

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CÂMPUS CORNÉLIO PROCÓPIO  
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
MESTRADO EM ENGENHARIA ELÉTRICA**

**LYVIA REGINA BIAGI SILVA**

**CLASSIFICAÇÃO DE FALHAS EM MÁQUINAS ELÉTRICAS USANDO  
REDES NEURAI, MODELOS *WAVELET* E MEDIDAS DE  
INFORMAÇÃO**

**DISSERTAÇÃO**

**CORNÉLIO PROCÓPIO**

**2014**

**LYVIA REGINA BIAGI SILVA**

**CLASSIFICAÇÃO DE FALHAS EM MÁQUINAS ELÉTRICAS USANDO  
REDES NEURAIIS, MODELOS *WAVELET* E MEDIDAS DE  
INFORMAÇÃO**

Dissertação apresentada ao Programa de 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

**CORNÉLIO PROCÓPIO**  
**2014**

---

Dados Internacionais de Catalogação na Publicação

---

- S586 Silva, Lyvia Regina Biagi  
Classificação de falhas em máquinas elétricas usando redes neurais, modelos *wavelet* e medidas de informação / Lyvia Regina Biagi Silva. – 2014.  
84 f. : il. ; 30 cm
- Orientador: Paulo Rogério Scalassara.  
Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-graduação em Engenharia Elétrica. Cornélio Procópio, 2014.  
Referências: p. 80-85.
1. Máquinas elétricas. 2. Redes neurais (Computação). 3. *Wavelet*. 4. Entropia. 5. Localização de falhas (Engenharia). 6. Engenharia elétrica – Dissertações. I. Scalassara, Paulo Rogério, orient. II. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDD (22. ed.) 621.3



---

## TERMO DE APROVAÇÃO

Classificação de Falhas em Máquinas Elétricas Usando Redes Neurais, Modelos *Wavelet* e  
Medidas de Informação

por

Lyvia Regina Biagi Silva

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Engenharia Elétrica” e aprovado em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná.  
Cornélio Procópio, 21/02/2014.

**Banca Examinadora:**

---

Paulo Rogério Scalassara, Prof. Dr.  
Coordenador do Curso

---

Paulo Rogério Scalassara, Prof. Dr.  
Orientador

---

Alessandro Goedtel, Prof. Dr.  
Universidade Tecnológica Federal do Paraná

---

Rodrigo Capobianco Guido, Prof. Dr.  
Universidade de São Paulo

Em memória de minha avó, Mariana.

## AGRADECIMENTOS

Meu inicial agradecimento a Deus, por estar sempre presente em minha vida, guiando meus passos e iluminando o meu caminho.

Aos meus pais Regina e Aylton, pelo constante incentivo e por terem me ensinado o valor do estudo.

À minha irmã Alana, meu cunhado Júnior, meus sobrinhos Leonardo e Heloísa, por todo apoio e auxílio durante meu trabalho, e pelos tão necessários momentos de distração proporcionados.

Ao meu namorado e colega de profissão, Arthur, pela amizade, incentivo, paciência e ajuda dedicados por tanto tempo.

À Universidade Tecnológica Federal do Paraná, Câmpus Cornélio Procópio, pela oportunidade.

Ao meu orientador, prof. Paulo, por toda a ajuda, paciência e pelas valiosas discussões durante a brilhante orientação deste trabalho.

Ao prof. Wagner Endo, por ter me ensinado os primeiros passos da pesquisa científica.

Aos professores Alessandro Goedtel, Cristiano Marcos Agulhari e Fábio Renan Durand pelas valiosas e imprescindíveis dicas de correção à proposta inicial deste trabalho. E por toda a ajuda durante a realização do mesmo.

Aos demais professores, que colaboraram direta ou indiretamente na realização deste trabalho.

Aos colegas do LSI, por toda ajuda e esclarecimentos quanto aos sinais dos motores.

Aos demais colegas do CIPECA.

À CAPES e ao CNPq, pela bolsa e financiamento, em especial ao projeto Casadinho/Procad processo número 552269/2011-5.

“... nada há encoberto, que não venha a ser revelado;  
nem oculto, que não venha a ser conhecido.”

Mt 10 : 26b

## RESUMO

SILVA, Lyvia R. B. **Classificação de Falhas em Máquinas Elétricas Usando Redes Neurais, Modelos *Wavelet* e Medidas de Informação**. 2014. 84 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2014.

Este trabalho apresenta uma proposta de metodologia para detecção e classificação de falhas em motores de indução trifásicos ligados diretamente à rede elétrica. O método proposto é baseado na análise dos sinais de corrente do estator, com e sem a presença de falhas nos rolamentos, estator e rotor. Um dos efeitos desses tipos de falhas é o aparecimento de componentes de frequência específicas, relacionados à velocidade de rotação da máquina. Os sinais foram analisados usando a decomposição *wavelet-packet*, que permite a avaliação dos sinais em bandas de frequência de tamanhos variáveis. A partir dessa decomposição, aplicaram-se medidas de previsibilidade, como entropia relativa, potência de previsão e variância de erro normalizada, obtida com a análise de componentes previsíveis. Com essas medidas, foi possível verificar quais componentes da decomposição são mais previsíveis. Neste trabalho, a variância de erro normalizada e a potência de previsão foram utilizadas como entradas para três topologias de redes neurais artificiais classificadoras: perceptron multicamadas, redes de funções de base radial e mapas auto-organizáveis de Kohonen. Foram testados seis diferentes vetores de entrada para as redes neurais, utilizando medidas de previsibilidade e número de elementos dos vetores variados. Os ensaios foram realizados considerando amostras de sinal de diferentes motores, com vários tipos de falha, operando sob diversos regimes de torque e condições de desequilíbrio de tensão. Primeiramente, os sinais foram classificados em dois padrões: com e sem a presença de falhas. Posteriormente, detectou-se o tipo de falha presente nos sinais: rolamento, estator ou rotor. Por último, as amostras foram classificadas dentro do subgrupo de falha em que estavam presentes.

**Palavras-chave:** Máquinas elétricas. Falhas. Redes Neurais Artificiais. *Wavelet*. Entropia.



## ABSTRACT

SILVA, Lyvia R. B. **Faults Classification in Electric Machines Using Artificial Neural Networks, Wavelet Models and Information Measures.** 2014. 84 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2014.

This work presents a methodology for diagnosis and classification of faults in three-phase induction motors connected directly to the power grid. The proposed method is based on the analysis of the stator current signals, with and without the presence of faults in the bearings, stator and rotor. These faults cause the presence of specific frequency components that are related to the machine rotational speed. The signals were analyzed using wavelet-packet decomposition, which allows a multiresolution evaluation of the signals. Using this decomposition, we estimated some predictability measures, such as relative entropy, predictive power and normalized error variance, obtained with the predictability component analysis. With this measures, we verified which were the most predictable components. In this work, normalized error variance and the predictive power were used as inputs to three topologies of artificial neural networks used as classifiers: multilayer perceptron, radial basis function and Kohonen self-organizing maps. We tested six different input vectors to the artificial neural networks, in which we vary the predictability measures and the number of elements of the vectors. The studies were performed considering samples of signals from different motors, with various kinds of faults, working under several load conditions and with voltage unbalance. The signals were firstly classified in two patterns: with and without the presence of faults. After, we detected the kind of fault was present in the signal: bearing, stator or rotor fault. Last, the samples were classified inside the subgroup in which they were.

**Keywords:** Electrical Machines. Faults. Artificial Neural Networks. Wavelet. Entropy.

## LISTA DE FIGURAS

FIGURA 1	– MIT modelo W22 Premium de fabricação da WEG. ....	27
FIGURA 2	– Principais partes de um MIT. ....	28
FIGURA 3	– Rotor gaiola de esquilo. ....	28
FIGURA 4	– Distribuição estatística dos tipos de falha em MITs. ....	29
FIGURA 5	– Ilustração da geometria do rolamento. ....	29
FIGURA 6	– Vista explodida do rolamento. ....	30
FIGURA 7	– Transformada de Fourier. ....	32
FIGURA 8	– Transformada de Fourier de Tempo Curto. ....	33
FIGURA 9	– Transformada <i>wavelet</i> de tempo contínuo. ....	33
FIGURA 10	– Representação tempo x frequência da DWT. ....	34
FIGURA 11	– Decomposição por transformada <i>wavelet</i> . ....	35
FIGURA 12	– Decomposição multinível por transformada <i>wavelet</i> . ....	35
FIGURA 13	– Decomposição multinível por transformada <i>wavelet-packet</i> . ....	36
FIGURA 14	– Neurônio artificial. ....	39
FIGURA 15	– Ilustração da rede PMC com $L$ camadas escondidas. ....	40
FIGURA 16	– Ilustração da rede RBF. ....	41
FIGURA 17	– Estrutura espacial de um mapa auto-organizável com 9 neurônios. ....	42
FIGURA 18	– Bancada de testes do LSI. ....	44
FIGURA 19	– Bancada de testes do LAIPS. ....	45
FIGURA 20	– (a)-(c) Subamostragem com <i>aliasing</i> . ....	48
FIGURA 21	– (a)-(c) Subamostragem com pré-filtro para evitar <i>aliasing</i> . ....	49
FIGURA 22	– Diagrama de blocos da metodologia proposta. ....	50
FIGURA 23	– Ilustração do nível DC nos sinais de corrente. ....	51
FIGURA 24	– Filtro ideal para diminuição da largura de banda para 2,5 kHz. ....	51
FIGURA 25	– Espectro de frequências de uma fase de um sinal sem falha: (a) antes do pré-processamento; (b) após a filtragem e subamostragem. ....	52
FIGURA 26	– Amostra de 50 ms dos sinais de corrente subamostrados e normalizados. ....	53
FIGURA 27	– Seis níveis de decomposição da DWP. ....	54
FIGURA 28	– (a) 200 ms do sinal pré-processado; (b) espectro de frequência do sinal pré-processado; (c) reconstrução do componente C63; (d) espectro de frequência do componente C63; (e) reconstrução do componente C64; (f) espectro de frequência do componente C64. ....	55
FIGURA 29	– (a) 200 ms do sinal pré-processado; (b) reconstrução do componente C64; (c) erro de reconstrução do componente C64. ....	55
FIGURA 30	– Variâncias de erro normalizadas dos três primeiros componentes do sexto nível de decomposição de uma fase de um sinal ....	57
FIGURA 31	– Obtenção das PDFs: (a) 150 ms do sinal original; (b) PDF do sinal original; (c) 150 ms do erro de reconstrução do componente C64; (d) PDF do erro. ....	57
FIGURA 32	– Potência de previsão: componentes C63, C64 e C65. ....	58
FIGURA 33	– Variâncias de erro normalizadas de todos os componentes do sexto nível de decomposição de uma fase de sinal de corrente. ....	59
FIGURA 34	– PPs de todos os componentes do sexto nível de decomposição de uma fase de sinal de corrente. ....	59

FIGURA 35 – Classificação dos sinais de corrente. .... 62

## LISTA DE TABELAS

TABELA 1	– Descrição das falhas. ....	46
TABELA 2	– Descrição dos MITs. ....	47
TABELA 3	– Fatores de subamostragem utilizados nos sinais. ....	52
TABELA 4	– Características das três topologias de RNAs utilizadas na classificação dos padrões. ....	61
TABELA 5	– Percentual de acerto para a primeira etapa - classificação em dois padrões (normal e falha). ....	63
TABELA 6	– Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras em dois padrões e resultados considerando o método 6. ....	64
TABELA 7	– Padrões da RNA para a classificação das amostras em dois padrões. ...	64
TABELA 8	– Detalhes da classificação das amostras em dois padrões. ....	65
TABELA 9	– Percentual de acerto para a segunda etapa - classificação em três padrões (identificação da falha). ....	66
TABELA 10	– Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras em três padrões e resultados considerando o método 6. ....	66
TABELA 11	– Padrões da RNA para a classificação das amostras em três padrões. ....	67
TABELA 12	– Detalhes da classificação das amostras em três padrões - identificação do tipo de falha. ....	67
TABELA 13	– Percentual de acerto para a etapa 3.a - classificação das falhas de rolamento. ....	68
TABELA 14	– Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras com falha de rolamento e resultados considerando o método 6. ...	68
TABELA 15	– Padrões da RNA para a classificação das amostras com falha de rolamento. ....	69
TABELA 16	– Detalhes da classificação das amostras com falha de rolamento. ....	69
TABELA 17	– Percentual de acerto para a etapa 3.b - classificação das falhas de estator. ....	70
TABELA 18	– Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras com falha de estator e resultados. ....	70
TABELA 19	– Padrões da RNA para a classificação das amostras com falha de estator. ....	71
TABELA 20	– Detalhes da classificação das amostras com falha de estator. ....	71
TABELA 21	– Percentual de acerto para a etapa 3.c - classificação das falhas de rotor. ....	72
TABELA 22	– Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras com falha de rotor e resultados considerando o método 6. ....	72
TABELA 23	– Padrões da RNA para a classificação das amostras com falha de rotor. .	72
TABELA 24	– Detalhes da classificação das amostras com falha de rotor. ....	73
TABELA 25	– Eficiência dos métodos na detecção e identificação do tipo de falha. ...	74
TABELA 26	– Eficiência dos métodos na classificação do tipo de falha no subgrupo em que está presente. ....	74

## LISTA DE SIGLAS E ABREVIATURAS

AR	Autorregressivo
BP	<i>Backpropagation</i>
CCA	<i>Canonical Correlation Analysis</i>
CIPECA	Centro Integrado de Pesquisa em Controle e Automação
CPs	Componentes Principais
CV	Cavalo Vapor
CWT	<i>Continuous Wavelet Transform</i>
DAQ	<i>Data Acquisition</i>
DSP	<i>Digital Signal Processor</i>
DTFT	<i>Discrete-time Fourier transform</i>
DWP	Decomposição <i>Wavelet-Packet</i>
DWT	<i>Discrete Wavelet Transform</i>
EESC	Escola de Engenharia de São Carlos
EMD	<i>Empirical Mode Decomposition</i>
EQM	Erro Quadrático Médio
FFT	<i>Fast Fourier Transform</i>
FPGA	<i>Field Programmable Gate Array</i>
FR	Fase Rebobinada
HOS	<i>Higher Order Spectra</i>
LAIPS	Laboratório de Automação Inteligente de Processos e Sistemas
LM	Levenberg-Marquardt
LSI	Laboratório de Sistemas Inteligentes
MCSA	<i>Machine Current Signature Analysis</i>
MIT	Motor de Indução Trifásico
NS	Não-Supervisionado
PCA	<i>Principal Component Analysis</i>
PDF	<i>Probability Density Function</i>
PMC	<i>Perceptron</i> Multicamadas
PP	Potência de Previsão
PrCA	<i>Predictable Component Analysis</i>
RBF	<i>Radial Basis Function</i>
RNA	Rede Neural Artificial

S	Supervisionado
SOM	<i>Self-Organizing Maps</i>
STFT	<i>Short-Time Fourier Transform</i>
SVM	<i>Support Vector Machine</i>
USP	Universidade de São Paulo
UTFPR	Universidade Tecnológica Federal do Paraná

## LISTA DE SÍMBOLOS

$b$	número de esferas do rolamento
$BD$	diâmetro das esferas do rolamento
$PD$	diâmetro da pista do rolamento
$\phi$	ângulo de contato das esferas
$f_{pi}$	frequência de vibração relacionada a falhas na pista interna
$f_{pe}$	frequência de vibração relacionada a falhas na pista externa
$f_g$	frequência de vibração relacionada a falhas na gaiola
$f_{eg}$	frequência de vibração relacionada a falhas nas esferas
$f_r$	velocidade de rotação da máquina em [Hz]
$f_b$	frequência característica de falha
$f_e$	frequência da rede
$f_v$	frequência característica de falha
$f_{cc}$	frequência característica de falhas por curto-circuito no estator
$p$	número de pares de polos
$s$	escorregamento
$f_{brq}$	componentes espectrais referentes às barras quebradas do rotor
$f_{load}$	frequências devido à variação de carga
$X(j\omega)$	representação do sinal $x(t)$ no domínio da frequência
$CWT(a, d)$	coeficientes <i>wavelet</i>
$\psi$	função <i>wavelet</i>
$a$	fator de compressão da <i>wavelet</i>
$d$	fator de translação da <i>wavelet</i>
$x[n]$	sinal discreto
$N$	número de amostras
$\Phi$	função de escala
$h_n$	filtro de decomposição passa-baixa
$g_n$	filtro de decomposição passa-alta
$j$	índice do somatório
$n$	índice do sinal
$H(X)$	entropia da variável aleatória discreta $X$
$X$	variável aleatória discreta
$\chi$	alfabeto de eventos da variável aleatória $X$
$p(x)$	função de densidade de probabilidade associada a $X$
$e$	Número de Euler
$D_{p  q}$	entropia relativa entre $p$ e $q$
$q(x)$	distribuição de probabilidade associada a $X$
$\lambda_k$	variância de erro normalizada relacionada ao componente $k$
$k$	número do componente
$\mathbf{X}_v$	estado observado do sistema no instante de tempo $v$
$\mathbf{E}_v$	erro de previsão do sistema no instante de tempo $v$
$\mathbf{q}^T \mathbf{e}_v$	projeção do erro de predição
$\mathbf{e}_v$	realização de $\mathbf{E}_v$
$\mathbf{q}^T \mathbf{x}_v$	projeção do estado observado
$\mathbf{x}_v$	realização de $\mathbf{X}_v$

$C_e$	matriz de covariância do erro
$C_o$	matriz de covariância do estado do sistema
$Q$	matriz de autovetores
$P$	matriz de padrões previsíveis
$x_i$	valor de entrada do neurônio artificial
$m$	número de entradas apresentadas ao neurônio artificial
$w_i$	peso sináptico
$u$	potencial de ativação
$\theta$	limiar de ativação
$g(\cdot)$	função de ativação
$y$	saída do neurônio artificial
$L$	número de camadas escondidas
$e_1$	quantidade de neurônios na primeira camada escondida
$e_2$	quantidade de neurônios na segunda camada escondida
$e_L$	quantidade de neurônios na $L$ -ésima camada escondida
$o$	quantidade de neurônios na camada de saída
$R$	Raio de abrangência
$x_c(t)$	sinal de tempo contínuo
$T$	período de amostragem
$f_s$	frequência de amostragem (amostras por segundo)
$\Omega_s$	frequência de amostragem (radianos por segundo)
$x_d[n]$	sequência subamostrada
$M$	fator de subamostragem (número inteiro)
$\Omega_N$	frequência de Nyquist
$X_c(j\Omega)$	transformada de Fourier de tempo contínuo de $x_c(t)$
$T_d$	período de subamostragem
$H_d(e^{j\omega})$	filtro passa-baixa ideal
$\tilde{x}[n]$	saída do sinal $x[n]$ após diminuição da largura de banda por um filtro passa-baixa ideal
$\tilde{X}(e^{j\omega})$	transformada rápida de Fourier de $\tilde{x}[n]$
$\tilde{X}_d(e^{j\omega})$	transformada rápida de Fourier da sequência subamostrada $\tilde{x}_d[n]$
$\tilde{x}_d[n]$	sequência subamostrada após a filtragem
$Xr$	Componente Reconstruído
$Err$	Erro de Reconstrução
$\lambda_{Ifck}$	variância de erro normalizada do componente $Ck$ referente à corrente $If$
$PP_{Ifck}$	potência de previsão do componente $Ck$ referente à corrente $If$



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>17</b>
1.1	JUSTIFICATIVA	18
1.2	OBJETIVOS	19
1.3	ESTRUTURA DA DISSERTAÇÃO	19
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>21</b>
2.1	MÉTODOS DE DIAGNÓSTICO DE FALHAS EM MITs	22
2.2	TRANSFORMADA <i>WAVELET</i>	23
2.3	MEDIDAS DE PREVISIBILIDADE	24
2.4	SISTEMAS INTELIGENTES	24
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>27</b>
3.1	MOTORES DE INDUÇÃO TRIFÁSICOS	27
3.1.1	Falhas de Rolamentos	29
3.1.2	Falhas de Estator	30
3.1.3	Falhas de Rotor	31
3.2	TRANSFORMADA <i>WAVELET</i> E <i>WAVELET-PACKET</i>	32
3.3	MEDIDAS DE INFORMAÇÃO	36
3.3.1	Entropia e Entropia Relativa	36
3.3.2	Potência de Previsão	37
3.3.3	Análise de componentes previsíveis	37
3.4	REDES NEURAIIS ARTIFICIAIS	39
3.4.1	Redes <i>Perceptron</i> Multicamadas	40
3.4.2	Redes de Função de Base Radial	41
3.4.3	Redes Auto-organizáveis de Kohonen	42
<b>4</b>	<b>MATERIAIS E MÉTODOS</b>	<b>44</b>
4.1	SUBAMOSTRAGEM	47
4.2	CLASSIFICAÇÃO DOS SINAIS	49
4.2.1	Pré-processamento do sinal	49
4.2.2	Decomposição <i>Wavelet-Packet</i>	53
4.2.3	Reconstrução do sinal	54
4.2.4	Medidas de Previsão	54
4.2.5	Análise das regiões de interesse	58
4.2.6	Redes Neurais Artificias	60
4.2.7	Decisão	61
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>63</b>
5.1	ETAPA 1 - CLASSIFICAÇÃO EM DOIS PADRÕES	63
5.2	ETAPA 2 - CLASSIFICAÇÃO EM TRÊS PADRÕES	66
5.3	ETAPA 3 - CLASSIFICAÇÃO DO TIPO DE FALHA	67
5.3.1	Etapa 3.a - Falha de Rolamento	67
5.3.2	Etapa 3.b - Falha de Estator	69
5.3.3	Etapa 3.c - Falha de Rotor	71
5.4	EFICIÊNCIA DA METODOLOGIA PROPOSTA	73
<b>6</b>	<b>CONCLUSÃO</b>	<b>76</b>
6.1	TRABALHOS FUTUROS	78
6.2	TRABALHO PUBLICADO	78

**REFERÊNCIAS** ..... 79

## 1 INTRODUÇÃO

Máquinas elétricas são elementos fundamentais na indústria, presentes nas mais diversas aplicações. De acordo com Brito (2002), máquinas elétricas estão sujeitas a uma série de fatores nocivos ao seu funcionamento, o que pode implicar no aparecimento de falhas significativas e até mesmo a quebra da máquina. Um sistema de monitoramento para predição e diagnóstico de falhas em máquinas elétricas é um assunto de grande interesse de pesquisa. Esses sistemas permitem a previsão de falhas iniciais que venham a ocorrer. Assim, podem-se tomar medidas necessárias para que não ocorram falhas mais significativas, evitando danos à própria máquina e a outros equipamentos, ou até mesmo evitando uma parada inesperada na produção. Dessa forma, o diagnóstico correto de falhas e sua detecção na fase inicial permitem a realização de manutenções não programadas de forma rápida e tempo de inatividade curto para o processo em questão, o que auxilia também na redução de perdas financeiras (BELLINI et al., 2008).

