



Universidade Federal da Paraíba
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica
Mestrado - Doutorado

SISTEMA INTELIGENTE PARA DIAGNÓSTICO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA ANÁLISE SONORA

por

Gabriela Jordão Lyra

GABRIELA JORDÃO LYRA

**SISTEMA INTELIGENTE PARA DIAGNÓSTICO DE
FALHAS EM ROLAMENTOS DE MOTORES DE
INDUÇÃO TRIFÁSICOS VIA ANÁLISE SONORA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba, em cumprimento às exigências para obtenção do Grau de Doutora.

Orientador: Prof. Dr. Abel Cavalcante Lima Filho.

João Pessoa – PB

2019.

L992s Lyra, Gabriela Jordão.

SISTEMA INTELIGENTE PARA DIAGNÓSTICO DE FALHAS EM
ROLAMENTOS DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA ANÁLISE
SONORA / Gabriela Jordão Lyra. - João Pessoa, 2019.
100 f. : il.

Tese (Doutorado) - UFPB/PPGEM.

1. Motor de Indução Trifásico. 2. Rede Neural
Artificial. 3. Processamento de Sinal de Som. 4.
Análise Multiresolução Wavelet. I. Título

UFPB/BC

SISTEMA INTELIGENTE PARA DIAGNÓSTICO DE FALHAS EM ROLAMENTO DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA ANÁLISE SONORA

por

Gabriela Jordão Lyra


Tese aprovada em 28 de junho de 2019




Prof. Dr. ABEL CAVALCANTE LIMA FILHO
Orientador - UFPB




Prof. Dr. FRANCISCO ANTONIO BELO
Examinador Interno - UFPB




Prof. Dr. MARCELO CAVALCANTI RODRIGUES
Examinador Interno - UFPB



Prof. Dr. ISAAC SOARES DE FREITAS
Examinador Externo - UFPB



Prof. Dr. FABIANO SALVADORI
Examinador Externo - UFPB



Prof. Dr. ALISSON VASCONCELOS DE BRITO
Examinador Externo - UFPB



Prof. Dr. MARCEÚ OLIVEIRA ADISSI
Examinador Externo - IFPB

DEDICATÓRIA

Dedico esta obra à Deus, por me iluminar em toda essa caminhada, ao meu sobrinho Henry Lyra Azevedo (Binho), e a minha irmã Camila Alice Jordão Lyra.

AGRADECIMENTO

A Deus por trilhar sempre meu caminho, pois sem seu agir nada seria possível.

Aos meus pais Alexandre José Jordão Lyra e Maria da Conceição Lyra, pois sem eles eu não estaria aqui.

Em especial ao meu pai Alexandre José Jordão Lyra, que não mediu esforços para me ajudar, dando todo apoio e incentivo possível para finalizar essa etapa, serei eternamente grata, pai.

À minha irmã, Camila Alice Jordão Lyra (Dogueira), por ser minha melhor amiga e estar presente em todas as etapas da minha vida.

Ao meu noivo Brainer de Castro Lacerda e minha sogra Ingrid de Castro Lacerda por toda compreensão e incentivo ao longo desse doutorado.

Ao meu orientador Abel Cavalcante Lima Filho, pela sua orientação, compreensão e ensinamentos.

Aos meus amigos do GPICCEMA, professor Belo, Carlos Nóbrega, Thyago Leite, Anselmo de Lucena, Júlio César, Fábio Araújo, Hugo Pimentel, Marlio Antonio, Nayara Formiga, Danyelson Barros e Frank Cesar.

Ao professor Jobson Francisco da Silva pela construção da bancada e por sempre estar disposto a ajudar.

Ao Diógenes Montenegro, pelo suporte e apoio nas montagens elétricas da bancada.

Ao IFMT por todo incentivo e apoio nos anos finais desse doutorado, em especial ao Departamento de Eletroeletrônica.

A todos os professores, funcionários e amigos do Programa de Pós-Graduação em Engenharia Mecânica.

A todos que contribuíram de certa forma com o andamento dessa tese.

SISTEMA INTELIGENTE PARA DIAGNÓSTICO DE FALHAS EM ROLAMENTO DE MOTORES DE INDUÇÃO TRIFÁSICOS VIA ANÁLISE SONORA

RESUMO

Os motores de indução trifásicos estão presentes em praticamente todos os processos industriais, sendo considerados a espinha dorsal da indústria moderna, mas, como qualquer outro equipamento, são vulneráveis a falhas, as quais, se não forem devidamente monitoradas, podem comprometer a produção e causar acidentes. As técnicas convencionais de detecção de falhas em motores de indução, por exemplo, análise da vibração e análise da corrente de armadura possuem certo grau de invasividade. A proposta desse trabalho é o desenvolvimento de um método totalmente não-invasivo para detecção e diagnóstico de falhas em rolamentos de motores de indução trifásicos através da análise do som emitido pelo motor em funcionamento, usando rede neural artificial e processamento Wavelet. A metodologia proposta baseia-se na aquisição da emissão sonora por um dispositivo eletrônico, na decomposição desse sinal adquirido em detalhes e aproximações utilizando a técnica Análise Wavelet Multiresolução (AWM) e por fim, o levantamento dos resultados estatísticos desses detalhes que servirão como entrada de dados para um sistema de redes neurais artificiais que serão do tipo Perceptron Multicamadas (PMC) e Rede de Função de Base Radial (RBF). A técnica proposta foi testada, validada e treinada experimentalmente usando uma bancada de testes. Como resultado a PMC apresentou uma média de 97% de acerto na detecção e a RBF apresentou uma média de 90% de acerto.

