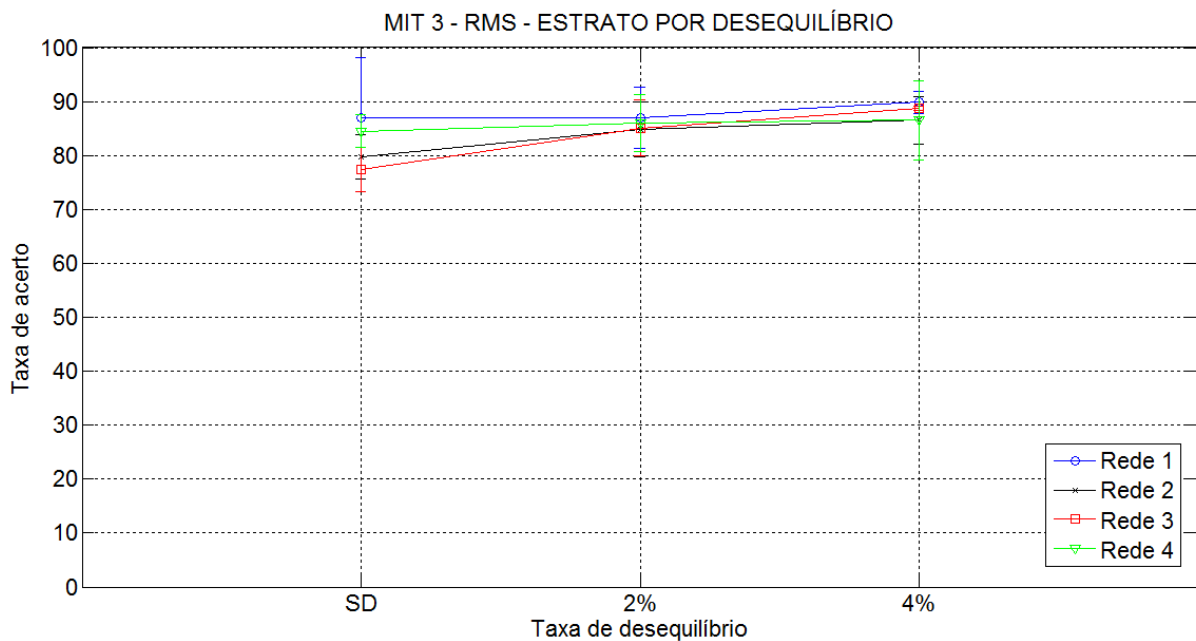
**Figura 37 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por desequilíbrio entre fases.**

Fonte: Autoria própria



**Figura 38 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por desequilíbrio entre fases.**

Fonte: Autoria própria



**Figura 39 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por desequilíbrio entre fases.**

Fonte: Autoria própria

### 5.1.3 Classificação utilizando Potência de Previsão

Esta seção se dedica a experimentos de classificação utilizando como entradas os coeficientes de Potência de Previsão referentes às componentes *wavelets*  $C(8,2)$ ,  $C(8,4)$ ,  $C(8,6)$ ,  $C(8,8)$ ,  $C(8,14)$  e  $C(8,16)$ , conforme Equação (18). Como realizado na subseção anterior, são promovidos experimentos com amostras estratificadas por de curto-circuito, bem como amostras estratificadas por intensidade de desequilíbrio entre fases da alimentação.

$$X^{(k)} = \begin{bmatrix} PP(C_{8,2}) \\ PP(C_{8,4}) \\ PP(C_{8,6}) \\ PP(C_{8,8}) \\ PP(C_{8,14}) \\ PP(C_{8,16}) \end{bmatrix} \quad (18)$$

A Tabela 38 compreende os resultados obtidos para as amostras de 7% e 10% das espiras curto-circuitadas, conforme o MIT analisado. Observa-se que taxa de acerto e o índice Kappa próximos da unidade, sendo semelhantes àqueles exibidos para o mesmo teste quando utilizado a medida RMS como entrada (Figura 21).

A matriz de confusão referente ao melhor desempenho deste experimento, Figura 39, exibe apenas um falso positivo.

**Tabela 38 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 7% e 10% das espiras.**

rede	Performance de classificação					
	MIT 1 (7% de c.c.)		MIT 2 (10% de c.c.)		MIT 3 (10% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	97,29%	0,945	95,00%	0,910	98,33%	0,967
2	97,91%	0,958	99,37%	0,987	96,25%	0,925
3	96,46%	0,929	98,95%	0,979	98,12%	0,962
4	95,00%	0,900	97,91%	0,953	97,73%	0,956

**Tabela 39 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 38.**

	Classificado como:	
	Sem falha	c.c. de 10%
Sem falha	60	0
c.c. de 10%	1	59

A Tabela 40 apresenta os resultados para as amostras com 5% das espiras curto-circuitadas. Observa-se que as redes obtiveram melhor desempenho para as amostras do MIT 1, cuja taxa de acerto se manteve acima de 90%, tal qual o índice Kappa. Já para os MIT 2 e 3, a taxa de acertos se manteve entre 80% e 90%, com índice Kappa em torno de 0,7. Destaca-se um aumento no desempenho geral das redes quando comparado ao mesmo experimento utilizando medidas RMS, observado na Figura 23. Novamente, nenhuma das redes se sobressaiu dentre as demais.

**Tabela 40 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 5% das espiras.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	93,54%	0,879	85,00%	0,700	83,54%	0,670
2	93,95%	0,867	82,91%	0,658	85,00%	0,700
3	95,00%	0,900	80,41%	0,608	89,58%	0,791
4	96,67%	0,933	75,62%	0,512	82,70%	0,651

Observa-se na matriz de confusão referente ao ensaio, Tabela 41, que houve apenas 7 erros de classificação, entre 120, sendo todos falsos positivos.

Considerando 3% de espiras curto-circuitadas, a Tabela 42 exibe a taxa média de acerto e o índice Kappa de todas as 4 redes testadas. Como verificado para o experimento com 5% de curto-circuito, o desempenho utilizando PP se mostra superior quando comparado àquele obtido com os valores RMS. Verifica-se, mais uma vez, as amostras do MIT 1

**Tabela 41 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 40.**

	Classificado como:	
	Sem falha	c.c. de 5%
Sem falha	53	7
c.c. de 5%	0	60

com taxa de acerto e índice Kappa superiores às demais.

A matriz de confusão para este caso é exibida na Tabela 43. Observa-se que o experimento com melhor taxa de acerto apresentou apenas 4 falsos positivos.

**Tabela 42 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito 3% das espiras.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	82,50%	0,650	80,62%	0,615	77,08%	0,541
2	84,79%	0,695	81,45%	0,629	80,00%	0,600
3	85,00%	0,700	77,08%	0,541	81,45%	0,629
4	89,79%	0,729	75,41%	0,508	78,12%	0,550

**Tabela 43 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 42.**

	Classificado como:	
	Sem falha	c.c. de 3%
Sem falha	56	4
c.c. de 3%	0	60

A Tabela 44 exibe o desempenho das redes quando utilizadas apenas amostras com 1% de curto-circuito. Os resultados obtidos para MIT 3 destoam daqueles obtidos para os demais motores, sendo superior tanto na taxa de acertos quanto no grau de confiabilidade. A matriz de confusão apresenta 5 falsos positivos e 1 falso negativo.

As Figuras 40, 41 e 42 ilustram, para os MIT 1, 2 e 3, respectivamente, o desempenho de cada um dos testes realizados nessa seção.

Para o MIT 1, fica claro que a taxa de acertos aumenta, enquanto que o desvio padrão reduz, conforme o curto-circuito se intensifica. Isso significa que, além de aumentar o número de classificações corretas, os experimentos tendem a se concentrar mais próximos de um único ponto, a média, exibindo, dessa forma, resultados mais precisos.


A Figura 41 exibe os resultados do MIT 2. Percebe-se que os resultados obtidos são independentes da rede utilizada, ou seja, uma topologia mais complexa não conseguiu um melhor desempenho.

**Tabela 44 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito 1% das espiras.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	78,75%	0,578	55,00%	0,101	92,50%	0,850
2	75,62%	0,512	52,50%	0,050	90,83%	0,816
3	71,66%	0,433	60,62%	0,212	92,29%	0,845
4	67,29%	0,345	56,67%	0,133	91,87%	0,837

**Tabela 45 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 44.**


	Classificado como:	
	Sem falha	c.c. de 1%
Sem falha	55	5
c.c. de 1%	1	59



**Figura 40 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de curto-circuito utilizando coeficientes PP.**


Fonte: Autoria própria

Para o MIT 3, Figura 42, percebe-se que as redes apresentam taxa de acerto superior ao esperado quando testadas as amostras com 1% de espiras curto-circuitadas, mesmo comportamento observado anteriormente na Figura 36.



**Figura 41 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de curto-circuito utilizando coeficientes PP.**

Fonte: Autoria própria



**Figura 42 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de curto-circuito utilizando coeficientes PP.**

Fonte: Autoria própria



Os resultados apresentados a seguir contemplam os ensaios utilizando as coeficientes de Potência de Previsão e amostras separadas de acordo com a intensidade de desequilíbrio entre as fases da alimentação do MIT.

Para amostras sem desequilíbrio, a Tabela 46 exibe a performance das redes. Destaca-se que as maiores taxas médias de acerto foram alcançadas com as amostras do MIT 3, as quais se mantiveram acima dos 90% para todas as redes. Para as amostras do MIT 2, entretanto, as redes mostraram mais dificuldade na classificação, com taxas de acerto na faixa dos 80%. O grau de confiança indicado pela estatística Kappa se mostra satisfatório para todos os casos, exceto para o MIT 2.

A matriz de confusão da Tabela 47 mostra que, do total de 42 amostras, apenas 1 foi classificada incorretamente, sendo esse um falso negativo.

**Tabela 46 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito de até 7% e 20%, amostras sem desequilíbrio.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	90,01%	0,780	83,92%	0,578	95,83%	0,876
2	87,50%	0,710	77,38%	0,473	92,85%	0,817
3	87,43%	0,656	79,16%	0,496	93,45%	0,829
4	87,51%	0,707	80,35%	0,607	92,85%	0,797

**Tabela 47 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 46.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	6	0
c.c. de até 20%	1	35

Considerando desequilíbrios de até 2% entre fases, os resultados obtidos são exibidos na Tabela 48. Em comparação com o experimento sem desequilíbrio, verifica-se que algumas redes apresentaram melhor desempenho, enquanto outras tiveram reduzidas suas taxas de acerto e índice Kappa. Contudo, no geral, percebe-se pouca mudança.

A matriz de confusão, Tabela 49, apresenta apenas dois falsos positivos na classificação, dentre 60 amostras.