O Motor de Indução Trifásico (MIT) é o motor mais utilizado nos mais diversos tipos de indústrias. As condições de operação e o tempo de uso desses motores fazem com que estejam sujeitos a diversas condições de falha, como por exemplo: falha nos rolamentos, falha nos enrolamentos do estator, falha no rotor, entre outras. Métodos não-invasivos para monitoramento são interessantes pois, além de monitorar as condições de operação do motor utilizando somente medições das tensões e correntes, são de baixo custo (ZHANG et al., 2009).

Bellini et al. (2008) destacaram o aumento do uso de técnicas de processamento de sinais, de forma a melhorar os desempenhos de métodos tradicionais para detecção de falhas em motores de indução. Diversos métodos de processamento de sinais são utilizados no diagnóstico de falhas em MITs. Benbouzid e Kliman (2003) analisaram sinais de corrente do estator com o intuito de diagnosticar falhas mecânicas. Os mesmos utilizaram métodos de análise na frequência, Transformada Rápida de Fourier (*Fast Fourier Transform* - FFT), vetor de Park e análise *wavelet*. Os melhores resultados do referido trabalho foram obtidos com a transformada *wavelet*.

A transformada *wavelet*, método de representação do sinal no domínio da frequência, é uma técnica de janelamento do sinal em tamanhos variáveis. Sendo assim, por permitir uma análise mais detalhada de bandas de frequência específicas, apresenta uma vantagem em relação à Transformada de Fourier de Tempo Curto (*Short-Time Fourier Transform* - STFT), que utiliza janelas de tamanho fixo (MEHALA; DAHIYA, 2008). Esta técnica pode ser usada, por exemplo, na extração de características de sinais de corrente de MITs na operação com e sem falha.

Outras ferramentas que podem ser úteis na análise de sinais de corrente do MIT são medidas de informação e previsibilidade. Segundo Scalassara (2009), medidas de previsibilidade são bastante utilizadas para análises de sistemas dinâmicos. Cabal-Yepez et al. (2010) apresentaram um sistema de monitoramento embarcado em *Field Programmable Gate Array* (FPGA) para detecção de múltiplas falhas em MITs utilizando entropia e redes neurais como ferramentas para analisar os sinais de vibração durante o transitório de partida. O método demonstrou bom desempenho na identificação de barras quebradas do rotor, falhas na pista externa de rolamentos, desequilíbrio na distribuição da carga mecânica e suas combinações.

De acordo com Santos, Silva e Suetake (2012), os métodos de detecção de falhas em motores baseados em sistemas inteligentes também apresentaram um aumento nos últimos anos. Dos sistemas inteligentes, um dos mais amplamente difundidos é a Rede Neural Artificial (RNA), que por sua capacidade de aquisição e manutenção do conhecimento, pode ser aplicada na solução de diversos problemas, como por exemplo, na classificação de padrões.

Tendo em vista a importância dos sistemas de monitoramento, detecção e diagnóstico de falhas em MITs e o crescente uso de processamento de sinais e sistemas inteligentes aplicados com essa finalidade, neste trabalho realizam-se a detecção e classificação de falhas em MITs utilizando RNAs com padrões obtidos com medidas de previsibilidade e modelos *wavelet*. A partir de um banco de dados com sinais de corrente coletados de diversos MITs, propõe-se uma metodologia que auxilie a detecção e diagnóstico de falhas. Analisam-se os sinais de corrente de MITs operando sob diversas condições de desequilíbrio de tensão e regimes de torque.

Realiza-se a decomposição dos sinais de corrente utilizando-se a transformada *wavelet-packet*. Em seguida, os componentes da decomposição são reconstruídos e analisa-se sua previsibilidade. Após isso, verificam-se as regiões de interesse, de forma a configurar vetores que serão utilizados como entradas em redes neurais classificadoras. Finalmente, verifica-se a condição das amostras em três diferentes etapas. Na primeira, o objetivo é detectar a presença de falha, classificando as amostras como normais ou com falha. Na segunda etapa, identifica-se o tipo de falha presente: estator, rotor ou rolamento. Finalmente, identifica-se o tipo de falha, dentro do grupo em que está presente. Nesta etapa, analisa-se somente um tipo de falha por vez.

## 1.1 JUSTIFICATIVA

Um sistema de detecção e diagnóstico de falhas pode auxiliar o setor de manutenção de uma indústria de diversas maneiras. Uma das principais vantagens desse sistema está na possibilidade de detectar a falha em seu estágio inicial, o que auxilia a manutenção preditiva e pode também evitar uma parada não programada da máquina, o que pode causar prejuízos à empresa.

A realização deste trabalho possibilitará não só a detecção da falha, mas também a identificação do seu tipo: se é uma falha relacionada aos rolamentos, estator ou rotor. Analisam-se amostras com e sem a presença de falhas. O diagnóstico do tipo da falha presente no MIT é interessante pois permite ao operador, em uma parada de manutenção, verificar diretamente o que necessita ser reparado.

Realiza-se a análise dos sinais de corrente, que tem como vantagem o fato de apresentar menores custos, em relação à análise de vibração, considerando motores de baixa potência, de até 5 CV (Cavalo Vapor). Destaca-se também a possibilidade de embarcar essa proposta em um dispositivo compacto, para utilização em um sistema de monitoramento *online* de falhas.

## 1.2 OBJETIVOS

Nesta seção, descrevem-se os objetivos geral e específicos deste trabalho.

### Objetivo Geral:

Classificar falhas em motores de indução trifásicos utilizando redes neurais artificiais com padrões obtidos com medidas de informação e modelos *wavelet*.

### Objetivos Específicos:

- Analisar características de sinais de máquinas elétricas com falhas;
- aplicar modelos *wavelet* nos sinais das máquinas elétricas e avaliar as características dos componentes;
- avaliar as variações das medidas de informação dos sinais;
- aplicar os métodos de previsibilidade nesses sinais;
- implementar redes neurais classificadoras para separar e classificar sinais com e sem falhas.

## 1.3 ESTRUTURA DA DISSERTAÇÃO

Este trabalho está dividido em seis capítulos, que são descritos a seguir.

O Capítulo 2 apresenta uma revisão bibliográfica, citando os métodos tradicionais utilizados na detecção de falhas em MITs, algumas aplicações da transformada *wavelet*, medidas de previsibilidade e sistemas inteligentes.

O Capítulo 3 define os conceitos abordados neste trabalho. Descrevem-se as teorias relacionadas às principais falhas em MITs, transformada *wavelet* e *wavelet-packet*, medidas de informação e previsibilidade, e redes neurais artificiais.

O Capítulo 4 apresenta os sinais utilizados e estabelece a metodologia adotada para a classificação. No Capítulo 5, discutem-se os resultados dos ensaios realizados. No Capítulo 6, apresentam-se as conclusões, as propostas de continuidade e as publicações relacionadas ao trabalho.

## 2 REVISÃO BIBLIOGRÁFICA

O uso de técnicas de processamento digital de sinais possibilita a análise de sinais em diversas aplicações, sendo de grande utilidade em sistemas de monitoramento. A proposta desses sistemas é prevenir manutenções não-programadas, bem como paradas indesejadas, evitando maiores custos.

Uma técnica de monitoramento que permite observar mudanças no tempo e na frequência em sinais de corrente de MITs é a chamada análise de padrões da corrente do estator (*Machine Current Signature Analysis* - MCSA). Esta técnica pode ser usada para avaliar, a partir do sinal de corrente, se o MIT tem ou não algum tipo de falha (AWADALLAH; MORCOS, 2003).

No trabalho de Benbouzid e Kliman (2003), os autores realizaram uma comparação entre técnicas de processamento de sinais utilizadas para detecção de falhas em MITs. Foram analisados os sinais de corrente do estator para detectar falhas por desgaste dos rolamentos e barras do rotor quebradas. Dentre outros métodos apresentados, estavam a FFT, STFT, análise por transformada *wavelet* e aproximação por vetor de Park, técnica que realiza uma representação bidimensional das correntes trifásicas do MIT. Em relação aos demais métodos apresentados, destacaram-se as vantagens apresentadas pela análise *wavelet*, que permite a análise do sinal no domínio tempo-frequência e tempo-escala, e também a análise de sinais em regime transitório. De acordo com Benbouzid e Kliman (2003), para as falhas mais severas, que apresentem variações nos sinais de corrente e velocidade de uma maneira mais imprevisível, esta análise é mais apropriada.

Bellini et al. (2008) analisaram diversos métodos de diagnóstico para detecção de falhas em motores de indução, mostrando um aumento no uso de processamento de sinais e inteligência artificial para aprimorar os métodos tradicionais. Cabal-Yepez et al. (2011) propuseram a utilização de entropia de informação como parâmetro na detecção de diferentes tipos de falhas em MITs através da análise de uma fase do sinal de corrente em regime. Nesse cenário, torna-se interessante estudar conceitos de teoria da informação juntamente com técnicas de processamento de sinais. Algumas medidas de informação que podem ser utilizadas, em conjunto com os modelos *wavelet*, para detecção de falhas em MITs são: entropia relativa, potência de previsão e variância de erro normalizada, obtida com a análise de componentes previsíveis (*Predictable Component Analysis* - PrCA). A PrCA realiza uma decomposição dos sinais em componentes ordenados por sua previsibilidade, o que possibilita a reconstrução dos mesmos utilizando somente os componentes mais previsíveis.

Santos, Silva e Suetake (2012) realizaram uma revisão bibliográfica em que foram discutidos diversos trabalhos sobre detecção de falhas em máquinas elétricas. Os autores destacaram o crescente uso de sistemas inteligentes, como RNAs, sistemas *fuzzy* e algoritmos genéticos

aplicados à análise e diagnóstico de falhas em MITs. A seguir, discorre-se sobre alguns métodos atualmente utilizados para detecção falhas em MITs, bem como aplicações das transformadas *wavelet*, medidas de previsibilidade e sistemas inteligentes.

## 2.1 MÉTODOS DE DIAGNÓSTICO DE FALHAS EM MITs

Dentre as falhas em máquinas elétricas, pode-se destacar: falhas nos enrolamentos de estator, barras quebradas no rotor, falhas de rolamento, entre outras. Uma técnica de processamento digital de sinais utilizada na extração das características de desempenho da máquina é a *Higher Order Spectra* (HOS), que estende as definições em análise espectral para medidas de terceira e quarta ordem, conhecidas como *bispectrum* e *trispectrum*, respectivamente. Segundo Arthur e Penman (2000), a razão para utilização desse método em um sistema de monitoramento é que ele pode detectar e identificar sistemas não-lineares. Awadallah e Morcos (2003) mostraram que a aplicação dessa técnica a sinais de vibração do rotor pode auxiliar o diagnóstico de falhas em motores de indução.

Em Cardoso et al. (1995) e Cardoso, Cruz e Fonseca (1997), utilizou-se a aproximação por vetor de Park para diagnosticar falhas de rotor e estator, respectivamente. As falhas de estator são normalmente curto-circuitos fase-terra ou entre fases. Segundo Awadallah e Morcos (2003), acredita-se que essas falhas iniciam como curto-circuitos entre espiras, que desenvolvem um curto-circuito maior, tendo um efeito destrutivo nas bobinas do estator. Joksimovic e Penman (2000) demonstraram que as harmônicas induzidas na corrente do estator em uma situação de falha são as mesmas harmônicas produzidas em uma situação sem falha, porém com maior amplitude. Esses componentes harmônicos também são sensíveis a outras características da máquina. Assim, os autores afirmaram que a utilização desses componentes específicos para detecção de curto-circuito entre espiras do estator pode ser ineficiente.

Falhas em rolamentos causam vibrações que podem até danificar a máquina. Mian-hao e Zi-ying (2009) analisaram sinais de vibração para diagnosticar esse tipo de falha. Os autores utilizaram métodos baseados em decomposição empírica (*Empirical Mode Decomposition* - EMD), técnica que particiona a banda de frequência do sinal original de forma adaptativa, de modo a extrair características sobre o estado dos rolamentos. Os autores também utilizaram máquinas de vetores de suporte (*Support Vector Machine* - SVM), método de aprendizado baseado na teoria estatística, associado a algoritmos de aprendizado, utilizado para análise de dados, reconhecimento de padrões e classificação. Chen et al. (2012) utilizaram a transformada *wavelet* discreta e processamento por transformada de Hilbert para diagnosticar sinais com falha de rolamento. Liling e Boqiang (2007) estabeleceram um método para diagnóstico desse tipo de falha com base em transformada de Fourier, filtros adaptativos e técnicas de estimativa do escorregamento com base nas frequências harmônicas do rotor.



## 2.2 TRANSFORMADA WAVELET

A transformada *wavelet* possibilita a representação de um sinal no domínio tempo-frequência, permitindo a análise multirresolução de um sinal. Mallat (1989) discute a aplicação da representação *wavelet* na compressão de dados de imagem e verifica que a ferramenta também pode ser utilizada em outros sistemas, como por exemplo, reconhecimento de padrões.

A análise multirresolução no domínio tempo-frequência pode auxiliar na verificação de detalhes não evidenciados com o uso de técnicas usuais de processamento de sinais. Keeton e Schlindwein (1997) utilizaram sinais de ultrassom tipo Doppler, e mostraram que *wavelets* podem ser utilizadas como ferramenta alternativa à FFT na extração das características tempo-frequência desse tipo de sinal.

Li, Qu e Liao (2007) usaram a transformada *wavelet* contínua no diagnóstico de três tipos de falhas, analisando sinais de vibração. Utilizou-se a família de *wavelets* Haar, a primeira e mais simples das famílias de *wavelets*, caracterizada por seu formato retangular e filtros de comprimento 2. Os resultados foram comparados com diagnósticos obtidos com a *wavelet* Morlet, que apresenta características como suporte infinito e simetria. Porém, a extração das características de falhas dos sinais foi possível com ambas as famílias de *wavelet*.

Yan, Gao e Chen (2013) apresentam uma revisão sobre as recentes aplicações de *wavelets* no diagnóstico de falhas em máquinas. As abordagens apresentadas são divididas nas seguintes categorias: diagnóstico de falhas com base na transformada *wavelet* contínua, discreta, com base na transformada *wavelet-packet* e com base na transformada *wavelet* de segunda geração. Quanto mais similar o sinal é da função *wavelet*, as características de falha são melhor extraídas. Os autores acreditam que com as futuras contribuições teóricas relacionadas à transformada *wavelet*, esta técnica continuará promissora na área de detecção de falhas em máquinas.

Radhika et al. (2010) utilizaram as *wavelets* das famílias Morlet, Haar e Daubechies para extrair características de sinais de correntes de MITs com e sem a presença de falhas de estator. As *wavelets* da família Daubechies são funções de suporte compacto e não são simétricas. Nesse trabalho, os autores analisaram falhas de curto-circuito em uma só fase, entre duas fases, entre fase e terra, e uma fase aberta. O método da árvore de decisão foi utilizado para seleção das características a serem utilizadas. A classificação foi realizada com base no método SVM. A melhor eficiência foi obtida pela análise realizada com a família de *wavelets* Haar, considerando o agrupamento de amostras sem falha e todas as condições de falha abordadas juntas.

### 2.3 MEDIDAS DE PREVISIBILIDADE

Em seu trabalho, DelSole (2004) buscou esclarecer a conexão entre previsibilidade e teoria da informação, previamente discutida também por Schneider e Griffies (1999). São apresentadas informações mais detalhadas sobre três medidas de informação: informação preditiva, entropia relativa e informação mútua, as quais proporcionam estruturas que quantificam a diferença entre duas distribuições.

Schneider e Griffies (1999) apresentaram a Potência de Previsão (PP), medida que se baseia na entropia do sinal e do seu erro de previsão. A PrCA também é apresentada nesse mesmo trabalho. Esta, similar à análise de componentes principais (*Principal Component Analysis* - PCA), decompõe um sistema em componentes ordenadas conforme sua potência de previsão. Essas medidas, a princípio, foram utilizadas em sistemas de previsão do tempo.

DelSole e Chang (2003) compararam as relações entre análise de correlação canônica (*Canonical Correlation Analysis* - CCA), modelo Autorregressivo (AR) e PrCA. A CCA é um procedimento utilizado para encontrar a combinação linear de variáveis em dois conjuntos de dados, de forma que a correlação temporal seja otimizada. O modelo AR relaciona o valor atual de um processo aos seus valores anteriores, com a adição de ruído. Os autores mostraram que modelos baseados na CCA são idênticos à previsões baseadas em modelos AR, quando todos os padrões canônicos são sobrepostos. A vantagem da CCA é que ela permite filtrar os componentes não previsíveis. A PrCA permite a generalização desse procedimento para qualquer modelo de previsão. Nesse trabalho, utiliza-se uma grandeza relacionada à PP, chamada variância de erro normalizada, associada à PrCA. DelSole e Tippett (2007) apresentaram estudos mais detalhados da PrCA.

Scalassara, Maciel e Pereira (2009) e Scalassara, Santos e Maciel (2011) aplicaram medidas de previsibilidade como PP e PrCA para classificar sinais de voz entre saudáveis e patológicos. Utilizando o mesmo banco de dados, Silva et al. (2013) propuseram um método para classificação dos sinais com base na PP e RNAs.

### 2.4 SISTEMAS INTELIGENTES

Um método para diagnóstico de falhas em MITs de simples implementação, é a análise do sinal de corrente, que elimina a necessidade de sensores de vibração e outros equipamentos. Gongora (2013) e Broniera et al. (2013) apresentaram abordagens neurais para detecção de falhas em rolamentos e falha de curto-circuito no estator, respectivamente. Em ambos os trabalhos, realizou-se a análise do sinal de corrente no domínio do tempo. Gongora (2013) realiza um teste de robustez em que são analisados sinais de diferentes motores nas etapas de treinamento e validação da rede neural. O autor obteve percentuais de acerto entre 74% e 97% para os

testes realizados. Nos testes de robustez realizados por Broniera et al. (2013), foram inseridos ruídos nas amostras de validação e foi verificado o percentual de acerto na classificação. Os autores obtiveram 94,54% na classificação das falhas de estator.

Muitos trabalhos apresentam métodos para diagnóstico de falhas em MITs analisando o sinal no domínio da frequência. Lee et al. (2004) utilizaram a transformada de Fourier para detecção de falhas em MITs pelo sinal de corrente, porém, para melhor extração das características, utilizaram também a transformada *wavelet*. Essas informações foram utilizadas como entradas de uma rede neural para decisão sobre qual tipo de falha. Em Barakat et al. (2011), apresentou-se uma técnica baseada em redes neurais adaptativas e transformada *wavelet* discreta para classificar falhas mecânicas em elementos girantes de um sistema de maquinário. O método proposto foi aplicado a um sistema que simula um reator químico, composto por motor elétrico, correias, engrenagens e rolamentos. Medidas estatísticas extraídas dos sub-sinais após a decomposição foram utilizadas como entradas das RNAs.

Ye, Wu e Zargari (2000) apresentaram um método para diagnóstico de falhas mecânicas em MITs (falhas nas barras do rotor), analisando sinais de corrente de estator, com base em redes neurais e nos coeficientes da decomposição *wavelet-packet*. Os componentes da decomposição analisados foram escolhidos de acordo com as frequências características das falhas de rotor. Dessa maneira, o nível de decomposição e o componente escolhido variam conforme o regime de torque e a velocidade em que o motor está operando. Os valores médios dos coeficientes são comparados para motores operando com e sem a presença de falhas. Também com base nos coeficientes de decomposição *wavelet-packet* e usando redes neurais, Wang, Zhang e Zhang (2010) apresentaram um método para diagnóstico de falhas de rolamentos em MITs, analisando os sinais de vibração. Os sinais de vibração foram decompostos utilizando a transformada *wavelet-packet*. Posteriormente os componentes de decomposição foram reconstruídos individualmente. Os autores analisaram a energia de cada componente reconstruído, comparando-se os resultados com e sem a presença de falhas. O vetor de entrada das duas topologias de redes neurais utilizadas foi composto pelos valores normalizados de energia das reconstruções de cada componente.

Zaeri et al. (2011) apresentaram uma metodologia para diagnóstico de falhas em esferas de rolamentos com base na transformada *wavelet* contínua e redes neurais artificiais. Os critérios para escolha das *wavelets* foram baseados na energia máxima e entropia de Shannon. A análise foi realizada em sinais de vibração. Santos, Silva e Suetake (2013) utilizaram um classificador neural com base em modelos *wavelet* e medidas estatísticas, para análise do sinal de corrente do estator. Os autores analisaram sinais de um MIT durante a operação sem falhas, com falhas de curto circuito no estator e falhas nos rolamentos. As medidas estatísticas consideradas para a obtenção do vetor de entrada das redes foram a média, o erro médio quadrático,

*skewness* e *kurtosis*. O coeficiente *skewness* indica o quão simétrica uma distribuição está em torno de sua média, já o coeficiente *kurtosis* mede a forma como a concentração dos dados está do pico da média. Os autores utilizaram duas topologias de RNAs para a classificação das amostras.

Diferentemente de grande parte dos estudos realizados na área de detecção de falhas pela análise dos sinais de corrente, Widodo et al. (2009) analisaram os sinais de corrente em regime transitório, ao invés do sinal de corrente em regime estacionário. Os autores propuseram uma metodologia inteligente para diagnóstico de falhas em MITs, com base na decomposição *wavelet* e SVM.

Schmitt et al. (2013) apresentaram um estudo com sinais de corrente de MITs simulados com rolamentos normais e com falhas. Analisou-se a previsibilidade dos sinais por meio da entropia relativa de componentes *wavelet*, e três topologias de redes neurais foram utilizadas para classificar os padrões. Os autores obtiveram percentuais de acerto entre 70% e 100% para os testes realizados para a classificação de amostras de sinais simulados. Dessa forma, de maneira similar ao realizado por Schmitt et al. (2013), este trabalho apresenta uma proposta de metodologia para diagnóstico de falhas em MITs, com base em modelos *wavelet*, medidas de previsibilidade e RNAs, porém com sinais reais. São analisados sinais de diversos MITs ligados diretamente à rede elétrica, operando sob desequilíbrio de tensão e variações de carga. Além de MITs em condições normais (sem falha) e com falhas de rolamentos, são analisadas também as condições de falhas de estator e rotor.

### 3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, definem-se os conceitos abordados neste trabalho. Descrevem-se teorias relacionadas às falhas de rolamento, transformada *wavelet* e *wavelet-packet*, medidas de informação e previsibilidade e redes neurais artificiais.

#### 3.1 MOTORES DE INDUÇÃO TRIFÁSICOS

Motores de indução podem ser utilizados nas mais diferentes aplicações: bombas, compressores, sopradores, ventiladores, etc. Entre os diversos tipos de motor existentes, o MIT é utilizado em pelo menos 90% da malha industrial (TRZYNADLOWSKI, 2001).


No motor de indução, a corrente alternada é fornecida diretamente ao estator, e o rotor recebe a corrente por indução. Quando excitado por uma fonte polifásica, um campo magnético é produzido no entreferro girando na velocidade síncrona. Essa velocidade é determinada pelo número de polos e a frequência aplicada ao estator (FITZGERALD; KINGSLEY; UMANS, 2003). As Figuras 1 e 2 ilustram um MIT e suas principais partes.