Palavras chaves: Motor de Indução Trifásico, Rede Neural Artificial, Processamento de Sinal De Som, Análise Multiresolução Wavelet.

SMART SYSTEM TO DIAGNOSE BEARING FAULTS IN THREE-PHASE INDUCTION MOTORS VIA SOUND ANALYSIS

ABSTRACT

Three-phase induction motors are part of practically every industrial process, they are considered the core of the modern industry, however, like any other equipment, they are susceptible to faults, which can compromise the production and cause accidents if they are not rightfully monitored. The conventional techniques to detect faults in induction motors, for example, vibration and motor signature current analyses, have some degree of invasiveness. The purpose of this work is to develop a method totally non-invasive in order to detect and to diagnose faults in three-phase induction motor bearings through sound analysis from the motor in operation, using artificial neural network and Wavelet processing. The proposed methodology is based on the acquisition of the sound emission by an electronic dispositive, the decomposition of this acquired signal in details and approximation using the Multiresolution Wavelet Analysis (MWA), and finally, the evaluation of the statistical results of these details that will count as data input for a system of artificial networks of the Multilayer Perceptron type (MLP) and Radial Basis Function Network (RBFN). The proposed technique was tested, validated and experimentally trained using a bench test. As an outcome, the MLP presented an average of 97% of matching results in the detection, and the RFB presented an average of 90%.

Keywords: Three-phase induction motor, artificial neural networks, sound signal processing, wavelet multiresolution analysis.

SUMÁRIO

1. INTRODUÇÃO	15
1.1 Objetivo Geral	18
1.2 Objetivo Específico	18
2. ESTADO DA ARTE	19
2.1 Justificativa e Motivação	19
2.2 Principais Tipos de Falhas Em MIT	20
2.3 Método De Detecção Via Emissão Sonora	22
2.4 Descrição da Metodologia para Detecção e Diagnóstico de Falha	26
2.5 Contribuições do Trabalho	32
3. FUNDAMENTAÇÃO TEÓRICA	33
3.1 Motor de Indução Trifásico	33
3.2 Processamento de Sinais	35
3.3 Transformada De Fourier	35
3.4 Transformada De Wavelet	38
3.5 Redes Neurais	45
3.5.1 Função de ativação	48
3.5.2 Rede Perceptron Multicamadas	50
3.5.3 Rede de Função de Base Radial	53
4. MATERIAIS E MÉTODOS	55
4.1 Bancada de Testes	55
4.2 Sistema de Acionamento	56
4.3 Gerador CC	57
4.4 Instrumentos De Medição	59
4.4.1 Torquímetro	59
4.4.2 Sistema de Aquisição De Som	60
4.5 Rolamento	60
4.6 Metodologia Para Análise De Falha	64
4.7 Caracterização da falha na decomposição Wavelet	64
4.8 Descrição da metodologia para detecção e diagnóstico de falha	66
5. RESULTADOS EXPERIMENTAIS	68
5.1 Resultados da PMC para dois tipos de falhas	79
5.2 Resultados da PMC e RBF para três tipos de falhas	83
6. CONCLUSÕES	88
REFERÊNCIAS BIBLIOGRÁFICAS	90

LISTA DE FIGURAS

Figura 2. 1- Classificação de falhas em MIT. Adaptado: CHOUDHARY,2018...	21
Figura 2.2- Índice de falhas no MITS, levantamento feito pela IEEE. Adaptado: CHOUDHARY,2018.....	22
Figura 3.1- Figura de um motor de indução fechado. Fonte: FRANCISCO, 2006.....	34
Figura 3.2- Comparação entre as resoluções da Wavelet e da STFT no plano tempo-frequência. Fonte: NÓBREGA , 2015.....	38
Figura 3.3- Processo de decomposição Multiresolução. Fonte: Autor.....	42
Figura 3.4- Banco de filtros e árvore de filtros com decomposição em três níveis. Fonte: NÓBREGA, 2015.....	43
Figura 3.5- Princípio da decomposição de um sinal via análise multiresolução: Sinal original, e decomposição do sinal original em suas componentes de aproximação e detalhe em três níveis. Fonte: Autor.	44
Figura 3.6- Decomposição Wavelet com nível 4 e frequência de amostragem igual à 5KHz. Fonte: Adaptado ALVES,2017.....	45
Figura 3.7- Neurônio Artificial. Fonte: Adaptado (Mculloch e Pitts).	47
Figura 3.8- Principais funções de ativação. Fonte: Autor..	50
Figura 3.9- Modelo de uma rede Perceptron Multicamadas. Fonte: Autor.....	52
Figura 4.1 – Bancada para ensaios de torção em motores de indução trifásicos.....	56
Figura 4.2 - Quadro de comando	56
Figura 4.3 - Gerador de corrente contínua. Fonte: Autor.	57
Figura 4.4 - Resistências aletadas acopladas à armadura Fonte: Autor	58
Figura 4.5 - Varivolt utilizado para variação da carga aplicada Fonte: Autor	58
Figura 4.6 - Circuito elétrico de acionamento do gerador CC. Fonte: ADISSI, 2015	59
Figura 4.7 - Torquímetro digital HBM T40B. Fonte: Autor..	59
Figura 4.8 - Sensor de emissão acústica. Fonte: Autor.	60

