



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA



Filipe Vidal Souto

**Método de Detecção e Isolamento de Falhas em
Rolamentos de Motores Elétricos**

João Pessoa

2018

Filipe Vidal Souto

Método de Detecção e Isolamento de Falhas em Rolamentos de Motores Elétricos

Monografia apresentada a Coordenação do Curso de Engenharia da Universidade Federal da Paraíba, como requisito parcial para obtenção do título de Engenheiro Eletricista.

Universidade Federal da Paraíba
Centro de Energias Alternativas e Renováveis
Departamento de Engenharia Elétrica

Orientador: Prof. Dr. Abel Cavalcante Lima Filho

Coorientador: Prof. Msc. Thyago Leite de Vasconcelos Lima

João Pessoa

2018

Catálogo na publicação
Seção de Catalogação e Classificação

S728m Souto, Filipe Vidal.

Método de Detecção e Isolamento de Falhas em Rolamentos de Motores Elétricos / Filipe Vidal Souto. - João Pessoa, 2018.

56 f. : il.

Orientação: Abel Cavalcante Lima Filho.

Coorientação: Thyago Leite de Vasconcelos Lima.

Monografia (Graduação) - UFPB/CEAR.

1. Detecção e Isolamento de Falhas. 2. Falhas de Rolamento. 3. Análise Multiresolução Wavelet. 4. Redes Neurais Artificiais. I. Lima Filho, Abel Cavalcante. II. Lima, Thyago Leite de Vasconcelos. III. Título.

UFPB/BC

Método de Detecção e Isolamento de Falhas em Rolamentos de Motores Elétricos

por

Filipe Vidal Souto

Trabalho de Conclusão de Curso aprovado em 31 de outubro de 2018

Período letivo 2018.1

Prof. Dr. Abel Cavalcante Lima Filho

Orientador – UFPB

Prof. Dr. Francisco Antônio Belo

Examinador Interno – UFPB

Prof. Dr. Koje Daniel Vasconcelos Mishina

Examinador Interno – UFPB

Prof. Msc. Thyago Leite de Vasconcelos Lima

Examinador Externo – IFPB

João Pessoa

2018

*À Isabelle e Inês,
Amanda e Thyago,
Vanessa e Theófilo.
E as boas-vindas a Thomas.*

AGRADECIMENTOS

Agradeço em primeiro lugar a Thyago, sem o qual este trabalho não seria possível. Por sua dedicação em motivar, orientar e ajudar, muito obrigado!

Ao Prof. Abel e ao Prof. Belo, pela referência intelectual e humana que são desde o início de minha formação.

À Isabelle, quem nunca conseguirei agradecer o suficiente por tudo que já fez por mim.

À Inês, Imélida, Vinícius, Amanda, Theófilo, Vanessa, Giselle e Nicolás, por todo suporte durante todos esses anos.

Aos meus colegas do GPICEEMA, por todo o convívio e aprendizado.

Por fim, a todos meus amigos que direta ou indiretamente contribuíram para a realização deste trabalho.

MÉTODO DE DETECÇÃO E ISOLAMENTO DE FALHAS EM ROLAMENTOS DE MOTORES ELÉTRICOS

RESUMO

As principais falhas em motores elétricos incluem defeitos nos rolamentos, problemas no estator, barras quebradas e falhas relacionadas à excentricidade. Dentre estas, 50% possuem relação direta com defeitos em rolamentos. Tais falhas podem ocasionar um aumento dos níveis de vibração, cuja magnitude pode ser utilizada para diferenciar motores em funcionamento normal de motores em regime de funcionamento comprometido. A detecção e o diagnóstico precoces requerem processamento adicional dos dados de vibração, uma vez que alguns defeitos não produzirão uma alteração significativa nos dados de vibração até que uma falha completa esteja prestes a acontecer. Este trabalho consiste no desenvolvimento de um método para detecção e isolamento de falhas em rolamentos (*Fault Detection and Isolation – FDI*) de motores elétricos, considerando a ocorrência de defeitos na pista interna, na pista externa e nas esferas através do processamento de dados vibracionais da máquina elétrica. Os dados de sinais de vibração são processados digitalmente para a extração de padrões de funcionamento normal e defeituoso utilizando a técnica de análise de multiresolução (MRA – *Multiresolution Analysis*) da transformada Wavelet e técnicas estatísticas como a média, desvio padrão e *Wavelet Power Spectrum* (PS). Estes padrões por sua vez, servem de entrada para um sistema de classificação baseado em inteligência artificial, no caso, uma Rede Neural Artificial (RNA). Para validação do método, a base de dados amplamente aceita na academia como uma referência para falhas de rolamentos em motores da CWRU (*Case Western Reserve University*) foi utilizada. O método proposto apresentou resultados excelentes no diagnóstico de falhas em pista interna, externa e esferas. Obteve-se 100% de acerto para as falhas em pista interna e externa, para ambos os rolamentos e todas as falhas estudadas. Nas falhas em esfera, os resultados foram 97,2% e 91%, para falhas no rolamento da extremidade do motor e na extremidade do ventilador, respectivamente. Esses resultados comprovam a eficácia do método proposto.

Palavras-chave – Detecção e Isolamento de Falhas, Falhas de Rolamento, Análise Multiresolução Wavelet, Redes Neurais Artificiais.

METHOD OF DETECTION AND ISOLATION OF FAULTS IN BEARINGS OF ELECTRIC MOTORS

ABSTRACT

Major failures in electric motors include bearing defects, stator problems, broken bars, and eccentricity-related failures. Of these, 50% are directly related to bearing defects. Such failures may lead to an increase in vibration levels, the magnitude of which can be used to differentiate motors in normal operation from motors in a compromised state. Early detection and diagnosis requires additional processing of the vibration data as some defects will not produce a significant change in the vibration data until a complete failure is about to occur. This work consists of the development of a Fault Detection and Isolation (FDI) method of electric motors, considering the occurrence of defects in the inner race, the outer race and the rolling elements through the processing of vibrational data of the electric machine. The vibration signal data are digitally processed for patterns extraction of normal and faulty operation using the Wavelet Transform Multiresolution Analysis (MRA) technique and statistical techniques such as mean, standard deviation and Wavelet Power Spectrum (PS). These patterns in turn serve as input to a classification system based on artificial intelligence, in this case, an Artificial Neural Network (ANN). To validate the method, the database widely accepted in the academy as a reference for bearing failures in motors, CWRU (Case Western Reserve University), was used. The proposed method presented excellent results in the diagnosis of inner race, outer race and balls faults. A perfect accuracy of 100% was obtained for inner and outer race failures, for both bearings and all failures studied. In ball faults, the results were 97.2% and 91%, for motor end and fan end bearing failures, respectively. These results prove the efficacy of the proposed method.

Keywords – Fault Detection and Isolation, Bearing Faults, Wavelet Multiresolution Analysis, Artificial Neural Network.

SUMÁRIO

CAPÍTULO I APRESENTAÇÃO	12
1.1 INTRODUÇÃO.....	12
1.2 ESTADO DA ARTE	15
1.3 PREMISSAS E HIPÓTESES	17
1.4 OBJETIVOS	18
1.4.1 <i>Objetivo Geral</i>	18
1.4.2 <i>Objetivos Específicos</i>	18
1.5 ORGANIZAÇÃO DO TEXTO.....	18
CAPÍTULO II FUNDAMENTAÇÃO TEÓRICA	19
2.1 ROLAMENTOS.....	19
2.2 DADOS VIBRACIONAIS E DEFEITOS EM ROLAMENTOS	22
2.2.1 <i>Falhas Características de Rolamento</i>	25
2.3 ANÁLISE MULTIRRESOLUÇÃO.....	27
2.4 REDES NEURAIS ARTIFICIAIS	30
CAPÍTULO III MATERIAIS E MÉTODOS.....	35
3.1 CARACTERÍSTICAS DA BASE DE DADOS UTILIZADA	35
3.2 EXTRAÇÃO DE PARÂMETROS E CLASSIFICAÇÃO DOS SINAIS.....	37
3.2.1 <i>Algoritmo para cálculo da AMR</i>	38
3.2.2 <i>Características da RNA utilizada</i>	40
CAPÍTULO IV RESULTADOS	43
4.1 SINAIS DA EXTREMIDADE DO MOTOR	43
4.1.1 <i>FALHAS DE PISTA INTERNA</i>	43
4.1.2 <i>FALHAS DE PISTA EXTERNA</i>	45
4.1.3 <i>FALHAS DE ESFERA</i>	46
4.2 SINAIS DA EXTREMIDADE DO VENTILADOR	47
4.2.1 <i>FALHAS DE PISTA INTERNA</i>	47
4.2.2 <i>FALHAS DE PISTA EXTERNA</i>	48
4.2.3 <i>FALHAS DE ESFERA</i>	49
CAPÍTULO V COMENTÁRIOS E CONCLUSÕES	50
5.1 TRABALHOS FUTUROS.....	51
REFERÊNCIAS BIBLIOGRÁFICAS.....	52

LISTA DE TABELAS

Tabela 1.1 – Algumas das técnicas existentes para monitoramento da condição de rolamentos.	17
Tabela 2.1 – Tipos de rolamentos e suas capacidades de carga	22
Tabela 3.1 – Principais características da base de dados utilizada para sinais do tipo EM	36
Tabela 3.2 – Principais características da base de dados utilizada para sinais do tipo EV	37
Tabela 3.3 – Níveis de resolução e suas respectivas faixas de frequência para os coeficientes de detalhes da transformada <i>wavelet</i>	40
Tabela 4.1 – Nomenclatura adotada para as falhas.....	43
Tabela 4.2 – Codificação adotada para as saídas da rede neural – Falha de Pista Interna (EM).....	44
Tabela 4.3 – Valores médios dos parâmetros descritores de falha – Pista Interna (EM)	44
Tabela 4.4 – Valores médios dos parâmetros descritores de falha – Pista Interna (EM)	45
Tabela 4.5 – Valores médios dos parâmetros descritores de falha – Esfera (EM)	46
Tabela 4.6 – Valores médios dos parâmetros descritores de falha – Pista Interna (EV).....	47
Tabela 4.7 – Valores médios dos parâmetros descritores de falha – Pista Externa (EV)	48
Tabela 4.8 – Valores médios dos parâmetros descritores de falha – Esfera (EV).....	49

LISTA DE FIGURAS

Figura 2.1 – Tipos de Rolamentos.....	21
Figura 2.2 – Dimensões de rolamentos e frequências de defeitos.....	26
Figura 2.3 – Mancal de rolamento.....	27
Figura 2.4 – Diagrama básico da análise multiresolução	29
Figura 2.5 – Árvore de decomposição Wavelet de um sinal em três níveis.....	30
Figura 2.6 – Modelo de neurônio artificial.....	31
Figura 2.7 – Rede neural de camada única.....	32
Figura 2.8 – Rede neural de múltiplas camadas	33
Figura 2.9 – Rede neural recorrente	33
Figura 3.1 – Bancada de testes para sistema de falhas em rolamento	35
Figura 3.2 – Processo de extração de parâmetros e classificação dos sinais.....	38
Figura 3.3 – Ilustração da decomposição do sinal em um nível.....	38
Figura 3.4 – Ilustração da decomposição do sinal em um nível.....	39
Figura 3.5 – Tela inicial do Toolbox de Redes Neurais do Matlab.....	41
Figura 3.6 – Tela inicial de ajuste do número de neurônios na camada oculta	41
Figura 3.7 – Tela inicial de treinamento e avaliação de performance da RNA.....	42
Figura 4.1 – Matriz de Confusão – Pista Interna (EM)	44
Figura 4.2 – Matriz de Confusão – Pista Externa (EM)	45
Figura 4.3 – Matriz de Confusão – Esfera (EM)	46
Figura 4.4 – Matriz de Confusão – Pista Interna (EV).....	47
Figura 4.5 – Matriz de Confusão – Pista Externa (EV).....	48
Figura 4.6 – Matriz de Confusão – Esfera (EV).....	49

LISTA DE SIGLAS E SÍMBOLOS

$\psi_{a,b}(t)$	<i>Wavelets-filhas</i>
ω_0	Frequência angular fundamental, rad/s
A	Aproximação
a	Parâmetro de escalonamento da <i>wavelet</i>
b	Parâmetro de Translação da <i>wavelet</i>
CWT	<i>Continuous Wavelet Transform</i> – Transformada de Wavelet Contínua
D	Detalhe
DFT	<i>Discrete Fourier Transform</i> – Transformada de Fourier Discreta
DWT	<i>Discrete Wavelet Transform</i> – Transformada de Wavelet Discreta
FFT	<i>Fast Fourier Transform</i> – Transformada Rápida de Fourier
FT	<i>Fourier Transform</i> – Transformada de Fourier
MRA	<i>Multiresolution Analysis</i> – Análise Multiresolução
RNA	Redes Neurais Artificiais
REBs	<i>Rolling Element Bearings</i> - Rolamentos
STFT	<i>Short Time Fourier Transform</i> – Transformada de Fourier de Curta Duração
T	Período do sinal
$\psi(t)$	<i>Wavelet-mãe</i>
$\phi(t)$	Função de escala

CAPÍTULO I

APRESENTAÇÃO

1.1 INTRODUÇÃO

Com um forte apelo econômico, o estudo de falhas em sistemas industriais é tão antigo quanto os próprios sistemas em si, como apontado por Nandi et al. (2005) em seu estudo revisionista. Ainda hoje, dois terços de toda energia consumida pela indústria mundialmente é devido motores elétricos (Kotak et al., 2016). Dentre as máquinas elétricas, motores de indução possuem posição de destaque com uso amplo devido sua confiabilidade, relativo baixo custo, robustez e eficiência (Ocak e Loparo, 2004; Immovilli et al., 2009; Gritli et al., 2017).