A Tabela 50 apresenta os resultados obtidos para desequilíbrios de até 4%. Em comparação com os ensaios anteriores desta mesma seção, observa-se um melhor desempenho geral das redes, principalmente para os MIT 1 e 2. Entretanto, os valores atingidos não diferem de forma relevante.

Na matriz de confusão podem se observar 3 falsos positivos e 1 falso negativo, de um total de 90 amostras de validação, sendo esse o melhor resultado alcançado neste caso.

**Tabela 48 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 2%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	91,67%	0,837	78,57%	0,571	88,98%	0,779
2	91,67%	0,767	73,21%	0,464	92,55%	0,851
3	90,83%	0,816	75,59%	0,511	91,67%	0,833
4	88,33%	0,760	79,17%	0,529	91,07%	0,821

**Tabela 49 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 48.**

	Classificado como:	
	Sem falha	c.c. de até 7%
Sem falha	10	2
c.c. de até 7%	0	48


**Tabela 50 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito de até 7% e 20%, considerando desequilíbrios de até 4%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	91,67%	0,793	85,71%	0,654	88,49%	0,739
2	94,72%	0,844	82,73%	0,594	90,27%	0,805
3	92,78%	0,835	83,13%	0,618	92,46%	0,819
4	91,38%	0,827	82,14%	0,607	92,06%	0,811

**Tabela 51 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 50.**


	Classificado como:	
	Sem falha	c.c. de até 7%
Sem falha	15	3
c.c. de até 7%	1	71

As Figuras 43, 44 e 45 ilustram os resultados na forma de gráficos, respectivamente, para os MIT 1,2 e 3. Os gráficos obtidos corroboram com as conclusões verificadas na seção 4.4, confirmando que a detecção do curto-circuito é praticamente independente do desequilíbrio.




**Figura 43 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por desequilíbrio utilizando coeficientes PP.**

Fonte: Autoria própria



**Figura 44 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por desequilíbrio utilizando coeficientes PP.**

Fonte: Autoria própria



**Figura 45 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por desequilíbrio utilizando coeficientes PP.**

Fonte: Autoria própria

## 5.2 CLASSIFICAÇÃO UTILIZANDO RADIAL BASIS FUNCTION

Nesta seção, busca-se determinar a viabilidade da utilização da arquitetura RBF para a classificação efetuada na seção anterior. Da mesma forma que a rede PMC, a RBF pode ser empregada para uma grande diversidade de problemas, dentre os quais a classificação de padrões. A estrutura típica de uma RBF pode ser conferida na Figura 46. Nota-se que essa rede é composta apenas de uma camada neural intermediária (escondida), cujas funções de ativação são sempre do tipo gaussiana.

O processo de treinamento da RBF é composto por duas fases distintas. A primeira fase envolve um aprendizado realizado de modo não-supervisionado. O procedimento se inicia calculando-se as distâncias euclidianas entre cada amostra e os pesos sinápticos de cada neurônio na camada escondida. Destaca-se que, para a primeira iteração, atribui-se ao vetor de pesos dos neurônios da camada escondida os valores das primeiras amostras de treinamento. A cada iteração, esses pesos são modificados e deslocam-se para o centro de um grupo de amostras. Esse é o principal objetivo dos neurônios da camada intermediária, ou seja, alocar os centros de suas gaussianas em regiões onde os padrões de entrada tenderão a se agrupar.

A Figura 47 exhibe, como exemplo, a disposição das amostras para um motor normal e com falha de 7%, considerando C(8,6) e C(8,8). De fato, trata-se do mesmo gráfico observado na Figura 33, todavia, na Figura 47, mostra-se dois vetores de pesos posicionados nos centros de cada classe, após o alcance da convergência da fase não-supervisionada de uma topologia RBF com dois neurônios na camada escondida.

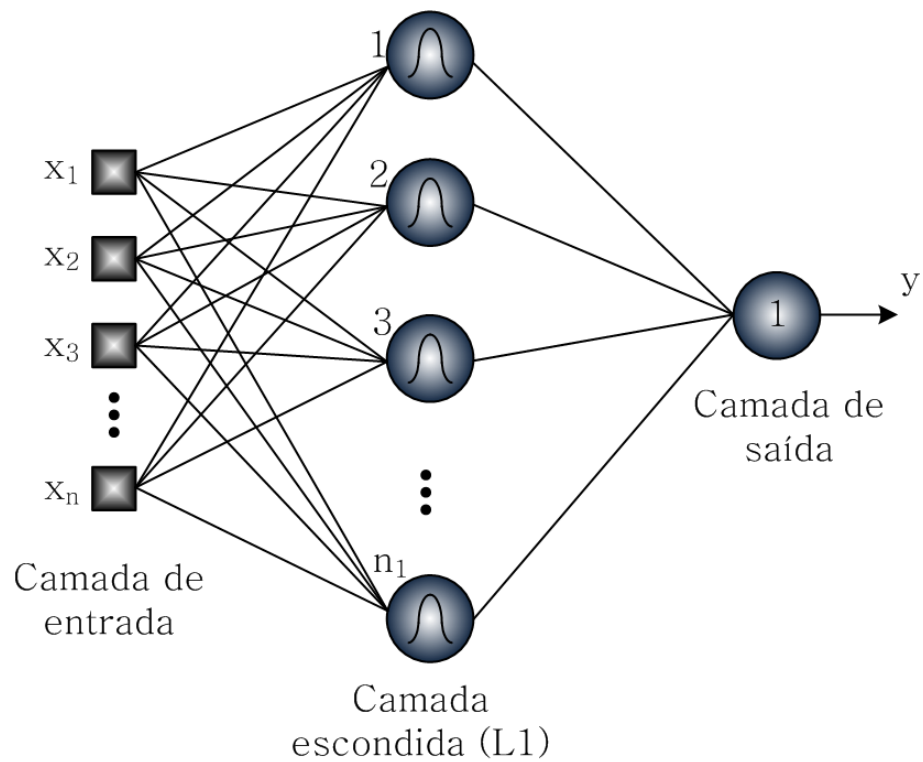


Figura 46 – Arquitetura *Radial Basis Function* (RBF).

Fonte: Adaptado de Silva, Spatti e Flauzino (2010).

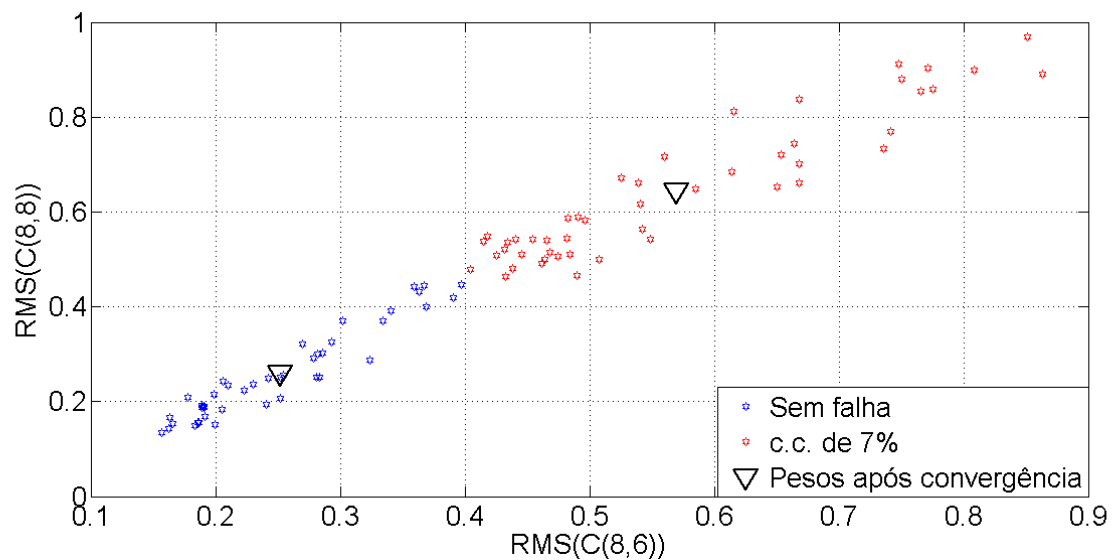


Figura 47 – Disposição do vetor de pesos dos neurônios da camada escondida após convergência para o centro das amostras.

Fonte: Autoria própria.

De acordo com as distâncias euclidianas calculadas, cada amostra será agrupada junto ao centro mais próximo. O algoritmo para assim que não houver mais alterações de amostras entre os grupos para iterações consecutivas. Esse método de clusterização é conhecido como *k-means*. Por fim, calcula-se a variância de cada uma das funções de ativação gaussianas de acordo com a distância média quadrática. Esse valor implicará no raio de abrangência dos campos receptivos hiperesféricos, os quais são responsáveis pela formação das fronteiras de delimitação de classes. A Figura 48 ilustra os campos receptivos radiais produzidos pela função de ativação gaussiana para o caso analisado na Figura 47, bem como a respectiva fronteira de separação de classes.

Verifica-se que, por meio dessa técnica, os dados de entrada são auto-organizados e dependem apenas de suas próprias características para serem agrupados, não possuindo vínculos com a saída desejada. No segundo estágio, entretanto, a aprendizagem se dá de forma supervisionada, utilizando os mesmos procedimentos para a última camada da PMC.

Da mesma forma que ocorre com a *perceptron*, a quantidade de neurônios mais apropriada na camada escondida é uma característica topológica que deve ser especificada por meios empíricos. Para tanto, a estratégia utilizada para determinação da topologia mais adequada consiste na técnica de validação cruzada. As topologias candidatas são discriminadas na Tabela 52. Acrescenta-se que a taxa de precisão requerida é de  $\varepsilon = 10^{-6}$  e que todas as redes possuem apenas 1 neurônio na camada de saída para os experimentos que seguem.

**Tabela 52 – Topologias RBF utilizadas nos experimentos.**

Nº da rede	Nº de neurônios na camada escondida
Rede 1	2
Rede 2	3
Rede 3	4
Rede 4	5
Rede 5	6
Rede 6	7
Rede 7	8

Do mesmo modo como foi realizado na seção anterior, primeiramente serão exibidos experimentos realizados com amostras estratificadas por intensidade de curto-circuito. Nas Tabelas 53 a 59, apresentam-se os resultados referentes às classificações da RBF considerando as medidas RMS das componentes *wavelet* reconstruídas C(8,2), C(8,4), C(8,6), C(8,8), C(8,14) e C(8,16). A organização das amostras para as fases de treinamento e validação seguem o mesmo modelo utilizado para os experimentos com PMC, inclusive a matriz de entradas é estruturada conforme a Equação (17).