Figura 4.9 - Geometria dos elementos de um rolamento. Fonte: NÓBREGA,2015	63
Figura 4.10- Broca do tipo ponta montada utilizada para perfuração dos furos nas pistas. Fonte: Autor.	63
Figura 4.11 - Furos nas pistas interna e externa (aproximadamente 5,8 mm de diâmetro). Fonte: Autor.....	63
Figura 4.12 - Diagrama do processo de diagnóstico de falha. Fonte: Autor.	64
Figura 4.13 - Espectro de potência Wavelet de cada detalhe do sinal sonoro do motor com carga aplicada de 100% para rolamento saudável, falha na pista externa, falhas na pista interna e falha na pista externa e interna. Fonte: Autor.	65
Figura 4.14- Sistema inteligente de identificação de identificação rolamentos defeituosos de MITs. Fonte: Autor.	66
Figura 5.1 - Espectro do sinal de emissão acústico: a) Motor com o rolamento saudável com acoplamento. b) Motor com rolamento com defeito na pista externa com acoplamento c) Motor com rolamento com defeito na pista interna com acoplamento. Fonte: Autor.....	69
Figura 5.2 - a) Espectro de potência do detalhe 1 ao 11 para as três cargas aplicadas, para um rolamento saudável (Sau), falha na pista externa (Ext), falha na pista interna (Int) e falha em ambas as pistas (Ext/Int). Fonte: Autor.	71
Figura 5.3 - Espectro de potência dos detalhes para um rolamento saudável, com falha na pista externa, na pista interna e na pista externa e interna juntas sem carga, para três ensaios feito no motor com aquisições da emissão sonora. Fonte: Autor.	72
Figura 5.4- Espectro de potência dos detalhes para um rolamento saudável, com falha na pista externa, na pista interna e na pista externa e interna juntas com carga média (50%), para três ensaios feito no motor com aquisições da emissão sonora. Fonte: Autor.	74
Figura 5.5 - Espectro de potência dos detalhes para um rolamento saudável, com falha na pista externa, na pista interna e na pista externa e interna juntas com carga alta (100%) para três ensaios feito no motor com aquisições da emissão sonora. Fonte: Autor.	76
Figura 5.6- Vetor de entrada utilizado para treinamento, validação e testes da rede. Fonte: Autor.....	86
Figura 5.7- Vetor de saída utilizado para treinamento, validação e testes da rede. Fonte: Autor.....	80
Figura 5.8- Matrix de Confusão da RNA para 3 classificações (a) 3 neurônios na camada oculta (b) 4 neurônios na camada oculta. Fonte: Autor.	81

Na figura 5.9 Desempenho da rede a cada interação (época), o gráfico representa os erros médios quadráticos (MSE) dos conjuntos de treinamento, validação e testes. Nota-se que o MSE cai notoriamente. Fonte: Autor.....	82
Figura 5.10- Modelo de Vetor de Entrada para dois Detalhes gerados pela AWM do sinal sonoro. Fonte: Autor.	84
Figura 5.11- Vetor de saída desejado para treinamento da Rede PMC e RBF. Fonte: Autor.	85
Figura 5.12- Performance da rede PMC para treinamento com o vetor de entrada composto por 11 detalhes. Fonte: Autor.....	85

LISTA DE TABELA

Tabela 3.1 - Pesquisa em Detecção de falha em MIT com RNA.....	30
Tabela 4.1 – Correspondência entre detalhe e faixa de frequência..	66
Tabela 5.1 – Dados de placa do motor... ..	68
Tabela 5.2– Carga de Acionamento da máquina.....	69
Tabela 5.3 – Frequência Característica das Falhas.....	69
Tabela 5.4 – Média do espectro de potência para os detalhes 4 e 5... ..	72
Tabela 5.5 – Criação do vetor de Saída da RNA.....	80
Tabela 5.6 – Resultado de simulação para Rede PMC para 3 classificações.....	83
Tabela 5.7 – Vetores de entrada para treinamento das redes PMC e RBF.	84
Tabela 5.8 – Desempenho da rede PMC e RBF para diferentes quantidades de detalhes..	86