**Figura 1 – MIT modelo W22 Premium de fabricação da WEG.**

**Fonte:** (WEG, 2013b).

O rotor da máquina de indução polifásica pode ser de dois tipos: rotor bobinado ou rotor de gaiola de esquilo. As máquinas com rotor bobinado são utilizadas em aplicações que exigem um alto conjugado resistente ou alta inércia na partida (WEG, 2013a). No motor com rotor bobinado, utilizam-se escovas de carvão conectadas em anéis deslizantes, montados sobre o eixo da máquina. Já o MIT com rotor de gaiola de esquilo é o motor mais comumente usado, devido a sua simplicidade e robustez de construção. Nesse motor, o enrolamento consiste em barras condutoras encaixadas em ranhuras do ferro do rotor, e curto-circuitadas por anéis condutores (FITZGERALD; KINGSLEY; UMANS, 2003). A Figura 3 ilustra um rotor de gaiola de esquilo.

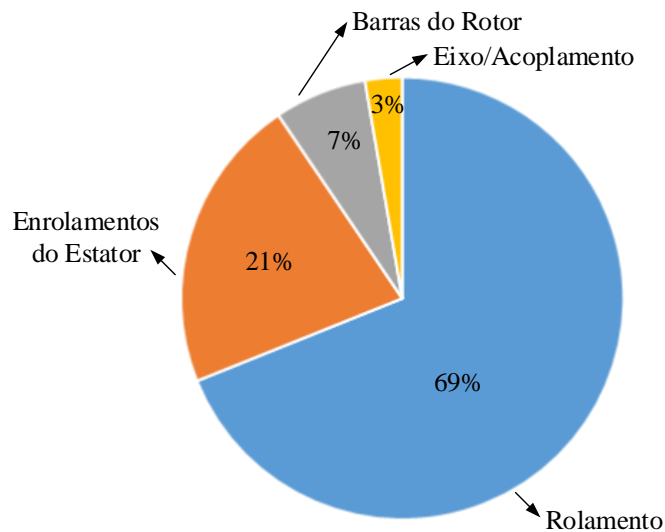


**Figura 2 – Principais partes de um MIT.**  
**Fonte: Adaptado de WEG (2013b).**



**Figura 3 – Rotor gaiola de esquilo.**  
**Fonte: Adaptado de Gongora (2013).**

Haja vista sua grande aplicação, os MITs são expostos a uma variedade de ambientes e condições, podendo estar sujeitos à diversas falhas, que podem contribuir para a degradação e eventual quebra dos mesmos (BRITO, 2002). Segundo Santos (2013), falhas elétricas e mecânicas podem ocorrer como consequência de esforços térmicos, elétricos e mecânicos durante o funcionamento do motor. Uma falha pode ser definida como um desvio de uma propriedade característica de um processo, o que irá causar uma diminuição do seu desempenho. Esse desvio pode ser causado por mudanças físicas temporárias ou permanentes no sistema (BARAKAT et al., 2011). De acordo com Bonnett e Yung (2008), os tipos de falha em MITs são distribuídos estatisticamente conforme ilustrado na Figura 4.



**Figura 4 – Distribuição estatística dos tipos de falha em MITs.**

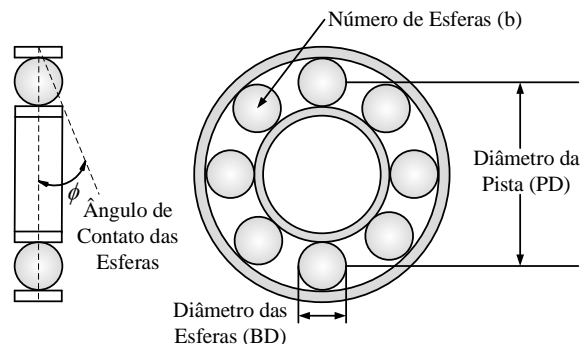
Fonte: Adaptado de Bonnett e Yung (2008).

As seções a seguir apresentam maiores detalhes dos tipos de falhas em MITs.

### 3.1.1 Falhas de Rolamentos

Falhas em rolamentos ocasionam vibrações no eixo da máquina que, por sua vez, causam variações no fluxo que circula no entreferro. Essas variações são refletidas na corrente que circula no estator da máquina, produzindo harmônicas relacionadas às frequências de vibração de cada tipo de falha (BLODT et al., 2004; DEVANEY; EREN, 2004).


As vibrações mecânicas causadas pelas falhas, podem ter suas frequências calculadas através de parâmetros da geometria do rolamento e da velocidade de rotação do eixo da máquina (DEVANEY; EREN, 2004). A Figura 5 ilustra os parâmetros da geometria de um rolamento, sendo  $b$  o número de esferas,  $BD$  o diâmetro das esferas,  $PD$  o diâmetro da pista e  $\phi$  o ângulo de contato das esferas



**Figura 5 – Ilustração da geometria do rolamento.**

Fonte: Adaptado de Eren e Devaney (2004) e Prieto, Roura e Martínez (2011).

A Figura 6 ilustra a vista explodida de um rolamento. É possível observar as partes do mesmo, como pista interna, pista externa, escudo, gaiola e esferas.



**Figura 6 – Vista explodida do rolamento.**

**Fonte: Adaptado de BONES (2011).**

As frequências de vibração associadas às falhas na pista interna ( $f_{pi}$ ), pista externa ( $f_{pe}$ ), gaiola ( $f_g$ ) e esferas ( $f_{eg}$ ) são dadas pelas Equações (1)-(4) respectivamente (DEVANEY; EREN, 2004).

$$f_{pi} = \frac{b}{2} \cdot f_r \cdot \left( 1 + \frac{BD}{PD} \cdot \cos \phi \right) \quad (1)$$

$$f_{pe} = \frac{b}{2} \cdot f_r \cdot \left( 1 - \frac{BD}{PD} \cdot \cos \phi \right) \quad (2)$$

$$f_g = \frac{1}{2} \cdot f_r \cdot \left( 1 - \frac{BD}{PD} \cdot \cos \phi \right) \quad (3)$$

$$f_{eg} = \frac{PD}{2 \cdot BD} \cdot f_r \cdot \left( 1 - \left( \frac{BD}{PD} \right)^2 \cdot \cos^2 \phi \right) \quad (4)$$

em que  $f_r$  é a velocidade de rotação da máquina em [Hz]. As frequências características de falhas ( $f_b$ ), refletidas no espectro de corrente dos sinais são calculadas pela Equação (5) (DEVANEY; EREN, 2004).

$$f_b = |f_e \pm k_1 \cdot f_v| \quad (5)$$

em que  $f_e$  é a frequência da rede,  $k_1 = 1, 2, 3, \dots$  e  $f_v$  é uma das quatro frequências de vibração características definidas pelas Equações (1) a (4).

### 3.1.2 Falhas de Estator

Segundo Thomson e Fenger (2001), as falhas nos enrolamentos do estator podem ser classificadas da seguinte maneira:



- Tipo 1: Curto-circuito entre espiras de uma mesma bobina;
- Tipo 2: Curto-circuito entre bobinas de uma mesma fase;
- Tipo 3: Curto-circuito entre fases;
- Tipo 4: Curto-circuito fase-terra;
- Tipo 5: Abertura de uma fase.

Na ocorrência das falhas dos tipos 1 e 2, o motor continua funcionando. Thomson e Fenger (2001) questionaram por quanto tempo o motor ainda continua operando sob essas condições de falhas. No caso das falhas dos tipos 3 e 4, ocorre a atuação dos equipamentos de proteção, desenergizando os motores. No caso da falha do tipo 5, o motor pode continuar operando, dependendo do conjugado de carga.

Obtêm-se, pela Equação (6), os componentes de frequência correspondentes às falhas por curto-circuito nos enrolamentos do estator ( $f_{cc}$ ).

$$f_{cc} = f_e \left\{ \frac{k_1}{p} (1 - s) \pm k_2 \right\} \quad (6)$$

em que  $p$  é o número de pares de polos,  $k_2 = 1, 3, 5, \dots$  e  $s$  é o escorregamento. Através da Equação (6), busca-se identificar somente os componentes de frequências em consequência de falhas por curto-circuito nas espiras, e não devido a qualquer outro problema ou característica mecânica (THOMSON; FENGER, 2001).

Segundo Thomson (2001), pode existir um tempo de operação do motor antes que o curto-circuito entre espiras evolua para curto-circuito entre fases ou entre curto-circuito fase-terra, o que justifica o desenvolvimento de sistemas detecção de falhas (BACCARINI, 2005).

### 3.1.3 Falhas de Rotor

Falhas por barras quebradas nos rotores em MITs também podem ser detectadas pelo monitoramento da corrente do estator. Analisam-se as frequências de escorregamento em torno da frequência fundamental. Quanto maior a severidade da falha na barra do rotor, maior a amplitude dessas frequências (SIDDIQUI; GIRI, 2012). Os componentes espectrais referentes às falhas por barras quebradas ( $f_{brq}$ ), são dados pela Equação (7).

$$f_{brq} = (1 \pm 2k_1s) f_e \quad (7)$$

em que (SONG et al., 2003). As frequências dadas para  $k_1 = 1$ , são comumente usadas para detectar falhas por barras quebradas (BENBOUZID, 2000).

As amplitudes das frequências em torno da frequência fundamental não sofrem influência somente da severidade das falhas nos elementos do motor. Essas amplitudes também são sensíveis às variações de carga. Segundo Benbouzid (2000), os harmônicos referentes aos efeitos de variação de carga ( $f_{load}$ ) são dados pela Equação (8).

$$f_{load} = f_e \pm k_1 \cdot f_r \quad (8)$$


Se o motor opera sob condições de cargas variáveis, a oscilação no torque resulta em características de harmônicos nos sinais de corrente que podem ser confundidas com as produzidas em situações de falha (BENBOUZID, 2000).

### 3.2 TRANSFORMADA WAVELET E WAVELET-PACKET

A transformada de Fourier de uma função  $x(t)$  é definida pela Equação (9).

$$X(j\omega) = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (9)$$

em que  $X(j\omega)$  é a representação do sinal  $x(t)$  no domínio da frequência. A transformada de Fourier decompõe um sinal em uma soma de senóides de diferentes frequências. A análise de Fourier trata-se de uma transformação do sinal do domínio do tempo para o domínio da frequência, conforme ilustrado pela Figura 7.




**Figura 7 – Transformada de Fourier.**

**Fonte: Adaptado de Misiti et al. (1997).**

A desvantagem da transformada de Fourier é que no domínio da frequência, a informação no tempo é perdida, ou seja, não é possível analisar quando ocorreu algum evento específico no sinal. Assim, transformada de Fourier é interessante para análises de sinais estacionários (MISITI et al., 1997).

A STFT, também chamada de técnica de janelamento do sinal, é uma adaptação da transformada de Fourier que permite a análise de uma pequena seção do sinal para determinado tempo. Ela permite analisar quando e em que frequências ocorre algum evento no sinal (MISITI

et al., 1997). Na Figura 8 observa-se um esboço da técnica de janelamento representada pela STFT.



**Figura 8 – Transformada de Fourier de Tempo Curto.**


Fonte: Adaptado de Misiti et al. (1997).

A análise *wavelet* é baseada na decomposição de um sinal em versões deslocadas e escalonadas de uma mesma função (*wavelet*-mãe), permitindo diferentes resoluções de tempo e frequência (MALLAT, 1999).

A transformada *wavelet* de tempo contínuo (*Continuous Wavelet Transform* - CWT) é calculada pela integral do sinal multiplicado por versões deslocadas e escalonadas de uma função *wavelet*, Equação (10).

$$CWT(a, d) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-d}{a}\right) dt \quad (10)$$

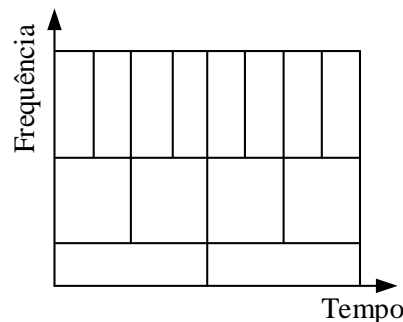
em que  $CWT(a, d)$  são os coeficientes *wavelet*,  $\psi$  é a *wavelet*,  $a$  é o fator de compressão e  $d$  é o fator de translação. Na Figura 9(a), compara-se a *wavelet* com uma seção inicial do sinal original e calcula-se um número (coeficiente) que representa o quanto essa *wavelet* é correlacionada com o sinal original. Quanto maior o coeficiente, maior a similaridade. Os resultados dependem da família de *wavelet* escolhida. Na Figura 9(b), a *wavelet* é deslocada e o passo anterior é repetido até que o processo seja realizado por todo o sinal. O processo também é repetido com a função *wavelet* em outra escala, conforme apresentado na Figura 9(c).



**Figura 9 – Transformada *wavelet* de tempo contínuo.**

Fonte: Adaptado de Misiti et al. (1997).

A transformada *wavelet* discreta (*Discrete Wavelet Transform* - DWT), desenvolvida por Mallat (1989), usa banco de filtros na análise multiresolução. Bancos de filtros de reconstrução perfeita são sistemas que decompõem sinais em bandas de frequência usando filtros seletivos e são capazes de reconstruí-los perfeitamente. Essa técnica possibilita a análise de sinais em diferentes resoluções no tempo e na frequência, através de um janelamento de tamanho variável, conforme pode ser observado na Figura 10. Dessa maneira, pode-se analisar as discontinuidades no sinal, por meio de janelas curtas de alta frequência. Da mesma forma, é possível analisar as baixas frequências por meio de janelas longas.



**Figura 10 – Representação tempo x frequência da DWT.**

Fonte: Adaptado de Keeton e Schlindwein (1997).

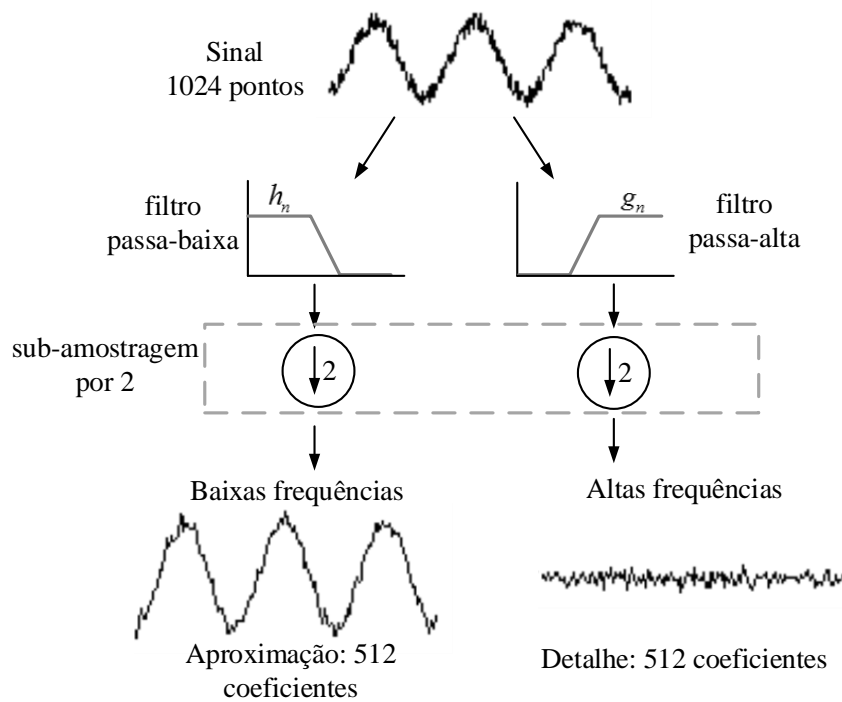
A DWT pode ser usada para decompor um sinal em vários níveis como descrito em Diniz, Silva e Netto (2002). Para um dado sinal discreto  $x[n]$ , com  $N$  amostras, a decomposição *wavelet* consiste em projeções dele mesmo em duas funções chamadas escala ( $\Phi$ ) e *wavelet* ( $\psi$ ).

As funções escala e *wavelet* podem ser definidas usando versões transladadas e escalonadas delas mesmas e também por um par de filtros de decomposição passa-baixa ( $h_n$ ) e passa-alta ( $g_n$ ), conforme as Equações (11) e (12), em que  $j$  é o índice do somatório, o qual depende do comprimento do filtro, e  $n$  é o índice do sinal.

$$\Phi[n] = \sum_j h_n \Phi[2n - j] \quad (11)$$

$$\psi[n] = \sum_j g_n \Phi[2n - j] \quad (12)$$

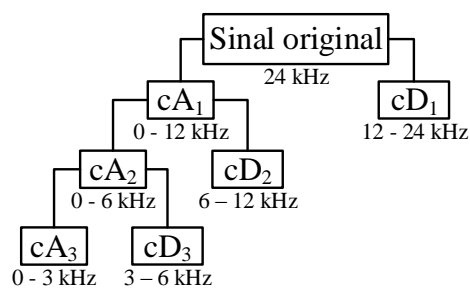
A decomposição é obtida pela convolução do sinal com o par de filtros, o que decompõe o sinal em duas partes: componentes de baixa e alta frequência, chamados de aproximação e detalhe respectivamente. Para cada nível, os sinais são subamostrados por um fator 2. Na Figura 11, pode-se observar esse processo. Considera-se um sinal com 1024 pontos. São obtidos os coeficientes de aproximação e detalhe, cada um com 512 pontos.



**Figura 11 – Decomposição por transformada *wavelet*.**

Fonte: Adaptado de Misiti et al. (1997).

Em análises multinível, decompõem-se sucessivamente os coeficientes de aproximação, conforme pode ser observado na Figura 12.




**Figura 12 – Decomposição multinível por transformada *wavelet*.**

Fonte: Adaptado de Misiti et al. (1997).

Observa-se, na Figura 12, o sinal original, com frequência igual a 24 kHz. Os blocos  $cA_1$  e  $cD_1$  representam os coeficientes de aproximação e detalhe do primeiro nível de decomposição. Esses coeficientes correspondem a bandas de frequência de 0 a 12 kHz e 12 a 24 kHz, respectivamente. Para o segundo nível de decomposição, somente o componente relacionados às baixas frequências (bloco  $cA_1$ ) é decomposto. Assim, são obtidos os componentes  $cA_2$  e  $cD_2$ , que correspondem às faixas de frequência de 0 a 6 kHz e 6 a 12 kHz. No nível seguinte, o processo é repetido.

Na Decomposição *Wavelet-Packet* (DWP) , ambos os componentes de baixa e alta frequência são decompostos novamente em cada um dos próximos níveis (MALLAT, 1999), conforme pode ser observado na Figura 13. Os blocos C1 e C2 representam os coeficientes de aproximação e detalhe do primeiro nível de decomposição. Os blocos C3, C4, C5 e C6 representam os componentes do segundo nível de decomposição. Os demais blocos representam os componentes do terceiro nível de decomposição. Observa-se a frequência do sinal original, igual a 24 kHz e a faixa de frequências relacionada a cada componente, abaixo de cada bloco.



**Figura 13 – Decomposição multinível por transformada *wavelet-packet*.**

**Fonte:** Autoria própria.

A reconstrução de um sinal utilizando os componentes *wavelet* é o processo inverso da decomposição. Se todos os componentes são utilizados nesse processo, obtém-se novamente o sinal original. Este processo é realizado sobreamostrando cada coeficiente por um fator de 2 seguido de convolução com os filtros de reconstrução criados com os filtros de decomposição,  $h_n$  e  $g_n$  (DINIZ; SILVA; NETTO, 2002; MALLAT, 1999). Devido à sobreamostragem, os sinais reconstruídos têm o mesmo tamanho que o sinal original.

### 3.3 MEDIDAS DE INFORMAÇÃO

Nesta seção, apresentam-se algumas medidas de informação como entropia e entropia relativa, as quais são calculadas com base na função de densidade de probabilidade (*Probability Density Function* (PDF) ).

#### 3.3.1 Entropia e Entropia Relativa

Segundo Shannon (1948), entropia é uma medida da aleatoriedade ou imprevisibilidade de uma variável aleatória. Conforme Cover e Thomas (2006), a entropia,  $H(X)$  , de uma variável aleatória discreta  $X$  é dada pela Equação (13).

$$H(X) = - \sum_{x \in \mathcal{X}} p(x) \log_2 p(x) \quad (13)$$

onde  $\chi$  é o alfabeto de eventos da variável  $X$  e  $p(x)$  a PDF associada a essa variável. A entropia é expressa em *bits*, uma vez que o logaritmo possui base 2. Se a base do logaritmo for  $e$  (base neperiana), a entropia é medida em *nats*.

A entropia relativa entre dois sinais, pode ser tratada como uma medida da distância entre duas distribuições de probabilidade. A entropia relativa,  $D_{p||q}$ , é calculada de acordo com a Equação (14), conforme Cover e Thomas (2006). Sendo  $p(x)$  e  $q(x)$  as PDFs dos sinais.

$$D_{p||q} = \sum_{x \in \chi} p(x) \log_2 \frac{p(x)}{q(x)} \quad (14)$$

### 3.3.2 Potência de Previsão

A PP é uma medida de previsibilidade baseada no cálculo da entropia, sendo aplicável tanto a sistemas univariáveis quanto a multivariáveis. Ao contrário de medidas baseadas no erro médio quadrático, a PP é invariante a transformações lineares arbitrárias. A PP não se baseia em pressupostos específicos sobre a distribuição das variáveis aleatórias envolvidas ou sobre o modelo adotado (SCHNEIDER; GRIFFIES, 1999).

No trabalho de Schneider e Griffies (1999), a PP é obtida pela diferença entre as entropias do sinal original e do seu erro de previsão. No entanto, em Scalassara, Maciel e Pereira (2009), a PP é obtida utilizando a entropia relativa entre o sinal original e seu erro de previsão. A mesma pode ser descrita pela Equação (15).

$$PP = 1 - e^{-D_{p||q}} \quad (15)$$

Se a entropia relativa cresce, é porque aumenta a diferença entre as PDFs do sinal e de seu erro de reconstrução e a previsibilidade é alta. Os valores de  $D_{p||q}$  variam entre 0 e infinito e os da PP variam de 0 a 1.

### 3.3.3 Análise de componentes previsíveis

A análise de componentes previsíveis é uma transformação de um vetor de dados em um novo sistema de coordenadas, de acordo com a previsibilidade em cada direção. É similar à análise de componentes principais, porém a previsibilidade é analisada ao invés da variância. A projeção de dados na primeira coordenada representa a mais alta previsibilidade, a projeção na segunda coordenada representa a segunda mais alta previsibilidade, e assim sucessivamente. Essas coordenadas são chamadas de componentes previsíveis, e são mutuamente descorrelacionadas (SCALASSARA; SANTOS; MACIEL, 2011). Segundo DelSole e Chang (2003), essa técnica identifica os componentes que o modelo prevê com maior precisão.

A PrCA é obtida por um procedimento que projeta a estimativa do erro de uma série temporal em seus Componentes Principais (CPs) e normaliza pelo desvio padrão destes. A previsibilidade do sistema é quantificada pela variância de erro normalizada, que é inversamente proporcional à PP. A variância de erro normalizada relacionada a cada componente é descrita por  $\lambda_k$ , onde  $k$  é o número da componente. A PrCA simultaneamente diagonaliza a matriz de covariância do sinal e a matriz de covariância do erro de previsão (SCHNEIDER; GRIFFIES, 1999).