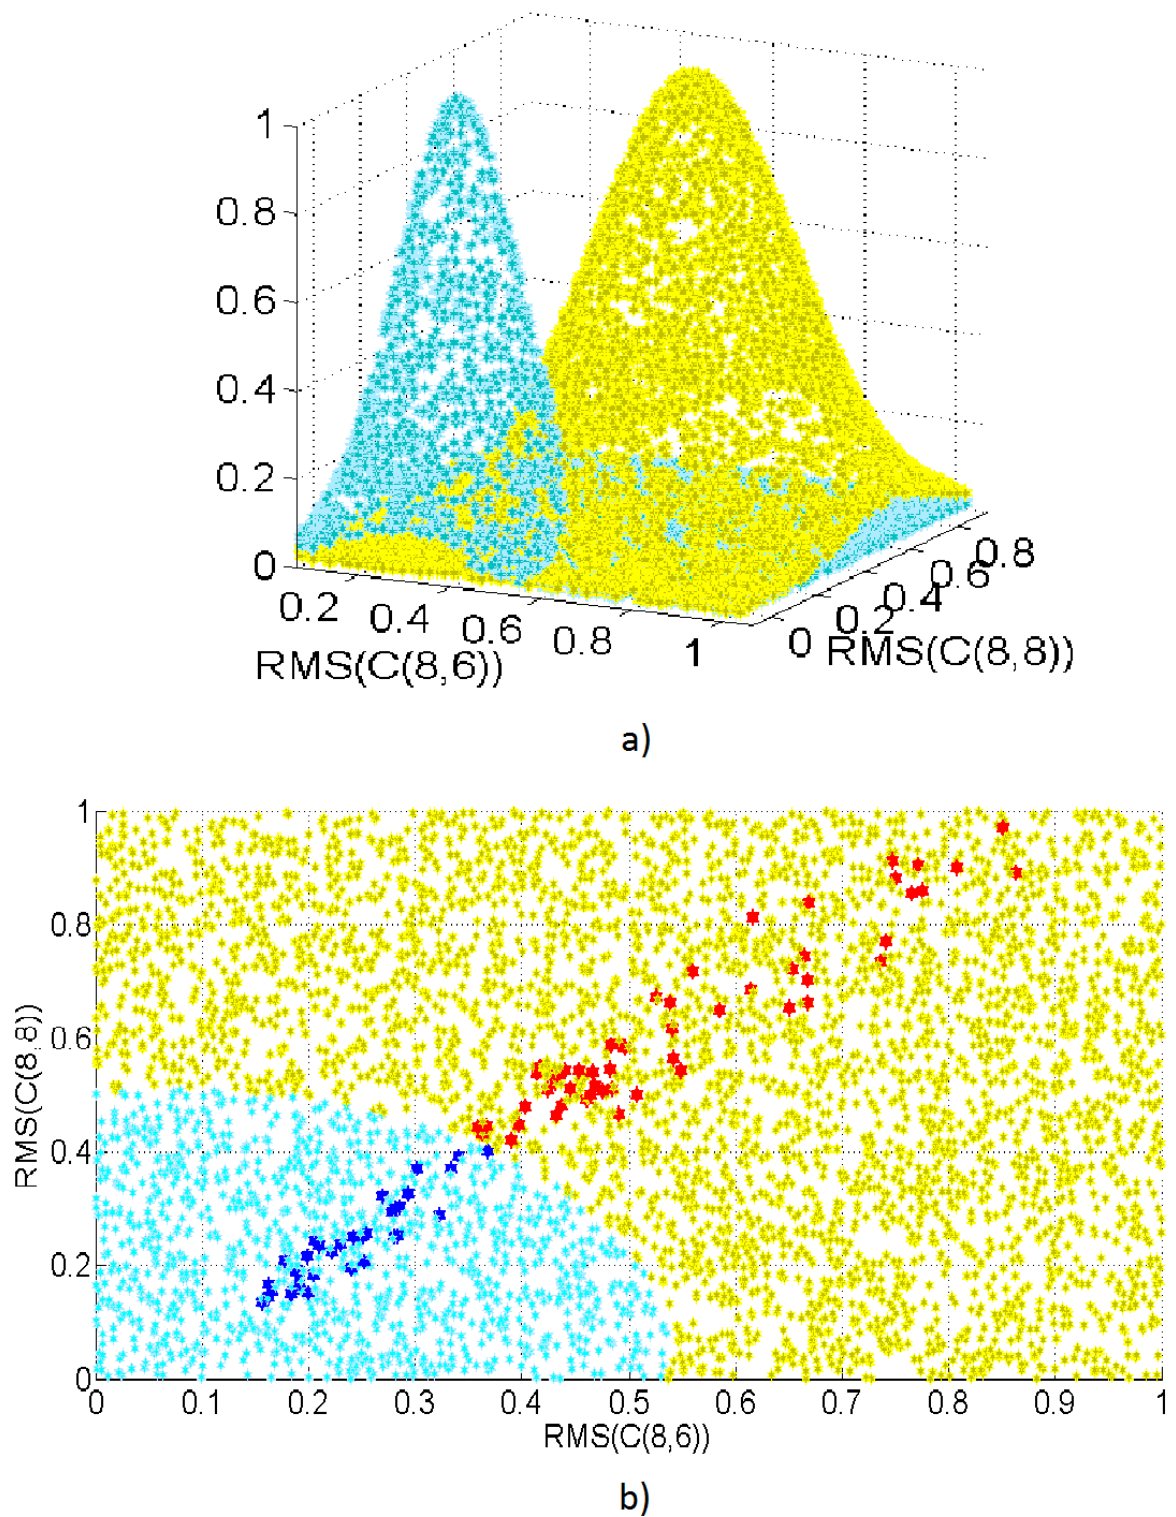


Figura 48 – a) Campos receptivos hiperesféricos referentes aos dois neurônios da camada escondida.  
b) Fronteira delimitadora de separação produzida.

Fonte: Autoria própria.

Os resultados observados na Tabela 53 mostram que o número de neurônios na camada escondida fez diferença para o desempenho das redes diante de amostras com 7% e 10% de espiras curto-circuitadas. Contudo, não foi verificado um padrão, uma vez que, para os MIT 1 e 3, a topologia mais simples, com 2 neurônios, foi aquela que apresentou melhor taxa de acerto e grau de confiabilidade Kappa. Já em relação ao MIT 2, a rede que classificou um maior número de amostras corretamente foi a mais complexa, com 8 neurônios. Destaca-se que os resultados são semelhantes aos encontrados no mesmo experimento com as topologias PMC, Tabela 13, com exceção das amostras com MIT 2, as quais mostraram melhor resultado com a arquitetura RBF.

**Tabela 53 – Resultados de validação, para amostras com 7% e 10% de curto-circuito.**

rede	Performance de classificação					
	MIT 1 (7%)		MIT 2 (10%)		MIT 3 (10%)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	92,50%	0,850	70,83%	0,416	99,33%	0,986
2	84,77%	0,695	86,22%	0,724	89,44%	0,788
3	82,11%	0,642	83,38%	0,667	84,83%	0,696
4	80,94%	0,618	89,11%	0,783	78,89%	0,577
5	81,27%	0,625	89,22%	0,783	88,27%	0,765
6	81,00%	0,862	89,16%	0,783	83,33%	0,667
7	81,33%	0,626	94,38%	0,887	77,17%	0,543

A Tabela 54 mostra a matriz de confusão para o melhor resultado obtido no experimento. Observa-se que a matriz exhibe apenas um falso positivo e nenhum falso negativo.

**Tabela 54 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 53.**

	Classificado como:	
	Sem falha	c.c. de 10%
Sem falha	59	1
c.c. de 10%	0	60

A Tabela 55 apresenta a taxa de acerto médio e o Índice Kappa para amostras com 5% de intensidade de curto-circuito. Observa-se que os dados do MIT 1 atingiram melhores desempenhos nesse caso. Os MIT 3 e 2 tiveram suas taxas médias de acerto substancialmente reduzidas, principalmente esse último. Além disso, o Índice Kappa revela que somente a Rede 1 conseguiu atingir patamares satisfatórios de confiabilidade nos seus resultados. Tal qual ocorreu no experimento anterior, na Tabela 56 verifica-se apenas um erro de classificação, sendo esse um falso positivo.



**Tabela 55 – Resultados de validação, para amostras com 5% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	92,75%	0,855	50,00%	0,010	73,48%	0,469
2	84,17%	0,683	50,83%	0,016	75,75%	0,515
3	84,17%	0,683	60,83%	0,216	71,96%	0,439
4	84,58%	0,711	55,25%	0,105	61,89%	0,237
5	86,25%	0,725	64,91%	0,298	62,45%	0,240
6	77,75%	0,555	69,75%	0,395	58,63%	0,172
7	77,91%	0,558	52,75%	0,055	57,57%	0,151

**Tabela 56 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 55.**

	Classificado como:	
	Sem falha	c.c. de 5%
Sem falha	59	1
c.c. de 5%	0	60

A exemplo do experimento com 5% de curto-circuito, o experimento com 3%, Figura 57 mostra que o MIT 1 obteve melhor desempenho em comparação aos demais, sendo a Rede 1 aquela que teve mais classificações corretas. Ainda assim, nota-se que o grau de confiabilidade de todos os testes não atingem níveis elevados. A Tabela 58 exibe a matriz de confusão, com vários erros de classificação, dos quais 20 são falsos positivos e 29 falsos negativos.

**Tabela 57 – Resultados de validação, para amostras com 3% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	80,00%	0,540	50,00%	0,000	50,00%	0,00
2	76,08%	0,521	50,00%	0,016	50,00%	0,00
3	77,00%	0,540	50,83%	0,016	53,33%	0,066
4	76,00%	0,520	53,67%	0,073	45,25%	0,095
5	75,25%	0,505	55,33%	0,106	48,41%	0,240
6	75,25%	0,505	47,58%	0,048	47,91%	0,041
7	72,00%	0,440	52,16%	0,043	52,25%	0,045

**Tabela 58 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 57.**

	Classificado como:	
	Sem falha	c.c. de 3%
Sem falha	40	20
c.c. de 3%	29	31

Na Tabela 59, exibem-se os resultados considerando 1% de curto-circuito. Verifica-se que nenhuma das redes apresentou taxa média de acertos superior a 55% e graus de confiabilidade muito próximos de zero. Conclui-se que a RBF não conseguiu para detectar a falha nesse nível de intensidade.


Dessa forma, pode-se dizer que alguns resultados obtidos utilizando a arquitetura RBF não se mostraram distantes daqueles encontrados com a PMC, contudo, o desempenho geral da RBF manteve-se inferior.