LISTA DE SÍMBOLOS

AE	- Emissão Acústica
CWT	- Transformada Wavelet Contínua
AWM	- Análise Wavelet Multiresolução
RNA	- Redes Neurais Artificiais
TF	- Transformada de Fourier
DFT	- Transformada Discreta de Fourier
CWT	- Transformada De Wavelet Contínua
FFT	- Transformada Rápida de Fourier
STFT	- Transformada de Fourier de Tempo Curto
DWT	- Transformada De Wavelet Discreta
EPE	- Empresa de Pesquisa Energética
E	- Espectro de potência
AWM	- Análise Wavelet de Multiresolução
LP	- Filtro Passa-Baixa
HP	- Filtro Passa-Alta
A_j	- Aproximação
D_j	- Detalhes
TH	- Transformada De Hilbert
SCE	- Envelope De Corrente Do Estator
SIFs	- Sistemas de Inferência Fuzzy
FL	- Lógica Fuzzy
RBF	- Função De Base Radial
DEM	- Decomposição Em Modo Empírico
FMI	- Funções De Modo Intrínseco
AG	- Algoritmos Genéticos
RMS	- Raiz Média Quadrada
σ^2	- Variância
Sk	- Torção
Ku	- Curtose
γ_6	- Sexto Momento Central Normalizado
SPSA	- Aproximação Estocástica Simultânea De Perturbação
SVM	- Máquinas De Vetores De Suporte
DNNs	- Redes Neurais Profundas
DWAE	- Codificados automático de ondas profundas
ELM	- Máquina de aprendizado extrema
BPNN	- Backpropagation feed-forward
RF	- random forest
MIT	- Motor de Indução Trifásico
F_0	- Frequência de Falha Na Pista Externa
F_i	- Frequência de Falha Na Pista Interna

N_B	- Número de Esferas
D_b	- Diâmetro da Esfera
D_c	- Diâmetro da Primitivo
β	- Ângulo de Contato com a Esfera
ψ	- Wavelet Mãe
$\psi_{a,b}(t)$	- Wavelet Filhas
dbN	- Daubechies de ordem N
a	- Parâmetro de escalonamento
b	- Coeficiente de translação
GPICEEMA	- Grupo de Pesquisa em Instrumentação e Controle em Estudo de Energia e Meio Ambiente
PMC	- Perceptron Multicamadas
RBF	- Redes de Função Base Radial
MCSA	- análise de assinatura de corrente de motor
MUSIC	- método de algoritmo de classificação de sinal múltiplo
SPMs	- pulsos de choque
IC	- Inteligência Computacional
X1	- estímulos de entrada da Rede
W1	- pesos sinápticos
Θ	- Limiar de ativação
u	- Potencial de Ativação
f(.)	- Função de Ativação
y_{RNA}	- Saída do Neurônio
$f_{tanh}(u)$	- Função de ativação tangente hiperbólica
$f_{logsig}(u)$	- Função de ativação logística
CC	- Corrente Contínua
CA	- Corrente Alternada
j e k	- Parâmetros discretos da DWT nível e posição, respectivamente;
PE	- Pista externa
PI	- Pista interna
PEI	- Pista externa e interna
DSP	- Processador Digital de Sinais
IEEE	- Institute of Electrical and Electronic Engineers
$W_{(j,n)}$	- n coeficientes do detalhe j
$X(f)$	- Transformada de Fourier
x(t)	- sinal contínuo no tempo
Δt	- Resolução temporal
$\Delta \omega$	- Resolução em frequência

1. INTRODUÇÃO

Conforme estudos realizados em 2017 pela Empresa de Pesquisa Energética (EPE), vinculada ao Ministério de Minas e Energia, estima-se que 35,7% da energia produzida no Brasil é consumida pela classe industrial, o que equivale a aproximadamente 164.557 GWh no ano de 2016 (fonte EPE, MME 2016). Os motores elétricos são responsáveis por 95% de todos os acionamentos das principais nações industrializadas e, entre eles, os motores de indução trifásicos consomem tipicamente de 40 a 50% de toda a energia consumida no setor industrial (NÓBREGA, 2015).

Diante desse contexto, deve ser dada uma especial atenção quando se trata do tema e detecção e diagnóstico de falha em motores de indução, pois, mesmo sendo considerados intrinsecamente confiáveis e exigirem uma manutenção mínima, podem eventualmente se deteriorar e falhar, assim como qualquer equipamento. Isso ocorre principalmente devido a uma combinação do ambiente, ciclo de trabalho, instalação e fatores relacionados à fabricação (AHMED *et al.*, 2010).

A priori é necessário diferenciar o conceito entre detecção e diagnóstico. Ambos são termos muito utilizados no campo da engenharia. No âmbito desse trabalho vamos considerar detecção o ato de revelar, descobrir a falha no rolamento, e diagnóstico é o ato de indicar qual falha está presente no rolamento do motor, podendo ser na pista externa, interna ou em ambas.

O custo com manutenção dos equipamentos de uma indústria está entre um dos maiores gastos dentro de um processo de fabricação, os equipamentos podem apresentar falhas incipientes, que se não forem detectadas em determinado espaço de tempo, podem levar à quebra total, interrompendo a produção e causando prejuízos.

A tendência é detectar essas falhas em seus estágios iniciais, e a monitoração dos sinais emitidos pela máquina com propósito de análise e correção das falhas, reduz os danos e paradas para manutenção não programada, e por consequência, aumenta a disponibilidade, eficiência e vida útil da máquina.

Vários autores têm se dedicado às técnicas de detecção e diagnósticos de falhas que priorizam a descoberta precoce de problemas e substituem a manutenção corretiva. Contudo, isso demanda o desenvolvimento de métodos cada vez mais avançados, que avaliem aspectos como: possibilidade ou não de se realizar paradas na linha de produção para inspeção dos motores, custo da manutenção, acompanhamento histórico e antecipação de resultados (DE OLIVEIRA, 2007).