Considera-se que o estado observado do sistema é  $\mathbf{X}_v$  no instante de tempo  $v$  e o erro de previsão é  $\mathbf{E}_v$ , ambos com média zero. Deseja-se determinar o vetor de projeção  $\mathbf{q}$  de forma que o erro projetado otimize  $\lambda$ .

O erro projetado é dado por  $\mathbf{q}^T \mathbf{e}_v$ , onde  $\mathbf{e}_v$  é a realização de  $\mathbf{E}_v$ . De forma similar, a projeção do estado observado é  $\mathbf{q}^T \mathbf{x}_v$ , onde  $\mathbf{x}_v$  é a realização de  $\mathbf{X}_v$ . Ambas as projeções são escalares. A variância de erro normalizada é obtida pela razão desses sinais, conforme mostra a Equação (16).

$$\lambda = \frac{\mathbf{q}^T \mathbf{C}_e \mathbf{q}}{\mathbf{q}^T \mathbf{C}_o \mathbf{q}} \quad (16)$$

onde  $\mathbf{C}_e = \langle \mathbf{E}_v \mathbf{E}_v^T \rangle$  e  $\mathbf{C}_o = \langle \mathbf{X}_v \mathbf{X}_v^T \rangle$  são as matrizes de covariância projetadas do erro do modelo e do estado do sistema. Onde  $\{\cdot\}^T$  é a transposição da matriz e  $\langle \cdot \rangle$  o valor esperado da mesma. Deseja-se determinar o vetor  $\mathbf{q}$  que minimize  $\lambda$  em (16). Logo, a variância de erro normalizada é associada ao vetor de projeção  $\mathbf{q}$  (DELSOLE; CHANG, 2003).

Conforme DelSole e Chang (2003),  $\lambda$  é uma forma de quociente de Rayleigh, em que a otimização do quociente  $\lambda$  em relação a  $\mathbf{q}$  é um problema de autovalor generalizado, conforme Equação (17).

$$\mathbf{C}_e \mathbf{q} = \lambda \mathbf{C}_o \mathbf{q} \quad (17)$$

Os autovetores  $\mathbf{q}$  são ordenados pelos seus autovalores em ordem crescente, de forma que o primeiro autovetor projete o vetor  $\mathbf{q}$  de forma que minimize  $\lambda$  sobre todos possíveis padrões, o segundo autovetor minimiza  $\lambda$  sobre todos os padrões descorrelacionados com o principal padrão, e assim sucessivamente. Os autovalores correspondentes são os valores de  $\lambda$  associados a cada autovetor.

A matriz composta pelas colunas de autovetores da Equação (17),  $\mathbf{Q}_k$ , é dada por  $\mathbf{Q} = [\mathbf{q}_1 \mathbf{q}_2 \cdots \mathbf{q}_M]$  e pode ser normalizada de forma que  $\mathbf{Q}^T \mathbf{C}_o \mathbf{Q} = \mathbf{I}$  e  $\mathbf{Q}^T \mathbf{C}_e \mathbf{Q} = \Lambda$ , onde  $\Lambda$  é matriz diagonal de autovalores associados a (17). A matriz de padrões (componentes) previsíveis  $\mathbf{P} = [\mathbf{p}_1 \mathbf{p}_2 \cdots \mathbf{p}_M]$ , em que  $\mathbf{p}_k$  são os padrões previsíveis, é biortogonal a  $\mathbf{Q}$ , ou seja,  $\mathbf{P} \mathbf{Q}^T = \mathbf{I}$  (DELSOLE; CHANG, 2003).

Uma vantagem da PrCA é que ela possibilita a remoção dos padrões menos previsíveis de uma decomposição, e a reconstrução do sinal somente com os componentes mais previsíveis.




Assim, o sinal reconstruído é mais previsível que o sinal original (SCALASSARA; SANTOS; MACIEL, 2011).

### 3.4 REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Estas possuem a capacidade de aquisição e manutenção do conhecimento (baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões, denominadas sinapses artificiais (SILVA; SPATTI; FLAUZINO, 2010).

A estrutura das RNAs foi desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos e do próprio cérebro humano. Os elementos computacionais ou unidades processadoras, denominadas neurônios artificiais, são modelos bem simplificados dos neurônios biológicos (SILVA; SPATTI; FLAUZINO, 2010). A estrutura mostrada na Figura 14 representa o neurônio artificial.



**Figura 14 – Neurônio artificial.**

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

O funcionamento do neurônio artificial pode ser resumido por:

- Apresentação de um conjunto de valores de entrada  $x_i$  ( $x_1, x_2, \dots, x_m$ ), em que  $m$  é o número de entradas;
- Multiplicação de cada entrada do neurônio pelo respectivo peso sináptico  $w_i$  ( $w_1, w_2, \dots, w_m$ );
- Obtenção do potencial de ativação  $u$  ( $u = \sum_{i=1}^m w_i \cdot x_i - \theta$ ), onde  $\theta$  é o limiar de ativação;
- Aplicação da função de ativação ( $g(\cdot)$ );
- Compilação da saída  $y$  ( $y = g(u)$ ).

De acordo com Haykin (2009), o poder computacional de uma rede neural é extraído através de sua estrutura paralelamente distribuída e sua habilidade de aprender e generalizar.

Generalização refere-se à capacidade da rede neural de produzir saídas razoáveis para entradas diferentes das utilizadas durante o treinamento (aprendizado).


Há vários trabalhos na literatura que utilizam redes neurais para reconhecimento e classificação de padrões. Três topologias de redes neurais que podem ser utilizadas como classificadoras são: *Perceptron* Multicamadas (PMC), redes de funções de base radial (*Radial Basis Function* - RBF) e mapas auto-organizáveis de Kohonen.

### 3.4.1 Redes *Perceptron* Multicamadas

O *Perceptron* é basicamente uma rede neural de camada única. Porém, essa rede é limitada à classificação de padrões linearmente separáveis. Para superar as limitações práticas do *Perceptron*, considera-se a *Perceptron* Multicamadas. Na rede PMC, os neurônios são organizados em camadas, sendo pelo menos uma camada de neurônios escondida, a qual é responsável pelo aprendizado relacionado a alguma aplicação específica (HAYKIN, 2009).

De acordo com Silva, Spatti e Flauzino (2010), as redes PMC são consideradas como arquiteturas versáteis quanto à aplicabilidade e são caracterizadas também pelas elevadas possibilidades de aplicações em diversos tipos de problemas, tais como: aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais, otimização de sistemas.

A rede PMC pertence à arquitetura *feedforward* de camadas múltiplas, cujo treinamento é efetivado de forma supervisionada. O fluxo de informações segue uma única direção, das entradas, percorrendo as camadas intermediárias, sendo finalizado nas camadas de saída. A Figura 15 ilustra a rede PMC com  $L$  camadas escondidas, em que  $e_1$ ,  $e_2$  e  $e_L$  representam, respectivamente, a quantidade de neurônios na primeira, segunda e  $L$ -ésima camadas intermediárias. O parâmetro  $o$  representa a quantidade de neurônios na camada de saída.



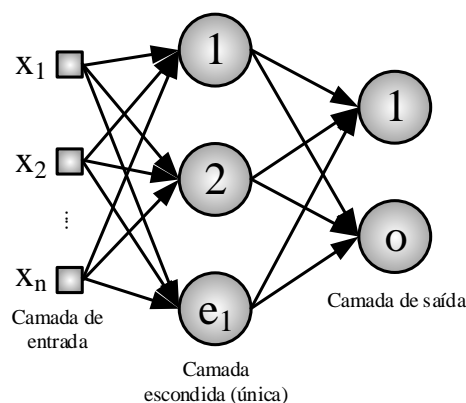
**Figura 15 – Ilustração da rede PMC com  $L$  camadas escondidas.**

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

O algoritmo comumente utilizado no treinamento das redes PMC é o *backpropagation*, baseado no método do gradiente descendente. A aplicação desse método em relação ao vetor de pesos  $\mathbf{w}$  tem como objetivo a busca do valor ótimo para o erro quadrático médio entre a saída desejada e a resposta do combinador linear. Porém, a utilização deste algoritmo tende a convergir muito lentamente, exigindo-se um elevado esforço computacional. Dentre as técnicas de otimização utilizadas a fim de reduzir o tempo de convergência e esforço computacional requeridos pelo algoritmo *backpropagation*, destaca-se o algoritmo de Levenberg-Marquardt. Trata-se de um método gradiente de segunda ordem, que utiliza a técnica de otimização dos mínimos quadrados para modelos não-lineares, que pode ser incorporado ao algoritmo *backpropagation* (HAGAN; MENHAJ, 1994).

### 3.4.2 Redes de Função de Base Radial

Assim como as redes PMC, as redes de funções de base radial podem ser empregadas em problemas que envolvem aproximação de funções e classificação de padrões. A rede RBF também pertence à arquitetura *feedforward*. A Figura 16 ilustra a rede RBF, em que  $e_1$  indica a quantidade de neurônios na primeira (e única) camada intermediária. O parâmetro  $o$  representa a quantidade de neurônios na camada de saída. A função de ativação utilizada na camada intermediária é do tipo gaussiana.



**Figura 16 – Ilustração da rede RBF.**

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

A estratégia de treinamento da RBF é constituída de duas fases ou estágios bem distintos entre si (SILVA; SPATTI; FLAUZINO, 2010). No primeiro estágio de treinamento, que compõe a fase de ajuste dos pesos sinápticos dos neurônios da camada intermediária, adota-se um método de aprendizagem não-supervisionado, dependente das características dos dados de entrada. O algoritmo utilizado nessa etapa de treinamento é denominado *k-means*, em que  $k$  é o número de centros de clusterização (DUDA; PETER; STORK, 2001). O número dos centros de clusterização é definido pela quantidade de neurônios na camada intermediária. O critério de

alocação das amostras de cada padrão é definido pela distância euclidiana entre a amostra e os referidos centros. O segundo estágio de treinamento consiste no ajuste dos pesos dos neurônios da camada de saída, que de forma similar ao PMC, utiliza o método do gradiente descendente.


### 3.4.3 Redes Auto-organizáveis de Kohonen

Nas redes PMC e RBF na etapa de treinamento, são apresentados os padrões de entrada e as respectivas saídas desejadas. Nas redes de Kohonen conta-se apenas com o conjunto de padrões de entrada, inexistindo, assim, as saídas desejadas (SILVA; SPATTI; FLAUZINO, 2010). As redes se auto-organizam por meio de métodos de treinamento competitivo, tem como princípio básico a concorrência entre os neurônios. Esse tipo de treinamento é capaz de detectar similaridades entre os padrões do conjunto de entrada, e agrupá-los em classes (KOHONEN, 1988).

Os mapas auto-organizáveis de Kohonen (*Self-Organizing Maps* - SOM) são arquiteturas de redes neurais de estrutura reticulada com aprendizado competitivo. O algoritmo competitivo apresenta algumas similaridades com o algoritmo *k-means*, também é relacionado às características dos padrões de entrada e é utilizado no agrupamento de dados. Porém, diferentemente do *k-means*, não é necessário especificar a quantidade de grupos a ser considerada.

A implementação do algoritmo competitivo permite a identificação do número de classes após a convergência do método. As conexões laterais, que demonstram como a saída do neurônio vencedor influencia os demais neurônios da rede são fornecidas por mapas topológicos de vizinhança. Um dos principais critérios de vizinhança consiste na especificação do raio  $R$  de abrangência, que é responsável pela definição da vizinhança de um determinado neurônio.

A Figura 17 ilustra um exemplo de mapa bidimensional constituído de 9 neurônios, com 3 linhas e 3 colunas de neurônios (estrutura 3x3).



**Figura 17** – Estrutura espacial de um mapa auto-organizável com 9 neurônios.


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

No caso da Figura 17, considerando o neurônio número 5, para um raio de vizinhança igual a 1 ( $R = 1$ ), os vizinhos seriam os neurônios de número 2, 4, 6 e 8. Para um raio de vizinhança igual a 1,75 ( $R = 1,75$ ), a vizinhança seria composta pelos neurônios 1, 2, 3, 4, 6, 7, 8 e 9.

Este capítulo apresentou alguns conceitos relacionados à falhas em MITs, transformada *wavelet*, medidas de informação e RNAs. Os conceitos apresentados serão utilizados para a descrição da metodologia proposta para classificação de falhas em MITs no Capítulo 4.

## 4 MATERIAIS E MÉTODOS


Os dados utilizados neste trabalho foram coletados seguindo os procedimentos descritos em Gongora (2013) e Suetake (2012), como uma parceria entre o Laboratório de Automação Inteligente de Processos e Sistemas (LAIPS) da Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo (USP) e o Laboratório de Sistemas Inteligentes (LSI) do Centro Integrado de Pesquisa em Controle e Automação (CIPECA) da Universidade Tecnológica Federal do Paraná (UTFPR) - Câmpus Cornélio Procópio. A Figura 18 apresenta a bancada de testes em que foram realizados os ensaios dos motores no LSI. A Figura 19, extraída do trabalho de Santos (2013), apresenta a bancada de testes do LAIPS.



**Figura 18 – Bancada de testes do LSI.**

**Fonte:** Autoria própria.

A utilização da bancada de testes, proposta por Goedtel (2007), permite o monitoramento e aquisição de diversas características de operação dos MITs, como tensão, corrente, vibração, torque e velocidade. Uma máquina de corrente contínua, operando como gerador, realiza a imposição de torque ao eixo do MIT. Utiliza-se uma placa de aquisição de dados (*Data Acquisition* - DAQ), modelo 6221 de fabricação da *National Instruments*.



**Figura 19 – Bancada de testes do LAIPS.**  
**Fonte: Adaptado de Santos (2013).**

O banco de dados é composto por aquisições de características de MITs operando sob diversas condições (operação sem falha, com falha no estator, rolamentos e rotor). Nas amostras com falhas de estator, consideram-se diferentes percentuais de curto-circuito entre espiras de uma mesma fase. Nas amostras com falha de rolamento, têm-se falhas nas pistas interna e externa, nas esferas, falha por curto-circuito e por desgaste excessivo. A falha por curto-circuito nos rolamentos é uma falha localizada, inserida de forma a emular um dano causado por uma descarga elétrica nos rolamentos. Os procedimentos para inserção das falhas nos rolamentos utilizados neste trabalho são descritos em Gongora (2013). As amostras referentes às falhas de rotor são compostas por ensaios do MIT operando com uma, duas e quatro barras quebradas. Para todos os casos, consideram-se diferentes regimes de carga (operação a vazio até a sobrecarga) e condições de desequilíbrio da tensão de alimentação do motor (0 a 10%). Durante a aquisição dos dados de cada ensaio não houve alterações no regime de carga e na tensão de alimentação do motor.

A Tabela 1 descreve algumas características do banco de dados de falhas usado nesse trabalho. Ao todo, tem-se 348 sinais normais, 292 com falha nos rolamentos, 1074 com falhas

no estator e 240 com falhas no rotor. Os ensaios foram realizados considerando o mínimo regime de torque de aproximadamente 0,5 Nm. Devido ao acoplamento mecânico existente entre os equipamentos da bancada, às perdas por atrito e ventilação, não foi possível obter valores menores de torque. Os ensaios em regime de sobrecarga consideraram aproximadamente 1 Nm a mais que o regime de operação nominal dos MITs utilizados.

**Tabela 1 – Descrição das falhas.**

Motor	Origem	Condição de Operação	Descrição das Falhas	Regime de Torque	Frequência de Amostragem	Número de Aquisições
(1)	LSI	Normal	-	0,5, 1, 2, 3 4 e 5 Nm	25 kHz	66
(2)	LSI	Normal	-	0,5, 1, 2, 3 4 e 5 Nm	25 kHz	36
		Falha de Rolamento	Desgaste Excessivo			36
			Curto Circuito*			34
			Pista Interna			66
Pista Externa	36					
(3)	LSI	Normal	-	0,5, 1, 2, 3	25 kHz	60
		Falha de Rolamento	Falha nas Esferas	4, 5, 6, 7,		60
			Pista Externa	8 e 9 Nm		60
(4)	LAIPS	Normal	-	0,5, 1, 2, 3 4 e 5 Nm	30 kHz	6
		Falha de Estator	Curto Circuito (1%)			60
			Curto Circuito (3%)			60
			Curto Circuito (5%)			60
	Curto Circuito (7%)		54			
	LSI	Normal	-	0,5, 1, 2, 3 4 e 5 Nm	15,5 kHz	60
Falha de Estator		Curto Circuito (1%)	60			
(5)	LSI	Falha de Estator	Curto Circuito (3%)	0,5, 1, 2, 3 4 e 5 Nm	15,5 kHz	60
			Curto Circuito (5%)			60
			Curto Circuito (10%)			60
			Curto Circuito (15%)			60
			Curto Circuito (20%)			60
			Normal			-
(6)	LSI	Falha de Estator	Curto Circuito (1%)	0,5, 2, 4, 6, 8 e 9 Nm	15,5 kHz	60
			Curto Circuito (3%)			60
			Curto Circuito (5%)			60
			Curto Circuito (10%)			60
(7)	LAIPS	Falha de Rotor	1 Barra Quebrada	0,5, 1, 2, 3 4 e 5 Nm	30 kHz	60
			2 Barras Quebradas			60
			4 Barras Quebradas Consecutivas			60
			4 Barras Quebradas Alternadas			60
<b>TOTAL DE AMOSTRAS</b>						1954

\* falhas localizadas em rolamentos, de forma a caracterizar danos causados por descargas elétricas

**Fonte: Autoria própria.**



A Tabela 2 apresenta as principais características dos MITs utilizados neste trabalho. Todos os MITs são de 4 polos, 60 Hz, 220V/380V.

**Tabela 2 – Descrição dos MITs.**

<b>Motor</b>	<b>Potência</b>	<b>Linha</b>	<b>Velocidade Nominal</b>	<b>Rendimento %</b>	<b>Fator de Potência</b>
(1)	1 CV	Alto Rendimento	1730 rpm	82,6	0,8
(2)	1 CV	<i>Standard</i>	1720 rpm	79,5	0,78
(3)	2 CV	Alto Rendimento	1750 rpm	84,2	0,78
(4)	1 CV - 1 FR	<i>Standard</i>	1720 rpm	79,5	0,82
(5)	1 CV - 3 FR	Alto Rendimento	1730 rpm	80,5	0,81
(6)	2 CV - 3 FR	Alto Rendimento	1750 rpm	84,2	0,78
(7)	1 CV	<i>Standard</i>	1715 rpm	...	...

1 FR - Uma Fase Rebobinada  
3 FR - Três Fases Rebobinadas

**Fonte: Autoria própria.**

Todos os MITs apresentados na Tabela 2, com exceção MIT (7), estão disponíveis no LSI. As características coletadas com o MIT (7) emulavam a operação com falha de rotor, e a aquisição foi realizada no LAIPS. Assim, as características rendimento e fator de potência desse MIT não estão presentes na Tabela 2.

Devido à diferença entre as frequências de amostragem dos sinais do banco de dados, conforme apresentado na Tabela 1, os sinais foram subamostrados. Dessa forma foi possível obter frequências similares para todas as amostras. Com isso, consegue-se melhor extrair as características dos sinais e analisar a região de interesse com faixa de frequência de 0 a 2,5 kHz. A seguir explica-se o processo de subamostragem.

#### 4.1 SUBAMOSTRAGEM

Um sinal de tempo contínuo,  $x_c(t)$ , pode ser representado por um sinal de tempo discreto composto pela sequência de amostras,  $x[n]$ , Equação (18). Em que  $n$  é um inteiro e  $T$  é o período de amostragem.


$$x[n] = x_c(nT) \quad (18)$$

A frequência de amostragem,  $f_s$ , é definida por  $f_s = 1/T$ , em amostras por segundo, ou  $\Omega_s$ , onde  $\Omega_s = 2\pi/T$ , em radianos por segundo (OPPENHEIM; SCHAFER, 2010). A redução da taxa de amostragem de um sinal é conhecida como subamostragem (ou *downsampling*) e é descrita pela Equação (19). Em que  $x_d[n]$  é a sequência subamostrada e  $M$  é o fator de subamostragem (número inteiro)

$$x_d[n] = x[nM] = x_c(nMT) \quad (19)$$

O teorema de amostragem de Nyquist estabelece a mínima frequência de amostragem (taxa de Nyquist) para que não ocorra *aliasing*,  $\Omega_s \geq 2\Omega_N$ , onde a frequência  $\Omega_N$  é a máxima frequência do sinal. *Aliasing* é o efeito da sobreposição de frequências, em que ocorre uma distorção do sinal amostrado.


As Figuras 20 e 21 apresentam o processo de subamostragem de um sinal. Ilustra-se a situação em que ocorre *aliasing* e apresenta-se o método com a utilização de um pré-filtro para evitar o *aliasing*. Na Figura 20(a) tem-se uma possível transformada de Fourier de tempo contínuo de  $x_c(t)$ ,  $X_c(j\Omega)$ . A Figura 20(b) mostra a transformada de Fourier de tempo discreto (*Discrete-time Fourier transform* - DTFT) da sequência  $x[n]$ , quando  $\Omega_s = 4\Omega_N$ . Assim,  $\omega_N = \Omega_N T = \pi/2$ . Se o sinal for subamostrado por um fator  $M = 3$ , obtém-se a sequência  $x_d[n] = x[3n] = x_c(n3T)$ , cuja DTFT está traçada na Figura 20(c), com frequência normalizada  $\omega = \Omega T_d$ , em que  $T_d$  é o período de subamostragem, dado por  $T_d = MT$ . Como  $M\omega_N = 3\pi/2$ , ocorre *aliasing*. Para que não ocorra *aliasing* na subamostragem por um fator  $M$ , é necessário que  $M\omega_N \leq \pi$ .



**Figura 20 – (a)-(c) Subamostragem com *aliasing*.**

**Fonte: (OPPENHEIM; SCHAFFER, 2010).**

Se a largura de banda do sinal for diminuída antes da subamostragem, ou seja, se o sinal  $x[n]$  passar por um filtro passa-baixa ideal, com frequência de corte igual a  $\pi/M$  (Figura 21(a) -  $H_d(e^{j\omega})$ ), a saída  $\tilde{x}[n]$  pode ser subamostrada sem que ocorra *aliasing*. A Figura 21(b) ilustra a DTFT  $\tilde{X}(e^{j\omega})$  da saída  $\tilde{x}[n]$ . A Figura 21(c) ilustra a DTFT  $\tilde{X}_d(e^{j\omega})$  da saída subamostrada  $\tilde{x}_d[n]$  (OPPENHEIM; SCHAFER, 2010).