Para garantir uma operação segura e confiável, os fabricantes e usuários de máquinas elétricas contavam inicialmente apenas com proteções simples e, em sua maioria, para condições elétricas como sobrecorrente, sobretensão e falha de aterramento. Entretanto, à medida que a complexidade das máquinas e as tarefas realizadas por estas aumentaram em complexidade, também cresceu a necessidade do diagnóstico de falhas, pois o monitoramento de condições de máquinas rotativas é importante em termos de manutenção do sistema e automação de processos (Malhi e Gao, 2004).

Ao longo das últimas décadas muitos avanços foram alcançados no desenvolvimento de processos de fabricação, técnicas de controle e manutenção industrial. No entanto, as ferramentas de manutenção para indústrias de manufatura ainda exigem melhorias constantes (Lou e Loparo, 2004). Hoje, o campo da detecção e isolamento de falhas em motores elétricos é extensivamente estudado, principalmente motivado pela economia de custos e manutenção (Sassi et al., 2007; Immovilli et al., 2009; Gritli et al., 2017). Além de refrear a redução da confiabilidade e disponibilidade das plantas industriais – grandes causadores de prejuízos financeiros para operadores

fabris, a prevenção de falhas também garante ambientes de trabalho mais seguros (Rai e Upadhyay, 2016).

Dada tamanha necessidade de aperfeiçoamento das técnicas de detecção e isolamento de falhas (Fault Detection and Isolation – FDI), grande número de artigos pode ser encontrado na literatura, com falhas em motores elétricos classificadas geralmente em quatro tipos diferentes. Nandi et al. (2005) e William e Hoffman (2011) delimitam as falhas em quatro principais grupos que demandam mais atenção, sendo elas as falhas de rolamento; falhas no estator ou armadura; defeitos do rotor, como barras ou anéis condutores quebrados; e falhas relacionadas à excentricidade. De maneira similar e mais generalizada, Immovilli et al. (2009) e Gritli et al. (2017) dividem os defeitos de máquinas elétricas em quatro classes principais que agrupam um determinado tipo de falha cada. Estas são:

- **falhas mecânicas**, que podem ser classificadas comumente em falhas de rolamentos, falhas de conexão de carga do eixo, falhas de engrenagem e desequilíbrios mecânicos;

- **falhas relacionadas ao estator**, como rompimento ou curto de um ou mais enrolamentos do estator e conexões anormais dos enrolamentos;

- **falhas relacionadas ao rotor**, como quebras em barras e anéis ou curto-circuito nos enrolamentos do circuito de campo;

- **outras falhas** como resfriamento, conexão, caixa de terminais elétricos, falhas no conversor de energia, eixo curvo (semelhante à excentricidade), etc.

Dentre tão grande variedade, falhas em rolamentos (Rolling Element Bearings - REBs) apresentam um protagonismo devido sua alta taxa de incidência (Li et al., 2000; Smith e Randall, 2015) – até 50% de todas as falhas em motores elétricos (Stack et al., 2004; Nandi et al., 2005; Osman e Wang, 2014; William e Hoffman, 2011; Rai e Upadhyay, 2016). Alguns autores chegam mesmo a estimar que dependendo do tipo e tamanho da máquina, a distribuição de falhas de rolamento varia de cerca de 40% a cerca de 90% (Gritli et al., 2017). O funcionamento de máquinas rotativas é totalmente dependente da condição dos REBs (Rai e Upadhyay, 2016), sendo os componentes mais prevacentes e que desempenham um papel notavelmente vital em quase todos os tipos de máquinas rotativas e, como tal, usados extensivamente nas indústrias devido ao seu preço baixo e facilidade operacional (Smith e Randall, 2015; Rai e Upadhyay, 2016). Portanto, a capacidade de prever uma falha do rolamento é de grande importância prática, pois identificar a existência e a gravidade de uma condição defeituosa no

estágio inicial fornecerá informações valiosas para ajustar o cronograma de manutenção e minimizar o tempo de inatividade da máquina. Além do mais, com o objetivo de prever a vida útil restante de uma máquina, assim que um defeito é identificado, é ainda mais importante que o sistema de monitoramento forneça uma estimativa do nível de gravidade do defeito. Essa capacidade é de grande relevância para a indústria (Malhi e Gao, 2004).

Todavia, em alguns ambientes industriais severos os sinais mecânicos não podem ser adquiridos. Também, à medida que a gravidade do defeito aumenta, a tendência geral de vibração crescente é sobreposta por variações locais de magnitudes menores (ruídos) devido à natureza estocástica da propagação de defeitos em máquinas. Conjuntamente, um grande número de entradas, enquanto aumenta a carga computacional, não contribui necessariamente para melhorar a eficácia da classificação de defeitos. Além disso, a latência típica do monitoramento de sensor e condição de falhas mecânicas por sinais de vibração é bastante alta. Ademais a morfologia do sinal que resulta de uma falha muda com o tempo à medida que progride de inicialização para o defeito de fato, de tal forma que algumas falhas serão indetectáveis até que sejam iminentes. (Lou e Loparo, 2004; Malhi e Gao, 2004; Gritli et al., 2017). Como a detecção precoce e o isolamento de falhas são importantes para a manutenção baseada em condições, é necessária uma abordagem de processamento de sinal mais sofisticada. Estas e outras dificuldades fazem com que a necessidade de desenvolvimento de técnicas cada vez mais poderosas e eficientes esteja sempre presente. Pesquisadores se esforçam continuamente para desenvolver melhorias nos métodos de diagnóstico estabelecidos. Estudos dessa natureza beneficiam-se muito da disponibilidade no domínio público de conjuntos de dados de referência, nos quais os pesquisadores podem testar seus algoritmos recém-desenvolvidos (Smith e Randall, 2015). Bases de dados facilitam o progresso científico na área de processamento de dados, ao permitirem uma maior a falseabilidade e garantir a integridade dos resultados – visto que eles provêm de dados conhecidos. Além do mais, o uso de “data sets” facilita a comparação entre resultados de diferentes estudos ao retirar o debate sobre a metodologia de aquisição dos dados processados. Este trabalho faz uso de um banco de dados de ampla utilização no campo da detecção e isolamento de falhas em rolamentos, que será abordado mais a frente.

1.2 ESTADO DA ARTE

Os métodos utilizados para analisar sinais de falhas em rolamentos de motores incluem análise probabilística, análise espectral, análise no domínio do tempo e até mesmo análise de elementos finitos. A abordagem da análise no domínio da frequência é a mais popular, devido à disponibilidade da técnica da Transformada de Fourier. Outro fator relevante é que as características dos sinais de vibração são mais facilmente notadas no domínio da frequência do que no domínio do tempo. Como a maioria das vibrações de rolamento são movimentos periódicos, é fácil extrair recursos de vibração do domínio de frequência usando a poderosa, computacionalmente eficiente e popular técnica da FFT (*Fast Fourier Transform* – do inglês, Transformada Rápida de Fourier).

No projeto e estudo de esquemas de diagnóstico de falhas de rolamentos de motor, é importante determinar se o algoritmo de diagnóstico de falhas projetado é capaz de classificar corretamente diferentes condições de falha de rolamento. A presença de uma variedade de ruído e um amplo espectro de sinais de defeito de rolamento apresenta dificuldade na detecção da condição do rolamento usando sinais de vibração no domínio do tempo. Isso exige uma abordagem para identificação e quantificação dos recursos característicos relevantes para as condições do rolamento. Embora muitas vezes a inspeção visual das características do domínio da frequência dos sinais de vibração seja adequada para identificar as falhas, existe a necessidade de um procedimento confiável, rápido e automatizado de diagnósticos (Li et al., 2000; Samanta e Al-Balushi, 2003).

Os sinais de vibração de uma máquina podem acabar agindo como uma modulação de amplitude (AM – em inglês, Amplitude Modulation). Devido a falhas nos rolamentos, a frequência da portadora e seus componentes de banda lateral ocorrem em regiões de ressonância mecânica natural; portanto, esses componentes de frequência são salientes na vibração da máquina. Entretanto, as frequências características de falha são determinadas pela geometria do rolamento, ocorrendo tipicamente em baixas frequências. Nesta região, um amortecimento mecânico significativo pode estar presente. Portanto, no momento em que a energia nessas frequências de falha características se propaga do rolamento para o sensor de vibração, elas podem ser significativamente atenuadas. Este fenômeno é especialmente perceptível em falhas de

rolamentos incipientes onde a energia nas frequências características é baixa (Stack et al., 2004).

Para Osman e Wang (2014), as condições da dinamicidade são determinantes nas dificuldades encontradas no estudo das falhas em rolamentos. É sabido que os sinais de vibração gerados pelos rolamentos podem ser estacionários ou não estacionários. Se ocorrer um defeito na pista fixa de um rolamento, a sua assinatura correspondente pode ser caracterizada como estacionária, o que é relativamente fácil de analisar utilizando técnicas clássicas de análise de dados, *e.g.* técnicas que empreguem indicadores estatísticos. Contudo, como vimos previamente, quando ocorre um defeito em uma pista rotativa ou elemento rolante de um rolamento, as assinaturas resultantes relacionadas a defeitos são moduladas posteriormente e se tornam não estacionárias, o que adiciona mais dificuldades ao usar a maioria das técnicas de detecção de falta de rolamentos atualmente disponíveis. Além disso, os sinais de vibração dos rolamentos em aplicações do mundo real são quase sempre não estacionários, uma vez que os rolamentos estão operando sob condições de operação inerentemente dinâmicas – por exemplo, as condições de velocidade e carga mudam com o tempo. Correspondentemente, a detecção confiável de falhas em rolamentos continua sendo uma tarefa desafiadora, especialmente para aplicações industriais do mundo real (Osman e Wang, 2014).

Para Malhi e Gao (2004) os principais recursos estatísticos no domínio do tempo considerados para diagnosticar defeitos no rolamento incluem o valor eficaz (RMS – *Root Mean Square*), fator de crista, assimetria e curtose. Outras características investigadas incluíram as frequências características relacionadas com a rotação de componentes de suporte, por exemplo, BPFO, BPFI, BSF – estas serão detalhadamente explicadas no capítulo seguinte. Estas características estão intimamente relacionadas com defeitos localizados através das amplitudes em frequências específicas e, portanto, não fornecem uma boa medida do estado de saúde do rolamento. Verificou-se que as características do domínio do tempo e da frequência, quando utilizadas isoladamente, são de eficácia limitada para detectar falhas na fase inicial, devido às suas amplitudes geralmente fracas e curta duração. Portanto, técnicas como a da análise no domínio Wavelet podem ser alternativas interessantes.

Tabela 1.1 – Algumas das técnicas existentes para monitoramento da condição de rolamentos.

Domínio do Tempo	Domínio da Frequência	Domínio Wavelet
Valor de pico (P_{pv})	Amplitude na BPFI (F_i)	Amplitude na BPFI (W_i)
RMS (P_{RMS})	Amplitude na BPFO (F_o)	Amplitude na BPFO (W_o)
Fator de crista (P_{cf})	Amplitude na BSF (F_b)	Amplitude na BSF (W_b)
Assimetria (P_{sr})	Potência na região da frequência da falha (F_{pwr})	Potência na região da frequência da falha (W_{pwr})
Curtose (P_k)		

Intuitivamente, é difícil estimar quais técnicas são mais sensíveis ao desenvolvimento e à propagação de defeitos em máquinas elétricas, pois vários fatores afetam a eficácia das técnicas, por exemplo, localização dos sensores, relação sinal-ruído (SNR – *Signal-to-Noise Ratio*) do sistema de aquisição de dados, etc. A maioria das pesquisas neste campo tem como objetivo categorizar os tipos de defeitos de rolamento usando técnicas estatísticas, modelos matemáticos complexos ou inteligência artificial. Entretanto, o conhecimento sobre o nível de severidade do defeito é necessário de antemão para desenvolver um modelo apropriado de rede neural (Malhi e Gao, 2004). Outro problema, como explicado por Smith e Randall (2015), é que a maioria dos estudos parece produzir classificações não-físicas a partir de algoritmos de aprendizado de máquina. Uma vez que esses algoritmos não identificam características físicas permanece a dúvida sobre a aplicabilidade mais ampla de alguns dos métodos desenvolvidos, especialmente nos casos em que dados atípicos do tipo de falha de rolamento foram usados. Essas considerações devem ser levadas em conta durante o planejamento das técnicas de processamento e de classificação para métodos de detecção e isolamento de falha a ser implementado.

1.3 PREMISSAS E HIPÓTESES

- É possível realizar o diagnóstico da falha precocemente, antes da parada total do funcionamento do motor.
- É possível obter-se informações corretas de detecção e isolamento das falhas sem se conhecer as condições de carregamento às quais o motor está submetido.
- É possível a aplicação do método de detecção e isolamento desenvolvido sem a necessidade do conhecimento da geometria do rolamento instalado.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

Desenvolver, validar, implementar e analisar um método para detecção e isolamento de falhas em rolamentos de motores elétricos.