Técnicas que permitem detectar a falha ainda no início, conhecidas como preditivas, se mostram mais eficazes nos diversos sentidos apresentados anteriormente, pois possibilitam, a intervenção antes que a falha no motor em questão prejudique o processo produtivo (DE OLIVEIRA, 2007).

A base para qualquer método de diagnóstico de falha em motores de indução trifásicos é a compreensão de seu comportamento elétrico, magnético e mecânico quando em funcionamento normal e perante alguma condição de falha (FISER e FERKOLJ, 2001). Portanto a presença de qualquer tipo de falha em uma máquina de indução, provoca mudanças de interação de fluxo entre o estator e o rotor, resultando em mudanças na corrente do estator, nas tensões, no campo magnético, na vibração da máquina, na temperatura de operação, nos ruídos audíveis, dentre outras (REIS, 2010). Assim sendo, procura-se encontrar a correlação entre o tipo de falha e a respectiva perturbação causada em uma ou mais dessas variáveis. Acompanhar a variável em questão consiste em realizar o monitoramento da evolução de uma possível falha (VITOR, 2012).

Dentre as mudanças advindas das falhas nos motores, o som produzido pelo mesmo, é um fenômeno físico que fornece informações sobre o comportamento do sistema e pode ser usado como um parâmetro para determinar sua condição. Ao considerar o som como a propagação de ondas sonoras acústicas produzidas por vibrações mecânicas, pode-se esperar que essas ondas sonoras produzidas por uma máquina contenham informações sobre o comportamento da máquina e a condição de operação. O motor elétrico não é uma exceção disso, e as vibrações geradas por defeitos em rolamentos, desequilíbrios mecânicos e barras quebradas produzem sons com frequências características associadas a cada falha (DELGADO-ARREDONDO *et al.*, 2017).

A correlação entre falhas mecânicas e frequências sonoras características possibilita determinar a condição de funcionamento do rolamento do motor elétrico através da análise espectral do sinal de emissão sonoro. Além disso, a detecção e diagnóstico através da análise

desse tipo de sinal é um método não invasivo que pode ser facilmente implementado, como será demonstrado.

As técnicas mais populares para a detecção de falhas em motores de indução são através da análise da assinatura de corrente do motor e da análise de sinais de vibração. Todavia, nos últimos anos a análise de sinais acústicos e de emissão sonora para detectar falhas em motores de indução tem crescido. Todas essas técnicas de diagnóstico de falhas apresentam vantagens e desvantagens, por exemplo, a técnica da assinatura de corrente tem a vantagem de ser mais simples de implementar, proporcionando bons resultados no diagnóstico de falhas, no entanto, sob certas condições, a sua aplicação não é suficientemente sensível, porque tem uma relação sinal / ruído baixa. Já a análise de vibração tem a vantagem de que seus resultados são independentes do tipo de fonte de energia do motor e produz bons resultados, mas sua implementação requer o uso de acelerômetros que devem ser colocados perto ou no motor, o que às vezes é difícil acesso. A análise de sinais sonoros para diagnóstico de falhas em motores de indução tem como uma das principais vantagens que os resultados não dependem do tipo de fonte de energia. Além disso, o sensor primário é um microfone acústico padrão que pode ser colocado em qualquer lugar perto da máquina em análise, não necessariamente em contato direto, o que torna fácil sua instalação. No entanto, uma das desvantagens da análise do sinal sonoro é a sensibilidade ao ruído externo, o que deve ser evitado sempre que possível.

Os métodos utilizando inteligência computacional, por intermédio de técnicas baseadas em Redes Neurais Artificiais (RNAs), Sistemas de Inferência Fuzzy (SIFs) e Algoritmos Genéticos (AGs), tem mostrado resultados promissores na detecção e identificação de falhas em motores de indução trifásicos. (HWANG *et al*, 2009, RAO *et al*, 2012; UNAL *et al*, 2013,2014; BIN, 2012; MINI E USHAKUMARI, 2011, NOREESUWAN e SUKSAWAT, 2010; BENBOUZID E NEJJARI, 2001), fatos estes em virtude da sua habilidade de lidar com sistemas não-lineares e variantes no tempo e de não necessitar de modelos matemáticos precisos que representem o sistema, além de apresentar certa facilidade de integração computacional com as técnicas convencionais (SUETAKE, 2012).

Nesse contexto, a motivação para a realização deste trabalho de tese é estudar e desenvolver um método para detectar e diagnosticar falhas em motores de indução trifásicos com vistas à aplicação industrial. Diante disso, é abordado e desenvolvido o método de detecção e diagnóstico de falhas em rolamentos por emissão sonora, fazendo uso da Análise

Wavelet Multiresolução (AWM) cuja análise dos espectros de potência dos seus detalhes foi utilizada como entrada para uma Rede Neural Artificial (RNA), de forma que na saída seja obtida uma informação de possível avaria do MIT presente.