**Tabela 59 – Resultados de validação, para amostras com 1% de curto-circuito.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	47,50%	0,050	49,17%	0,017	48,25%	0,035
2	49,58%	0,008	54,25%	0,085	46,33%	0,073
3	45,00%	0,100	47,75%	0,045	45,17%	0,096
4	48,50%	0,030	53,67%	0,073	45,75%	0,085
5	46,66%	0,067	53,67%	0,073	45,41%	0,091
6	53,33%	0,066	54,08%	0,081	45,33%	0,083
7	46,08%	0,078	50,91%	0,018	45,33%	0,093


As Figuras 49, 50 e 51 ilustram os resultados obtidos nos experimentos acima mencionados, referentes aos MIT 1, 2 e 3, respectivamente.

Observa-se que, para o MIT 1, o desempenho das redes foram mais elevados para as intensidades de curto-circuito de 3% e 5%. Percebe-se que, para o MIT 2 e MIT 3, os resultados se mantêm entre 50% e 60% de acerto, exceto para o grau de curto-circuito de 10%. Além disso, todas as redes seguiram a mesma tendência e apresentaram resultados bastante concentrados em torno da média, haja vista o baixo valor de desvio padrão demonstrado nas figuras.




**Figura 49 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de curto-circuito utilizando RMS.**

Fonte: Autoria própria



**Figura 50 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de curto-circuito utilizando RMS.**

Fonte: Autoria própria



**Figura 51 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de curto-circuito utilizando RMS.**

Fonte: Autoria própria

Nas Tabelas 60 até 64, exibem-se os resultados de validação para amostras estratificadas por grau de desequilíbrio entre fases da alimentação. As amostras para treinamento e validação foram estruturadas da forma exibida nas Tabelas 29, 32 e 35.

Diante dos valores exibidos na Tabela 60, amostras sem desequilíbrio, percebe-se que, no geral, a taxa de acerto e o Índice Kappa mantiveram-se praticamente no mesmo patamar para todos os casos. O valor mínimo verificado foi de 76% de acerto e o máximo de 92% de acerto, com grau de confiabilidade de 0,842. A matriz de confusão, Tabela 61, exibe apenas 3 falsos negativos.

**Tabela 60 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras sem desequilíbrio.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	82,67%	0,623	85,71%	0,664	85,71%	0,664
2	76,67%	0,533	85,71%	0,665	85,71%	0,662
3	83,33%	0,667	85,71%	0,665	85,71%	0,662
4	80,00%	0,600	85,71%	0,664	85,47%	0,669
5	80,60%	0,557	85,00%	0,610	85,71%	0,664
6	83,33%	0,585	87,38%	0,717	85,71%	0,664
7	83,33%	0,585	92,14%	0,752	85,71%	0,705

**Tabela 61 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 60.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	6	0
c.c. de até 20%	3	33

Para desequilíbrios de até 2% de intensidade, Tabela 62, encontram-se taxas de acerto em torno de 85%. A Tabela 63 exibe 3 falsos positivos e 7 falsos negativos, dentre um total de 84 amostras de validação.

**Tabela 62 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 2%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	85,71%	0,614	85,71%	0,614	85,71%	0,614
2	85,72%	0,615	80,50%	0,565	85,71%	0,614
3	84,50%	0,590	85,71%	0,615	85,71%	0,614
4	85,71%	0,614	85,71%	0,614	85,71%	0,614
5	85,00%	0,600	87,61%	0,652	85,71%	0,614
6	80,00%	0,601	88,09%	0,661	86,19%	0,623
7	80,00%	0,500	88,09%	0,661	87,02%	0,640

**Tabela 63 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 62.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	9	3
c.c. de até 20%	7	65

Considerando amostras com até 4% de desequilíbrio, Tabela 64, novamente a taxa média de acertos fica, no geral, na faixa de 85%. Dessa forma, observa-se que o desequilíbrio não interferiu no desempenho de classificação da RBF, tal como foi verificado com a PMC. A Tabela 65 exibe 4 falsos negativos e 11 falsos positivos.

As Figuras 52, 53 e 54 mostram, respectivamente, para os MIT 1, 2 e 3, os gráficos referentes às tabelas apresentadas para amostras estratificadas por desequilíbrio.


Verifica-se que todos os gráficos seguem a mesma tendência, ou seja, mantêm-se na mesma faixa de taxa de acerto independente do nível de desequilíbrio. As diferenças entre as topologias se mostraram pouco relevantes, acumulando-se entre 80% e 90% de acerto.

**Tabela 64 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 4%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	85,55%	0,611	85,71%	0,614	85,71%	0,614
2	82,22%	0,544	85,71%	0,614	85,71%	0,614
3	81,22%	0,524	85,71%	0,615	85,71%	0,614
4	81,11%	0,522	86,58%	0,631	85,71%	0,614
5	80,33%	0,506	85,71%	0,641	85,71%	0,614
6	80,88%	0,517	85,71%	0,641	83,41%	0,568
7	82,44%	0,548	85,71%	0,641	85,71%	0,614

**Tabela 65 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 64.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	7	11
c.c. de até 20%	4	104



**Figura 52 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de desequilíbrio utilizando RMS.**

Fonte: Autoria própria




Figura 53 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de desequilíbrio utilizando RMS.

Fonte: Autoria própria




Figura 54 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de desequilíbrio utilizando RMS.

Fonte: Autoria própria

### 5.2.1 Classificação utilizando Potência de Previsão

Em seguida, são exibidos os resultados das classificações aplicando-se Potência de Previsão aos componentes *wavelets* de interesse, Tabelas 66, 68, 70 e 71.

A Tabela 66 exibe os valores alcançados pelas redes referentes às amostras com 7% e 10% de curto-circuito. Percebe-se que as taxas de acerto, em sua maioria, superam a faixa dos 90%, principalmente para o MIT 3. De fato, os resultados observados se assemelham com aqueles obtidos utilizando-se os valores RMS dos componentes. A Tabela 67 mostra a matriz de confusão, com 1 falso negativo somente.

**Tabela 66 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 7% e 10% das espiras.**

rede	Performance de classificação					
	MIT 1 (7%)		MIT 2 (10%)		MIT 3 (10%)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	90,30%	0,606	97,16%	0,943	91,67%	0,833
2	86,33%	0,726	98,00%	0,960	90,83%	0,816
3	87,00%	0,740	83,38%	0,667	91,67%	0,833
4	85,30%	0,706	89,11%	0,783	92,33%	0,846
5	86,33%	0,726	89,22%	0,783	93,33%	0,867
6	85,20%	0,704	89,16%	0,783	94,75%	0,895
7	81,33%	0,626	97,75%	0,955	94,41%	0,883

**Tabela 67 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 66.**

	Classificado como:	
	Sem falha	c.c. de 10%
Sem falha	60	0
c.c. de 10%	1	59



A Tabela 68 apresenta o desempenho das redes para amostras com 5% de curto-circuito. Percebe-se que a taxa de acertos decaiu, contudo, no geral, os valores se mantêm acima daqueles obtidos pela utilização do RMS como entrada para as redes (Tabela 55).

**Tabela 68 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 5% das espiras.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	87,50%	0,750	57,50%	0,150	65,00%	0,300
2	89,16%	0,783	69,16%	0,383	62,50%	0,250
3	82,50%	0,650	75,83%	0,516	71,00%	0,420
4	88,33%	0,767	66,83%	0,516	67,50%	0,350
5	85,00%	0,700	74,16%	0,483	70,83%	0,416
6	84,50%	0,690	73,33%	0,466	70,50%	0,410
7	87,11%	0,758	66,66%	0,333	74,50%	0,490

Na Tabela 69, pode-se conferir a matriz de confusão para o experimento, na qual observam-se 20 falsos positivos e 4 falsos negativos.

**Tabela 69 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 68.**

	Classificado como:	
	Sem falha	c.c. de 5%
Sem falha	40	20
c.c. de 5%	4	56

Considerando-se 3% e 1% de falha, as Tabelas 70 e 71, respectivamente, exibem os desempenhos das redes. Verifica-se que, neste ponto, as redes voltam a obter resultados próximos de 50%.

As Figuras 55, 56 e 57 exibem os gráficos referentes aos MIT 1, 2 e 3, respectivamente. Destaca-se que em todos os casos os gráficos seguem uma tendência, mesmo que o desempenho se altere em relação às diversas topologias. Somente são verificados resultados satisfatórios para curtos-circuitos de intensidade superiores, e o desvio padrão verificado é quase imperceptível.

**Tabela 70 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 3% das espiras.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	56,66%	0,133	50,00%	0,000	50,00%	0,00
2	68,33%	0,367	50,00%	0,016	50,00%	0,00
3	64,16%	0,283	50,00%	0,00	62,50%	0,250
4	63,16%	0,263	64,17%	0,283	60,83%	0,216
5	61,66%	0,233	66,66%	0,333	61,22%	0,220
6	62,66%	0,253	69,17%	0,383	62,00%	0,240
7	62,66%	0,253	66,16%	0,383	58,00%	0,160

**Tabela 71 – Resultados de validação para coeficientes PP, considerando amostras com curto-circuito em 1% das espiras.**

rede	Performance de classificação					
	MIT 1		MIT 2		MIT 3	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	50,00%	0,000	50,00%	0,000	49,17%	0,016
2	54,16%	0,083	50,00%	0,000	51,67%	0,033
3	52,66%	0,053	50,00%	0,000	52,83%	0,056
4	55,00%	0,100	50,00%	0,000	49,16%	0,017
5	54,16%	0,083	50,00%	0,000	50,00%	0,000
6	54,16%	0,083	50,00%	0,000	49,50%	0,010
7	53,33%	0,067	49,66%	0,007	48,00%	0,040




Figura 55 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de curto-circuito utilizando coeficientes PP.

Fonte: Autoria própria





Figura 56 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de curto-circuito utilizando coeficientes PP.

Fonte: Autoria própria



**Figura 57 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de curto-circuito utilizando coeficientes PP.**

Fonte: Autoria própria

As seguintes Tabelas apresentam os resultados considerando estrato de desequilíbrio para os coeficientes de PP.

A Tabela 72 apresenta o desempenho das 7 topologias de redes neurais RBF testadas para amostras sem desequilíbrio. Verifica-se que, no geral, a taxa média de acertos manteve-se próximo de 80%, inferior aqueles obtidos quando utilizada a arquitetura PMC. A Tabela 73 apresenta a matriz de confusão para o experimento.