1.4.2 Objetivos Específicos

- Pesquisar as técnicas existentes para diagnóstico de falhas em rolamentos;
- Desenvolver um algoritmo para o processamento de sinais, visando à obtenção dos parâmetros descritores de falhas;
- Desenvolver um algoritmo para a detecção e isolamento de falhas em diferentes condições de funcionamento e grau de comprometimento;
- Realizar testes, validando as medidas e analisando a exatidão dos resultados;

1.5 ORGANIZAÇÃO DO TEXTO

Neste texto, primeiramente, iremos apresentar no segundo capítulo uma fundamentação teórica, abordando o conteúdo teórico que envolve os rolamentos de motores, como também as técnicas de processamento e classificação de sinais a serem utilizadas. Após, no terceiro capítulo serão detalhados os métodos para desenvolvimento do trabalho, descrevendo a base de dados utilizada, as ferramentas de análise de dados e o algoritmo de classificação. Em seguida, no quarto capítulo, serão apresentados os resultados do método de detecção e isolamento de falhas desenvolvido, relatando como funcionou nosso método para os casos que são descritos na metodologia. Por fim, o último capítulo é destinado para as considerações finais, relatando as percepções gerais e específicas a cerca do resultado do trabalho e debatendo a possibilidade de futuros projetos.

CAPÍTULO II

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordados os principais conceitos e definições das ferramentas de análise de sinais utilizadas no presente trabalho de pesquisa, como também será apresentado um estudo criterioso a cerca dos rolamentos de motores elétricos. Serão evidenciados aspectos teóricos sobre a mecânica e funcionamento dos rolamentos, como também suas falhas características. Também será destacada a transformada matemática *Wavelet* no que tange suas aplicações no processamento de sinais. Além disso, serão tratados algoritmos de classificação que deverão ser utilizadas no sistema de detecção proposto no trabalho – no caso, as Redes Neurais Artificiais.

2.1 ROLAMENTOS

REBs estão entre os componentes mais precisos em conjuntos mecânicos, são produzidos com tolerâncias muito restritas e normalmente são encontrados na maioria dos equipamentos rotacionais (Gebraeel et al, 2004). Cada rolamento consiste em dois anéis - um interno e outro externo. Um conjunto de esferas ou elementos rolantes colocados entre as pistas interna e externa gira dentro desses anéis para que as cargas axiais e radiais possam ser transmitidas através dos elementos rolantes. Habitualmente, uma das pistas é mantida fixa. Assim, o movimento da pista que permanece em estado rotacional faz com que as esferas também se desloquem ao longo do rolamento. Pela geometria e dinâmica do dispositivo, as esferas em movimento possuem um coeficiente de atrito muito menor do que se duas superfícies planas estivessem girando uma na outra. Este é o propósito de um REB, reduzir o atrito rotacional e suportar cargas radiais e axiais (Sassi et al., 2007; Rao et al., 2012).

A condição e a integridade dos rolamentos desempenham um papel importante na funcionalidade e no desempenho desses equipamentos, pois o papel de um REB dentro de uma máquina é fornecer um posicionamento de alta precisão e capacidade de

carga entre um eixo rotativo e uma caixa de eixo fixa, mantendo um torque de atrito pequeno, baixa vibração e baixa emissão de ruído. É simples em forma e conceito, mas extremamente eficaz na redução do atrito e do desgaste em uma ampla gama de produtos de máquinas (Sassi et al., 2007). Rolamentos são encontrados em quase todas as aplicações de engenharia e existem numerosos *designs*, cada qual oferecendo *trade-offs*. Eles também podem ser feitos de diversos materiais, incluindo: aço inoxidável, aço cromado e cerâmica. Existem até mesmo REBs híbridos, possuindo esferas de material cerâmico e pistas metálicas (Rao et al., 2012). A Fig. 1 ilustra diferentes tipos de rolamentos e suas estruturas. A Tabela 1 lista brevemente os tipos de rolamentos e suas respectivas capacidades de carga. Dentre tais tipos de rolamentos e suas aplicações, destacam-se os seguintes:

Os rolamentos de esferas, que são o tipo mais comum de rolamento e podem suportar cargas radiais e axiais. Neste tipo de rolamento, os pontos de contato entre a esfera e a pista externa são muito pequenos devido à sua forma esférica, o que ajuda o rolamento a girar suavemente. Entretanto, como o ponto de contato é muito pequeno, o rolamento pode ficar sobrecarregado em um ponto específico, causando deformação e arruinando o rolamento. Por tal razão, os rolamentos de esferas são normalmente usados em aplicações em que a carga é relativamente pequena.

Os rolamentos de rolos cilíndricos, que são um tipo de rolamento semelhante a um rolamento de esferas, mas usando pequenos rolos cilíndricos em vez de bolas. Com um rolamento de rolos em vez de ter um ponto de contato único e pequeno, há uma faixa inteira ao longo da largura do rolamento. Por tal razão são mais utilizados em aplicações que requerem serviços pesados, como rolos de correia transportadora, onde devem conter cargas radiais severas.

Os rolamentos de rolos esféricos, que normalmente consistem em duas filas de rolos em forma de barril, onde uma está no anel interno e a outra está em uma superfície esférica contínua retificada no diâmetro interno do anel externo. Isso permite que o rolamento opere com algum desalinhamento. Rolos esféricos têm perfis de barril que combinam com os perfis das pistas, tornando-os robustos e com alta capacidade de carga. Eles são montados em pares dentro do alojamento do mancal e posicionados em direções opostas para que a carga possa ser suportada em qualquer direção.

Os rolamentos de rolos de agulhas, que são semelhantes aos rolamentos de rolo cilíndricos, destacando-se destes por possuírem cilindros de diâmetro muito pequeno,

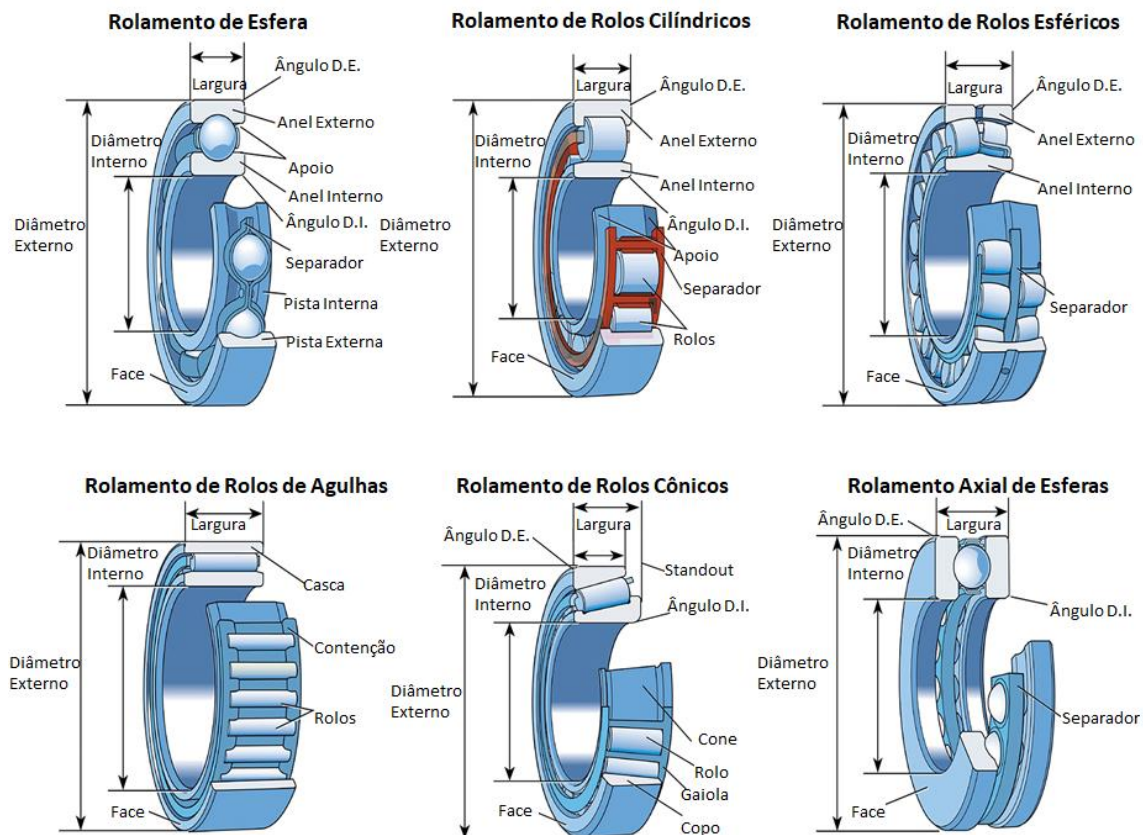
tornando-os ideais para aplicações em lugares exíguos, como caixas de engrenagens que giram em velocidades mais altas.

Os rolamentos de rolos cônicos, que possuem rolos inclinados. Eles são projetados para suportar grandes cargas axiais e radiais, fazendo com que sejam utilizados em aplicações como rolamentos para cubo de rodas de veículos.

Os rolamentos axiais de esferas são projetados para lidar com cargas axiais e são compostos por duas placas ranhuradas com um conjunto de esferas entre elas. Estes rolamentos são usados principalmente para aplicações de baixa precisão e baixa velocidade, além de que eles não podem receber muita carga radial.

Por fim, os rolamentos magnéticos e fluídos, que são utilizados em aplicações que demandam baixíssimo atrito.

Figura 2.1 – Tipos de Rolamentos



Fonte: Gonzalez (2015)

Tabela 2.1 – Tipos de rolamentos e suas capacidades de carga

Classificações Médias Relativas			
	Tipo	Capacidade	
		Radial	Axial
Rolamentos de Esferas	Conrad	Bom	Razoável
	Auto-alinhamento	Razoável	Razoável
Rolamentos de Rolos Cilíndricos	Anel Interno Separável	Excelente	0
	Auto-contido	Excelente	Ruim
Rolamentos de Rolos Esféricos	Auto-alinhamento	Excelente	Bom
Rolamentos de Rolos de Agulha	Rolamento completo	Bom	0
Rolamentos de Rolos Cônicos	Auto-alinhamento	Bom	Razoável
Rolamentos Axiais	Esfera com pista ranhurada	Ruim	Excelente
	Sentido único	0	Excelente

Fonte: Gonzalez (2015)

2.2 DADOS VIBRACIONAIS E DEFEITOS EM ROLAMENTOS

A detecção de falhas de rolamentos pode ser realizada com base em diferentes portadores de informações, como informações de propriedades do lubrificante, informações de temperatura, emissão acústica, assinatura de corrente ou sinal de vibração. A análise baseada em vibração é a abordagem mais usada devido à sua facilidade de medição e relativamente maior sinal para relação de ruído (Osman e Wang, 2014). Conjuntamente, é importante evidenciar que qualquer alteração na estrutura mecânica de uma máquina rotativa gera uma variação de força periódica que produz uma “assinatura” no espectro do sinal de vibração. Em qualquer tipo de falha mecânica, esse processo começa com uma intensidade muito baixa: rachaduras ou fragmentação e, mais tarde, degenera em efeitos superiores. Um dos principais desafios é detectar os fenômenos iniciais, que podem estar abaixo dos limiares de ruído ou ocultos (Gritli et al., 2017). A vibração do rolamento pode degradar a qualidade de uma linha de produtos que é acionada por um sistema de motor. Altos níveis de vibração em rolamentos podem até mesmo causar o funcionamento incorreto de todo o sistema do motor, resultando em tempo de inatividade para o sistema e perdas econômicas.

Os defeitos responsáveis por danos no rolamento podem ser localizados ou distribuídos. Defeitos localizados (geralmente ocorrendo como resultado do processo de fadiga) incluem rachaduras, cavidades ou fragmentação. Os defeitos distribuídos, que são causados por imperfeições de fabricação inevitáveis, incluem rugosidade, ondulação e manutenção da superfície. Respostas de vibração causadas por defeitos localizados são importantes no monitoramento de condições e na manutenção do sistema, enquanto as respostas de defeitos distribuídos são usadas para inspeção de qualidade (Sassi et al., 2007). A importância de usar a análise de vibração para detecção de falhas em rolamentos está no processo de degradação destes elementos. Mesmo sob condições normais de operação, com carga equilibrada e bom alinhamento, podem ocorrer falhas por fadiga. O despedaçamento ou fragmentação dos rolamentos pode ocorrer quando a fadiga faz com que pequenos pedaços se desprendam do rolamento. Essas falhas podem levar a um aumento dos níveis de vibração e ruído (Nandi et al., 2005).