1.1. Objetivo Geral

O objetivo geral do trabalho é o desenvolvimento de um método baseado em Wavelet/Redes Neurais Artificiais (RNA) para detecção e diagnóstico de falhas em rolamentos de motores de indução trifásicos (MIT) realizando o processamento dos dados de som emitidos pelo motor.

1.2. Objetivos Específicos

Abaixo são listados os objetivos específicos do projeto:

- a) Desenvolver algoritmo de Redes Neurais Artificiais (RNA) para detecção de falhas em rolamentos de MIT, utilizando como entrada o espectro de potência dos detalhes e aproximações Wavelet do sinal de som emitido;
- b) Desenvolver duas topologias de RNA: Perceptron Multicamadas (PMC) e Redes de Função Base Radial (RBF), para comparação de desempenho.
- c) Validar a técnica experimentalmente.

2. ESTADO DA ARTE

A seguir serão apresentadas a justificativa e a motivação desse trabalho, em seguida os principais trabalhos encontrados na área de detecção de falhas em rolamentos, em barra quebradas e desbalanceamento mecânico via vibração e emissão sonora, bem como algumas estratégias utilizando sistemas inteligentes para diagnóstico.

2.1. Justificativa e Motivação

A seguir, os principais fatores que levaram ao desenvolvimento desse trabalho.

- Motores de indução trifásicos estão presentes em praticamente todos os setores industriais, cuja quebra pode ocasionar desastres operacionais.

- O rolamento é a falha mais comum em motores de indução respondendo por 41% das ocorrências (CHOUDHARY, 2018).

- De todos os sistemas de diagnóstico existentes para MIT, o método pela análise sonora é o único totalmente invasivo, não existe a necessidade de contato com o motor ou quadro de comando para se obter o diagnóstico, o que viabiliza diversas aplicações em ambientes industriais.

- As técnicas encontradas no estado da arte que utilizam som para diagnóstico, demandam a utilização de múltiplos sensores, tornando o sistema complexo e aumentando o custo de implementação.

- Métodos de processamento de dados para diagnóstico de falhas no domínio da frequência tendem a não ser eficientes em sistemas sob variação de carga, inviabilizando a sua aplicação na maioria dos processos industriais.

Baseado no que foi dito, a motivação principal e a justificativa do trabalho se baseia no desenvolvimento de um método com total não invasividade (usando som), no domínio do tempo (viabilizando aplicações sob carga variável) e de baixo custo (usando um único sensor

e plataforma arduíno). Como o sistema é não linear e variante no tempo, se faz necessário o uso de uma ferramenta computacional para classificação da falha, no caso, as Redes Neurais Artificiais foi utilizada para classificar as falhas no rolamento do MIT.

2.2. Principais Tipos de Falhas em MIT

Os métodos de detecção das falhas em motores de indução trifásicos baseiam-se na aquisição dos sinais relacionados ao funcionamento do motor (corrente, vibração mecânica, emissão acústica) e processamento desses sinais para extração da informação. A integração de sistemas inteligentes com os métodos já existentes tem sido muito explorada. Dentre as falhas mais comuns destacam-se, falhas no rolamento, barras quebradas e desbalanceamento.

CHOUDHARY *et al* (2018) em seu trabalho faz uma pesquisa de revisão dos atuais métodos utilizados para monitoração da condição do motor e da detecção de falha, na sua revisão ele apresenta a importância de um monitoramento de forma on-line, sendo assim uma manutenção preditiva, pois os MIT podem apresentar falhas em tempos irregulares, tornando a manutenção preventiva ineficiente. O monitoramento baseado na condição da máquina é usado para aumentar o desempenho e a eficiência da mesma, melhorando a vida e a produtividade, reduzindo assim, os danos internos e externos. O monitoramento dos MITs é essencial para interromper falhas inesperadas e minimizar o tempo de inatividade não programado. O motor pode apresentar falhas internas e externas que são classificadas em falhas mecânicas, elétricas e ambientais. As falhas podem ser classificadas no rotor, estator, rolamento e outras falhas mecânicas com base em sua localização no equipamento, como mostrado na Fig. 2.1.




Figura 2.1- Classificação de falhas em MIT. Adaptado: (CHOUDHARY, 2018)

NANDI *et al* (2005) classificou os parâmetros do MIT relacionados as falhas da seguinte forma: monitoramento de campo eletromagnético; medições de temperatura; reconhecimento infravermelho; monitoramento de emissões de radiofrequência; monitoramento de ruído e vibração; análise química; medições de ruído acústico; análise de assinatura de corrente de motor (MCSA); inteligência artificial e técnicas baseada em redes neurais artificiais.

Na figura 2.2, é apresentado um levantamento realizado pela IEEE das falhas nos MITS, onde pode ser observado que o principal componente que apresenta falha é o rolamento.




Figura 2.2 - Índice de falhas no MITS, levantamento feito pela IEEE. Adaptado: (CHOUDHARY, 2018)

2.3. Método de Detecção Via Emissão Sonora

Vibração pode ser definida como a oscilação de um corpo em torno de uma posição de referência. Trata-se frequentemente de um processo destrutivo, ocasionando falhas nos elementos das máquinas por fadiga. Além disso, a vibração é a resposta às forças dinâmicas, que por sua vez, vibra em várias frequências que se propagam por toda a máquina. Estas frequências podem ser identificadas e, na maioria das vezes, relacionadas a um tipo de falha.