**Tabela 72 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras sem desequilíbrio.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	80,00%	0,600	80,00%	0,600	80,00%	0,600
2	78,67%	0,573	80,60%	0,600	80,00%	0,600
3	80,00%	0,600	80,00%	0,600	80,00%	0,600
4	76,67%	0,533	77,33%	0,546	80,00%	0,600
5	73,33%	0,466	78,66%	0,573	80,00%	0,600
6	70,00%	0,400	78,66%	0,573	80,00%	0,600
7	76,67%	0,533	78,66%	0,573	80,00%	0,600

**Tabela 73 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 72.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	5	1
c.c. de até 20%	0	24

Para taxas de desequilíbrio de até 2%, a Tabela 74 mostra o desempenho das redes. Verifica-se uma elevação na taxa média de acerto (em torno de 85%), quando comparado ao caso anterior. O mesmo desempenho geral foi observado para a Tabela 76, cujas amostras englobam desequilíbrios de até 4% entre fases.

**Tabela 74 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 2%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	85,00%	0,600	85,71%	0,614	85,71%	0,614
2	88,33%	0,676	85,71%	0,614	85,71%	0,614
3	85,33%	0,607	85,71%	0,615	85,71%	0,614
4	83,00%	0,560	85,71%	0,614	85,71%	0,614
5	82,00%	0,540	85,71%	0,614	85,71%	0,614
6	80,00%	0,500	85,47%	0,609	85,71%	0,614
7	80,00%	0,500	85,47%	0,609	85,71%	0,614

**Tabela 75 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 74.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	10	8
c.c. de até 20%	0	108


A exemplo dos gráficos exibidos para os experimentos com RMS, as Figuras 58, 59 e 60, exibem linhas quase horizontais.

**Tabela 76 – Resultados de validação para amostras com curto-circuito de até 7% e 20%, amostras com desequilíbrio de até 4%.**

rede	Performance de classificação					
	MIT 1 (até 7% de c.c.)		MIT 2 (até 20% de c.c.)		MIT 3 (até 20% de c.c.)	
	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa	Taxa média de acertos	Índice Kappa
1	84,44%	0,588	85,71%	0,614	85,71%	0,614
2	83,33%	0,567	85,71%	0,614	85,71%	0,614
3	85,55%	0,611	85,71%	0,615	85,71%	0,614
4	83,33%	0,567	85,71%	0,614	85,71%	0,614
5	83,11%	0,562	85,71%	0,641	85,71%	0,614
6	82,22%	0,544	85,71%	0,641	85,71%	0,614
7	82,22%	0,644	85,71%	0,641	85,23%	0,604


**Tabela 77 – Exemplo de matriz de confusão para o experimento com maior taxa de acertos da Tabela 76.**

	Classificado como:	
	Sem falha	c.c. de até 20%
Sem falha	13	5
c.c. de até 20%	0	72




**Figura 58 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 1, estrato por intensidade de desequilíbrio utilizando coeficientes PP.**

Fonte: Autoria própria



**Figura 59 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 2, estrato por intensidade de desequilíbrio utilizando coeficientes PP.**

Fonte: Autoria própria



**Figura 60 – Taxa média de acertos e desvio médio padrão para cada rede, MIT 3, estrato por intensidade de desequilíbrio utilizando coeficientes PP.**

Fonte: Autoria própria

Em geral, os resultados obtidos pelas Redes RBF demonstraram a capacidade dessa arquitetura para a classificação de padrões, cuja performance se assemelha aquela observada com a PMC. Contudo, na maioria dos casos, pode-se notar um número de acertos ligeiramente superior da PMC em relação à RBF. Destaca-se também que o desvio padrão das classificações da RBF apresenta-se nitidamente inferior àquele apresentado pelas topologias PMC. Dessa forma, os resultados da RBF tendem a ficar mais próximos de suas respectivas médias, sendo essa uma característica interessante observada nos testes com essa arquitetura. Todavia, como dito, foram poucas as vezes que a RBF sobressaiu diante da PMC em termos de porcentagem de acerto na detecção da falha. Portanto, na seção seguinte serão observados somente os testes com a PMC.

Vale ressaltar também que nenhuma topologia RBF em particular revelou um desempenho que se destacasse claramente entre as demais, sendo que, por várias vezes, as topologias com diferentes números de neurônios na camada escondida se revesavam como aquela que atingia melhores desempenhos.

### 5.3 TESTES DE ROBUSTEZ

Nessa seção, os experimentos realizados incluem ensaios nos quais o conjunto de treinamento da rede e o conjunto de validação são provenientes de motores diferentes. Dessa forma, é possível avaliar com mais rigor o desempenho e robustez das redes. Para evitar excesso desnecessário de informação, será testada apenas estrutura da Rede 1 da PMC para os seguintes experimentos, haja vista que nas seções anteriores não foi observada nenhuma vantagem explícita de se utilizar topologias mais complexas. Primeiramente, serão apresentadas as tabelas relativas aos ensaios realizados com valores RMS, e, em seguida, com Potência de Previsão. Por fim, exibem-se resultados de classificações utilizando as fases B e C.

A Tabela 78 exibe os resultados dos ensaios estratificados por curto-circuito e desequilíbrio de tensão para subamostras de treinamento oriundas do MIT 1 e validadas com subamostras do MIT 2. Verifica-se um baixo desempenho da rede quando analisadas as amostras estratificadas por curto-circuito, não sendo superior a 57%. O desempenho, considerando estrato por desequilíbrio, manteve-se praticamente constante em torno de 75% de taxa média de acertos.

**Tabela 78 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 2 para validação.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	75,47%	0,509
5%	56,81%	0,136	2%	73,01%	0,460
3%	53,52%	0,070	0%	76,13%	0,522
1%	55,13%	0,102	-	-	-

Na Tabela 79, podem ser observados os resultados do treinamento com amostras



do MIT 1 validadas com amostras do MIT 3. Verifica-se uma maior taxa de acertos considerando 5% e 3% de espiras curto-circuitadas, atingindo 83,53%. Contudo, para 1% de espiras curto-circuitadas e demais testes por ensaio de desequilíbrio, houve uma redução na taxa média de acertos. Nenhum dos casos apresentados exibe um valor satisfatório para o índice Kappa, comprometendo a confiabilidade dos resultados.

**Tabela 79 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 3 para validação .**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	66,57%	0,331
5%	83,53%	0,670	2%	74,56%	0,511
3%	60,41%	0,208	0%	70,45%	0,409
1%	36,36%	0,029	-	-	-

Na Tabela 80, podem ser observados os resultados dos ensaios treinados com amostras do MIT 2 validadas com amostras do MIT 1. Verifica-se a taxa de acerto e o índice Kappa estão substancialmente mais elevados quando comparados ao ensaio no qual o treinamento foi realizado com MIT 1 e validação com MIT 2, Tabela 78. A taxa de acerto para os testes com estrato de desequilíbrio mantiveram-se aproximadamente nos mesmos patamares.

**Tabela 80 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 1 para validação .**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	73,67%	0,473
5%	93,52%	0,870	2%	74,71%	0,494
3%	87,84%	0,756	0%	71,59%	0,431
1%	63,13%	0,268	-	-	-

Para treinamento com amostras do MIT 2 e validação com amostras do MIT 3, a Tabela 81 apresenta os resultados para taxa de acerto e índice Kappa. Considerando o estrato de desequilíbrio, verificam-se taxa de acerto na ordem de 66%, inferiores às demais apresentadas nos ensaios anteriores. Contudo, observa-se um bom desempenho para 10% e 5% de curto-circuito.

Na Tabela 82, podem ser observados os resultados dos ensaios treinados com amostras do MIT 3 validadas com amostras do MIT 1. Verifica-se a taxa de acerto e o índice Kappa estão mais elevados quando comparados ao ensaio no qual o treinamento foi realizado com MIT 1 e validação com MIT 3, Tabela 78. A taxa de acerto para os testes com estrato de desequilíbrio mostraram-se mais elevados que aqueles dos ensaios anteriores.

**Tabela 81 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 3 para validação .**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	94,31%	0,886	4%	69,85%	0,397
5%	76,89%	0,537	2%	66,47%	0,329
3%	60,60%	0,212	0%	65,58%	0,311
1%	52,65%	0,213	-	-	-

**Tabela 82 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 1 para validação .**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	79,92%	0,598
5%	94,20%	0,884	2%	78,83%	0,576
3%	74,20%	0,484	0%	76,98%	0,539
1%	54,54%	0,090	-	-	-

Na Tabela 83, são apresentados os resultados dos ensaios cujos treinamentos foram realizados com amostras do MIT 3 validadas com amostras do MIT 2. Nos ensaios por estrato de curto-circuito, verifica-se que as taxa de acerto e índice Kappa não estão em níveis satisfatórios para os casos de 5%, 3% e 1% de espiras curto-circuitadas. Para os ensaios por estrato de desequilíbrio, as taxa de acerto superam 80%, melhores desempenhos até então para esse tipo de experimento.

**Tabela 83 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 2 para validação .**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	80,56%	0,611	4%	81,33%	0,626
5%	56,02%	0,120	2%	84,17%	0,683
3%	52,50%	0,050	0%	82,79%	0,655
1%	50,34%	0,006	-	-	-

Analisando os experimentos anteriores, percebe-se que os dados do MIT 1 não resultaram bons desempenhos quando utilizados para treinamento. Além disso, ao inverter a ordem das amostras de dois MIT diferentes para treinamento e validação, o desempenho das redes pode se alterar substancialmente. Para os ensaios estratificados por desequilíbrio, embora o desempenho tenha se modificado de uma tabela para outra, o desempenho se mantém sempre relativamente constante para um mesmo grupo de amostras, independente da intensidade do desequilíbrio.

As tabelas seguintes expõem os resultados para os ensaios de robustez quando

utilizados os coeficientes PP. Na Tabela 84 é exibido o desempenho da rede quando são utilizadas as amostras do MIT 1 para o treinamento e do MIT 2 para a validação. Observa-se que para 5% de curto-circuito a rede atingiu a melhor taxa de acertos, bem acima do valor encontrado para o mesmo caso utilizando RMS (56,81%). Quando se trata de estrato por desequilíbrio, tem-se resultados bastante semelhantes com aqueles apresentados para o experimento com RMS.

**Tabela 84 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 2 para validação, com coeficientes PP.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	71,42%	0,428
5%	81,47%	0,629	2%	72,97%	0,459
3%	60,00%	0,202	0%	74,83%	0,496
1%	52,04%	0,040	-	-	-

A Tabela 85 apresenta os resultados utilizando as amostras do MIT 3 para validação, ainda com as amostras do MIT 1 para treinamento. No geral, o desempenho exibido pela rede é inferior aos encontrados na Tabela 84 e ao ensaio com RMS, Tabela 79.