A fadiga do rolamento normalmente começa com rachaduras superficiais iniciando dentro do material da pista. Durante a operação, as rachaduras se propagam e eventualmente atingem a superfície da pista, desalojando um pedaço de metal da superfície. Isso resulta em um processo fragmentação, que é conhecido no inglês como “*spalling*” e em muitas aplicações é definido como o início da falha. Assim o faz Osman et al., (2004), que classifica esse como o início dos defeitos de ponto único, onde elementos como esferas ou roletes giram sobre a pista causando impactos repetitivos toda vez que passam sobre a falha, produzindo ondas de choque mecânicas. Conseqüentemente, uma frequência distinta é excitada. Esta frequência, conhecida como a frequência do defeito (ou frequência característica de defeito) é uma função do número de esferas, da velocidade de rotação do motor, da geometria do rolamento (o diâmetro do passo em relação ao diâmetro da esfera) e dos tipos de defeitos e sua localização. Já a amplitude dos sinais de vibração dos componentes defeituosos da máquina aumenta à medida que a gravidade do defeito aumenta. Assim, a análise de vibrações torna-se a técnica de monitoramento de condições mais adequada para investigar a evolução dessas frequências características de defeito ao longo do tempo, uma vez ocorrida uma degradação na superfície de uma pista ou elemento rolante (Gebraeel et al., 2004; Malhi e Gao, 2004; Ocak e Loparo, 2004).

A vibração é a resposta de um sistema mecânico às forças produzidas pelos defeitos. Um motor (ou um rolamento) perfeito produziria uma vibração mínima durante a operação normal. Assim, outra razão pela qual os sinais de vibração são

comumente adotados para detecção de falhas mecânicas em motores de indução e cargas mecânicas relacionadas é que, além dos defeitos de rolamentos, é possível com estes a identificação de outros problemas ao compararem-se os sinais de vibração de uma máquina operando com e sem condições defeituosas – tais como desbalanceamento de massa, desalinhamento do eixo, atrito do rotor e falhas na engrenagem. Esses sinais também podem ser usados para detectar as falhas incipientes dos componentes da máquina, através de sistemas supervisórios in loco, reduzindo a possibilidade de danos catastróficos (Samanta e Al-Balushi, 2003; Ocak e Loparo, 2004; Gritli et al., 2017). As características únicas de cada falha que podem ser isoladas durante a análise do espectro dos sinais de vibração são conhecidas como “assinaturas” da falha.

A manutenção preditiva é mais útil para prever falhas de equipamentos e evitar atividades de manutenção desnecessárias. O monitoramento de condições é um componente inerente da manutenção preditiva e o acompanhamento dos sinais vibracionais do rolamento é o método comumente usado para avaliar as condições destes. Dessa forma, o monitoramento adequado dos níveis de vibração em um sistema de motor é altamente econômico na minimização do tempo de inatividade da manutenção, uma vez que é garantido através do aviso antecipado que o sistema não se deteriore para uma condição onde é necessária ação de emergência. Portanto, é fundamental incluir o monitoramento de sinais de vibração no esquema de diagnóstico de falhas de máquinas rotativas (Li et al., 2000; Gebraeel et al., 2004).

O monitoramento de vibração é amplo e depende de padrões comuns, como o ISO10816, que estabelece as condições gerais e procedimentos para medição e avaliação de vibrações de peças de máquinas. Os sinais de vibração são obtidos por sensores colocados na parte externa da máquina e são bastante confiáveis e maduros. Na maioria dos sistemas de diagnóstico e prognóstico de falha de máquina, a vibração da máquina rotativa (motor, caixa de engrenagens, base de sustentação) é medida diretamente por um acelerômetro, em alguns poucos casos, por um captador acústico. Algumas técnicas também usam as correntes do estator do motor elétrico como sinais de entrada para detecção de falhas (Lou e Loparo, 2004) – estas não serão abordadas neste trabalho, que focará na análise de sinais vibracionais. A análise dos espectros de vibração para isolamento das “assinaturas” das falhas é indispensável, ainda mais no caso de elementos com falhas mecânicas tão constantes quanto os REBs (Gritli et al., 2017). Os fabricantes geralmente fornecem essas frequências na folha de dados do rolamento, usualmente de acordo com os padrões vigentes, tais como a ISO10816 já

mencionada ou a ISO13373 que estabelece diretrizes para os procedimentos gerais a serem considerados ao realizar o diagnóstico de vibração de máquinas rotativas. Todavia, os valores medidos para as frequências características podem não corresponder aos calculados teoricamente, especialmente quando os rolamentos de esferas têm cargas de impulso significativas e pré-cargas internas (Ocak e Loparo, 2004).


Geralmente, as técnicas de diagnóstico baseadas na análise dos sinais mecânicos mostram bons desempenhos, uma vez que examinando a magnitude dos dados de vibração sob condições de operação com falhas de rolamento, é possível distinguir os dados normais de diferentes tipos de dados de falha. No entanto, isso nem sempre é aplicável e tais técnicas também possuem complicações em sua implantação (Lou e Loparo, 2004; Gritli et al., 2017).

2.2.1 Falhas Características de Rolamento

Uma classe importante de detecção de falhas em REBs baseia-se nas frequências de defeito do rolamento, que são frequências nas quais os elementos rolantes passam sobre um ponto de defeito. Para uma determinada geometria do rolamento, a pista interna, a pista externa e as falhas do elemento rolante geram espectros de vibração com componentes de frequência exclusivos. Essas frequências são excitadas à medida que um defeito de rolamento evolui e suas amplitudes são tipicamente uma indicação da gravidade do defeito. A presença dos harmônicos das frequências características de defeito é também outra indicação de degradação nos elementos (Ocak e Loparo, 2004; Gebraeel et al., 2004). Na Fig. 2.2 temos a ilustração de um rolamento e suas dimensões, onde os principais parâmetros geométricos são o diâmetro da esfera (B_d), o a distância média de afastamento entre esferas (P_d), o ângulo de contato (Φ) e por fim o número de elementos rolantes (N). Usualmente, a pista do anel externo é considerada estacionária. Também são ilustradas as diferentes frequências características de defeito. Na Fig. 2.3, está ilustrado um mancal de rolamentos, onde podemos detalhar: (a) furos de relubrificação em ambos os lados; (b) capa externa esférica, podendo conferir até 2° de auto-alinhamento; (c) separadores de esferas em aço; (d) mancal “*pillow-block*”; (e) graxeira para relubrificação; (f) combinação de chapa de aço e vedação em borracha sintética (blindagem); (g) fixação do rolamento no eixo através de parafusos, colar (concêntrico ou excêntrico) ou bucha adaptadora.

Na literatura, existem cinco movimentos básicos que são usados para descrever a dinâmica dos elementos de rolamento, com cada movimento tendo uma frequência correspondente. Esses movimentos estão evidenciados com suas respectivas frequências na Fig. 2.2.

Figura 2.2 – Dimensões de rolamentos e frequências de defeitos



Fonte: William e Hoffman (2011)

- **FREQUÊNCIA DE ROTAÇÃO (f_s):** É a frequência referente à velocidade de rotação do eixo do rotor no sistema rolamento-rotor. Todas as outras frequências são uma função dessa frequência.
- **FREQUÊNCIA DE DEFEITO NA GAIOLA (FTF):** Está relacionada ao movimento da gaiola.

$$FTF = \frac{f_s}{2} \left[1 - \frac{B_d}{P_d} \cos \phi \right] \quad (2.1)$$

- **FREQUÊNCIA DE DEFEITO NA PISTA EXTERNA (BPFO):** É definida como a taxa na qual as esferas passam um ponto na pista do anel externo.

$$BPFO = N(FTF) \quad (2.2)$$


- **FREQUÊNCIA DE DEFEITO NA PISTA INTERNA (BPFI):** Indica a taxa na qual as esferas passam um ponto na pista do anel interno.

$$BPFI = N(f_s - FTF) \quad (2.3)$$

- **FREQUÊNCIA DE DEFEITO NO ELEMENTO ROLANTE (BSF):**
É a taxa de rotação de uma esfera em torno de seu próprio eixo em um rolamento.

$$BSF = \frac{f_s}{2} \left(\frac{P_d}{B_d} \right) \left[1 - \left(\frac{B_d}{P_d} \right)^2 \cos\phi \right] \quad (2.4)$$

Figura 2.3 – Mancal de rolamento



Fonte: Adaptado de FRM (2018)

2.3 ANÁLISE MULIRESOLUÇÃO

A transformada de Wavelet foi desenvolvida como uma alternativa à transformada de Fourier de Tempo Curto (STFT), visando solucionar o problema da resolução (Oliveira, 2007). De maneira similar à STFT, a análise com wavelets também consiste em multiplicar o sinal por uma função, ou janela, mas esta não tem mais um tamanho fixo durante a análise, mas variável que se adapta conforme as necessidades de resolução de cada situação em estudo. Tem-se uma alta resolução no tempo e baixa na frequência para frequências mais altas e pouca resolução no tempo e alta na frequência para frequências mais baixas. Tal comportamento é justificado ao se verificar que a maioria dos sinais estudados possuem componentes de alta frequência com curta

duração e componentes de baixa frequência com uma duração mais longa (Graps, 1999; Burrus et al., 1998). Essa maneira de se analisar o sinal em frequências diferentes com resoluções diferentes é conhecida como Análise Multiresolução (MRA).

As Transformadas Discretas de Wavelet (DWT) foram introduzidas no intuito de proporcionar uma descrição mais eficiente que a Transformada Contínua de Wavelet (CWT), que apresenta problemas no aspecto prático, uma vez que os parâmetros envolvidos na transformada (escala e posição) são contínuos e sua mudança constante gera grande esforço computacional e exige uma grande quantidade de dados para que a análise seja realizada. A DWT não é transladada nem escalonada continuamente, mas sim em intervalos discretos (Oliveira, 2007). Na Equação 2.5 encontra-se descrita a equação para a DWT

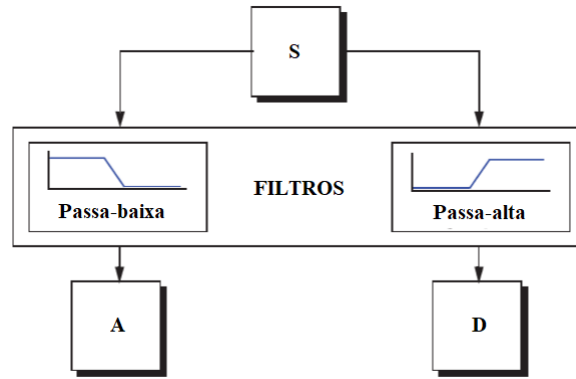
$$DWT(j,k) = |a_0^j|^{-1/2} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t - kb_0 a_0^j}{a_0^j} \right) dt \quad (2.5)$$

Em que os parâmetros j e k são inteiros, $a_0 > 1$ é um parâmetro de dilatação fixo, b_0 é o fator de translação fixo. Na literatura, os valores dos parâmetros são, geralmente, adotados como sendo $a_0 = 2$ e $b_0 = 1$, pelo fato de eliminarem a redundância da CWT, garantindo a inversibilidade e a formação de uma base ortonormal pelas wavelets-filhas (Araujo, 2011; Brito & Pires, 2005). Adotando-se tais parâmetros na Equação 2.5, tem-se:

$$DWT(j,k) = 2^{-j/2} \int_{-\infty}^{+\infty} x(t) \psi^*(2^{-j}t - k) dt \quad (2.6)$$

Mallat (1989) propôs um algoritmo para a implementação da DWT, conhecido como Algoritmo Piramidal de Mallat ou Análise Multiresolução (MRA). No trabalho é demonstrado que um sinal pode ser decomposto em duas componentes, aproximação e detalhe, bem como pode ser reconstruído a partir delas. A aproximação pode ser interpretada como um filtro passa-baixa, o qual contém informações em baixa frequência do sinal original e o detalhe pode ser interpretado como um filtro passa-alta que contém, por sua vez, informações em alta frequência do mesmo sinal original (Lacerda, 2011), como ilustrado na Figura 2.4.

Figura 2.4 – Diagrama básico da análise multiresolução



Fonte: Adaptado de Misiti *et al.* (2009)

Na análise multiresolução, o sinal é decomposto em um número de resoluções ou níveis. A função $\psi(j, k)$ é correlacionada a um filtro passa-alta, fornecendo os detalhes em vários níveis. Uma função de escala $\phi(j, k)$, cujo surgimento decorre da análise multiresolução, se correlaciona a um filtro passa-baixa e fornece as aproximações do sinal (Santiago 2004). Dessa forma, a DWT pode ser obtida por (Kim & Aggarwal, 2001):

$$D_j(n) = \sum_k h(k) A_{j-1}(n-k) \quad (2.7)$$

$$A_j(n) = \sum_k l(k) A_{j-1}(n-k) \quad (2.8)$$


Em que l e h são os vetores filtros passa-baixa e passa-alta, respectivamente. D_j e A_j são os detalhes e as aproximações do sinal original na resolução j , $j = 1, 2, \dots, J$, respectivamente, A_{j-1} é a aproximação no nível imediatamente acima do nível j , e $k = 1, 2, \dots, K$, em que k é o comprimento do vetor filtro.

Na teoria de análise multiresolução, um sinal original discreto S é decomposto em duas componentes A_1 (aproximação do sinal) e D_1 (detalhe do sinal), de forma que:

$$S = A_1 + D_1 \quad (2.9)$$

Extendendo esse raciocínio para diversos níveis de análise multiresolução, nota-se que relação similar é válida para todos os componentes do sinal reconstruído. Dessa forma, existem várias maneiras de se reconstruir o sinal original (Misiti et al., 2009), como ilustrado na Figura 2.5

Figura 2.5 – Árvore de decomposição Wavelet de um sinal em três níveis



Fonte: Adaptado de Misiti *et al.* (2009)

2.4 REDES NEURAIS ARTIFICIAIS

Uma rede neural artificial (RNA) é um sistema composto por processadores paralelos, conectados uns aos outros como em um grafo orientado, em que cada processador (neurônio artificial) é representado como um nó (Freeman & Skapura, 1993). A estrutura de neurônios artificiais interconectados tenta imitar as capacidades computacionais do cérebro humano ao buscar e encontrar novos modelos de processamento para a solução de problemas do mundo real, como reconhecimento de padrões e controle inteligente.