**Figura 21 – (a)-(c) Subamostragem com pré-filtro para evitar *aliasing*.**

**Fonte: (OPPENHEIM; SCHAFER, 2010).**

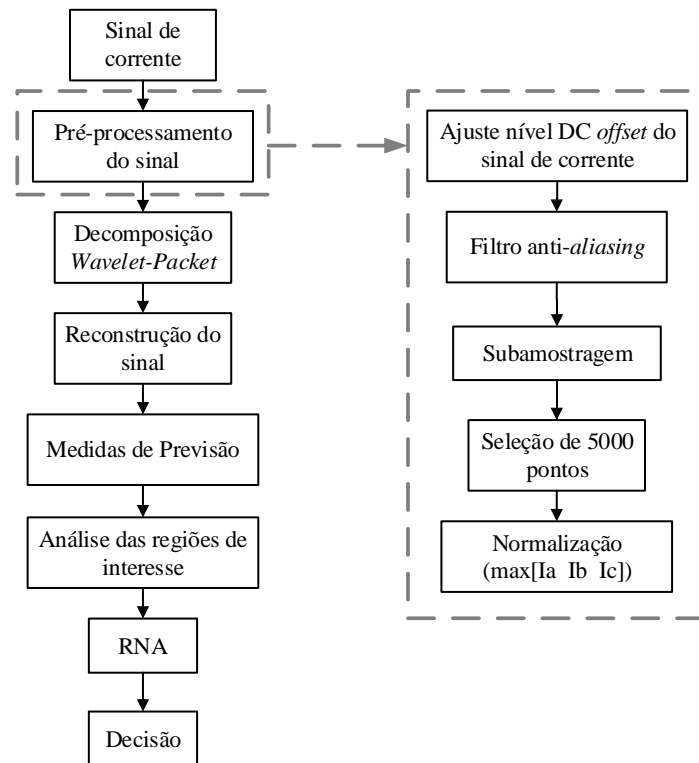
## 4.2 CLASSIFICAÇÃO DOS SINAIS

O método proposto neste trabalho tem como objetivo classificar sinais de corrente de MITs com e sem a presença de falhas. Os diagramas de blocos da Figura 22 apresentam os procedimentos adotados.

As seções a seguir descrevem com mais detalhes as etapas da metodologia proposta.

### 4.2.1 Pré-processamento do sinal

A etapa de pré-processamento do sinal pode ser descrita conforme diagrama de blocos da Figura 22 (direita). Primeiramente, realiza-se o ajuste de *offset* dos sinais de corrente. O



**Figura 22 – Diagrama de blocos da metodologia proposta.**

**Fonte: Autoria própria.**

nível DC ocorre devido a uma sequência de *offsets* nas etapas de medição, condicionamento e aquisição dos sinais. A Figura 23 ilustra 50 ms de um sinal de corrente, demonstrando a necessidade de ajuste do nível DC nos sinais. Esse ajuste foi realizado em *software*, para cada fase do sinal de corrente, subtraiu-se o valor médio do vetor de dados.

Em seguida, os sinais foram pré-filtrados para diminuição da largura de banda. Dessa forma, foi possível analisar somente a região de interesse (0 a 2,5kHz) e pôde-se realizar a subamostragem sem que ocorresse *aliasing*. A frequência de corte do filtro foi escolhida de forma que fosse possível, após a subamostragem, obter frequências próximas a um mesmo valor, uma vez que as frequências de amostragem utilizadas nos ensaios eram diferentes. O filtro ideal para diminuição da largura de banda pode ser observado na Figura 24.

Após a filtragem os sinais foram subamostrados. Conforme se observa na Tabela 1, os sinais coletados apresentam três diferentes frequências de amostragem. Assim, estes foram subamostrados considerando diferentes fatores. A Tabela 3 apresenta os valores de  $M$  utilizados e as frequências após a subamostragem.

Observa-se na Tabela 3, que mesmo após a subamostragem, os sinais apresentavam frequências diferentes. Como só é possível realizar a subamostragem considerando-se um fator  $M$  inteiro, não foi possível obter valores de frequência iguais para todos os sinais.




Figura 23 – Ilustração do nível DC nos sinais de corrente.

Fonte: Autoria própria.

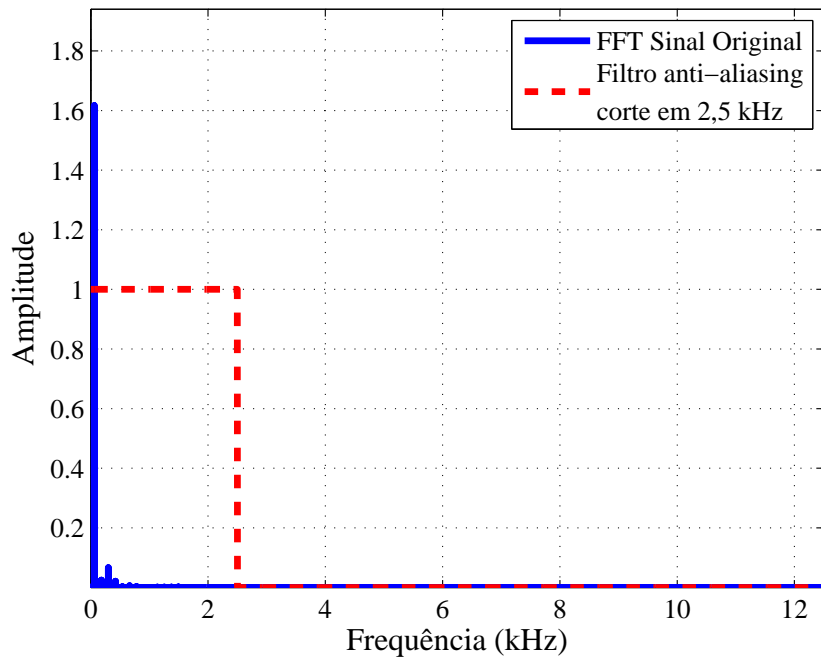


Figura 24 – Filtro ideal para diminuição da largura de banda para 2,5 kHz.

Fonte: Autoria própria.

Na Figura 25, observam-se o espectro da corrente de uma fase de um sinal sem falha (a) antes do pré-processamento do sinal e (b) após a filtragem e subamostragem.

Tabela 3 – Fatores de subamostragem utilizados nos sinais.

Frequência de Amostragem	Fator de Subamostragem ( $M$ )	Frequência após Subamostragem
25 kHz	5	5 kHz
30 kHz	6	5 kHz
15,5 kHz	3	5,167 kHz

Fonte: Autoria própria.

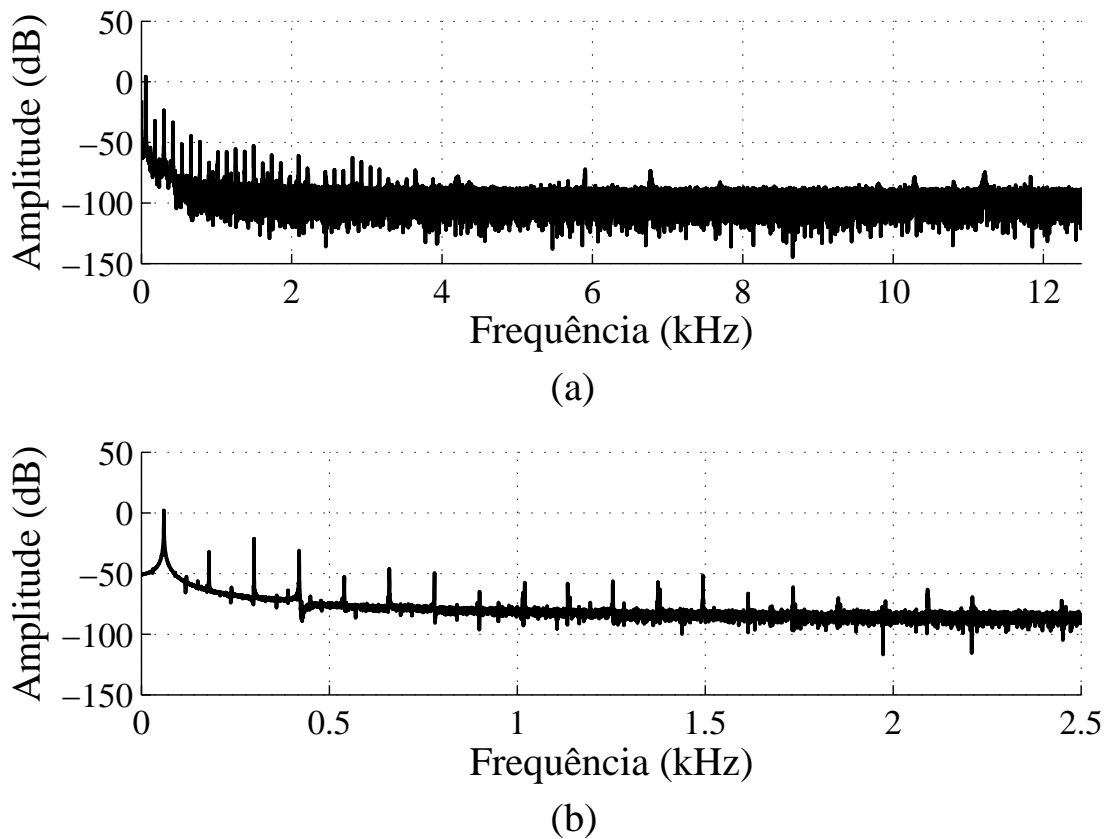



Figura 25 – Espectro de frequências de uma fase de um sinal sem falha: (a) antes do pré-processamento; (b) após a filtragem e subamostragem.

Fonte: Autoria própria.

Após a subamostragem, escolheu-se analisar o equivalente a aproximadamente 1 segundo dos sinais. Para isso, realizou-se a seleção de 5000 pontos dos sinais, iniciando-se no primeiro ponto do semiciclo positivo da corrente da fase A. Esses sinais são normalizados pelo maior valor de corrente entre as três fases. Dessa maneira, os sinais normalizados ficam “desvinculados” do regime de torque, mas não perdem as características no caso de uma possível condição de desequilíbrio de tensão. A Figura 26 ilustra 50 ms de uma amostra de sinal já normalizada.



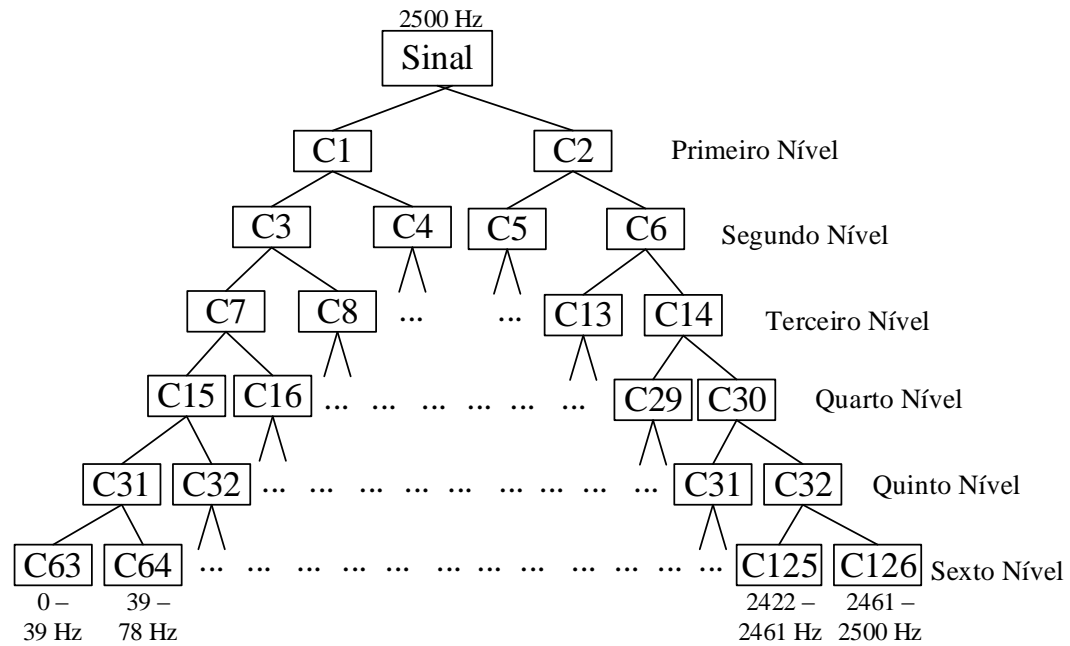
**Figura 26 – Amostra de 50 ms dos sinais de corrente subamostrados e normalizados.**  
**Fonte: Autoria própria.**

Após a normalização e seleção do trecho equivalente a aproximadamente 1 segundo do sinal, realizou-se a decomposição do sinal utilizando-se a DWP.

#### 4.2.2 Decomposição *Wavelet-Packet*

Também com o propósito de diagnóstico de falhas em MITs pela análise do sinal de corrente, Cunha, Spatti e Silva (2013) realizaram testes usando a família de *wavelets* Daubechies. Os autores buscaram detectar falhas de estator e rotor utilizando a DWT e medidas estatísticas como padrões de entrada em RNAs. Schmitt (2013) realizou vários testes em sinais simulados com falhas de rolamentos, considerando diversas famílias de *wavelets*, e obteve os melhores resultados com a família Daubechies.

Tendo em vista os recentes trabalhos realizados na área de detecção de falhas em MITs que utilizaram a transformada *wavelet* e as funções da família Daubechies, neste trabalho escolheu-se a *wavelet* da família Daubechies com suporte igual a 40 (*db20*). A escolha desse suporte permite uma boa resolução na análise dos sinais tanto no domínio do tempo quanto no da frequência. Neste trabalho, realizou-se a decomposição dos sinais utilizando-se a DWP, até o sexto nível. Cada componente corresponde a bandas de frequência de aproximadamente 40 Hz. A Figura 27 ilustra, de forma simplificada, os seis níveis de decomposição e os respectivos componentes de um sinal com frequência de amostragem igual a 5 kHz.



**Figura 27 – Seis níveis de decomposição da DWP.**

**Fonte: Autoria própria.**

#### 4.2.3 Reconstrução do sinal

Após a decomposição utilizando a DWP, realiza-se a reconstrução de cada componente individualmente. Na Figura 28, pode-se observar 200 ms de uma fase de sinal pré-processado e normalizado, e seu respectivo espectro de frequência. Apresenta-se também 200 ms da reconstrução dos componentes C63 e C64, juntamente com seus espectros de frequência.

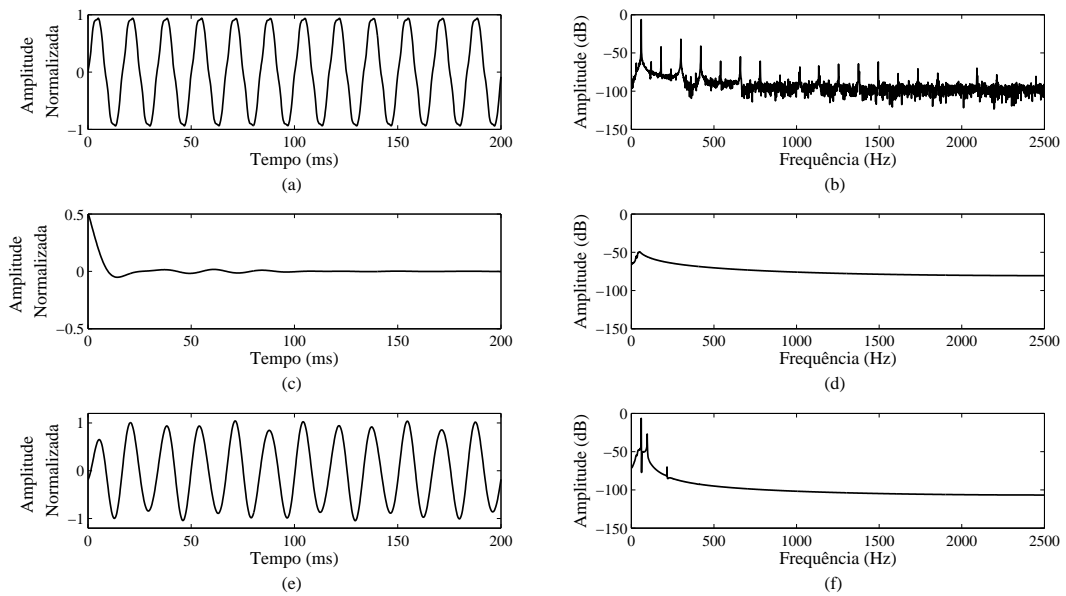
Observa-se, na Figura 28, que o sinal referente à reconstrução do componente C64 (Figura 28-(e)) é similar ao sinal original (Figura 28-(a)). A faixa de frequências desse componente engloba a frequência da rede (60 Hz). Isto pode ser observado no espectro de frequência deste sinal (Figura 28-(f)).

Na Figura 29, pode-se observar (a) 200 ms de uma fase de sinal pré-processado e normalizado, (b) 200 ms da reconstrução do componente C64 e (c) seu respectivo erro de reconstrução, que é a diferença entre o sinal original pré-processado e o sinal reconstruído.

#### 4.2.4 Medidas de Previsão


Após a reconstrução dos componentes, avalia-se a previsibilidade de cada componente reconstruído, conforme descrição da Seção 3.3. Os sinais são analisados por meio de duas medidas de previsão: variância de erro normalizada, obtida com a PrCA e a potência de previsão. A seguir, apresentam-se dois exemplos, um de PrCA e outro de PP.





**Figura 28 – (a) 200 ms do sinal pré-processado; (b) espectro de frequência do sinal pré-processado; (c) reconstrução do componente C63; (d) espectro de frequência do componente C63; (e) reconstrução do componente C64; (f) espectro de frequência do componente C64.**

**Fonte: Autoria própria.**



**Figura 29 – (a) 200 ms do sinal pré-processado; (b) reconstrução do componente C64; (c) erro de reconstrução do componente C64.**

**Fonte: Autoria própria.**

Para o exemplo da PrCA, explica-se como são obtidas as variâncias de erro normalizadas relacionadas aos componentes previsíveis. O cálculo dos valores de  $\lambda$  é realizado considerando-se o componente reconstruído e o respectivo erro de reconstrução. De forma a simplificar o exemplo, utilizam-se somente os três primeiros componentes do sexto nível de decomposição (C63, C64 e C65) de uma fase de um sinal de corrente de MIT sem falhas.

No exemplo, pode-se observar as reconstruções de cada um dos componentes analisados ( $Xr$ ), cada uma com 5000 pontos e os respectivos erros de reconstrução ( $Err$ ), também com 5000 pontos cada. A partir das reconstruções de cada componente e dos respectivos erros de reconstrução, calcula-se a matriz de covariância dos sinais reconstruídos ( $C_o$ ) e a matriz de covariância dos erros de reconstrução ( $C_e$ ). Essas matrizes sumarizam a covariância (ou o grau de inter-relação) entre os componentes reconstruídos ( $C_o$ ), ou entre os erros de reconstrução ( $C_e$ ). Em seguida, obtém-se as variâncias de erro normalizadas associadas aos componentes de decomposição ( $\Lambda_1$ ) e aos componentes previsíveis ( $\Lambda_2$ ).

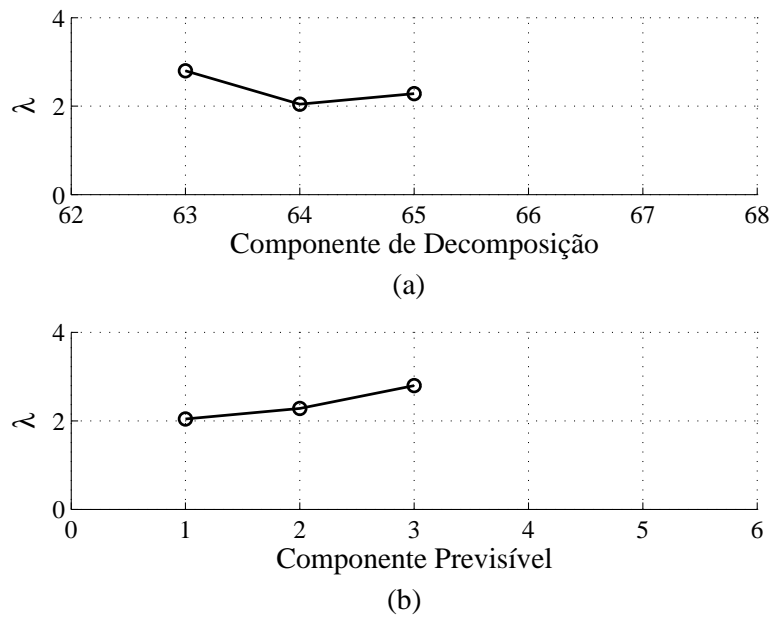
$$\begin{aligned}
 & \begin{bmatrix} Xr_{C63} & Xr_{C64} & Xr_{C65} \end{bmatrix}_{5000 \times 3} & \begin{bmatrix} Err_{C63} & Err_{C64} & Err_{C65} \end{bmatrix}_{5000 \times 3} \\
 & \qquad \qquad \qquad \downarrow & \qquad \qquad \qquad \downarrow \\
 C_o = & \begin{bmatrix} 0,1498 & 0,1493 & 0,1480 \\ 0,1493 & 0,1498 & 0,1493 \\ 0,1480 & 0,1493 & 0,1498 \end{bmatrix} & C_e = \begin{bmatrix} 0,3074 & 0,3064 & 0,3034 \\ 0,3064 & 0,3074 & 0,3064 \\ 0,3034 & 0,3064 & 0,3074 \end{bmatrix} \\
 \Rightarrow \Lambda_1 = & \begin{bmatrix} 2,7967 & 0 & 0 \\ 0 & 2,0436 & 0 \\ 0 & 0 & 2,2805 \end{bmatrix} & \Rightarrow \Lambda_2 = \begin{bmatrix} 2,0436 & 0 & 0 \\ 0 & 2,2805 & 0 \\ 0 & 0 & 2,7967 \end{bmatrix}
 \end{aligned}$$

A Figura 30 apresenta as variâncias de erro normalizadas para a PrCA dos três primeiros componentes do sexto nível de decomposição de uma fase de um sinal.

A seguir, apresenta-se o exemplo para a PP. Conforme visto na Equação (15), a PP pode ser tratada como uma normalização da entropia relativa. O cálculo da entropia relativa é realizado considerando-se o sinal original e o erro de reconstrução de cada componente. A PDF dos sinais é obtida com base em histogramas com passo de quantização de amplitude constante, assim como em Scalassara (2009). O uso dessa técnica se mostrou eficiente para sinais com diferentes faixas de amplitude, pois o número de células de cada histograma é diferente.