**Tabela 85 – Resultado dos ensaios utilizando amostras do MIT 1 para treinamento e amostras do MIT 3 para validação, com coeficientes PP.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	68,29%	0,365
5%	70,45%	0,409	2%	67,20%	0,344
3%	59,09%	0,181	0%	69,23%	0,384
1%	39,77%	0,021	-	-	-

As Tabelas 86 e 87 exibem os resultados para as amostras do MIT 2 como treinamento e dos MIT 1 e 3, respectivamente, como validação. No primeiro caso, verifica-se que somente com 5% das espiras curto-circuitadas conseguiu-se desempenho satisfatório. No segundo caso, é possível o teste com 10% de espiras curto-circuitadas, sendo esse o ensaio que conseguiu melhor taxa de acertos. Em ambos os casos, os resultados obtidos se assemelham àqueles observados com os valores RMS, Tabelas 80 e 81.

As Tabelas 88 e 89 exibem os resultados para as amostras do MIT 3 como treinamento e dos MIT 1 e 2, respectivamente, como validação. No primeiro caso, tratando-se do estrato por desequilíbrio, verifica-se que com até 2% de desequilíbrio entre fases, o resultado ficou abaixo do esperado. No caso do estrato por curto-circuito, novamente o ensaio com 5% das espiras de estator curto-circuitadas atingiu patamares mais aceitáveis. Contudo, mesmo esse resultado ainda se verifica inferior quando comparado ao mesmo ensaio realizado com valores RMS (Tabela 82).

**Tabela 86 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 1 para validação, com coeficientes PP.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	63,35%	0,267
5%	95,45%	0,809	2%	61,22%	0,224
3%	69,09%	0,381	0%	65,90%	0,318
1%	56,47%	0,126	-	-	-

**Tabela 87 – Resultado dos ensaios utilizando amostras do MIT 2 para treinamento e amostras do MIT 3 para validação, com coeficientes PP.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	94,50%	0,890	4%	62,21%	0,244
5%	63,06%	0,261	2%	60,08%	0,201
3%	54,16%	0,083	0%	57,38%	0,147
1%	49,26%	0,011	-	-	-

No segundo caso, Tabela 89, os testes por estrato de desequilíbrio retomam o padrão, mantendo-se um pouco acima de 70% de acertos, qualquer que seja a intensidade do desequilíbrio. Comparando com a análise efetuada com base nos valores RMS, Tabela 83, observa-se que o processamento das amostras com PP melhorou significativamente o desempenho da classificação para os testes estratificados por curto-circuito, contudo, para as amostras estratificadas por intensidade de desequilíbrio, o resultado mostra-se inferior.

**Tabela 88 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 1 para validação, com coeficientes PP.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	-	-	4%	79,92%	0,598
5%	82,04%	0,640	2%	40,76%	0,097
3%	57,50%	0,150	0%	46,68%	0,120
1%	39,31%	0,010	-	-	-

Comparando os desempenhos obtidos utilizando somente o valor RMS da componente e utilizando a Potência de Previsão, concluiu-se que em alguns casos o processamento adicional do PP se justifica, proporcionando um aumento de até 25 pontos percentuais na taxas de acerto. Contudo, por várias vezes, os resultados alcançados com o uso do RMS nessa seção se mostraram superiores quando colocados frente àqueles alcançados pelo uso da PP. Diante dos ensaios realizados nessa seção não se pode afirmar que o custo computacional do processamento por PP converte-se em benefício para a classificação correta da RNA.

**Tabela 89 – Resultado dos ensaios utilizando amostras do MIT 3 para treinamento e amostras do MIT 2 para validação, com coeficientes PP.**

	Estrato por curto-circuito			Estrato por desequilíbrio	
	Taxa de acertos	Índice Kappa		Taxa acertos	Índice Kappa
10%	92,27%	0,845	4%	73,01%	0,460
5%	63,52%	0,270	2%	72,44%	0,448
3%	50,75%	0,025	0%	71,02%	0,420
1%	48,06%	0,03	-	-	-

Na Tabela 90 podem ser observados os resultados obtidos para todas as condições avaliadas durante o decorrer do trabalho, ou seja, diversas intensidades de curto-circuito, desequilíbrios de tensão e carregamentos. Essa tabela inclui também testes com amostras de treinamento e validação oriundas dos mesmos motores.

**Tabela 90 – Resultado geral, considerando todas as condições de operação, incluindo desequilíbrios, carregamentos e curto-circuito.**

Treinamento	Validação	RMS		PP	
		Taxa de acerto	Índice Kappa	Taxa de acerto	Índice Kappa
MIT 1	MIT 1	78,41%	0,572	92,91%	0,884
MIT 1	MIT 2	78,31%	0,591	83,40%	0,725
MIT 1	MIT 3	63,83%	0,277	70,89%	0,402
MIT 2	MIT 1	79,22%	0,597	92,03%	0,858
MIT 2	MIT 2	75,76%	0,450	84,54%	0,650
MIT 2	MIT 3	74,29%	0,518	88,52%	0,772
MIT 3	MIT 1	76,36%	0,527	81,33%	0,612
MIT 3	MIT 2	85,40%	0,690	91,27%	0,823
MIT 3	MIT 3	88,98%	0,792	90,25%	0,819

Os piores resultados se verificaram quando houve treinamento com amostras do MIT 1 e validação com MIT 3, atingindo 63,83% de acerto (RMS) e 70,89% de acerto (PP). A maior taxa de acerto se verificou para treinamento e validação com as amostras do MIT 1, 92,91%, utilizando PP. Considerando valores RMS, verifica-se que as taxas de acerto foi maior quando a rede foi treinada e validada com o MIT 3, expondo a taxa de 88,98%. Percebe-se que, no geral, as taxas de acerto com PP se mantiveram superiores quando comparadas aos testes com RMS.

Por fim, é verificada a viabilidade de classificação utilizando as demais fases como entrada para a rede. Na Tabela 91, exibe-se os resultados de classificações utilizando as fases B e C. Para esses testes, foram usadas todas as intensidades de desequilíbrio, carregamento e curto-circuito.

Conforme verificado na Seção 4.3, os efeitos da falha na corrente de estator se propagam para as demais fases além daquela na qual ocorreu de fato o curto-circuito. Este último teste tem por objetivo avaliar, num teste geral, se tais efeitos são suficientes para se alcançar taxas de acerto semelhantes às aquelas obtidas durante o decorrer do trabalho.

Tabela 91 – Resultados de validação considerando as fases B e C.

MIT	Corrente	RMS		PP	
		Taxa de acerto	Índice Kappa	Taxa de acerto	Índice Kappa
1	$I_B$	90,36	0,713	93,45	0,732
1	$I_C$	86,54	0,598	88,48	0,659
2	$I_B$	82,66	0,438	88,00	0,625
2	$I_C$	84,54	0,577	84,02	0,602
3	$I_B$	87,08	0,622	91,36	0,618
3	$I_C$	91,97	0,689	89,82	0,653

Como ocorre para a fase A, quando as correntes das fases B e C são utilizadas como entradas para a rede classificadora, verificam-se taxas de acerto com PP são ligeiramente superiores aquelas com RMS. O valor máximo ocorre para a corrente  $I_B$ , MIT 1, com 93,45% de acerto, enquanto que o valor mínimo se observa para a corrente  $I_B$ , MIT 2, com 82,66%. Mais uma vez, verifica-se que as amostras do MIT 2 atingiram taxas de acerto inferiores.

#### 5.4 CONCLUSÃO

Este capítulo apresentou os resultados experimentais obtidos pelas RNA referentes aos dados coletados dos 3 motores de indução frente à metodologia proposta de detecção de falhas de estator. Foram analisadas diversas topologias de duas arquiteturas diferentes de redes neurais, a PMC e a RBF. Como entradas para as redes, foram testados os valores RMS das componentes da decomposição *wavelet* estudados no Capítulo 4, e, em seguida, foram utilizados os valores de Potência de Previsão das mesmas componentes. As amostras foram estratificadas considerando intensidade de curto-circuito e intensidade de desequilíbrio. Primeiramente, foram realizados treinamento e validação com dados do mesmo motor, contudo, coletados em ocasiões diferentes. Por fim, foi realizado um teste de robustez, no qual a metodologia foi posta à prova com amostras de treinamento e validação provenientes de MIT diferentes.

Perante o exposto nas subseções 5.1.1 e 5.1.2, conclui-se que o desempenho global das redes PMC testadas foi marginalmente superior quando utilizadas 6 componentes como entradas, sugerindo que, de fato, as componentes adicionais contém informação relevante ao diagnóstico de falha. Dessa forma, confirma-se que a utilização das componentes 2, 4, 6, 8, 14 e 16 do oitavo nível da decomposição é imprescindível para se atingir resultados mais confiáveis. Além disso, avaliando-se o desempenho das redes em cada caso, nenhuma delas, de maneira geral, manifestou uma performance de indubitável destaque em relação às demais. Portanto, considera-se a Rede 1 a mais adequada para a finalidade proposta, pois a mesma atingiu resultados significativos dispendo da topologia mais simples entre as candidatas. Esse fato reforça que aumento indiscriminado de neurônios assim como o incremento de camadas intermediárias não asseguram a generalização apropriada.

As classificações perante as amostras estratificadas por intensidade de curto-circuito reiteram o fato de que com o aumento do nível da falha, as redes convergem corretamente com mais frequência. Isso ficou claro principalmente para os MIT 1 e 2. Outra conclusão observada nesse conjunto de testes é que o desempenho das topologias quando o curto-circuito equivale a 7% ou 10% de espiras estatóricas danificadas é independente do método utilizado, ou seja, tanto o valor RMS quanto os coeficientes PP atingiram por várias vezes taxas de acerto acima de 98%. Contudo, considerando os demais níveis de curto-circuito, a classificação utilizando PP culminou em resultados consideravelmente mais precisos e confiáveis.

A análise por estrato de desequilíbrio permitiu concluir que, utilizando a metodologia apresentada, a taxa de acerto nas classificações torna-se independente da intensidade de desequilíbrio entre as fases, pelo menos dentro dos limites de intensidade estudados. Os resultados apresentados evidenciam que, para desequilíbrios na ordem de 2% e 4%, o desempenho das topologias foi muito semelhante àquele atingido utilizando amostras com desequilíbrio inferior a 0,5%. Lembra-se ainda que, na investigação de padrões efetuada no Capítulo 4, concluiu-se que as componentes *wavelet* que mais se relacionaram com a falha de curto-circuito eram também pouco sensíveis a variações de desequilíbrio (C(8,6) e C(8,8)). Dessa forma, o estudo por estrato de desequilíbrio apresentado ajuda a ratificar essa conjectura anteriormente apresentada. Portanto, pode-se afirmar que o método apresentado não tem seu desempenho prejudicado por desequilíbrios de tensão eventualmente encontrados no ambiente industrial (isso é garantido para desequilíbrios de intensidade inferior a 4%).