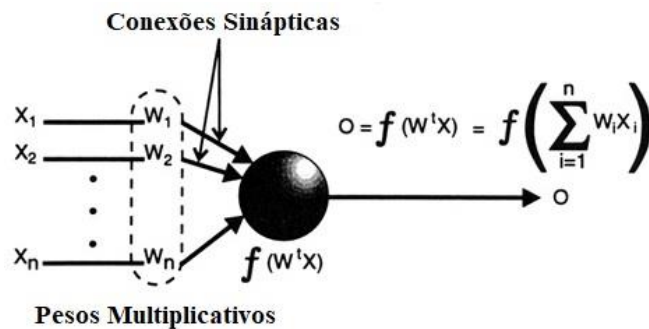
Uma rede neural se assemelha ao cérebro humano em dois aspectos (Haykin, 2008):

- O conhecimento é adquirido pela rede a partir de seu ambiente, por meio de um processo de aprendizagem;
- As forças de conexão internas, ou pesos sinápticos, são utilizadas para o armazenamento do conhecimento adquirido.

A unidade de processamento fundamental de uma RNA, o neurônio artificial, pode receber um ou mais sinais de entrada, possuindo apenas uma conexão de saída que se ramifica, conforme desejado, em conexões derivadas que carregam o mesmo sinal de saída do elemento de processamento. O sinal de saída, por sua vez, pode ser passado

adiante como sinal de entrada para um ou vários neurônios de uma camada subsequente (Ludwig Jr. & Costa, 2007). Na Figura 2.6 é ilustrada a estrutura básica de um neurônio artificial.

Figura 2.6 – Modelo de neurônio artificial



Fonte: Adaptado de Pandya & Macy (1995)

Os valores recebidos nas entradas do neurônio artificial são ponderados pelos pesos sinápticos e cada neurônio atua como um combinador linear, que soma um conjunto de entradas ponderadas por pesos e provê uma saída por meio de uma função de ativação (Kulkarni et al., 2010). O processamento de informações que ocorre dentro de cada neurônio pode ser definido arbitrariamente, desde que seja completamente local (Hutch-Nielsen, 1990).

Uma RNA é capaz de aprender a partir da observação do ambiente e essa aprendizagem acontece mediante a mudança dos pesos que conectam os neurônios (Aggarwal, 2018). Os métodos de aprendizagem são classificados em duas categorias (Castillo et al., 1999):

- **Aprendizado supervisionado** – a RNA é submetida a um conjunto de padrões de treinamento, constituídos por pares entrada/saída desejada, de maneira que os pesos são obtidos mediante a minimização de uma função de erro que mede a diferença entre os valores de saída desejados e aqueles apresentados pela RNA;


- **Aprendizado não supervisionado** – a RNA é treinada unicamente com os parâmetros de entrada, não sendo oferecidas informações externas, de modo que sejam descobertos padrões ou categorias de forma autônoma. Não existem saídas desejadas, mas o sistema acaba por evoluir de maneira auto-organizada para um estado estável considerado.

Segundo Pagliosa (2003), a arquitetura de uma RNA pode ser definida pelo número de camadas da rede e pelo tipo de conexão entre os neurônios. Existem três tipos de camadas (Amezcuca & Castillo, 2017):

- Camada de entrada, composta por neurônios que recebem dados;
- Camada oculta, que não possui conexão direta com o ambiente e é responsável por dar à rede neural graus adicionais de liberdade que proporcionam a descoberta de representações internas correspondentes a certas características do ambiente, proporcionando maior riqueza computacional;
- Camada de saída, cujos neurônios fornecem a resposta final da RNA.

De acordo com o número de camadas, uma RNA pode ser classificada como de camada única (single layer), em que se tem uma camada de entrada de nós de origem que se projeta diretamente em uma camada de saída de neurônios (Figura 2.7), ou de múltiplas camadas (multilayer), em que se percebem a presença de uma ou mais camadas intermediárias, chamadas de camadas ocultas (Figura 2.8) (Haykin,2008) .

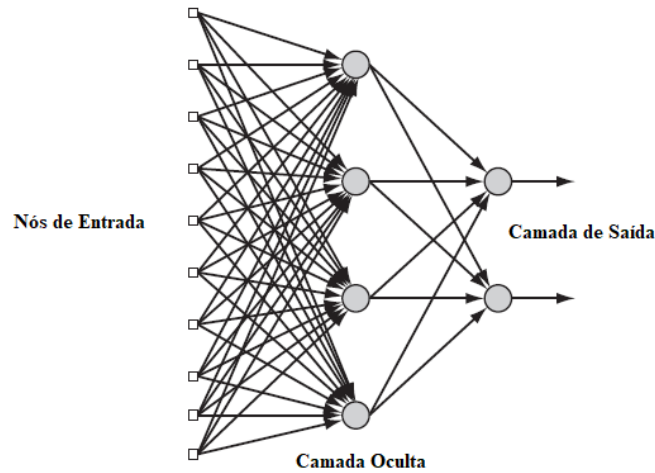
Figura 2.7 – Rede neural de camada única



Fonte: Adaptado de Haykin (2008)

Levando-se em consideração o tipo de conexão entre os neurônios, ou o fluxo de dados em uma rede neural, existem redes unidirecionais (*feedforward*), em que a informação circula dos neurônios de entrada aos neurônios de saída (sentido único) e redes recorrentes (*feedback*), em que a informação pode circular entre camadas em qualquer direção (Figura 2.9) (Amezcuca et al., 2017).

Figura 2.8 – Rede neural de múltiplas camadas




Fonte: Adaptado de Haykin (2008)

Redes neurais artificiais vêm sendo amplamente utilizadas em diversas áreas, como medicina (Yan *et al.*, 2006), química (Zhang & Friedrich, 2003), biologia (Tian & Shang, 2006). Em Fernandes (2009) é demonstrada a aplicação de RNA para classificação de fontes de correntes harmônicas em sistemas de distribuição de energia elétrica.

O trabalho apresentado em Dubery & Agrawal (2015) utiliza uma combinação de decomposição de modo empírico, transformada de Hilbert e redes neurais para a extração de padrões e classificação de falhas em rolamentos de motores trifásicos. São utilizados sinais de vibração extraídos de diversas condições de operação do motor e verificou-se que o sistema apresentou desempenho superior quando comparado com outras técnicas propostas na literatura.

Figura 2.9 – Rede neural recorrente



Fonte: Adaptado de Haykin (2008)

Gongora *et al.* (2016) apresentaram um método baseado em RNA para a detecção e classificação de falhas em rolamentos de motores de indução trifásicos conectados diretamente à rede elétrica. São observadas apenas variáveis elétricas do processo (tensões e correntes) em situações em que o motor atua em situações de desequilíbrios da tensão de alimentação e variações de carga. Os resultados mostraram uma taxa de acerto de 99% e 97% para validação cruzada e não cruzada, respectivamente.

CAPÍTULO III


MATERIAIS E MÉTODOS

Neste capítulo serão abordados os processos realizados para produção deste trabalho, desde a explanação sobre a base de dados utilizadas, como também o fluxo de análise dos dados, notabilizando a Análise Multiresolução Wavelet e as principais características da RNA empregada.

3.1 CARACTERÍSTICAS DA BASE DE DADOS UTILIZADA

Na Figura 3.1 encontra-se ilustrada a bancada de testes utilizada para análise de falhas de rolamento, que encontra-se instalada na *Case Western Reserve University* (CWRU).

Figura 3.1 – Bancada de testes para sistema de falhas em rolamento



Fonte: CRWU (2004)

A bancada de testes é composta por um motor de 2 hp, um transdutor de torque (encoder), um dinamômetro, sistema de controle e um motor CC para aplicação de carga no eixo. Falhas pontuais foram inseridas nos rolamentos usados para testes, cujos

diâmetros foram de 0,1778 mm, 0,3566 mm, 0,5334 mm e 0,7112 mm, com variações de profundidade para o último caso, pois estes utilizaram rolamentos de diferente fabricante, a fim de equiparar as condições iniciais dos rolamentos. As falhas foram impostas nos rolamentos do mancal da extremidade do motor (EM) e da extremidade do ventilador (EV). Foram utilizados rolamentos 6205-2RS JEM e 6203-2RS JEM da fabricante SKF para as falhas EM e EV, respectivamente, para os diâmetros de 0,1778 mm, 0,3566 mm, 0,5334 mm e rolamentos equivalentes da fabricante NTN para o diâmetro de 0,7112 mm. Os testes foram realizados sob quatro condições de carregamento do eixo, 0 hp, 1 hp, 2 hp e 3 hp.

No presente trabalho, são analisados os sinais do tipo EM e EV e a posição da falha na pista externa considerada foi a centrada. Na tabela 3.1 são sumarizadas informações de interesse sobre a bancada de testes e o conjunto de dados para os sinais do tipo EM. Na tabela 3.2 são sumarizadas informações de interesse sobre a bancada de testes e o conjunto de dados para os sinais do tipo EV.

Tabela 3.1 – Principais características da base de dados utilizada para sinais do tipo EM

Posição do Rolamento	Localização da Falha	Dimensões (mm)		Condições de Operação (Arquivo.mat)				Fabricante
		Diâmetro	Profundidade	0 hp	1 hp	2 hp	3 hp	
EM	Pista Interna	0,1778	0,2794	105	106	107	108	SKF
		0,3566	0,2794	169	170	171	172	SKF
		0,5334	0,2794	209	210	211	212	SKF
		0,7112	1,27	3001	3002	3003	3004	NTN
	Pista Externa	0,1778	0,2794	130	131	132	133	SKF
		0,3566	0,2794	197	198	199	200	SKF
		0,5334	0,2794	234	235	236	237	SKF
		0,7112	1,27	*	*	*	*	*
	Esfera	0,01778	0,2794	118	119	120	121	SKF
		0,3566	0,2794	185	186	187	188	SKF
		0,5334	0,2794	222	223	224	225	SKF
		0,7112	3,8100	3005	3006	3007	3008	NTN

Fonte: CRWU (2004)

Tabela 3.2 – Principais características da base de dados utilizada para sinais do tipo EV

Posição do Rolamento	Localização da Falha	Dimensões (mm)		Condições de Operação (Arquivo.mat)				Fabricante
		Diâmetro	Profundidade	0 hp	1 hp	2 hp	3 hp	
EV	Pista Interna	0,1778	0,2794	278	279	280	281	SKF
		0,3566	0,2794	274	275	276	277	SKF
		0,5334	0,2794	270	271	272	273	SKF
		0,7112	1,27	*	*	*	*	*
	Pista Externa	0,1778	0,2794	294	295	296	297	SKF
		0,3566	0,2794	313	*	*	*	SKF
		0,5334	0,2794	315	*	*	*	SKF
		0,7112	1,27	*	*	*	*	*
	Esfera	0,01778	0,2794	282	283	284	285	SKF
		0,3566	0,2794	286	287	288	289	SKF
		0,5334	0,2794	290	291	292	293	SKF
		0,7112	3,8100	*	*	*	*	*

Fonte: CRWU (2004)


Os dados colhidos mediante o uso de acelerômetros foram processados no Matlab e estão no formato (*.mat), apresentando uma frequência de aquisição de 12 kHz para todas as situações e de 48 kHz para as situações de falha EM. Os dados de velocidade e potência foram coletados usando-se um transdutor de torque e foram computados manualmente.

3.2 EXTRAÇÃO DE PARÂMETROS E CLASSIFICAÇÃO DOS SINAIS

O processo de classificação dos sinais ocorre em quatro etapas, sendo a primeira dela a obtenção dos sinais da base de dados. Em seguida, os sinais a serem analisados passam pela etapa da Transformada Wavelet, onde o sinal é desconstruído e reconstruído seguindo o método da Análise de Multiresolução (AMR). Então, na etapa seguinte, os parâmetros estatísticos são calculados dos detalhes resultantes da etapa

anterior. Esses parâmetros servem como entrada para o algoritmo de classificação, no caso, a RNA. Esta etapa, então, é responsável por finalizar o processamento e apresentar o diagnóstico do sinal, se trata-se de um sinal defeituoso ou não. Todo o processo descrito pode ser visualizado na Fig. 3.2.