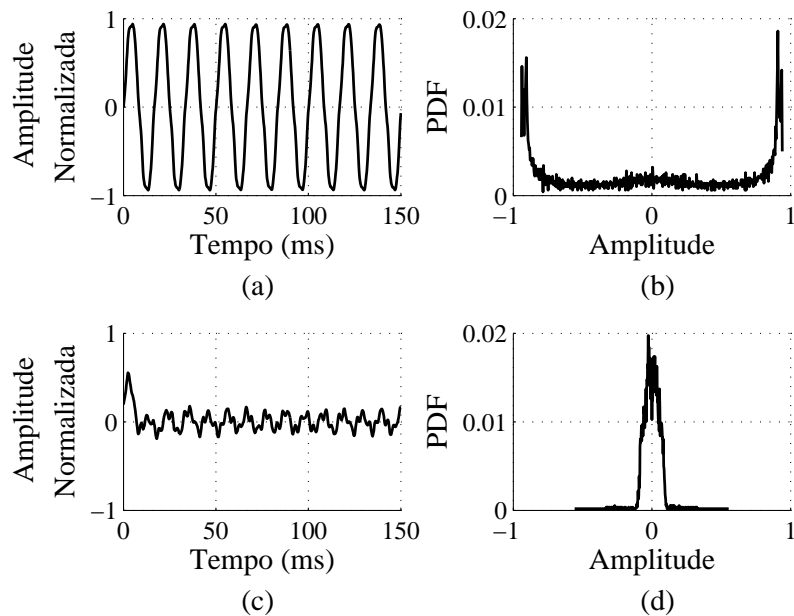
Utilizou-se um passo de quantização de amplitude constante igual a 0,004, que, assim como em Schmitt (2013), apresentou uma boa resolução nas PDFs analisadas.

Na Figura 31, apresentam-se as PDFs de uma fase do sinal original e do erro de reconstrução do segundo componente do sexto nível de decomposição (C64).



**Figura 30 – Variâncias de erro normalizadas dos três primeiros componentes do 6° nível de decomposição de uma fase de um sinal: (a)  $\lambda$  relacionado ao componente de decomposição e (b)  $\lambda$  relacionado ao componente previsível (ordem crescente).**

Fonte: Autoria própria.

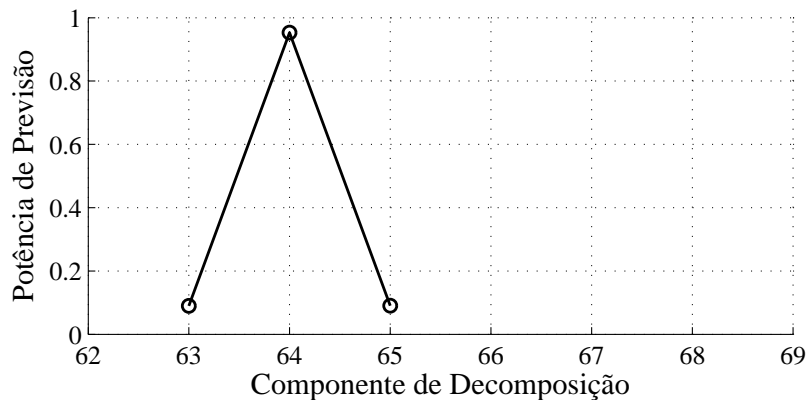


**Figura 31 – Obtenção das PDFs: (a) 150 ms do sinal original; (b) PDF do sinal original; (c) 150 ms do erro de reconstrução do componente C64; (d) PDF do erro.**

Fonte: Autoria própria.

Os componentes que apresentam os menores erros de reconstrução são mais previsíveis. Quando a diferença entre o sinal original e o sinal reconstruído é alta, pode-se considerar

que o sinal é mais imprevisível e apresenta maior erro de previsão. A Figura 32 apresenta as PPs dos três primeiros componentes do sexto nível de decomposição de uma fase de um sinal (C63, C64 e C65). Como a reconstrução do componente C64 é similar ao sinal original, e o erro é bem diferente, observa-se que a PP deste componente é bem maior que a dos demais componentes analisados.



**Figura 32 – Potência de previsão: componentes C63, C64 e C65.**

**Fonte: Autoria própria.**

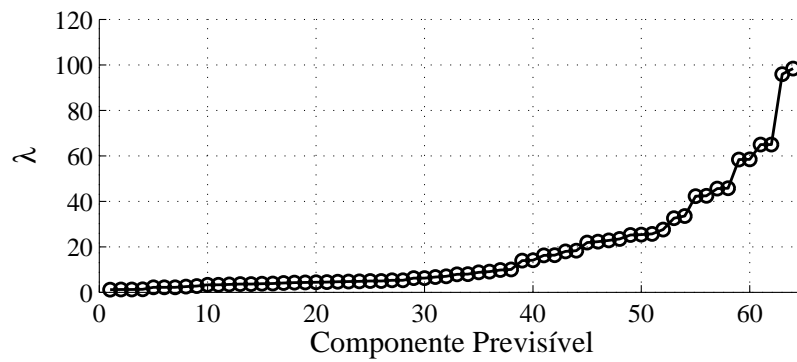
#### 4.2.5 Análise das regiões de interesse

Após a análise dos sinais por meio das medidas de previsão, escolhem-se os vetores que serão usados como entradas das redes neurais. As entradas são escolhidas considerando-se três métodos, que consistem em três diferentes vetores de entrada para as redes neurais.

##### Método 1: $\lambda$ como entrada da rede neural

Esse método adota a PrCA como medida de previsibilidade. A Figura 33 apresenta as variâncias de erro normalizadas de todos os componentes do sexto nível de decomposição de uma fase de um sinal de corrente. Porém, como esses valores de  $\lambda$  já estão em ordem crescente, estão relacionados aos componentes previsíveis e não aos componentes de decomposição.

No trabalho de Scalassara, Santos e Maciel (2011), a PrCA foi obtida considerando os sinais originais e os erros de reconstrução. Dessa forma, os menores valores da variância de erro normalizada representavam os componentes mais previsíveis. Neste trabalho os valores de  $\lambda$  foram obtidos considerando os sinais reconstruídos e os respectivos erros de reconstrução. Assim, as variâncias de erro normalizadas estão em ordem crescente, quanto maior o  $\lambda$ , mais previsível é o componente relacionado a ele. Para a escolha dos vetores a serem utilizados como entradas das redes neurais, realizaram-se duas abordagens: uma considerando os 5 maiores  $\lambda$  de cada fase, e outra considerando os 10 maiores  $\lambda$ , formando vetores de 15 e 30 elementos, respectivamente. No Capítulo 5, esses vetores de entrada são representados por  $[5 \lambda]$  e  $[10 \lambda]$ .



**Figura 33 – Variâncias de erro normalizadas de todos os componentes do sexto nível de decomposição de uma fase de sinal de corrente.**

**Fonte: Autoria própria.**


O vetor de entrada da rede neural classificadora é similar ao descrito na Equação (20). Em que  $\lambda_{Ifck}$  é a variância de erro normalizada do componente  $Ck$  referente à corrente  $If$ .

$$\left[ \lambda_{Ia_{C1}} \quad \cdots \quad \lambda_{Ia_{Ck}} \quad \vdots \quad \lambda_{Ib_{C1}} \quad \cdots \quad \lambda_{Ib_{Ck}} \quad \vdots \quad \lambda_{Ic_{C1}} \quad \cdots \quad \lambda_{Ic_{Ck}} \right] \quad (20)$$

Esses vetores foram normalizados de forma dinâmica, ou seja, considerou-se o valor máximo de cada amostra para a normalização. Realizaram-se testes em que os vetores foram normalizados considerando-se o máximo geral entre todo o universo de amostras, porém os resultados obtidos foram muito similares aos primeiros, assim, optou-se por manter a normalização dinâmica.

### Método 2: PP como entrada da rede neural

Nesse método, adota-se a PP como medida de previsibilidade. A Figura 34 apresenta as PP de todos os componentes do sexto nível de decomposição de uma fase de um sinal de corrente.



**Figura 34 – PPs de todos os componentes do sexto nível de decomposição de uma fase de sinal de corrente.**

**Fonte: Autoria própria.**

As PPs estão relacionadas aos componentes de decomposição do sexto nível (C63 a C126). Quanto maior a PP, significa que mais previsível é aquele componente. Para a escolha dos vetores a serem utilizados como entradas das redes neurais, realizaram-se duas abordagens: uma considerando as 5 maiores PPs de cada fase, e outra considerando as 10 maiores PPs, formando vetores de 15 e 30 elementos, respectivamente. No Capítulo 5, esses vetores de entrada são representados por **[5 PP]** e **[10 PP]**.

O vetor de entrada da rede neural tem formato similar ao descrito na Equação (21), onde  $PP_{IfCk}$  é a PP do componente  $Ck$  referente à corrente  $If$ . Os valores de PP são ordenados, e os maiores valores são escolhidos para configurar os vetores de entrada das RNAs.

$$\left[ PP_{IaC1} \quad \cdots \quad PP_{IaCk} \quad \vdots \quad PP_{IbC1} \quad \cdots \quad PP_{IbCk} \quad \vdots \quad PP_{IcC1} \quad \cdots \quad PP_{IcCk} \right] \quad (21)$$

Como a PP trata-se de uma normalização da entropia relativa, os valores já estão entre 0 e 1. Assim, não é necessária a normalização desse vetor.

### Método 3: $\lambda$ e PP como entradas da rede neural

O terceiro método adota como entrada das redes neurais um vetor que associa os vetores encontrados nos dois métodos propostos anteriormente. Os vetores de entrada passam a conter valores de  $\lambda$  (já normalizados) e de PP. Realizaram-se também duas abordagens, na primeira, considerou-se os 5 maiores valores de  $\lambda$  e os 5 maiores valores de PP de cada fase, totalizando um vetor com 30 elementos. Já na segunda abordagem, considerou-se os 10 maiores valores de  $\lambda$  e PP, totalizando um vetor com 60 elementos. No Capítulo 5, esses vetores de entrada são representados por **[5  $\lambda$  + 5 PP]** e **[10  $\lambda$  + 10 PP]**.

#### 4.2.6 Redes Neurais Artificiais

Após a escolha dos vetores de entradas das redes neurais, definem-se três arquiteturas de redes neurais a serem utilizadas na classificação das amostras. A Tabela 4 apresenta as principais características das três redes estudadas. Essas características não foram alteradas durante os testes realizados.

As demais variáveis relacionadas às redes utilizadas são apresentadas somente para as topologias que apresentarem maior percentual de acerto em cada etapa da classificação das amostras. Os valores dessas variáveis são apresentados no Capítulo 5.

Nesta etapa, as amostras foram separadas entre amostras de treinamento e validação. Para o conjunto de dados de treinamento, considerou-se as condições de máximo e mínimo de desequilíbrio de tensão e máximo e mínimo de torque. Ou seja, todas as amostras correspondentes à operação em vazio ou em sobrecarga de todos os ensaios foram alocadas nesse grupo, bem como todas as amostras com o mínimo e máximo de desequilíbrio de tensão de todos os

**Tabela 4 – Características das três topologias de RNAs utilizadas na classificação dos padrões.**

<b>Topologia</b>	<b>Rede 1</b>	<b>Rede 2</b>	<b>Rede 3</b>
Arquitetura	PMC	RBF	Kohonen
Treinamento	S	S	NS
Algoritmo de treinamento	BP + LM	k-means BP	Competitivo
Número de Camadas Escondidas	1	1	-
Função de Ativação da Camada Escondida	Logística	Gaussiana	-
Função de Ativação da Camada de Saída	Logística	Linear	-

S - Supervisionado  
 NS - Não-Supervisionado  
 BP - *Backpropagation*  
 LM - Levenberg-Marquardt

**Fonte:** Autoria própria.

ensaios realizados. No caso das amostras com falha de estator, consideram-se, no treinamento, também as amostras com mínimo e máximo de curto-circuito entre as espiras.

Os métodos utilizados para escolha das entradas das RNAs, da seção 4.2.5, também influenciaram no número de amostras de treinamento e validação. Os valores máximos e mínimos dos vetores de entrada das redes, foram alocados no conjunto de dados de treinamento. Ou seja, as amostras que continham os maiores e menores valores dos vetores correspondentes às amostras de sinais (sem falha ou com falhas de estator, rotor ou rolamento), foram adicionadas ao conjunto de dados de treinamento.

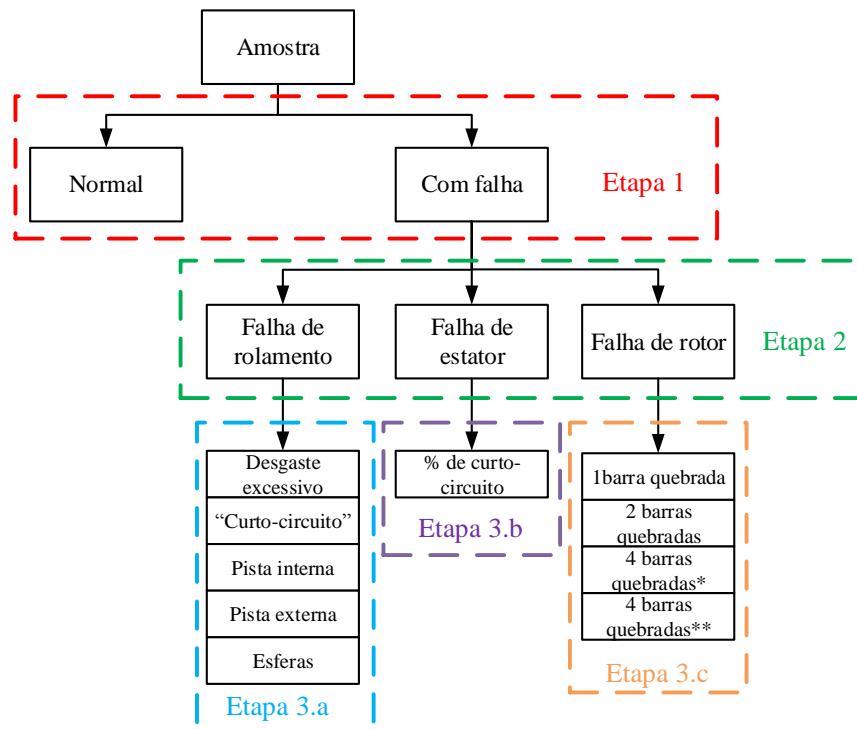
Dessa maneira, o número de amostras utilizadas no treinamento e na validação varia conforme a escolha dos vetores a serem utilizados como entradas das redes.

O conjunto de dados de validação é composto pelas amostras restantes, ou seja, pelas amostras intermediárias. Isso permite a verificação da capacidade de generalização das redes testadas. O percentual de acertos na classificação das amostras é calculado conforme a Equação (22).

$$\% \text{ de acerto} = \frac{\text{n}^\circ \text{ de classificações corretas}}{\text{n}^\circ \text{ total de amostras de validação}} \times 100 \quad (22)$$

#### 4.2.7 Decisão

O diagrama da Figura 35 ilustra a proposta de metodologia para a classificação das falhas. Na etapa 1, as amostras são separadas entre normais e com falha. Na etapa 2, decide-se qual o tipo de falha que está presente nas amostras, se falha no rolamento, no estator, ou no rotor. Em seguida, nas etapas 3.a, 3.b e 3.c, ocorre a classificação da falha no grupo em que está presente.



**Figura 35 – Classificação dos sinais de corrente.**  
**Fonte: Autoria própria.**

Essa metodologia foi testada e validada para todas as 1954 amostras de sinais descritas na Tabela 1. No Capítulo 5, apresentam-se os resultados obtidos em cada etapa de classificação, considerando os diferentes vetores de entrada das redes neurais.



## 5 RESULTADOS E DISCUSSÕES

Neste capítulo, discutem-se os resultados obtidos com a aplicação da metodologia descrita no capítulo anterior. Conforme visto na Seção 4.2.7, a classificação dos sinais é realizada considerando 3 etapas.

Na etapa 1, realizou-se a separação das amostras entre normais ou com a presença de falhas. Na etapa 2, utilizaram-se somente os dados de amostras com falhas, e buscou-se identificar qual o tipo de falha que estava presente nos sinais, se de estator, rotor ou rolamento. Finalmente, na etapa 3, buscou-se especificar o tipo da falha, dentro do grupo em que estava presente. Essa etapa foi dividida em outras três: 3.a, 3.b e 3.c. Para essas etapas, utilizaram-se somente os dados de um tipo de falha: em 3.a, os dados de falhas de rolamento, em 3.b, falhas de estator, e em 3.c, falhas de rotor. As seções a seguir apresentam os resultados obtidos em cada uma dessas etapas.

### 5.1 ETAPA 1 - CLASSIFICAÇÃO EM DOIS PADRÕES

Na primeira etapa, realizou-se a classificação das amostras em dois grupos: com e sem a presença de falhas. Os vetores de entradas das redes neurais foram escolhidos conforme descrito na Seção 4.2.5. Realizaram-se testes considerando três topologias de RNAs e seis diferentes vetores de entradas. A Tabela 5 apresenta os resultados de classificação de cada uma das redes.

**Tabela 5 – Percentual de acerto para a primeira etapa - classificação em dois padrões (normal e falha).**

<b>Método</b>	<b>Vetor de Entrada</b>	<b>Rede 1 PMC</b>	<b>Rede 2 RBF</b>	<b>Rede 3 Kohonen</b>
<b>1</b>	<b>5 <math>\lambda</math></b>	86,53%	77,14%	67,55%
<b>2</b>	<b>5 PP</b>	84,53%	76,90%	66,59%
<b>3</b>	<b>5 <math>\lambda</math> + 5 PP</b>	90,33%	77,52%	77,73%
<b>4</b>	<b>10 <math>\lambda</math></b>	87,67%	77,41%	71,45%
<b>5</b>	<b>10 PP</b>	85,35%	76,64%	63,48%
<b>6</b>	<b>10 <math>\lambda</math> + 10 PP</b>	91,52%	77,60%	82,60%

Fonte: Autoria própria.

Os melhores resultados da classificação das amostras foram obtidos considerando a rede 1 - PMC, conforme pode ser observado nos resultados da Tabela 5. Dos seis diferentes métodos de obtenção dos vetores a serem apresentados como entrada às redes, o método 6 apresentou maior percentual de acerto na classificação das amostras. Esse método considerou os 10 maiores  $\lambda$  e 10 maiores PPs de cada fase. O segundo maior percentual de acerto foi obtido com o método 3, que considerou os 5 maiores  $\lambda$  e 5 maiores PPs de cada fase. Para esses

dois casos, para a obtenção dos vetores de entrada das redes, deve-se calcular tanto valores de  $\lambda$ , quanto os de PP, considerando todos os componentes do sexto nível de decomposição da DWP. Nos demais casos, utilizou-se somente uma medida de previsão. No caso dos métodos 1 e 4, consideraram-se somente as medidas obtidas com a PrCA, não havendo a necessidade de calcular os valores de PP. No caso dos métodos 2 e 5, aconteceu o oposto. Apesar dos métodos 1, 2, 4 e 5 terem apresentado menor percentual de acerto, o processamento exigido para obtenção desses vetores de entrada foi menor que nos métodos 3 e 6, considerando que nestes, foi necessário realizar tanto o cálculo das PPs quanto dos valores de  $\lambda$ . A Tabela 6 apresenta as variáveis relacionadas à topologia que apresentou maior percentual de acerto. Os demais parâmetros relacionados às topologias de RNAs apresentadas constam na Tabela 4 da Seção 4.2.6.

**Tabela 6 – Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras em dois padrões e resultados considerando o método 6.**

<b>Vetor de entrada</b>	<b>10 <math>\lambda</math> + 10 PP</b>
Número de elementos do vetor	60
Amostras de Treinamento	1494
Amostras de Validação	460
Neurônios na Camada Escondida	30
Neurônios na Camada de Saída	2
Taxa de Aprendizado	$10^{-3}$
Precisão	$10^{-11}$
<b>Resultados</b>	
Número de Épocas	116
EQM	$6,695 \times 10^{-3}$
Percentual de Acerto	91,52

EQM - Erro Quadrático Médio

**Fonte: Autoria própria.**

Optou-se por utilizar dois neurônios na camada de saída, tendo como função de ativação a função logística. A classificação da existência ou não de falhas nos sinais foi possível através de lógica combinacional. A Tabela 7 apresenta as possíveis saídas da rede para a etapa de classificação em dois padrões.

**Tabela 7 – Padrões da RNA para a classificação das amostras em dois padrões.**

<b>Saída</b>	<b>y1</b>	<b>y2</b>
Sem falha	1	0
Com falha	0	1

**Fonte: Autoria própria.**

Das 1954 amostras do banco de dados, 1494 foram utilizadas no treinamento. Das 460 restantes, utilizadas na validação, são 103 amostras sem falha, 93 com falha de rolamento,

196 com falha de estator e 68 com falha de rotor. Os detalhes da classificação dessas amostras podem ser visualizados na Tabela 8.

**Tabela 8 – Detalhes da classificação das amostras em dois padrões.**

Amostra	Classificação	
	Sem Falha	Falha
<b>Sem Falha</b>	78	25
<b>Falha Rolamento</b>	9	84
<b>Falha Estator</b>	4	192
<b>Falha Rotor</b>	1	67

**Fonte:** Autoria própria.

Em preto, têm-se as classificações corretas. Em azul, a quantidade de sinais normais classificados com falha (falsos positivos). Em vermelho, observa-se as classificações de sinais com falha classificados como normais (falsos negativos).

Conforme pode ser observado na Tabela 5, para todos os métodos de entradas considerados, a rede 2 - RBF apresentou um percentual de acerto na faixa de 77%. Essa rede, para todos os testes realizados, classificou todas as amostras (normais e com falha) como com falha. Isso significa que a rede classificou corretamente todas as amostras de sinais com falhas e errou todas as amostras de sinais normais, classificando-os como se apresentassem falhas (falsos positivos). Foram realizados vários testes, variando parâmetros como número de neurônios na camada intermediária, taxa de aprendizado, precisão, e mesmo assim essa rede não foi capaz de separar os dados, o que seria o propósito principal desta etapa da classificação.

A rede 3, Kohonen, também não apresentou um alto percentual de acerto na classificação das amostras em dois padrões. Possivelmente, os baixos percentuais de acerto das redes 2 e 3 sejam em consequência das próprias características apresentadas como entradas às redes. O primeiro estágio de treinamento da rede RBF e o treinamento da rede Kohonen são ambos não-supervisionados e dependentes diretamente das características dos dados de entrada apresentados.

Acredita-se que métodos que geraram os vetores de dados a serem utilizados como entradas das redes não sejam apropriados quando se consideram as redes 2 e 3. Há a necessidade de maiores análises das características obtidas através das medidas de previsibilidade estudadas nesse trabalho. Dessa forma, pode-se realizar mais testes, buscando encontrar conjuntos de dados que permitam a utilização dessas redes na classificação dos sinais.

Tendo em vista os melhores resultados apresentados pela rede PMC, em comparação com as outras topologias de redes testadas, nas etapas seguintes mostram-se apenas os resultados da rede PMC.

## 5.2 ETAPA 2 - CLASSIFICAÇÃO EM TRÊS PADRÕES

Na segunda etapa, realizou-se a discriminação do tipo de falha que estava presente nas amostras. Utilizaram-se somente os sinais com a presença de falhas, seja no rotor, estator ou rolamento. As amostras referentes aos sinais normais (sem falha) não foram consideradas nesta etapa. Considerou-se somente a rede PMC e seis diferentes vetores de entrada, formados por valores de  $\lambda$ , PP e suas combinações, conforme pode ser observado na Tabela 9. A Tabela 9 apresenta os resultados de classificação para cada um dos métodos testados com a rede PMC.