Ainda a respeito do estudo por estrato de desequilíbrio, percebe-se que a taxa de acertos e o índice Kappa, em geral, mantiveram-se superiores para as amostras que passaram pelo processamento da PP, quando em comparação com aquelas organizadas com valores RMS. Tal fato se torna claro ao observar as Figuras 37, 38, 39, 43, 45 e 45, nas quais percebe-se que as RNA das 3 últimas figuras classificaram corretamente, em média, com alguns pontos percentuais a mais os dados da PP.

O teste de robustez registrou bons índices de desempenho quando usadas amostras estratificadas para 10% de espiras curto-circuitadas, atingindo taxas de acertos em sua maioria acima de 90%. Para 5% de espiras curto-circuitadas, os resultados oscilaram dentro de um amplo intervalo, sendo o pior caso registrado com 56% de acerto e o melhor de 95%. Com 3% curto-circuito, os melhores desempenhos foram resultado de validação com amostras do MIT 1, não ultrapassando a taxa de 87% de acerto. Por último, quando considerado 1% de falha, os resultados se apresentaram em torno de 50% de acerto. Dessa forma, no geral, a falha só seria detectada quando evoluísse para uma maior quantidade de espiras. O teste com todos os níveis de curto-circuito reunidos e separado por níveis de desequilíbrio de tensão exibiu desempenhos entre 70% e 80% na maioria das vezes. Por fim, realizaram-se testes gerais entre os três MIT, com as amostras de todas as faixas de desequilíbrio, intensidade de falha e carregamento disponíveis. Verificou-se que as melhores taxa de acerto ocorreram entre amostras de um mesmo MIT, contudo, um dos maiores valores foi observado para rede treinada com MIT 2 e validada com MIT 1, com 92,03%. Por último, o teste com fases B e C mostraram valores de acerto e índice Kappa semelhante àqueles obtidos com a fase A, na qual ocorre a falha.

## 6 CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma metodologia alternativa para diagnósticos de falha de curto-circuito nas bobinas do estator de um motor de indução trifásico. O trabalho fundamentou-se em conceitos estabelecidas na literatura, principalmente no que diz respeito às frequências que surgem nas correntes de estator quando da ocorrência da falha mencionada. Baseado nessas frequências específicas e nas observações realizadas pela análise dos espectros de Fourier, concluiu-se que as componentes de frequência 150 Hz e 210 Hz foram aquelas que mais sofreram modificações quando da aplicação de um curto-circuito. Contudo, um método de detecção da falha utilizando a TF deve estar preparado para eventuais mudanças de carregamento no eixo do MIT.

Após a abordagem fundamentada pela análise no domínio da frequência, o estudo buscou na TW uma alternativa para complicações as quais surgiam diante da TF. A capacidade das *wavelets* de separar componentes de um sinal dentro de um determinado intervalo de frequências possibilita a análise da frequência mesmo diante de alterações de carregamento. Desta forma, contorna-se o problema da análise pontual obtida por Fourier.

Por meio da *wavelet-packet*, buscou-se investigar de que forma as condições de operação (curto-circuito, carregamento e desequilíbrio) modificam as componentes *wavelet* examinadas. Ao fim da análise, concluiu-se que as componentes C(8,2), C(8,4), C(8,6), C(8,8), C(8,14) e C(8,16) sofrem algum tipo de alteração de acordo com as condições de operação da máquina, sendo as componentes C(8,6) e C(8,8) aquelas que manifestam mudanças mais significativas na amplitude diante de curto-circuitos de estator. Tais padrões sugeriram que essas componentes contêm as frequências indicadas por Fourier (150Hz e 210Hz). Além disso, os testes mostraram a pouca ou nenhuma variação dessas componentes perante uma elevação de carga no eixo e modificações nos desequilíbrios entre fases.

Sendo assim, as simulações mediante RNA como classificadoras de padrões foram utilizadas para mensurar a viabilidade do uso dessas componentes da decomposição *wavelet* para a detecção de falha de estator frente a diversas condições de testes. De forma resumida, os experimentos com redes neurais contemplaram as condições e aspectos listados a seguir:

- Dados de três motores de indução trifásicos distintos;
- Dados com variação de intensidade de desequilíbrio de tensão entre as fases da alimentação de até 4%;
- Dados com variação de carga no eixo, abrangendo sinais do motor operando a vazio e com aumentos graduais de conjugado até atingir uma ligeira sobrecarga;
- Dados com variação do número de espiras estatóricas curto-circuitadas de até 20%;
- Processamento de sinais utilizando Transformada *Wavelet* e Potência de Previsão;
- Simulação computacional de redes neurais para classificação de padrões utilizando PMC e RBF;



- Testes utilizando somente as componentes *wavelets* 6 e 8 do oitavo nível;
- Testes utilizando as componentes *wavelets* 2, 4, 6, 8, 14 e 16 do oitavo nível;
- Testes envolvendo treinamento e validação com dados do mesmo motor;
- Testes envolvendo treinamento e validação com dados de motores distintos;
- Testes organizando as amostras por estrato de curto-circuito;
- Testes organizando as amostras por estrato de desequilíbrio;
- Testes utilizando o valor RMS das componentes *wavelets* selecionadas;
- Testes submetendo as componentes *wavelets* selecionadas ao algoritmo da PP;

Em vista de suas características para classificadores de padrões, foi verificada a viabilidade das redes PMC e RBF frente à metodologia proposta. Primeiramente, utilizou-se como entrada para as redes somente o valor RMS das duas componentes mencionadas, C(8,6) e C(8,8), separando-se as amostras por nível de curto-circuito. Considera-se que ambas as redes obtiveram resultados satisfatórios perante curto-circuitos mais intensos, acima de 7%, contudo, foi demonstrado decaimento expressivo na taxa de acertos de forma proporcional à diminuição do nível do curto. No intuito de melhorar o desempenho das redes foi considerado utilizar como entradas outras componentes que se destacaram na análise da *wavelet-packet*, ou seja, C(8,2), C(8,4), C(8,6), C(8,8), C(8,14) e C(8,16). Essa nova estratégia possibilitou uma nítida melhora na taxa de acerto global das redes. Entretanto, considerando falhas incipientes, na faixa de 1%, os resultados ainda não foram satisfatórios. Os resultados obtidos esboçam a dificuldade existente para distinguir as amostras sem falha daquelas com apenas 1% de espiras curto-circuitadas. O teste realizado com amostras separadas por nível de curto-circuito evidencia que a dificuldade de classificação das falhas é inversamente proporcional à intensidade com a qual se apresenta a mesma. Em relação ao uso das redes RBF ou PMC, nota-se a partir da análise realizada no Capítulo 5 que a taxa de acerto global nos experimentos não mostrou vantagem de nenhuma arquitetura em relação a outra na detecção de uma falha incipiente, com 1% de espiras curto-circuitadas. Contudo, no geral, percebe-se que a PMC levou vantagem na maioria dos demais experimentos.

Por meio do teste estratificado por desequilíbrio, foi possível concluir que a taxa de acerto na detecção da falha não tem vinculação com o nível de desequilíbrio apresentado, dentro dos limites analisados. Ou seja, não foi verificada tendência de diminuição da taxa de acerto com a elevação do desequilíbrio. A taxa de acerto considerando valores RMS como entradas atingiu valores entre 70% e 90% no geral, para todos os motores, sendo que o MIT 3 revelou resultados ligeiramente superiores. A taxa de acerto considerando valores de PP encontrou-se num patamar mais elevado, acima de 90% para o MIT 3 e na maioria dos casos para o MIT 1, entretanto, na faixa dos 80% para o MIT 2.

Os resultados obtidos até esse ponto mostraram que a topologia da rede pouco influenciava na detecção da falha, portanto, foi escolhida a rede mais simples, Rede 1, para os experimentos posteriores. A partir dos testes realizados com treinamento e validação

com motores diferentes foi possível concluir que os resultados obtidos com valor RMS são bastante semelhantes àqueles obtidos com PP. Dessa forma, para as condições analisadas nesses testes, seria injustificada a utilização do processamento adicional exigido pelo PP, mesmo que tenha algumas vezes conseguido desempenhos marginalmente superiores. A taxa de acerto para amostras estratificadas por desequilíbrio se mantiveram na faixa de 75%. Para os testes de robustez envolvendo amostras estratificadas por curto-circuito, os resultados só foram satisfatórios, no geral, para intensidades acima de 5% de espiras curto-circuitadas, atingindo por várias vezes nesses casos, taxa de acerto acima de 90%. Considerando apenas 1% de espiras curto-circuitadas, os resultados não apresentaram taxas acima de 65% de acerto.

Para efeito de comparação, Santos (2013) propôs um sistema de classificação de falhas de curto-circuito e barras quebradas por meio da aplicação de variáveis estatísticas (média, RMS, *skewness* e *kurtosis*) nas componentes *wavelets* de terceiro nível. As taxas de acerto mais elevadas atingiram patamares de 95%, contudo, não foram considerados no estudo desequilíbrios de tensão. Já o trabalho de Silva (2014) atingiu taxas de acerto de até 91%, sendo utilizadas a decomposição *wavelet-packet* e medidas de previsibilidade PP e PrCA em conjunto.

## 6.1 AGRADECIMENTOS

Este trabalho conta com o apoio financeiro da Fundação Araucária de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná (Processo *Nº* 338/2012 e *Nº* 06/56093-3), do Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq (Processo *Nº* 474290/2008-5, 473576/2011-2 e *Nº* 552269/2011-5) e bolsa Capes-DS.

## 6.2 PUBLICAÇÃO ASSOCIADA AO TRABALHO

A seguinte publicação é associada a este trabalho:

- XX Congresso Brasileiro de Automática, CBA 2014;  
DETECÇÃO DE FALHAS ELÉTRICAS EM MOTORES DE INDUÇÃO UTILIZANDO REDE RADIAL BASIS FUNCTION.  
(VITOR, A. L. de O. and OLIVEIRA, F. M. and RONQUI, L. A. and GOEDTEL, A. and SCALASSARA, P. R. and SILVA, S. A. O. and VALLIM, M. B. R.)  
Setembro, 2014.