Figura 3.2 – Processo de extração de parâmetros e classificação dos sinais

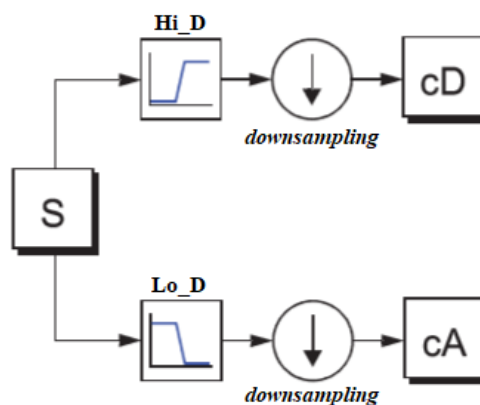


Fonte: Autor (2018)

3.2.1 Algoritmo para cálculo da AMR

O algoritmo para a AMR é em decomposição e reconstrução do sinal. O primeiro passo consiste em obter vetores com os coeficientes das aproximações e dos detalhes do sinal original na etapa de decomposição. É realizada a convolução do sinal original com o filtro passa-baixa (Lo_D), para obtenção das aproximações, e com o filtro passa-alta (Hi_D), para a obtenção dos detalhes. O passo seguinte é a realização a eliminação dos valores de índice ímpar (*downsampling*). A operação de decomposição em um nível do sinal encontra-se ilustrada na Figura 3.3.

Figura 3.3 – Ilustração da decomposição do sinal em um nível

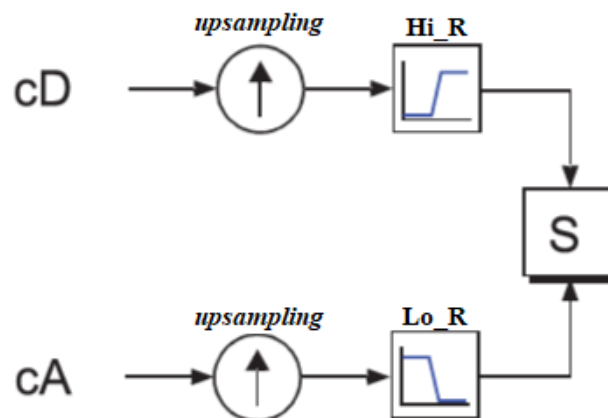


Fonte: Adaptado de Misiti *et al.* (2009)

O processo de decomposição pode ser iterado, com sucessivas aproximações sendo decompostas por sua vez, de modo que um sinal seja dividido em muitos componentes de menor resolução (Misiti *et al.*, 2009).

Após a etapa de decomposição, é necessário que os vetores de coeficientes de detalhes e de aproximações sejam reconstruídos, contendo ao fim dessa operação o mesmo número de pontos do sinal original em análise. O primeiro passo do processo de reconstrução é a inclusão de zeros entre os valores da amostra (*upsampling*) e, em seguida, realizar a convolução desses vetores com os filtros de reconstrução. Analogamente ao realizado na decomposição do sinal, os coeficientes de aproximação passam por convolução com o filtro passa-baixa (*Lo_R*), e os coeficientes dos detalhes com o filtro passa-alta (*Hi_R*). A operação de reconstrução em um nível do sinal encontra-se ilustrada na Figura 3.4.

Figura 3.4 – Ilustração da decomposição do sinal em um nível



Fonte: Adaptado de Misiti *et al.* (2009)

Cada sinal analisado deve ser decomposto em níveis de resolução, de acordo com a faixa de frequência que se deseja analisar. Para o presente estudo foram considerados os detalhes que possuem frequências próximas às naturais de ressonância dos rolamentos, cuja faixa está delimitada entre 3 kHz e 50 kHz (Graney & Starry, 2011). A faixa de frequência total que possui relevância em cada detalhe pode ser obtida conforme exemplificado em Santos *et al.* (2015). Na Tabela 3.3 podem ser observados os níveis de resolução e suas respectivas faixas de frequência para um sinal adquirido com uma taxa de amostragem de 12 kHz.

Tabela 3.3 – Níveis de resolução e suas respectivas faixas de frequência para os coeficientes de detalhes da transformada *wavelet*

Nível de Resolução	Faixa de Frequências (Hz)
1	3000 – 6000
2	1500 – 3000
3	750 – 1500
4	375 – 750
5	187,5 – 375
6	93,75 – 187,5
7	46,78 – 93,75
8	23,44 – 46,78
9	11,72 – 23,44

Fonte: Adaptado de Santos *et al.* (2015)

Após a etapa de reconstrução, serão extraídos três parâmetros descritores dos detalhes escolhidos: a média (MD), o desvio padrão (DPD), a energia normalizada (EN) e o espectro de potência wavelet (EPW), este último sendo dado por (Liu *et al.*, 2007):

$$EPW = 2^{-j} \sum_n |W_{j,n}|^2 \quad (3.1)$$

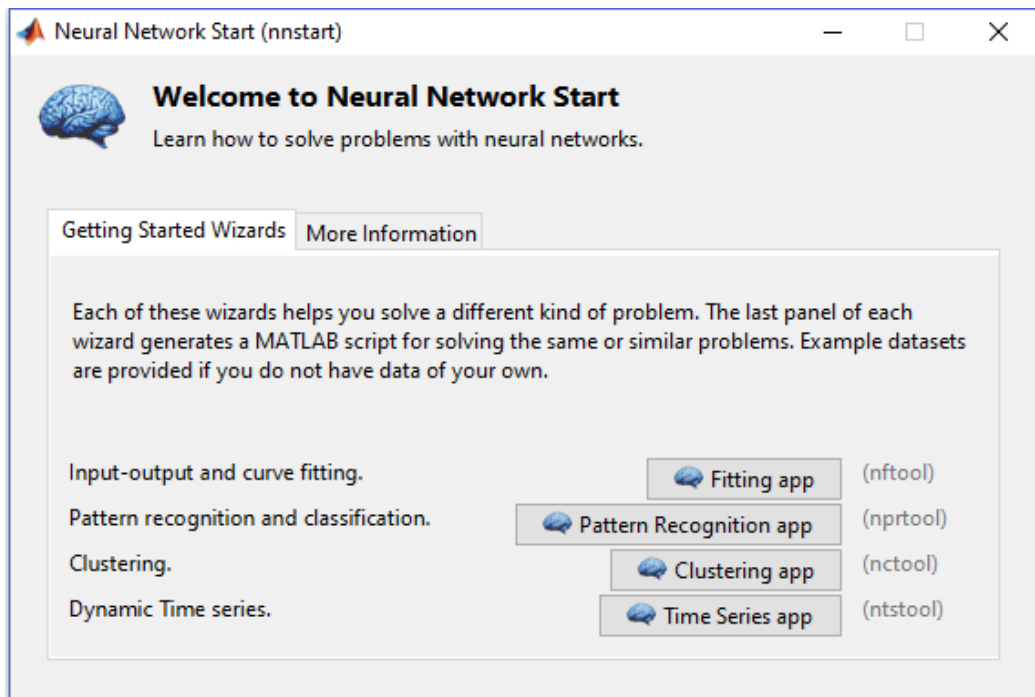
Em que n varia entre 1 e o comprimento total do vetor, j é a escala, ou o nível de decomposição e $W_{j,n}$ são os coeficientes wavelet em uma determinada escala. Os valores dos parâmetros descritores servirão para se obter os padrões de funcionamento normal e de falha.

A medida de energia normaliza estabelece o percentual de energia que cada detalhe possui em relação à composição original do sinal.

3.2.2 Características da RNA utilizada

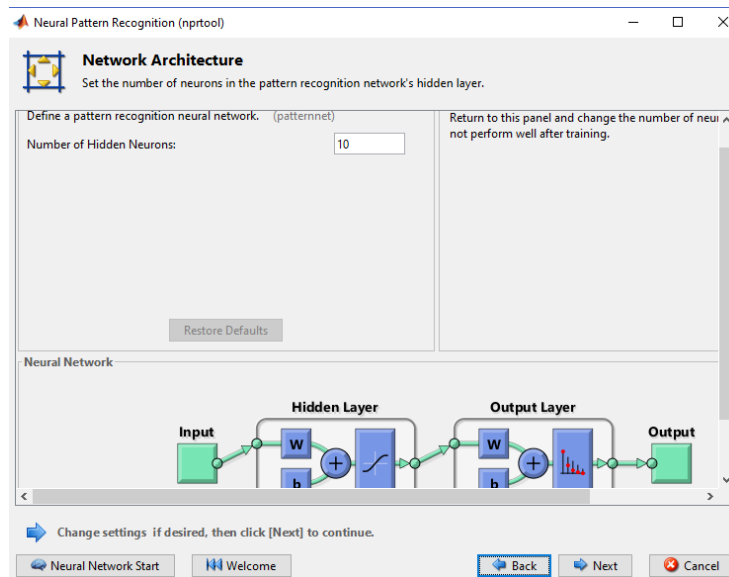
Para a implementação e configuração da RNA fez-se uso do Toolbox de Redes Neurais do Matlab (Figura 3.5). Utilizou-se o aplicativo de configuração de reconhecimento e classificação de padrões (*Pattern Recognition App*).

Figura 3.5 – Tela inicial do Toolbox de Redes Neurais do Matlab



Fonte: Autor (2018)

Figura 3.6 – Tela inicial de ajuste do número de neurônios na camada oculta

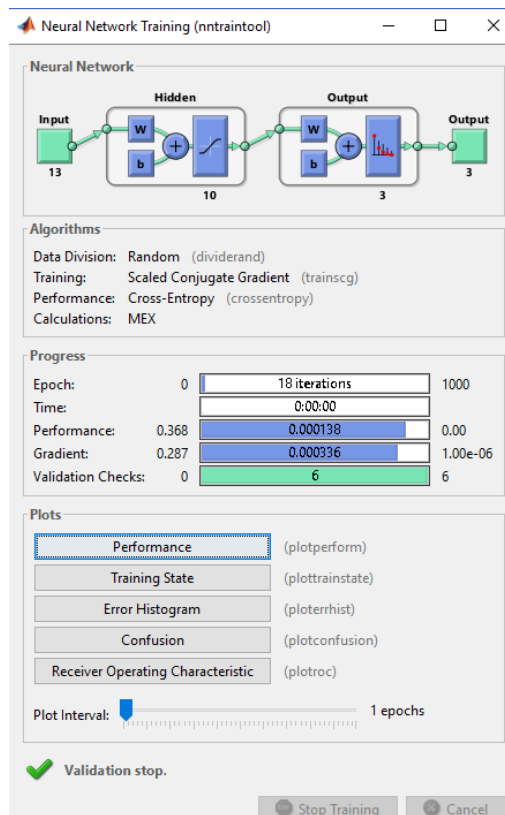


Fonte: Autor (2018)

A aplicação em questão implementa uma rede multicamadas unidirecional com função de ativação sigmóide na camada oculta e softmax na camada de saída. A função custo adotada foi a de Entropia Cruzada e o algoritmo de treinamento utilizado foi o

back-propagation com algoritmo do gradiente conjugado escalonado. O aplicativo permite a escolha do número de neurônios na camada oculta (Figura 3.6) e também disponibiliza uma série de ferramentas gráficas para avaliar o desempenho da rede neural (Figura 3.7).

Figura 3.7 – Tela inicial de treinamento e avaliação de performance da RNA



Fonte: Autor (2018)

CAPÍTULO IV

RESULTADOS

Neste capítulo serão apresentados resultados obtidos para a detecção e isolamento das falhas em rolamentos de motores elétricos, avaliando-se o desempenho da metodologia proposta. Para todos os casos, os filtros wavelet da família db4 foram utilizados e intervalos contendo amostras referentes a um segundo de cada sinal foram considerados para a extração dos descritores de falha. Na Tabela 4.1 pode-se visualizar a nomenclatura adotada para a representação de cada falha.

O detalhe observado nos testes foi o D1 e a rede neural possui dez neurônios na camada oculta. Além disso, foram consideradas todas as condições de operação, não sendo fornecida a informação de carregamento no eixo para a rede neural. Dessa forma, espera-se que a rede classifique corretamente a falha, independente da velocidade.

Tabela 4.1 – Nomenclatura adotada para as falhas

F1	Falha de 0,1778 mm
F2	Falha de 0,3566 mm
F3	Falha de 0,5334 mm
F4	Falha de 0,7112 mm

Fonte: Autor (2018)

4.1 Sinais da Extremidade do Motor

4.1.1 Falhas de Pista Interna

Para esta situação foram obtidos dois vetores com 180 amostras cada, sendo um vetor contendo os quatro parâmetros de entrada e um vetor contendo a representação de cada classe de saída. A codificação de classes seguiu o modelo *one of c-classes*, representada na Tabela 4.2. Os valores médios obtidos para parâmetros adotados encontram-se devidamente descritos na Tabela 4.3.