**Tabela 9 – Percentual de acerto para a segunda etapa - classificação em três padrões (identificação da falha).**

<b>Método</b>	<b>Vetor de Entrada</b>	<b>Rede PMC</b>
<b>1</b>	<b>5 <math>\lambda</math></b>	86,24%
<b>2</b>	<b>5 PP</b>	87,93%
<b>3</b>	<b>5 <math>\lambda</math> + 5 PP</b>	96,74%
<b>4</b>	<b>10 <math>\lambda</math></b>	86,73%
<b>5</b>	<b>10 PP</b>	90,85%
<b>6</b>	<b>10 <math>\lambda</math> + 10 PP</b>	97,75%

Fonte: Autoria própria.

Assim como na etapa 1, os melhores resultados foram obtidos considerando-se o método que utiliza os 10 maiores  $\lambda$  e 10 maiores PPs por fase. A Tabela 10 apresenta as variáveis relacionadas à topologia de RNA que apresentou o maior percentual de acerto na classificação das amostras em três padrões. Essa estrutura contou com três neurônios na camada de saída. A Tabela 11 apresenta as possíveis saídas da rede para a etapa de classificação em três padrões.

**Tabela 10 – Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras em três padrões e resultados considerando o método 6.**

<b>Vetor de entrada</b>	<b>10 <math>\lambda</math> + 10 PP</b>
Número de elementos do vetor	60
Amostras de Treinamento	1249
Amostras de Validação	357
Neurônios na Camada Escondida	10
Neurônios na Camada de Saída	3
Taxa de Aprendizado	$10^{-3}$
Precisão	$10^{-11}$
<b>Resultados</b>	
Número de Épocas	21
EQM	$5,7686 \times 10^{-12}$
Percentual de Acerto	97,75

Fonte: Autoria própria.

**Tabela 11 – Padrões da RNA para a classificação das amostras em três padrões.**

<b>Saída</b>	<b>y1</b>	<b>y2</b>	<b>y3</b>
Falha de Rolamento	1	0	0
Falha de Estator	0	1	0
Falha de Rotor	0	0	1

**Fonte: Autoria própria.**

Das 1606 amostras com falhas do banco de dados, 1249 foram utilizadas no treinamento, sendo 199 com falha de rolamento, 878 com falha de estator e 172 com falha de rotor. As 357 amostras restantes, utilizadas na validação, são 93 com falha de rolamento, 196 com falha de estator e 68 com falha de rotor. Os detalhes da classificação dessas amostras podem ser visualizados na Tabela 12.

**Tabela 12 – Detalhes da classificação das amostras em três padrões - identificação do tipo de falha.**

<b>Amostra</b>	<b>Classificação</b>			
	<b>Falha Rolamento</b>	<b>Falha Estator</b>	<b>Falha Rotor</b>	<b>Sem Classificação</b>
<b>Falha Rolamento</b>	89	3	0	1
<b>Falha Estator</b>	1	194	0	1
<b>Falha Rotor</b>	0	0	66	2

**Fonte: Autoria própria.**

Em preto tem-se as classificações corretas e em vermelho, as incorretas. Houve apenas 8 casos de classificações incorretas, sendo que em 4 casos, as amostras foram classificadas como se fossem de outro tipo de falha. Nos outros 4 casos, a classificação não seguiu nenhum dos padrões mostrados na Tabela 11.

### 5.3 ETAPA 3 - CLASSIFICAÇÃO DO TIPO DE FALHA

Nesta etapa, buscou-se identificar o tipo de falha no subgrupo em que estava presente. Na etapa 3.a, os testes foram realizados considerando-se somente as amostras com falha de rolamento. Na etapa 3.b e 3.c, considerou-se somente as amostras com falha de estator e rotor, respectivamente.

#### 5.3.1 Etapa 3.a - Falha de Rolamento

As amostras com falhas nos rolamentos são de cinco tipos: falha por desgaste excessivo, falha por curto circuito (falha localizada no rolamento que caracteriza danos causados por descargas elétricas), falha nas pistas interna e externa e falha nas esferas. Nesta etapa, considerando-se somente as amostras com falhas de rolamento, realizou-se a identificação do

tipo da falha presente nos sinais. A Tabela 13 apresenta os resultados de classificação para cada um dos métodos testados com a rede PMC.

**Tabela 13 – Percentual de acerto para a etapa 3.a - classificação das falhas de rolamento.**

<b>Método</b>	<b>Vetor de Entrada</b>	<b>Rede PMC</b>
<b>1</b>	<b>5 <math>\lambda</math></b>	66,67%
<b>2</b>	<b>5 PP</b>	63,00%
<b>3</b>	<b>5 <math>\lambda</math> + 5 PP</b>	68,00%
<b>4</b>	<b>10 <math>\lambda</math></b>	67,32%
<b>5</b>	<b>10 PP</b>	65,95%
<b>6</b>	<b>10 <math>\lambda</math> + 10 PP</b>	72,04%

Fonte: Autoria própria.

Observando-se os percentuais de acerto apresentados na Tabela 13, o melhor resultado foi obtido quando considerou-se o método 6 como vetor de entrada da rede neural. A Tabela 14 apresenta as variáveis relacionadas à topologia de RNA que apresentou o maior percentual de acerto na classificação das amostras com falha de rolamento. Essa estrutura contou com três neurônios na camada de saída. A Tabela 15 apresenta as possíveis saídas da rede para a etapa de classificação das falhas de rolamento.

**Tabela 14 – Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras com falha de rolamento e resultados considerando o método 6.**

<b>Vetor de entrada</b>	<b>10 <math>\lambda</math> + 10 PP</b>
Número de elementos do vetor	60
Amostras de Treinamento	199
Amostras de Validação	93
Neurônios na Camada Escondida	20
Neurônios na Camada de Saída	3
Taxa de Aprendizado	$10^{-3}$
Precisão	$10^{-11}$
<b>Resultados</b>	
Número de Épocas	24
EQM	$3,4724 \times 10^{-12}$
Percentual de Acerto	72,04

Fonte: Autoria própria.

Das 292 amostras com falha de rolamento, 199 foram utilizadas na etapa de treinamento. As 93 amostras utilizadas na validação estavam divididas em 10 amostras com falha por desgaste excessivo, 10 com falha por curto circuito, 24 com falha na pista interna, 29 com falha na pista externa e 20 com falha nas esferas. Os detalhes da classificação dessas amostras podem ser visualizados na Tabela 16.

Tabela 15 – Padrões da RNA para a classificação das amostras com falha de rolamento.

Saída	y1	y2	y3
Desgaste Excessivo	1	1	1
Curto-Circuito	1	1	0
Pista Interna	1	0	1
Pista Externa	0	1	1
Esferas	0	0	1

Fonte: Autoria própria.

Tabela 16 – Detalhes da classificação das amostras com falha de rolamento.

Amostra	Classificação				
	Desgaste Excessivo	Curto-Circuito	Pista Interna	Pista Externa	Esferas
<b>Desgaste Excessivo</b>	10	0	0	0	0
<b>Curto-Circuito</b>	1	9	0	0	0
<b>Pista Interna</b>	3	5	14	0	2
<b>Pista Externa</b>	0	0	0	19	10
<b>Esferas</b>	0	0	0	5	15

Fonte: Autoria própria.

Em preto, apresentam-se as amostras classificadas corretamente. Em vermelho, as amostras classificadas como se apresentassem outro tipo de falha de rolamento. Todas as amostras com falha por desgaste excessivo foram classificadas corretamente. Somente uma amostra de sinal com falha por curto-circuito foi classificada incorretamente como se apresentasse falha por desgaste excessivo. Tanto as amostras de falhas nas pistas interna e externa apresentaram 10 erros de classificação cada. Todas as amostras com falha na pista externa que foram classificadas de forma incorreta, foram classificadas como se apresentassem falhas nas esferas. Já as classificações incorretas das amostras com falha na pista interna foram distribuídas entre três outros tipos de falha. Cinco amostras de sinais com falha nas esferas foram classificadas como se apresentassem falha na pista externa.

Este trabalho utiliza uma metodologia genérica para obter os vetores de entradas das redes neurais. Os vetores são obtidos da mesma maneira nas etapas 1, 2 e 3. Dessa forma, para a obtenção de melhores resultados na etapa de classificação das falhas de rolamento (Etapa 3.a), é interessante analisar os aspectos específicos de cada tipo de falha rolamento. Essas características são apresentadas pelas Equações (1) - (4).

### 5.3.2 Etapa 3.b - Falha de Estator

As falhas de estator consideradas neste trabalho tratavam-se de falhas de curto-circuito entre espiras de uma mesma fase. Dentre as amostras de sinais com falhas no estator, haviam

amostras com 1%, 3%, 5%, 7%, 10%, 15% e 20% de curto-circuito entre as espiras. Entre as amostras de validação estavam amostras de sinais com 3%, 5%, 10% e 15% de curto-circuito entre as espiras de uma mesma fase. A Tabela 17 apresenta os resultados de classificação para cada um dos métodos testados com a rede PMC.

**Tabela 17 – Percentual de acerto para a etapa 3.b - classificação das falhas de estator.**

<b>Método</b>	<b>Vetor de Entrada</b>	<b>Rede PMC</b>
<b>1</b>	<b>5 <math>\lambda</math></b>	49,00%
<b>2</b>	<b>5 PP</b>	47,97%
<b>3</b>	<b>5 <math>\lambda</math> + 5 PP</b>	54,54%
<b>4</b>	<b>10 <math>\lambda</math></b>	51,00%
<b>5</b>	<b>10 PP</b>	48,97%
<b>6</b>	<b>10 <math>\lambda</math> + 10 PP</b>	55,61%

**Fonte: Autoria própria.**

O maior percentual de acerto foi obtido quando considerou-se o método 6 como vetor de entrada da rede neural. A Tabela 18 apresenta as variáveis relacionadas à topologia de RNA que apresentou o maior percentual de acerto na classificação das amostras com falha de estator. Essa estrutura contou com três neurônios na camada de saída. A Tabela 19 apresenta as saídas da rede para a etapa de classificação das falhas de estator.

**Tabela 18 – Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras com falha de estator e resultados.**

<b>Vetor de entrada</b>	<b>10 <math>\lambda</math> + 10 PP</b>
Número de elementos do vetor	60
Amostras de Treinamento	878
Amostras de Validação	196
Neurônios na Camada Escondida	10
Neurônios na Camada de Saída	3
Taxa de Aprendizado	$10^{-3}$
Precisão	$10^{-11}$
<b>Resultados</b>	
Número de Épocas	69
EQM	$8 \times 10^{-3}$
Percentual de Acerto	55,61

**Fonte: Autoria própria.**

Das 1074 amostras com falha de estator, 878 foram utilizadas na etapa de treinamento. As 196 amostras utilizadas na validação estavam divididas em 79 amostras com 3% de curto-circuito entre as espiras, 79 com 5% de curto-circuito, 19 com 10% e 19 com 15%. Os detalhes da classificação dessas amostras podem ser visualizados na Tabela 20.



Tabela 19 – Padrões da RNA para a classificação das amostras com falha de estator.

Saída	y1	y2	y3
1%	1	1	1
3%	1	1	0
5%	1	0	1
7%	0	1	1
10%	0	0	1
15%	0	1	0
20%	1	0	0

Fonte: Autoria própria.

Tabela 20 – Detalhes da classificação das amostras com falha de estator.

Amostra	Classificação							Sem Classificação
	1%	3%	5%	7%	10%	15%	20%	
3%	22	38	14	2	1	1	1	0
5%	9	15	44	5	3	0	3	0
10%	0	0	2	4	13	0	0	0
15%	0	0	0	0	1	14	2	2

Fonte: Autoria própria.

Em preto têm-se as classificações corretas, e em vermelho as incorretas. Nota-se que para todas as amostras de validação, com 3%, 5%, 10% ou 15% de curto-circuito, o maior número de classificações incorretas encontra-se com um valor percentual próximo ao valor correto. A rede neural foi utilizada para classificação de padrões, definidos na Tabela 19. Assim, para essa etapa da metodologia de diagnóstico proposta, a utilização da rede para estimar o percentual de curto-circuito entre as espiras é mais apropriada, uma vez que os erros na classificação são, na maioria das vezes, compostos por amostras que foram consideradas com percentuais de curto-circuito próximos aos corretos.

### 5.3.3 Etapa 3.c - Falha de Rotor

As amostras com falhas de rotor utilizadas neste trabalho apresentavam barras quebradas no rotor. Havia amostras com falha por uma barra quebrada, duas barras quebradas, quatro barras quebradas consecutivas e quatro barras quebradas alternadas (2 consecutivas + 2 consecutivas). Nesta etapa, considerando-se somente as amostras com falha de rotor, buscou-se identificar o tipo da falha presente nos sinais. A Tabela 21 apresenta os resultados de classificação para cada um dos métodos testados com a rede PMC.

Observou-se que o maior percentual de acerto foi obtido quando considerou-se o método 6 como vetor de entrada da rede neural. A Tabela 22 apresenta as variáveis relacionadas

Tabela 21 – Percentual de acerto para a etapa 3.c - classificação das falhas de rotor.

Método	Vetor de Entrada	Rede PMC
1	5 $\lambda$	73,68%
2	5 PP	82,67%
3	5 $\lambda$ + 5 PP	91,54%
4	10 $\lambda$	81,57%
5	10 PP	84,50%
6	10 $\lambda$ + 10 PP	94,11%

Fonte: Autoria própria.

à topologia de RNA que apresentou o maior percentual de acerto na classificação das amostras com falha de rotor. Essa estrutura contou com dois neurônios na camada de saída. A Tabela 23 apresenta as possíveis saídas da rede para a etapa de classificação das falhas de rotor.

Tabela 22 – Variáveis relacionadas à topologia de RNA utilizada na classificação das amostras com falha de rotor e resultados considerando o método 6.

Vetor de entrada	10 $\lambda$ + 10 PP
Número de elementos do vetor	60
Amostras de Treinamento	172
Amostras de Validação	68
Neurônios na Camada Escondida	10
Neurônios na Camada de Saída	2
Taxa de Aprendizado	$10^{-3}$
Precisão	$10^{-11}$
Resultados	
Número de Épocas	27
EQM	$1,0893 \times 10^{-11}$
Percentual de Acerto	94,11

Fonte: Autoria própria.

Tabela 23 – Padrões da RNA para a classificação das amostras com falha de rotor.

Saída	y1	y2
1 barra quebrada	1	1
2 barras quebradas	0	0
4 barras quebradas*	1	0
4 barras quebradas**	0	1

\* 4 barras quebradas consecutivas

\*\* 4 barras quebradas (2 consecutivas + 2 consecutivas)

Fonte: Autoria própria.

Das 240 amostras com falha de rolamento, 172 foram utilizadas na etapa de treinamento. As 68 amostras utilizadas na validação estavam divididas em 16 amostras com falha por

uma barra quebrada, 17 por duas barras quebradas, 17 por quatro barras quebradas consecutivas, 18 com quatro barras quebradas alternadas. Os detalhes da classificação dessas amostras podem ser visualizados na Tabela 24.

**Tabela 24 – Detalhes da classificação das amostras com falha de rotor.**

Amostra	Classificação			
	1 barra quebrada	2 barras quebradas	4 barras quebradas*	4 barras quebradas**
1 barra quebrada	14	1	0	1
2 barras quebradas	0	16	0	1
4 barras quebradas*	0	0	16	1
4 barras quebradas**	0	0	0	18

Fonte: Autoria própria.

Em preto, apresentam-se as amostras classificadas corretamente. Em vermelho, as amostras classificadas como se apresentassem outro tipo de falha de rotor. Todas as amostras com falhas por quatro barras quebradas alternadas foram classificadas corretamente. As demais amostras apresentaram pelo menos um erro na classificação.

#### 5.4 EFICIÊNCIA DA METODOLOGIA PROPOSTA

Realizou-se o cálculo da eficiência da metodologia proposta em duas etapas. Essa medida foi calculada primeiramente considerando-se somente as etapas de detecção e identificação do tipo de falha. Em seguida, calculou-se a eficiência dos métodos na distinção do tipo de falha, no subgrupo em que estava presente.

A eficiência é dada pelo produto entre o percentual de acerto de cada método para cada etapa de classificação. O percentual de acerto para cada etapa foi calculado conforme Equação (22). Uma vez que os melhores resultados da etapa 1 foram obtidos com a rede PMC, para o cálculo da eficiência foram considerados somente os valores obtidos com essa topologia. A Tabela 25 apresenta os valores dessa medida para cada um dos métodos propostos na detecção e identificação do tipo de falha. Esses valores são os produtos dos resultados apresentados pelas Tabelas 5 (coluna relacionada à rede PMC) e 9.

A eficiência dos métodos na classificação do tipo de falha no subgrupo em que está presente é dada pelo produto dos valores apresentados na Tabela 25 com os valores obtidos na etapa 3 (Tabelas 13, 17 e 21). Os valores de eficiência dos métodos para a classificação correta das falhas de rolamento, estator e rotor são apresentados na Tabela 26.

Há uma diminuição considerável na eficiência dos métodos propostos quando consideram-se os percentuais de acerto obtidos na etapa de classificação das falhas nos grupos em que estão presentes. Observa-se também que, tanto na etapa de detecção e identificação do

Tabela 25 – Eficiência dos métodos na detecção e identificação do tipo de falha.

Método	Vetor de Entrada	Detecção e Identificação da Falha
1	5 $\lambda$	74,62%
2	5 PP	74,33%
3	5 $\lambda$ + 5 PP	87,39%
4	10 $\lambda$	76,04%
5	10 PP	77,54%
6	10 $\lambda$ + 10 PP	89,46%

Fonte: Autoria própria.

Tabela 26 – Eficiência dos métodos na classificação do tipo de falha no subgrupo em que está presente.

Método	Vetor de Entrada	Falha de Rolamento	Falha de Estator	Falha de Rotor
1	5 $\lambda$	49,75%	36,57%	54,98%
2	5 PP	46,83%	35,65%	61,45%
3	5 $\lambda$ + 5 PP	59,42%	47,66%	79,99%
4	10 $\lambda$	51,19%	38,78%	62,02%
5	10 PP	51,14%	37,97%	65,52%
6	10 $\lambda$ + 10 PP	64,45%	49,75%	84,19%

Fonte: Autoria própria.

tipo de falha, quanto na etapa de classificação da falha em seu subgrupo, os métodos 3 e 6 utilizados como entradas das redes apresentaram os valores mais altos de eficiência. Porém, para a obtenção dos vetores de entrada das redes por esses métodos, foi necessário o cálculo de duas medidas de previsibilidade, ao contrário dos demais métodos, em que foi necessário somente o cálculo de uma dessas medidas. A seguir, apresentam-se as eficiências de alguns trabalhos recentes sobre detecção de falhas em MITs utilizando RNAs.

Em Cunha, Spatti e Silva (2013), os autores utilizaram um método baseado em redes neurais. Analisaram-se os sinais de corrente de MITs por meio da decomposição *wavelet* e utilizaram-se medidas estatísticas para a obtenção do vetor de entrada de duas topologias de RNAs. A transformação dos sinais com a DWT utilizou os filtros da família Daubechies com suporte 4 e 6. A identificação do *status* do motor foi realizada pelas redes neurais PMC e Elman. O método proposto considerou duas etapas, em que analisaram-se separadamente amostras com falhas de estator e com falha de rotor. Para cada etapa, utilizaram-se 332 amostras na etapa de treinamento e 212 amostras na etapa de validação, sendo amostras com e sem a presença de falhas.

O sistema de diagnóstico proposto por Cunha, Spatti e Silva (2013) voltado às falhas do rotor buscava separar as falhas em quatro grupos: sem falhas, com duas barras quebradas, com quatro barras quebradas e com outros tipos de falhas. O melhor resultado obtido para esse sistema considerou a rede PMC e o sistema de diagnóstico formado pela DWT utilizando a família Daubechies 6 e atingiu 87,6% de acerto na classificação. O sistema de diagnóstico voltado às falhas de estator também buscava separar as falhas em quatro grupos: sem falhas, curto-circuito na fase A, curto circuito na fase B e com outros tipos de falhas. O melhor resultado obtido para esse sistema considerou a rede Elman e o sistema de diagnóstico formado pela DWT utilizando a família Daubechies 4 e atingiu 91,4% de acerto na classificação. Os métodos apresentados foram eficientes, porém diferentemente da metodologia proposta no presente trabalho, amostras de sinais sem falha foram analisadas juntamente com amostras de sinais com somente um tipo de falha. Neste trabalho, os sinais normais foram analisados somente na primeira etapa, em que consideraram-se também amostras com outros três tipos de falhas. Nas etapas subsequentes, somente as amostras com presença de falha foram analisadas.

Oliveira et al. (2013) apresentaram dois métodos para detecção de falhas por curto circuito entre espiras em um MIT acionado por conversor de frequência. Um método aborda os componentes de frequência referentes às falhas por curto-circuito no estator, o outro método utiliza a PCA. Aplicam-se classificadores de padrões neurais para a detecção do estado do MIT e são analisados os sinais de corrente de um MIT, operando em diversas faixas de frequência. O melhor resultado obtido na etapa de validação, com o método que aborda os componentes de frequência foi igual a 70,2%. Em busca de maiores taxas de classificação, aplicou-se a PCA sobre o conjunto de dados original, atingindo-se 97,43% de acerto na classificação, porém esse método demandou uma topologia de rede com um maior número de conexões.

Broniera Jr., Goedtel e Graciola (2013) realizaram a análise de sinais de corrente de MITs no domínio do tempo, utilizando RNAs para detectar falhas de curto-circuito no estator. Os autores utilizaram três topologias de RNAs e trabalharam com amostras com e sem a presença de falhas. Para testar a robustez do método proposto, foram inseridos ruídos nos sinais, na etapa de validação. Obtiveram um percentual de acerto na classificação igual a 92,73%, considerando 55 amostras na etapa de validação.

O presente trabalho é uma proposta de metodologia para detecção e classificação de falhas em MITs. Foram analisadas amostras de sinais normais e com falhas de rotor, estator e rolamento. Como essas amostras foram tratadas de forma genérica, os resultados obtidos no diagnóstico das falhas foram satisfatórios. Para a obtenção de melhores resultados, estudos mais aprofundados a respeito das características dos sinais e dos métodos utilizados devem ser realizados.

## 6 CONCLUSÃO

Este trabalho apresenta uma proposta de metodologia para detecção de falhas em MITs, o qual é baseado em medidas de previsibilidade, usando modelos *wavelet* e redes neurais artificiais. Realizaram-se testes considerando-se um banco de dados contendo 1954 amostras de sinais de motores. Essas amostras tratavam-se de aquisições de características de MITs operando em diversas condições, como variações de carga e diferentes desequilíbrios nas tensões de alimentação. As amostras continham sinais de corrente do motor operando em condições normais e com falhas nos rolamentos, estator e rotor.

Os sinais de corrente foram pré-processados, inicialmente realizou-se o ajuste do nível DC (*offset*) dos sinais e posteriormente, estes foram filtrados, para diminuição da largura de banda e subamostrados. A subamostragem foi realizada devido à diferença nas frequências de amostragem adotadas nas aquisições dos sinais. Após isso, selecionou-se um trecho de 5000 pontos para a análise, o equivalente a aproximadamente 1 segundo das amostras. Esses trechos foram normalizados dinamicamente, considerando-se o valor máximo entre as três fases. Dessa maneira os sinais ficaram “desvinculados” do regime de torque e não perderam as características referentes aos possíveis desequilíbrios de tensão.