De acordo com BONALDI (2005) cada elemento da máquina induz uma excitação característica, gerando formas específicas de vibração, tornando assim a análise de vibrações um processo eficiente. É justamente por essa razão que os defeitos nesses elementos podem ser detectados.

A emissão sonora é uma técnica de ensaios considerado não destrutivos, não invasiva, de grande utilidade na detecção de defeitos ativos internos em materiais e equipamentos. Sinais sonoros, gerados no interior de equipamentos em operação ou quando submetido a esforços programados, trazem informações importantes sobre a integridade destes equipamentos. Estes sinais são geralmente associados à presença de defeitos internos ou às características próprias do funcionamento dos equipamentos e seus componentes.

As técnicas de monitoramento de emissão sonora e vibração são atualmente conhecidas para diagnóstico de falha em rolamento (ORMAN *et al*, 2015, KUMAR *et al*, 2018).

Kumar et al, 2018 realiza a detecção das falhas nas esferas, pista interna e pista externa do rolamento através da emissão acústica utilizando para processamento do sinal a FFT e analisando os seguintes parâmetros: RMS, desvio padrão, curtose e densidade espectral. E conclui que quando a velocidades de rotação varia, cada um dos 4 parâmetros pode indicar diferentes falhas nos rolamentos, por exemplo a uma velocidade de 550 rpm, o RMS, o desvio padrão e a curtose podem ser usados para detectar defeitos na pista externa enquanto curtose pode ser usada para detectar defeitos nas esferas, pista interna e pista externa do rolamento. Em ORMAN et al 2015, foi utilizado o microfone do Smartphone, levando a uma dificuldade para fins de diagnóstico de falhas em MIT na qual a resposta de frequência do microfone do Smartphone é muito pobre (abaixo de 200 Hz) onde normalmente as frequências de falha do rolamento se encontram. Após apresentados esses dois trabalhos, o trabalho proposto faz detecção da falha utilizando um único parâmetro gerado pelo detalhe Wavelet do sinal de emissão acústica e com a utilização do microfone escolhido é possível abranger toda a faixa de frequência necessária.

Essa vibração e emissão sonora são medidas e utilizadas para revelar falhas nos componentes do motor. Uma diferença importante entre esses dois métodos de detecção é que a detecção por vibração tem um grau de invasividade maior ao sistema, quando comparado com a detecção pelo sinal som. Na maioria das vezes o analista de vibração trabalha com sinais de vários acelerômetros instalados na máquina, já pela emissão sonora, a análise é realizada pela vibração do som que se propaga no ar proveniente do motor elétrico, o método é não invasivo. Isso é uma grande vantagem, principalmente se a máquina estiver com difícil acesso para instalação de sensores com contato direto.

Tratando-se de detecção e diagnóstico por emissão sonora de rolamentos, há um aumento de atrito dos componentes do rolamento, portanto, essa alteração fornece nos sinais sonoros informações úteis sobre a integridade do rolamento (GLOWACZ *et al*, 2017).

A seguir serão apresentados alguns trabalhos encontrados na literatura que abordam diferentes métodos baseados em análises do sinal de som para detecção de falhas em motores de indução.

WEIDONG LI *et al.* (2006) realizaram em seu trabalho uma comparação da detecção de falhas do motor de indução usando a corrente do estator, vibração e emissão sonora. As falhas avaliadas por eles foram, barra quebrada de rotor e uma combinação de falhas de rolamento (pista interna, pista externa e falhas das esferas). Para abordar a capacidade de detecção dos métodos acima, as comparações são feitas no domínio do tempo e tempo-

frequência conjuntas. Observaram com os resultados experimentais que o método da corrente do estator é sensível à falha da barra quebrada do rotor enquanto o método de vibração é sensível às falhas de rolamento.

GARCIA-PEREZ *et al.* (2011) desenvolveram uma estratégia para monitoração e detecção de falha específica em um motor de indução através da análise de um sinal sonoro. A metodologia proposta pelos autores baseia-se no algoritmo de classificação de múltiplos sinais para análise espectral de alta resolução. Três falhas do motor de indução foram consideradas, desbalanceamento, rolamento e barras quebradas. Os resultados mostram que a metodologia proposta de análise de som poderia melhorar as técnicas padrões para a detecção de falhas do motor de indução, aumentando a detectabilidade. Para análise e processamento dos sinais foi utilizado o método de algoritmo de classificação de sinal múltiplo (MUSIC).

ORMAN *et al.* (2015) desenvolveram um método de detecção de falha em rolamentos de motores elétricos via aquisição sonora através de um celular. A principal dificuldade encontrada pelos autores foi o fato do microfone embutido do celular quando utilizado para fins de diagnóstico de falhas em motores, apresentar uma resposta de frequência muito pobre. Porém os resultados indicam que, dado um método de processamento de sinal adequado, é possível indicar a presença de falhas nos rolamentos. Os métodos de processamento que foram utilizados pelos autores consistem na curtose espectral e transformada de Hilbert. Os resultados mostram que as aquisições do som baseadas no celular contêm informações suficientes para distinguir não apenas entre casos saudáveis e defeituosos, mas também para determinar o tipo específico de falha de rolamento.