Tabela 4.2 – Codificação adotada para as saídas da rede neural – Falha de Pista Interna (EM)

Classe	y ₁	y ₂	y ₃	y ₄	y ₅
Normal	1	0	0	0	0
Falha de 0,1778 mm	0	1	0	0	0
Falha de 0,3566 mm	0	0	1	0	0
Falha de 0,5334 mm	0	0	0	1	0
Falha de 0,7112 mm	0	0	0	0	1

Fonte: Autor (2018)

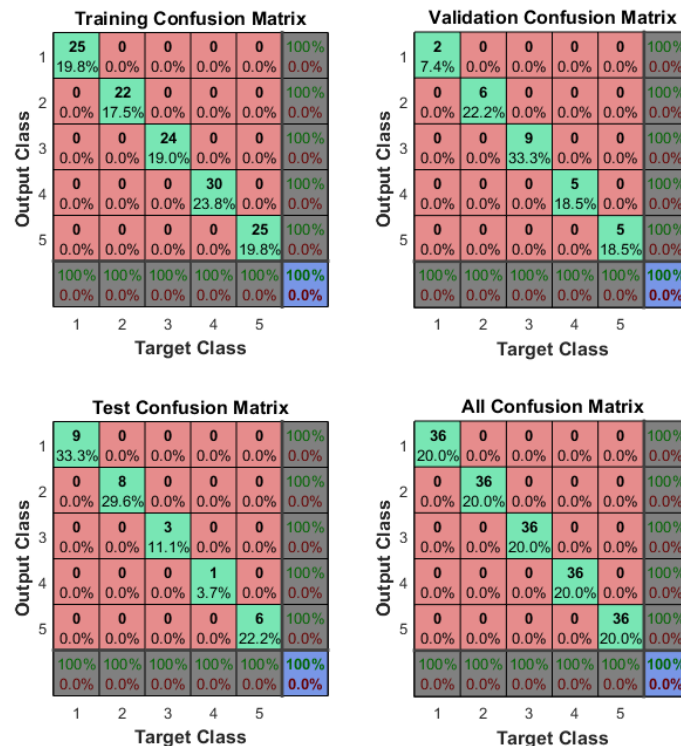
Tabela 4.3 – Valores médios dos parâmetros descritores de falha – Pista Interna (EM)

Sinal	Parâmetros			
	MD	DPD	EM	EPW
Normal	0.0071	0.0043	0.0091	0.00043
F1	0.1390	0.1426	0.2181	0.2386
F2	0.0753	0.1040	0.1407	0.0991
F3	0.2069	0.2316	0.3403	0.5811
F4	0.2963	0.2315	0.4119	0.8559

Fonte: Autor (2018)

As 180 amostras foram divididas, de maneira aleatória, em: 126 para a etapa de treinamento, 27 para a etapa de validação e 27 para a etapa de teste. O erro percentual em todas as etapas foi de 0%. Na Figura 4.1 são apresentadas as matrizes de confusão para todas as etapas, bem como a matriz de confusão geral, considerando todas as situações em uma única tabela.

Figura 4.1 – Matriz de Confusão – Pista Interna (EM)



Fonte: Autor (2018)

4.1.2 Falhas de Pista Externa

A base de dados adotada para a realização do experimento não possui informações acerca da falha de 0,7112 mm (F4) para as falhas de pista externa, considerando-se a posição relativa à zona de carga como sendo centrada. Os valores dos parâmetros descritores de falha encontram-se descritos na Tabela 4.4.


Tabela 4.4 – Valores médios dos parâmetros descritores de falha – Pista Interna (EM)

Sinal	Parâmetros			
	MD	DPD	EM	EPW
Normal	0.0071	0.0043	0.0091	0.00043
F1	0.2859	0.3771	0.5184	1.3474
F2	0.0603	0.0462	0.0832	0.0347
F3	0.2041	0.3997	0.4918	1.2201

Fonte: Autor (2018)

Foram obtidas 144 amostras, divididas aleatoriamente em 100 amostras para treinamento, e 22 amostras para a etapa de validação e 22 amostras para a etapa de testes. A RNA, para o presente caso, apresentou um erro percentual de 0% em todas as etapas, conforme pode ser observado na Figura 4.2.

Figura 4.2 – Matriz de Confusão – Pista Externa (EM)



Fonte: Autor (2018)

4.1.3 Falhas de Esfera

Para a situação de falha na esfera, também foram extraídas 180 amostras, divididas da mesma maneira que a situação de falha na pista interna. Os valores médios dos parâmetros descritores de falha encontram-se exposto na Tabela 4.5.

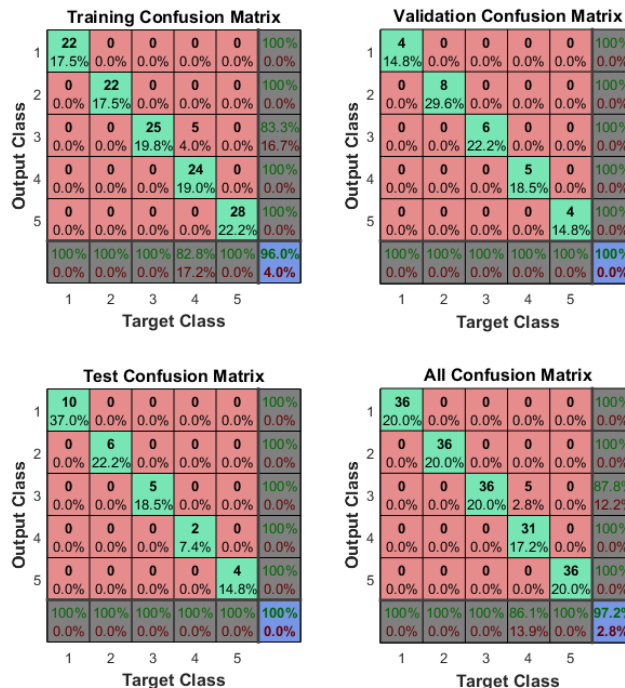
Tabela 4.5 – Valores médios dos parâmetros descritores de falha – Esfera (EM)

Sinal	Parâmetros			
	MD	DPD	EM	EPW
Normal	0.0071	0.0043	0.0091	0.00043
F1	0.0869	0.0651	0.1190	0.0071
F2	0.0665	0.0777	0.1120	0.0069
F3	0.0623	0.0510	0.0882	0.0039
F4	1.0700	0.9216	1.5471	1.1986

Fonte: Autor (2018)

O erro percentual atingiu um valor aproximado de 3,97% na etapa de treinamento e de 0% nas etapas de validação e de teste. O desempenho geral da rede foi de 97,2% de acerto. Na Figura 4.3 são apresentadas as matrizes de confusão resultantes para a situação em estudo.

Figura 4.3 – Matriz de Confusão – Esfera (EM)



Fonte: Autor (2018)

4.2 Sinais da Extremidade do Ventilador

4.2.1 Falhas de Pista Interna

Para os sinais do tipo EV, a base de dados adotada para a realização do experimento não possui informações acerca da falha de 0,7112 mm (F4) para as falhas de pista interna. Os valores dos parâmetros descritores de falha encontram-se descritos na Tabela 4.6.

Tabela 4.6 – Valores médios dos parâmetros descritores de falha – Pista Interna (EV)

Sinal	Parâmetros			
	MD	DPD	EM	EPW
Normal	0.0082	0.0053	0.0106	5.7514e-05
F1	0.1207	0.1222	0.1882	0.0179
F2	0.0792	0.0775	0.1214	0.0075
F3	0.1759	0.1728	0.2701	0.0366

Fonte: Autor (2018)

Foram obtidas 144 amostras, divididas aleatoriamente em 100 amostras para treinamento, e 22 amostras para a etapa de validação e 22 amostras para a etapa de testes. A RNA, para o presente caso, apresentou um erro percentual de 0% em todas as etapas, conforme pode ser observado na Figura 4.4.

Figura 4.4 – Matriz de Confusão – Pista Interna (EV)



Fonte: Autor (2018)

4.2.2 Falhas de Pista Externa

Para pista externa, a base de dados adotada para a realização do experimento não possui informações acerca de diversos parâmetros, sendo eles: a falha de 0,7112 mm (F4) e os carregamentos de 1 hp, 2 hp e 3 hp para as falhas de 0,3566mm (F2) e 0,5334 mm (F3), considerando-se a posição relativa à zona de carga como sendo centrada. Os valores dos parâmetros descritores de falha encontram-se descritos na Tabela 4.7.

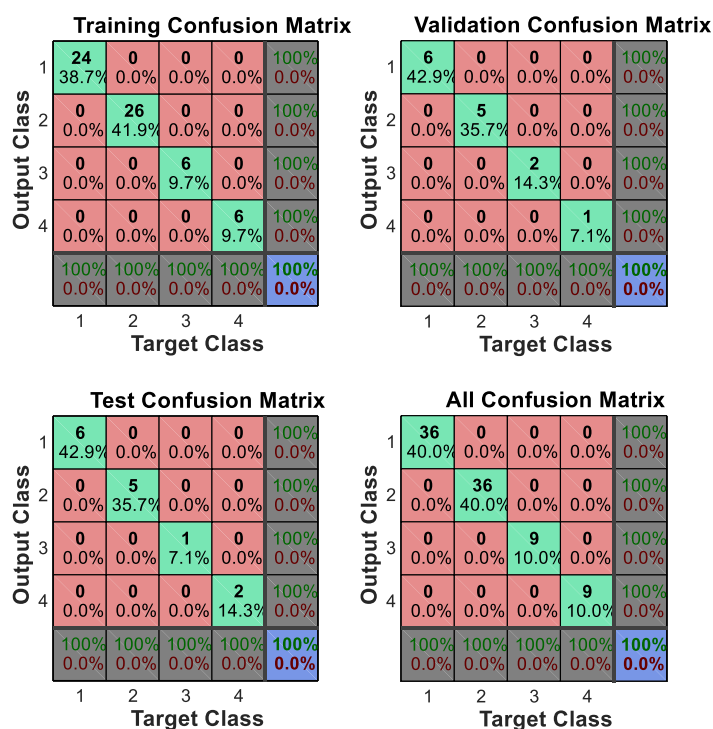
Tabela 4.7 – Valores médios dos parâmetros descritores de falha – Pista Externa (EV)

Sinal	Parâmetros			
	MD	DPD	EM	EPW
Normal	0.0082	0.0053	0.0106	5.7514e-05
F1	0.1743	0.2542	0.3378	0.0572
F2	0.4650	0.6348	0.8621	0.3716
F3	0.3731	0.4850	0.6703	0.2247

Fonte: Autor (2018)

Foram obtidas 90 amostras, divididas aleatoriamente em 62 amostras para treinamento, e 14 amostras para a etapa de validação e 14 amostras para a etapa de testes. A RNA, para o presente caso, apresentou um erro percentual de 0% em todas as etapas, conforme pode ser observado na Figura 4.5.

Figura 4.5 – Matriz de Confusão – Pista Externa (EV)



Fonte: Autor (2018)

4.2.3 Falhas de Esfera

Para a situação de falha na esfera, também foram extraídas 144 amostras, divididas da mesma maneira que a situação de falha na pista interna, pois também não há dados sobre a falha de 0,7112 mm (F4). Os valores médios dos parâmetros descritores de falha encontram-se exposto na Tabela 4.5.

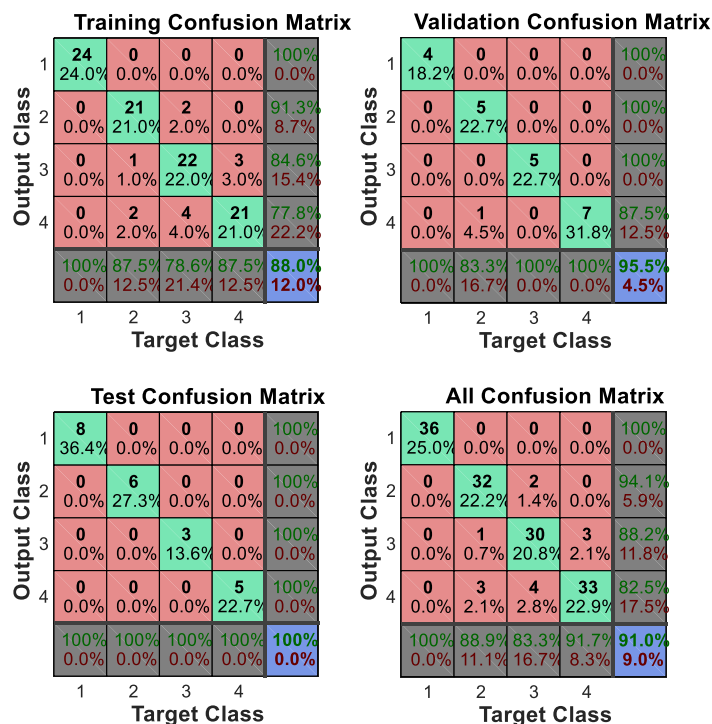
Tabela 4.8 – Valores médios dos parâmetros descritores de falha – Esfera (EV)

Sinal	Parâmetros			
	MD	DPD	EM	EPW
Normal	0.0082	0.0053	0.0106	5.7514e-05
F1	0.0547	0.0459	0.0785	0.0031
F2	0.1163	0.1350	0.1954	0.0202
F3	0.0976	0.0845	0.1414	0.0101

Fonte: Autor (2018)

O erro percentual atingiu um valor aproximado de 12% na etapa de treinamento, de 4,5% na etapa de validação e de 0% na etapa de teste. O desempenho geral da rede foi de 91% de acerto. Na Figura 4.6 são apresentadas as matrizes de confusão resultantes para a situação em estudo.

Figura 4.6 – Matriz de Confusão – Esfera (EV)



Fonte: Autor (2018)

CAPÍTULO V

COMENTÁRIOS E CONCLUSÕES

Motores elétricos estão entre os principais equipamentos industriais utilizados mundo a fora. Boa parte da produção industrializada mundial depende de seu bom funcionamento. Dentre os defeitos que podem acometê-los, as falhas de rolamento são uma das principais. Elas causam paradas na linha de produção que são demasiadamente custosas, como também perigosas. Em casos críticos, falhas desse tipo levarão à pane total na produção e conseqüentemente duras perdas financeiras.