A avaliação da previsibilidade dos sinais foi realizada considerando-se previsões dos sinais através de decomposições pela transformada *wavelet-packet*, que permite a análise multirresoluções dos espectros dos sinais de corrente. Cada componente de decomposição foi reconstruído individualmente. Após a reconstrução, avaliou-se a previsibilidade de cada um por meio de duas medidas de previsibilidade: PP e  $\lambda$  (PrCA).

No estudo dos sinais com a análise de componentes previsíveis, consideraram-se os componentes reconstruídos e os respectivos erros de reconstrução, e avaliou-se a variância de erro normalizada. Já na análise realizada com a potência de previsão, considerou-se a entropia relativa entre o sinal original e o erro de reconstrução de cada componente. Nas duas análises, os maiores valores observados, tanto de  $\lambda$  como de PP, indicavam os componentes mais previsíveis. Esses valores, de forma organizada, configuraram seis diferentes vetores utilizados como entradas para redes neurais classificadoras.

A classificação das amostras foi realizada considerando-se três diferentes etapas. Na primeira etapa, realizaram-se testes com três topologias de redes neurais: PMC, RBF e mapas de Kohonen e buscou-se realizar a distinção entre amostras com e sem a presença de falhas. Como os melhores resultados foram obtidos com a rede PMC, nas etapas seguintes os testes foram realizados considerando-se somente essa topologia. Na segunda etapa, realizaram-se testes considerando-se somente as amostras com falhas, e buscou-se detectar qual o tipo de falha que estava presente nas amostras, se de estator, rotor ou rolamento. Na terceira etapa, buscou-se

identificar o tipo de falha, dentro do subgrupo em que estava presente. Dessa maneira, essa etapa foi dividida em três outras, em que se utilizaram somente as amostras com falha de rolamento (etapa 3.a), ou com falha de estator (etapa 3.b) ou com falha de rotor (etapa 3.c).

A eficiência dos métodos propostos foi calculada considerando-se duas etapas. Primeiramente, calculou-se a eficiência dos métodos para a detecção e identificação correta do tipo de falha. Esse cálculo foi obtido pelo produto dos percentuais de acerto das classificações das etapas 1 e 2. Em seguida, calculou-se a eficiência dos métodos propostos para identificar as falhas nos grupos em que estavam presentes. Notou-se uma diminuição considerável dos valores de eficiência, em comparação com a primeira etapa.

O presente trabalho buscou realizar a classificação dos sinais de 7 diferentes MITs, adquiridos sob diferentes condições, totalizando 1954 amostras. Acredita-se que para a obtenção de melhores resultados na última etapa do trabalho, deve-se realizar um estudo mais aprofundado sobre a influência de cada tipo de falha no sinal, de forma a permitir uma análise melhor das especificidades de cada tipo. Esse trabalho usa uma metodologia genérica, que apresentou resultados satisfatórios nas etapas de detecção e classificação das falhas. Os testes foram realizados considerando topologias de redes neurais classificadoras. Para o caso de falhas de estator, é interessante utilizar redes neurais para estimar o percentual de curto-circuito entre espiras de uma mesma fase, ao invés de classificar essas amostras.

Essa metodologia para detecção e classificação de falhas pode ser implementada e aplicada em sistemas de monitoramento *online* de falhas. Porém, para a aplicação do método em um sistema embarcado, utilizando por exemplo um Processador Digital de Sinais (*Digital Signal Processor* - DSP), deve-se levar em consideração as limitações de memória impostas pelo sistema. Por exemplo; os métodos 3 e 6, que utilizaram  $\lambda$  e PP como entradas das redes, foram os que apresentaram os melhores desempenhos na classificação em todas as etapas. Apesar do método 3 ter apresentado percentuais de classificação um pouco menores que os do método 6, deve-se levar em consideração que o primeiro apresentava um vetor de entrada com metade do número de elementos que o segundo. Ainda que os treinamentos das redes neurais foram realizados de maneira *offline*, a etapa de teste considera as matrizes de pesos sinápticos obtidas nos treinamentos. Quanto maior o número de elementos dos vetores de entrada, maiores as matrizes de pesos e maiores os números de operações a serem realizadas para que se efetue a classificação da amostra. Os demais métodos propostos, que apresentaram menores desempenhos que os métodos 3 e 6, não devem ser descartados. Para a obtenção dos vetores de entrada utilizando os métodos 1, 2, 4 e 5, houve a necessidade do cálculo de somente uma medida de previsibilidade. Diferentemente dos métodos 3 e 6, em que foi necessário o cálculo de duas medidas de previsibilidade.

As seções a seguir apresentam as propostas de continuidade do presente trabalho e o trabalho publicado relacionado ao mesmo.

## 6.1 TRABALHOS FUTUROS

Com os resultados obtidos com a aplicação da metodologia proposta, baseadas em modelos *wavelet*, medidas de previsibilidade e RNAs, cria-se a possibilidade de continuidade dos estudos, dando margem a melhorias nos métodos propostos ou até mesmo novos trabalhos.

Uma proposta de continuidade é a verificação das PPs dos primeiros componentes da decomposição *wavelet-packet*. De forma similar ao proposto em Silva et al. (2013), em que são analisadas as PPs dos componentes relacionados às baixas frequências, diferentemente do presente trabalho, que analisou as maiores PPs, de forma ordenada. Ou, então, analisar as PPs dos componentes que variam entre os sinais normais e com falhas.

Deve-se testar também outras famílias de *wavelets*, pois os estudos foram realizados somente com as funções da família Daubechies. Para estudos mais específicos a respeito das características das falhas, estas devem ser analisadas pelas suas assinaturas. Deve-se verificar as frequências específicas de cada tipo de falha.

Os resultados obtidos com os métodos propostos não foram favoráveis à utilização das redes RBF e Kohonen. Pode-se também buscar novos métodos (vetores de entrada), considerando outros métodos de previsão, que apresentem bons resultados com essas e outras topologias de RNAs.

## 6.2 TRABALHO PUBLICADO

SILVA, L. R. B.; BERTACHI, A. H.; SCHMITT, H. L.; SCALASSARA, P. R.; GOEDEL, A. Classification of voice pathologies based on neural networks and predictability measures. In: **XI Simpósio Brasileiro de Automação Inteligente (SBAI'2013)**. Fortaleza - CE: 2013.



## REFERÊNCIAS

- ARTHUR, N.; PENMAN, J. Induction machine condition monitoring with higher order spectra. **IEEE Transactions on Industrial Electronics**, v. 47, n. 5, p. 1031–1041, 2000.
- AWADALLAH, M.; MORCOS, M. Application of AI tools in fault diagnosis of electrical machines and drives - An overview. **IEEE Transactions on Energy Conversion**, v. 18, n. 2, p. 245–251, june 2003.
- BACCARINI, L. M. R. **Detecção e Diagnóstico de Falhas em Motores de Indução**. 179 p. Tese (Doutorado em Engenharia Elétrica) — Universidade Federal de Minas Gerais, Belo Horizonte, 2005.
- BARAKAT, M.; DRUAUX, F.; LEFEBVRE, D.; KHALIL, M.; MUSTAPHA, O. Self adaptive growing neural network classifier for faults detection and diagnosis. **Neurocomputing**, v. 74, n. 18, p. 3865–3876, nov. 2011.
- BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G.-A. Advances in diagnostic techniques for induction machines. **IEEE Transactions on Industrial Electronics**, v. 55, n. 12, p. 4109–4126, dec. 2008.
- BENBOUZID, M.; KLIMAN, G. What stator current processing-based technique to use for induction motor rotor faults diagnosis? **IEEE Transactions on Energy Conversion**, v. 18, n. 2, p. 238–244, 2003.
- 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, 2000.
- BLODT, M.; GRANJON, P.; RAISON, B.; ROSTAING, G. Models for bearing damage detection in induction motors using stator current monitoring. In: **IEEE International Symposium on Industrial Electronics**. Ajaccio, France: [s.n.], 2004. v. 1, p. 383–388.
- BONES, B. **Manutenção e limpeza dos rolamentos**. 2011. Disponível em: <<http://localzonly.wordpress.com/2011/06/28/manutencao-e-limpeza-de-rolamentos/>>. Acesso em: 11 de setembro de 2013.
- BONNETT, A.; YUNG, C. Increased efficiency versus increased reliability. **IEEE Industry Applications Magazine**, v. 14, n. 1, p. 29–36, jan./feb. 2008.
- BRITO, J. N. **Desenvolvimento de um Sistema Inteligente Híbrido para Diagnóstico de Falhas em Motores de Indução Trifásicos**. 214 p. Tese (Doutorado em Engenharia Mecânica) — Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2002.
- BRONIERA JR., P.; GOEDEL, A.; GRACIOLA, C. L. Uma estratégia neural para diagnóstico de curto-circuito entre espiras no enrolamento de estator em máquinas de indução trifásicas. In: **XI Simpósio Brasileiro de Automação Inteligente (SBAI'2013)**. Fortaleza - CE: [s.n.], 2013. p. -. Disponível em: <<http://www.sbai2013.ufc.br/pdfs/5148.pdf>>. Acesso em: 11 nov. 2013.

- BRONIERA, P. J.; GONGORA, W. S.; GOEDTEL, A.; GODOY, W. F. Diagnosis of stator winding inter-turn short circuit in three-phase induction motors by using artificial neural networks. In: **IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics Drives (SDEMPED'2103)**. Valencia, Spain: [s.n.], 2013. p. 361–367.
- CABAL-YEPEZ, E.; ROMERO-TRONCOSO, R.; GARCIA-PEREZ, A.; OSORNIO-RIOS, R.; ALVAREZ-SALAS, R. Multiple fault detection through information entropy analysis in asd-fed induction motors. In: **IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics Drives (SDEMPED'2011)**. Bologna: [s.n.], 2011. p. 391–396.
- CABAL-YEPEZ, E.; SAUCEDO-GALLAGA, R.; GARCIA-RAMIREZ, A.; FERNANDEZ-JARAMILLO, A.; PENA-ANAYA, M.; VALTIERRA-RODRIGUEZ, M. Fpga-based online detection of multiple-combined faults through information entropy and neural networks. In: **International Conference on Reconfigurable Computing and FPGAs (ReConFig'2010)**. Quintana Roo: [s.n.], 2010. p. 244–249.
- CARDOSO, A.; CRUZ, S. M. A.; FONSECA, D. S. B. Inter-turn stator winding fault diagnosis in three-phase induction motors by park's vector approach. In: **IEEE International Electric Machines and Drives Conference Record**. Milwaukee, WI: [s.n.], 1997. p. MB1/5.1–MB1/5.3.
- CARDOSO, A. J. M.; CRUZ, S. M. A.; CARVALHO, J. F. S.; SARAIVA, E. Rotor cage fault diagnosis in three-phase induction motors by park's vector approach. In: **Conference Record of the 1995 IEEE Industry Applications Conference, 1995. Thirtieth IAS Annual Meeting (IAS'1995)**. Orlando, FL: [s.n.], 1995. v. 1, p. 642–646.
- CHEN, K.; LI, X.; WANG, F.; WANG, T.; WU, C. Bearing fault diagnosis using wavelet analysis. In: **International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (ICQR2MSE'2012)**. Chengdu: [s.n.], 2012. p. 699–702.
- COVER, T.; THOMAS, J. **Elements of information theory**. New York: John Wiley and Sons, Inc., 2006.
- CUNHA, F. M. da; SPATTI, D. H.; SILVA, I. N. da. Identificação de falhas em motores de indução pela abordagem das redes neurais. In: **XI Simpósio Brasileiro de Automação Inteligente (SBAI'2013)**. Fortaleza - CE: [s.n.], 2013. p. –. Disponível em: <<http://www.sbai2013.ufc.br/pdfs/8037.pdf>>. Acesso em: 11 nov. 2013.
- DELSOLE, T. Predictability and information theory. part I: Measures of predictability. **Journal of the Atmospheric Sciences**, v. 61, n. 4, p. 2425–2440, 2004.
- DELSOLE, T.; CHANG, P. Predictable component analysis, canonical correlation analysis and autoregressive models. **Journal of the Atmospheric Sciences**, v. 60, n. 2, p. 409–416, 2003.
- DELSOLE, T.; TIPPETT, M. K. Predictability: Recent insights from information theory. **Reviews of Geophysics**, v. 45, n. 4, p. n/a–n/a, 2007.
- DEVANEY, M.; EREN, L. Detecting motor bearing faults. **IEEE Instrumentation Measurement Magazine**, v. 7, n. 4, p. 30–50, dec. 2004.
- DINIZ, P. S. R.; SILVA, E. A. B. da; NETTO, S. L. **Digital signal processing: system analysis and design**. Cambridge: Cambridge University Press, 2002.

DUDA, R. O.; PETER, E.; STORK, D. G. **Pattern classification**. 2. ed. New York, US: J. Wiley, 2001.

EREN, L.; DEVANEY, M. Bearing damage detection via wavelet packet decomposition of the stator current. **IEEE Transactions on Instrumentation and Measurement**, v. 53, n. 2, p. 431–436, apr. 2004.

FITZGERALD, A.; KINGSLEY, C.; UMANS, S. **Electric machinery**. Boston, MA: McGraw-Hill Companies, Incorporated, 2003. (Electrical Engineering Series).

GOEDEL, A. **Estimador neural de velocidade para motores de indução trifásicos**. 159 p. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, São Carlos, 2007.

GONGORA, W. S. **Uma abordagem neural no diagnóstico de falhas em rolamentos de motores de indução trifásicos**. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2013.

HAGAN, M.; MENHAJ, M.-B. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, nov. 1994.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. New York, NY: Prentice Hall, 2009.

JOKSIMOVIC, G.; PENMAN, J. The detection of inter-turn short circuits in the stator windings of operating motors. **IEEE Transactions on Industrial Electronics**, v. 47, n. 5, p. 1078–1084, 2000.

KEETON, P.; SCHLINDWEIN, F. Application of wavelets in doppler ultrasound. **Sensor Review**, MCB University Press, v. 17, n. 1, p. 38–45, 1997.

KOHONEN, T. **Self-organization and associative memory**. [S.l.]: Springer-Verlag, 1988. (Springer series in information sciences).

LEE, S.-H.; KIM, S.; KIM, J.-M.; LEE, M. H. Fourier and wavelet transformations for the fault detection of induction motor with stator current. In: **30th Annual Conference of IEEE Industrial Electronics Society (IECON'2004)**. Busan, South Korea: [s.n.], 2004. v. 1, p. 383–388.

LI, L.; QU, L.; LIAO, X. Haar wavelet for machine fault diagnosis. **Mechanical Systems and Signal Processing**, v. 21, n. 4, p. 1773–1786, 2007.

LILING, S.; BOQIANG, X. An improvement of stator current based detection of bearing fault in induction motors. In: **Conference Record of the 2007 IEEE Industry Applications Conference. 42nd IAS Annual Meeting**. New Orleans, LA: [s.n.], 2007. p. 2277–2281.

MALLAT, S. A theory for multiresolution signal decomposition: the wavelet representation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 11, n. 7, p. 674–693, Jul. 1989.

MALLAT, S. **A wavelet tour of signal processing**. 2. ed. Cambridge: Academic Press, 1999.

MEHALA, N.; DAHIYA, R. A comparative study of FFT, STFT and wavelet techniques for induction machine fault diagnostic analysis. In: **Proceedings of the 7th WSEAS International Conference on Computational Intelligence, Man-machine Systems and Cybernetics**. Cairo, Egypt: [s.n.], 2008. (CIMMACS'08), p. 203–208.

MIAN-HAO, Q.; ZI-YING, W. Fault diagnosis of bearing based on empirical mode decomposition and decision directed acyclic graph support vector machine. In: **International Conference on Computational Intelligence and Natural Computing (CINC'2009)**. Wuhan: [s.n.], 2009. v. 2, p. 471–474.

MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J.-M. **Wavelet toolbox for use with MATLAB**. [S.l.]: mathworks, 1997.

OLIVEIRA, A. G.; BESSA, R.; COELHO, D. N.; MEDEIROS, C. M. S.; PONTES, R. S. T. Técnicas computacionais para a detecção de falhas por curto-circuito entre espiras de um motor de indução acionado por conversor de frequência. In: **XI Simpósio Brasileiro de Automação Inteligente (SBAI'2013)**. Fortaleza - CE: [s.n.], 2013. p. —. Disponível em: <<http://www.sbai2013.ufc.br/pdfs/8469.pdf>>. Acesso em: 11 nov. 2013.

OPPENHEIM, A.; SCHAFER, R. **Discrete-time signal processing**. Upper Saddle River: Prentice Hall, 2010. (Prentice-Hall signal processing series).

PRIETO, M. D.; ROURA, J. C. i; MARTÍNEZ, J. L. R. **Bearings fault detection using inference tools, vibration analysis and control - new trends and developments**. InTech, 2011. Disponível em: <<http://www.intechopen.com/books/vibration-analysis-and-control-new-trends-and-developments/bearings-fault-detection-using-inference-tools>>.

RADHIKA, S.; SABAREESH, G.; JAGADANAND, G.; SUGUMARAN, V. Precise wavelet for current signature in 3 $\phi$  IM. **Expert Systems with Applications**, v. 37, n. 1, p. 450–455, 2010.

SANTOS, F. M. C. **Identificação de Falhas em Motores de Indução trifásicos Usando Sistemas Inteligentes**. 106 p. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, São Carlos, 2013.

SANTOS, F. M. C.; SILVA, I. N. da; SUETAKE, M. Neural network classifier for faults detection in induction motors. In: **International Conference on Computer Applications Technology (ICCAT'2013)**. Sousse: [s.n.], 2013. p. 1–5.

SANTOS, F. M. da C.; SILVA, I. N. da; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - Uma visão geral. **Revista Controle & Automação**, v. 23, n. 5, p. 553–569, set./out. 2012.

SCALASSARA, P. R. **Utilização de Medidas de Previsibilidade em Sinais de Voz para Discriminação de Patologias de Laringe**. 231 p. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, São Carlos, 2009.

SCALASSARA, P. R.; MACIEL, C. D.; PEREIRA, J. C. Predictability analysis of voice signals. **IEEE Engineering in Medicine and Biology Magazine**, v. 28, p. 30–34, 2009.

SCALASSARA, P. R.; SANTOS, L. A.; MACIEL, C. D. Voice pathology detection with predictable component analysis and wavelet decomposition model. In: **IEEE Information Theory Workshop (ITW'2011)**. Paraty: [s.n.], 2011. p. 95–99.

SCHMITT, H. L. **Detecção de falhas de rolamentos em máquinas elétricas utilizando medidas de previsibilidade**. Trabalho de Conclusão de Curso (Graduação) — Curso de Engenharia Industrial Elétrica. Universidade Tecnológica Federal do Paraná: Cornélio Procópio, 2013.

SCHMITT, H. L.; SILVA, L. R. B.; SCALASSARA, P. R.; GOEDEL, A. Bearing fault detection using relative entropy of wavelet components and artificial neural networks. In: **IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics Drives (SDEMPED'2013)**. Valencia, Spain: [s.n.], 2013. p. 566–571.

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

SHANNON, C. E. A mathematical theory of communication. **The Bell System Technical Journal**, v. 27, p. 379–423, July-October 1948.

SIDDIQUI, K. M.; GIRI, V. K. Broken rotor bar fault detection in induction motors using wavelet transform. In: **International Conference on Computing Electronics and Electrical Technologies (ICCEET'2012)**. [S.l.: s.n.], 2012. p. 1–6.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas - curso prático**. São Paulo: ARTLIBER, 2010.

SILVA, L. R. B.; BERTACHI, A. H.; SCHMITT, H. L.; SCALASSARA, P. R.; GOEDEL, A. Classification of voice pathologies based on neural networks and predictability measures. In: **XI Simpósio Brasileiro de Automação Inteligente (SBAI'2013)**. Fortaleza - CE: [s.n.], 2013. p. –. Disponível em: <<http://www.sbai2013.ufc.br/pdfs/5502.pdf>>. Acesso em: 11 nov. 2013.

SONG, M.-H.; KANG, E.-S.; JEONG, C.-H.; CHOW, M.-Y.; AYHAN, B. Mean absolute difference approach for induction motor broken rotor bar fault detection. In: **4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED'2003)**. [S.l.: s.n.], 2003. p. 115–118.

SUETAKE, M. **Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos**. 128 p. Tese (Doutorado em Engenharia Elétrica) — Escola de Engenharia de São Carlos, São Carlos, 2012.

THOMSON, W. On-line MCSA to diagnose shorted turns in low voltage stator windings of 3-phase induction motors prior to failure. In: **IEEE International Electric Machines and Drives Conference (IEMDC'2001)**. [S.l.: s.n.], 2001. p. 891–898.

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

TRZYNADLOWSKI, A. **Control of induction motors**. 1. ed. University of Nevada, Reno, U.S.A.: Academic Press, 2001. (Academic Press Series in Engineering).

WANG, D.; ZHANG, W.; ZHANG, J. Fault bearing identification based on wavelet packet transform technique and artificial neural network. In: **International Conference on System Science, Engineering Design and Manufacturing Informatization (ICSEM'2010)**. Yichang: [s.n.], 2010. v. 2, p. 11–14.

WEG. **Motor de Indução Trifásico: Rotor Bobinado com Sistema Motorizado de Levantamento das Escovas**. 2013. Disponível em: <<http://ecatalog.weg.net/files/wegnet/WEG-motor-com-sistema-de-levantamento-das-escovas-folheto-50042391-catalogo-portugues-br.pdf>>.

Acesso em: 26 de fevereiro de 2014.

WEG. **Motores: Aplicações Industriais**. 2013. Disponível em: <<http://ecatalog.weg.net/files/wegnet/WEG-motores-aplicacoes-industriais-50009275-catalogo-portugues-br.pdf>>. Acesso em: 30 de setembro de 2013.

WIDODO, A.; YANG, B.-S.; GU, D.-S.; CHOI, B.-K. Intelligent fault diagnosis system of induction motor based on transient current signal. **Mechatronics**, v. 19, n. 5, p. 680–689, 2009.

YAN, R.; GAO, R. X.; CHEN, X. Wavelets for fault diagnosis of rotary machines: A review with applications. **Signal Processing**, n. 0, p. –, 2013.

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

ZAERI, R.; GHANBARZADEH, A.; ATTARAN, B.; MORADI, S. Artificial neural network based fault diagnostics of rolling element bearings using continuous wavelet transform. In: **2nd International Conference on Control, Instrumentation and Automation (ICCIA'2011)**. Shiraz: [s.n.], 2011. p. 753–758.

ZHANG, P.; DU, Y.; HABELTLER, T.; LU, B. A survey of condition monitoring and protection methods for medium voltage induction motors. In: **IEEE Energy Conversion Congress and Exposition (ECCE'2009)**. [S.l.: s.n.], 2009. p. 3165–3174.