## REFERÊNCIAS

- BANGURA, J.; DEMERDASH, N. Comparison between characterization and diagnosis of broken bars/end-ring connectors and airgap eccentricities of induction motors in asds using a coupled finite element-state space method. **IEEE Transactions on Energy Conversion**, v. 15, n. 1, p. 48–56, Mar 2000.
- BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, v. 55, n. 12, p. 4109–4126, Dec 2008.
- BENBOUZID, M. E. H. A review of induction motors signature analysis as a medium for faults detection. **IEEE Transactions on Industrial Electronics**, v. 47, n. 5, p. 984–993, Oct 2000.
- BENESTY, J.; CHEN, J.; HUANG, Y.; COHEN, I. **Noise Reduction in Processing**. 2. ed. Berlin: Springer Berlin Heidelberg, 2009.
- BONNETT, A.; SOUKUP, G. Cause and analysis of stator and rotor failures in three-phase squirrel-cage induction motors. **Industry Applications, IEEE Transactions on**, v. 28, n. 4, p. 921–937, Jul 1992.
- BORBA, J. Aneel aprova aumento nas tarifas de energia. **Folha de São Paulo**, Abril 2015.
- BRONIERA, P.; GONGORA, W.; GOEDEL, A.; GODOY, W. Diagnosis of stator winding inter-turn short circuit in three-phase induction motors by using artificial neural networks. **9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)**, p. 281–287, Aug 2013.
- CASTELLI, M.; FOSSATTI, J. P.; TERRA, J. I. Fault diagnosis of induction motors based on fft. **InTech**, 2012.
- CHANG, C.-I.; DU, Y.; WANG, J.; GUO, S.-M.; THOUIN, P. Survey and comparative analysis of entropy and relative entropy thresholding techniques. **Vision, Image and Signal Processing, IEEE Proceedings**, v. 153, n. 6, p. 837–850, Dec 2006.
- CHAPMAN, S. J. **Electric Machinery Fundamentals**. 5. ed. Nova York: McGraw-Hill, 2012.
- COVER, T.; THOMAS, J. **Elements of Information Theory**. New York: Jhon Wiley and Sons, 2006.
- DAS, S.; PURKAIT, P.; KOLEY, C.; CHAKRAVORTI, S. Performance of a load-immune classifier for robust identification of minor faults in induction motor stator winding. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 21, n. 1, p. 33–44, February 2014.
- DEL TORO, V. **Fundamentos de Máquinas Eléctricas**. Rio de Janeiro: LTC, 2011.
- DESOLE, T. Predictability and information theory. part i: Measures os predictability. **Journal of the Atmospheric Sciences**, v. 20, n. 61, p. 2425–2440, Outubro 2004.

DORRELL, D.; THOMSON, W.; ROACH, S. Analysis of airgap flux, current and vibration signals as a function of the combination of static and dynamic airgap eccentricity in 3-phase induction motors. **IEEE Transactions on Industry Applications**, v. 1, p. 563–570 vol.1, Oct 1995. ISSN 0197-2618.

FERREIRA, F. J. T. E.; ALMEIDA, A. T. Induction motor downsizing as a low-cost strategy to save energy. **Journal of cleaner production**, p. 117–131, Outubro de 2012.

FISER, R.; FERKOLJ, S. Application of a finite element method to predict damaged induction motor performance. **IEEE Transactions on Magnetics**, v. 37, n. 5, p. 3635–3639, Sep 2001.

FITZGERALD, A.; KINGSLEY, C.; UMANS, S. **Máquinas Elétricas**. 6. ed. Porto Alegre: Editora Bookman, 2008.

FITZGERALD, R.; LEES, B. Assessing the classification accuracy of multisource remote sensing data. **Remote Sensing of Environment**, v. 47, n. 3, p. 362 – 368, 1994.

GONGORA, W. S. **Uma Abordagem Neural no Diagnóstico de Falhas em Rolamentos de Motores de Indução Trifásicos**. 97 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Campus Cornélio Procópio, 2013.

GUIDO R.C.; SLAETS, J. K. R. A. L. P. J. A new technique to construct a wavelet transform matching a specified signal with applications to digital, real time, spike, and overlap pattern recognition. **Digital Signal Processing**, v. 16, n. 1, p. 24 – 34, 2006.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Física 2**. 5. ed. Rio de Janeiro: Editora LTC.

HAMBABA, A.; HUFF, E. Multiresolution error detection on early fatigue cracks in gears. **IEEE Aerospace Conference Proceedings**, v. 6, p. 367–372 vol.6, 2000.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre,RS: Editora Bookman, 2001.

HOUAISS, A. **Houaiss Conciso**. 1. ed. Rio de Janeiro: Editora Moderna, 2011.

IEEE. Ieee standard glossary of modeling and simulation terminology. **IEEE Std 610.3-1989**, p. 1–0, May 1989.

JARDINE, A. K.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, v. 20, n. 7, p. 1483 – 1510, 2006.

JOKSIMOVIC, G.; PENMAN, J. The detection of interturn short circuits in the stator windings of operating motors. **IEEE Proceedings of the 24th Annual Conference of the IECON**, v. 4, p. 1974–1979, Aug 1998.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, p. 159–174, 1977.

LEE, J.; WU, F.; ZHAO, W.; GHAFFARI, M.; LIAO, L.; SIEGEL, D. Prognostics and health management design for rotary machinery systems: reviews, methodology and applications. **Mechanical Systems and Signal Processing**, v. 42, n. 1?2, p. 314 – 334, 2014. ISSN 0888-3270.

LIU, B.; LING, S.; MENG, Q. Machinery diagnostics based on wavelet-packets. **Journal of Vibration and Control**, n. 3, p. 5–17, 1997.

MALLAT, S. **A Wavelet Tour of Signal Processing: The Sparse Way**. 3. ed. Burlington, USA: Elsevier, 2009.

MEHALA, N. **Condition Monitoring and Fault Diagnosis of Induction Motor Using Motor Current Signature Analysis**. 194 p. Tese (Doutorado) — National Institute of Technology, Kurukshetra, 2010.

NANDI, S.; AHMED, S.; TOLIYAT, H. Detection of rotor slot and other eccentricity related harmonics in a three phase induction motor with different rotor cages. **Energy Conversion, IEEE Transactions on**, v. 16, n. 3, p. 253–260, Sep 2001.

OPPENHEIM, A. V.; SCHAFER, R. W. **Processamento em tempo discreto de sinais**. 3. ed. São Paulo: Pearson Education do Brasil, 2012.

PENG, Z.; CHU, F. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. **Mechanical Systems and Signal Processing**, v. 18, n. 2, p. 199 – 221, 2004.

PENMAN, J.; SEDDING, H.; LLOYD, B.; FINK, W. Detection and location of interturn short circuits in the stator windings of operating motors. **Energy Conversion, IEEE Transactions on**, v. 9, n. 4, p. 652–658, Dec 1994.

PROAKIS, J.; MANOLAKIS, D. K. **Digital Signal Processing**. 4. ed. Londres: Editora Pearson, 2006.

SAMAGA, B.; VITTAL, K. Inclined mixed air gap eccentricity detection method for an induction motor. **Advances in Energy Conversion Technologies (ICAECT), 2014 International Conference on**, p. 37–41, Jan 2014.

SANTOS, F. M. C. **Identificação de Falhas em motores de Indução Trifásicos usando Sistemas Inteligentes**. 110 p. Tese (Doutorado) — Escola de Engenharia de São Carlos, USP, 2013.

SCALASSARA, P. R. **Utilização de Medidas de Previsibilidade em Sinais de Voz para Discriminação de Patologias de Laringe**. 265 p. Tese (Doutorado) — Escola de Engenharia de São Carlos, USP, 2009.

SCHMITT, H.; SILVA, L.; SCALASSARA, P.; GOEDEL, A. Bearing fault detection using relative entropy of wavelet components and artificial neural networks. **9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)**, p. 538–543, Aug 2013.

SCHMITT, H. L. **Detecção de Falhas de Rolamento em Máquinas Elétricas Utilizando Medidas de Previsibilidade**. 63 p. — Universidade Tecnológica Federal do Paraná, Campus Cornélio Procopio, 2013.

SCHMITT, H. L.; SCALASSARA, P. R.; GOEDEL, A.; ENDO, W. Detecting bearing faults in line-connected induction motors using information theory measures and neural networks. **Journal of Control, Automation and Electrical Systems**, v. 26, n. 5, p. 535 – 544, 2015.

SCHNEIDER, T.; GRIFFIES, S. M. A conceptual framework for predicability studies. **Journal of Climate**, v. 10, n. 12, p. 3133–3155, Outubro 1999.

SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, v. 27, n. 6, p. 379–423, Julho 1948.

SHIBATA, K.; TAKAHASHI, A.; SHIRAI, T. Fault diagnosis of rotating machinery through visualisation of sound signals. **Mechanical Systems and Signal Processing**, v. 14, n. 2, p. 229 – 241, 2000.

SIDDIQUI, K. M.; SAHAY, K.; GIRI, V. K. Health monitoring and fault diagnosis in induction motor, a review. **International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering**, v. 3, n. 1, p. 6549 – 6565, 2014.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. 1. ed. São Paulo, SP: Editora Artliber, 2010.

SILVA, L. R. B. **Classificação de Falhas em Máquinas Elétricas Usando Redes Neurais, Modelos Wavelet e Medidas de Informação**. 80 p. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, Campus Cornélio Procopio, 2014.

SIN, M. L.; SOONG, W. L.; ERTUGRUL, N. Induction machine on-line condition monitoring and fault diagnosis - a survey. **Australian Universities Power Engineering Conference - AUPEC2003**, v. 13, n. 2, p. 1–6, 2003.

SUETAKE, M. **Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução**. 130 p. Tese (Doutorado) — Escola de Engenharia de São Carlos, USP, 2012.

THOMSON, W. On-line mcsa to diagnose shorted turns in low voltage stator windings of 3-phase induction motors prior to failure. **IEEE International Electric Machines and Drives Conference (IEMDC)**, p. 891–898, 2001.

THOMSON, W.; FENGER, M. Current signature analysis to detect induction motor faults. **IEEE Industry Applications Magazine**, v. 7, n. 4, p. 26–34, Jul 2001.

VARANIS, M. V. M.; PEDERIVA, R. Extração de parâmetros para classificação de falhas em motores elétricos utilizando banco de filtros daubechies. **XI Simpósio Brasileiro de Automação Inteligente**, n. 8232, Outubro de 2013.

VIERA, A.; GARRETT, J. Understanding interobserver agreement: The kappa statistic. **Family medicine**, v. 37, n. 5, p. 360 – 363, 2005.

WEEKS, M. **Processamento de Sinais Utilizando Matlab e Wavelets**. 2. ed. Rio de Janeiro: LTC, 2012.

YE, Z.; WU, B.; ZARGARI, N. Online mechanical fault diagnosis of induction motor by wavelet artificial neural network using stator current. **Industrial Electronics Society, 2000. IECON 2000. 26th Annual Conference of the IEEE**, v. 2, p. 1183–1188, 2000.

YEN, G.; LIN, K.-C. Conditional health monitoring using vibration signatures. **Decision and Control, 1999. Proceedings of the 38th IEEE Conference on**, v. 5, p. 4493–4498, 1999.