Por tal razão, o estudo das falhas de rolamentos vem sendo desenvolvido há décadas, sendo um dos campos vanguardistas na detecção e isolamento de falhas. Dentre os diversos métodos já aplicados, nenhum demonstrou total hegemonia na classificação de todas as falhas para todas as situações dinâmicas possíveis. Acontece que a maioria dos métodos depende de frequências de defeitos específicos, que apesar de possuírem uma teoria bem consolidada, variam bastante entre o mundo real e teórico. Essa análise, por muitas vezes, se dá através da avaliação visual do espectro do sinal, o que é impraticável caso queira-se desenvolver uma aplicação de diagnóstico de falhas *online* em um ambiente industrial.

O método explicado e aplicado neste trabalho segue fortes tendências da detecção e isolamento de falhas em rolamentos existentes na literatura, como a utilização de um classificador (em nosso caso, uma rede neural) e na aplicação de ferramentas estatísticas para geração de parâmetros descritores de falhas. Entretanto, ele também traz diversas soluções para problemas frequentes nesse campo, como a dependência da contagem de picos de frequências ou aplicabilidade em apenas casos de mesmas condições de operação.

Nosso método demonstrou-se eficaz na detecção de falhas de pista interna, externa e de elementos rolantes para diferentes velocidades. Isto quer dizer que mesmo em situações de funcionamento distintas e vibrações distintas, o método foi capaz de identificar o diâmetro da falha em todos os casos investigados. Ele apresentou melhores

resultados para as falhas de pista interna e externa, sendo nestes casos impecável: 100% de eficácia. Entretanto, para ambas os casos de falhas nas esferas, a técnica caiu de aproveitamento, porém ainda continuou a oferecer resultados maiores que 90%. As razões pelas quais tais falhas foram mais difíceis de classificar ainda serão investigadas.

5.1 Trabalhos Futuros

Os próximos passos para desenvolvimento são distintos. Primeiramente, serão investigados os dados do *database* para o caso de sensores cruzados, isto é, para falhas ocorrendo na Extremidade do Ventilador, por exemplo, serão avaliados os dados provenientes dos acelerômetros da Extremidade do Motor, e vice-versa. Caso positivo, o resultado fortalecerá ainda mais nosso método, além de permitir uma possível diminuição na quantidade de sensores e instrumentação à qual as máquinas atualmente são submetidas.

Outro avanço que está sendo ponderado é a aplicação do método em um sistema embarcado. Tal sistema seria capaz de funcionar diretamente no ambiente industrial, tratando de diagnosticar a situação *online*.

Por fim, outras técnicas de processamento também poderão ser desenvolvidas, como a aplicação da Teoria do Caos para determinação de falhas. A busca será por um método mais eficiente e preciso.

REFERÊNCIAS BIBLIOGRÁFICAS

- Aggarwal, C. C., (2018). “**Neural Networks and Deep Learning – A Text Book**”, Springer. Nova York: Estados Unidos.
- Amezcuca, J., Castillo, O., Melim, P., (2017). “**New Classification Method Based on Modular Neural Networks with the LVQ Algorith and Type-2 Fuzzy Logic**”, Springer. [s.l].
- Araujo, M.S., (2011). “**Influência de Famílias Wavelets e suas Ordens no Desempenho de um Localizador de Faltas em Linhas Aéreas de Transmissão de Energia Elétrica**”. *Dissertação de Mestrado em Engenharia Elétrica*. Universidade Federal do Pará, UFPA. Belém: Brasil.
- Brito, N.S.D., Pires, F.A.C., (2005). “**Automação da Teoria Wavelet na Detecção e Localização de Distúrbios**”. *Seminário Brasileiro sobre Qualidade da Energia Elétrica – SBQEE*. Belém: Brasil.
- Burrus, C. S., Gopinath, R. A., Guo, H., (1998). “**Introduction to Wavelets and Wavelet Transforms: A primer**”. *Prentice-Hall*. [s.l.].
- Castillo, E., Cobo, A., Gutiérrez, J., & Pruneda, R., (1999). “**Introducción a las Redes Funcionales con Aplicaciones - Un Nuevo Paradigma Neuronal**”. *Paraninfo*. Espanha.
- Dubey, R., & Agrawal, D. (2015). “**Bearing fault classification using ANN-based Hilbert footprint analysis**”. *IET Science, Measurement & Technology*, vol. 9, nº 8, pp. 1016–1022.
- Fernandes, R. A. S., (2009). “**Identificação de Fontes de Correntes Harmônicas por Redes Neurais Artificiais**”. *Dissertação de Mestrado em Engenharia Elétrica*, Universidade de São Paulo, São Carlos: Brasil.
- Freeman, J.A., Skapura, D. (1993). “**Redes Neuronales: algoritmos, aplicaciones y técnicas de propagación**”. *Addison-Wesley*. México.
- Gebraeel, N., Lawley, M., Liu, R., & Parmeshwaran, V. (2004). “**Residual Life Predictions From Vibration-Based Degradation Signals : A Neural Network Approach**”, *IEEE Transactions on Industrial Electronics*, vol. 51, nº 3, pp.694–700.

- Gongora, S., W., Goedtel, A., Augusto Oliveira da Silva, S., & Luiz Graciola, C. (2016). “**Neural Approach to Fault Detection in Three-phase Induction Motors**”. *IEEE Latin America Transactions*, vol. 14, nº 3, pp. 1279–1288.
- Gonzales, C., (2015). “**What’s the Difference Between Bearings?**” Disponível em: <<https://www.machinedesign.com/whats-difference-between/what-s-difference-between-bearings-1>>. Acesso em: 21/09/2018.
- Graney, B. P., Starry, K., (2011). “**Rolling Element Bearing Analysis**”. *Materials Evaluation*, vol.70, nº1, pp. 78-85.
- Graps, A., 1999. “**An Introduction to Wavelets**”. *Stanford University*, Califórnia: Estados Unidos.
- Gritli, Y., Bellini, A., Rossi, C., Casadei, D., Filippetti, F., & Capolino, G. (n.d.). “**Condition Monitoring of Mechanical Faults in Induction Machines from Electrical Signatures : Review of Different Techniques**”
- Haykin, S. (2008). “**Neural Networks and Learning Machines**”. *Pearson*, 3ª edição. Estados Unidos
- Hetch-Nielsen, R., (1990). “**Neurocomputing**”, *Addison-Wesley*. Massachusetts: Estados Unidos.
- Immovilli, F., Member, S., Cocconcelli, M., Bellini, A., & Rubini, R. (2009). “**Detection of Generalized-Roughness Bearing Fault by Spectral-Kurtosis Energy of Vibration or Current Signals**”. *IEEE Transactions on Industrial Electronics*, vol. 56, nº11, pp. 4710–4717.
- Jayaswal, P. & Verma, S.N. (2011). “**Application of vibration signature analysis techniques for rolling element bearing fault identification**”. *Australian Journal of Mechanical Engineering*.
- Kim, C. H. , Aggarwal, R., (2001). “**Wavelet transforms in power systems: Part 2 Examples of application to actual power system transients**”. *Power Engineering Journal*, pp.193-2002. s.n.:s.l
- Kotak, V., Jaiwal, N. K., Patel, S. N., (2016). “**Improvising strategies for efficiency of IE 4 SCIM 2.2kW through simulation**” *International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, Chennai, pp. 3932-3936.
- Kulkarni, R., Forster, A., and Venayagamoorthy, G., 2010, “**Computational Intelligence in Wireless Sensor Networks: A Survey**”. *IEEE Communications Surveys & Tutorials*. vol. 13, pp. 68–96.

- Lacerda, A. L. M., Filho, P. C. M. L., Brito, J. N., 2011. “**Detection of Faults in Three Phase Induction Motors Using Wavelet Packet Analysis**”. Proceedings of the ABCM 21st International Congress of Mechanical Engineering (COBEM 2011). Natal: Brasil.
- Li, B., Chow, M.-Y., Tipsuwan, Y., Hung, J.C.,(2010). “**Neural-network-based Motor Rolling Bearing Fault Diagnosis**”. *IEEE Transactions on Industrial Electronics*, vol. 47, nº 5, pp. 1060-1069.
- Liu, Y., San Liang, X., & Weisberg, R. H. (2007). ‘**Rectification of the Bias in the Wavelet Power Spectrum**’. *Journal of Atmospheric and Oceanic Technology*, vol.24, nº 12, pp. 2093–2102.
- Lou, X., & Loparo, K. A., (2004). “**Bearing fault diagnosis based on wavelet transform and fuzzy inference**”, *Mechanical Systems and Signal Processing*, vol. 18, pp. 1077-1095.
- Ludwig Jr., O., Costa, E. M. M., 2007. “**Redes Neurais: Fundamentos e Aplicações com Programas em C**”. Editora Ciência Moderna. Rio de Janeiro: Brasil.
- Malhi, A., & Gao, R. X. (2004). “**PCA-Based Feature Selection Scheme for Machine Defect Classification**”. *IEEE Transactions on Instrumentation and Measurement*, vol. 6, nº 6, pp. 1517–1525.
- Mallat, S., 1989, “**A theory for multiresolution signal decomposition: The waveletrepresentation**”. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. vol 11, nº 7, pp 674–693. s.l.
- Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.-M., 2009. “**Wavelet Toolbox™ 4 - User’s Guide**”. *The MathWorks*. s.l.
- Nandi, S., Toliyat, H. A., Li, X. (2005). “**Condition Monitoring and Fault Diagnosis of Electrical Motors – A Review**”. *IEEE Transactions on Energy Conversion*, vol. 20, nº 4, pp. 719 – 729.
- Ocak, H., Loparo, K. A., (2004). “**Estimation of the running speed and bearing defect frequencies of an induction motor from vibration data**”. *Mechanical Systems and Signal Processing*, vol. 18, n. 3, pp. 515–533.
- Oliveira, H. M. de, 2007. “**Análise de Sinais para Engenheiros: Uma Abordagem via Wavelets**”. Editora Brassport. Rio de Janeiro: Brasil.
- Osman, S., & Wang, W. (2014). “**A normalized Hilbert-Huang transform technique for bearing fault detection**”. *Journal of Vibration and Control*, vol. 22, nº 11, pp. 2771 – 2787.

- Pagliosa, A.L., (2003). “**Obtenção das Funções de Pertinência de um Sistema Neurofuzzy Modificado pela Rede de Kohonen**”. *Dissertação de Mestrado Automação Industrial*. Universidade do Estado de Santa Catarina – UDESC. Joinville: Brasil.
- Rai, A., & Upadhyay, S. H. (2016). “**A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings**”. *Tribology International*, vol. 96, pp. 289–306.
- Rao, B. K. N., Pai, P. S., Nagabhushana, T. N., (2012). “**Failure Diagnosis and Prognosis of Rolling-Element Bearings using Artificial Neural Networks: A Critical Overview**”. *Journal of Physics: Conference Serie*, vol. 364, pp. 1-28.
- Samanda, B., & Al-Balushi, K. R., (2003). “**Artificial Neural Network Base Fault Diagnostics of Rolling Element Bearings Using Time-Domain Features**”. *Mechanical Systems and Signal Processing*., vol 17., nº 2, pp. 317-328.
- Santiago, D.F.A., 2004. “**Diagnóstico de Falhas em Máquinas Rotativas Utilizando Transformada de Wavelet e Redes Neurais Artificiais**”. Tese de Doutorado em Engenharia Mecânica. Universidade Estadual de Campinas. Campinas: Brasil.
- Santos, M. O., Lopes, L. W., Costa, S. L. do N. C., Correia, S. E. N., 2015. “**Acurácia das Medidas de Entropia e Energia da Transformada Wavelet na Avaliação de Vozes Infantis**”. *XXIII Congresso Brasileiro e IX Congresso Internacional de Fonoaudiologia*. Salvador: Brasil.
- Sassi, S. (2007). “**A Numerical Model to Predict Damaged Bearing**”, *Journal of Vibration and Control*, vol. 13, nº 11, pp. 1603–1628.
- Smith, W. A., & Randall, R. B. (2015). “**Rolling element bearing diagnostics using the Case Western Reserve University data : A benchmark study**”. *Mechanical Systems and Signal Processing*, vol. 64–65, pp. 100–131
- Stack, J. R., Harley, R. G., & Habetler, T. G. (2004). “**An Amplitude Modulation Detector for Fault Diagnosis in Rolling Element Bearings**”. *IEEE Transactions on Industrial Electronics*, vol. 51, nº 5, pp. 1097-1102.
- Tian, H., Shang, Z., (2006). “**Artificial Neural Network as a Classification Method of Mice by their Calls**”. *Ultrasonics*, vol.44, pp. e275-e278.
- William, P. E. A., Hoffman, M. W., (2011). “**Identification of bearing faults using time domain zero-crossings**”. *Mechanical Systems and Signal Processing*, vol. 25, nº 8, pp. 3078–3088.

- Yan, H., Jiang, Y., Zheng, J., Peng, C., Li, Q., (2006). “**A Multilayer Perceptron-based Medical Decision Support System for Heart Disease Diagnosis**”. *Expert Systems with Applications*, vol 30, n°2, pp. 272-281.
- Zhang, Z., Friedrich, K., (2003). “**Artificial Neural Networks Applied to Polymer Composites: A Review**”. *Elsevier Science, Composites Science and Technology*, vol. 63, n°14, pp. 2029-2044.