Nóbrega (2015) em sua tese fez um estudo comparativo de técnicas para detecção de falhas em motores de indução trifásico. Para tratamento dos dados utilizou a Transformada Rápida de Fourier (FFT) e as técnicas de processamento Wavelet. Chegando às seguintes conclusões: falhas mecânicas foram melhor diagnosticadas através da vibração e da análise sonora do ruído emitido pelo motor, a análise espectral do torque no entreferro e da aquisição do som por Análise Wavelet Multiresoluções (AWM) mostrou ser uma excelente alternativa para detecção de barras quebradas em termos de diagnóstico de falhas por severidade, para a detecção de falhas em rolamentos, a análise espectral associada à análise AWM para sinais de vibração foi a mais adequada e o diagnóstico de falhas por vibração mecânica via análise espectral se mostrou a melhor opção para desbalanceamento para diferentes cargas aplicadas.

KUMAR et al (2018) realizaram a análise estatística e de frequência de sinais sonoros para a detecção de defeitos de rolamentos. Os resultados mostraram que os parâmetros estatísticos utilizados, valor de RMS, desvio padrão, assimetria e curtose, podem ser usados para detectar diferentes tipos de falhas em esferas dos rolamentos. A análise da densidade espectral de potência mostra que rolamentos com diferentes condições físicas operando em diferentes velocidades emitem sinais acústicos com diferentes espectros de potência.

GERMEN et al (2014) analisa as falhas dos motores de indução por meio dos dados sonoros adquiridos através de vários microfones simultaneamente, para extrair recursos necessários dos dados é utilizado a análise de correlação cruzada dos dados e Wavelet. As características obtidas dos mesmos tipos de motores com diferentes tipos de falhas são utilizadas para a classificação pelo método de Mapas Auto-Organizáveis. Os resultados obtidos nos conjuntos de treinamento e teste indicam 100% de classificações corretas.

DELGADO- ARREDONDO et al (2017) usa uma metodologia para detectar falhas nos motores de indução em estado estacionário com base na análise de som e sinais de vibração. Utiliza a *Complete Ensemble Empirical Mode Decomposition* para decompor o sinal em várias funções do modo intrínseco. Para obter o conteúdo espectral, a frequência marginal da representação de Gabor é calculada. Justifica a utilização de Gabor por possuir uma melhor tolerância ao ruído que a FFT e o espectro resultante ser suavizado, facilitando sua interpretação. Essa metodologia revelou ser extremamente útil nos casos em que o som ou os sinais de vibração são os únicos sinais disponíveis.

LU et al (2016) propõe um método denominado método KLTAR que utiliza uma câmera de alta velocidade para estimar a velocidade de rotação e fornece uma abordagem distinta para o diagnóstico de falhas em rolamentos sob velocidade variável. Uma câmera de alta velocidade, em vez de um codificador tradicional, é usada para estimar a velocidade do motor usando algoritmos de detecção de borda e rastreamento de objetos Kanade-Lucas-Tomasi (KLT). O algoritmo KLT rastreia os pontos de recurso no acoplamento circular para obter as distâncias de deslocamento entre os quadros adjacentes. O ângulo de rotação instantâneo (IRA) e as curvas de ângulo acumuladas são plotadas junto com os quadros de vídeo que estão sendo processados. O som do rolamento que é gravado usando um microfone é então analisado para encontrar as características distintas associadas às falhas do rolamento. O sinal sonoro varia com o tempo porque o motor gira sob velocidade variável. O método apresentou bom potencial no diagnóstico de falhas em rolamentos.

2.4. Redes Neurais para diagnóstico de Falha em MIT

Dos sistemas inteligentes, um dos mais amplamente difundidos é a Rede Neural Artificial, que por sua capacidade de aquisição e manutenção do conhecimento, pode ser aplicada na solução de diversos problemas, como no caso dessa pesquisa, na classificação de padrões complexos sem a necessidade de um conhecimento detalhado do comportamento do sistema no qual eles ocorrem.

Tratando de diagnóstico de falha em motores de indução é difícil estabelecer exatamente uma formulação matemática que descreva a relação entre as falhas elétricas e as harmônicas de vibração geradas. Portanto, um modelo de rede neural pode ser alcançado mais eficientemente porque é um modelo empírico não linear que pode capturar a dinâmica não linear do sistema e não requer conhecimento de parâmetros específicos do sistema. Abaixo segue um breve referencial bibliográfico de autores que aplicaram as redes neurais junto com outros tipos de mecanismos de inteligência artificial para detecção de falhas em motores de indução.

BESSAM *et al.* (2016) desenvolveram uma técnica eficiente baseada em uma abordagem de redes neurais e a transformada de Hilbert (TH) para diagnóstico de barras de rotor quebradas em máquinas de indução com baixa carga. A transformada de Hilbert é usada para extrair o envelope de corrente do estator. Duas características são selecionadas do espectro (a amplitude e a frequência da harmônica). Esses recursos foram utilizados como entrada para a rede neural.

ONEL *et al.* (2006), propõem uma técnica de detecção e diagnóstico em motores de indução baseada na corrente de armadura do motor e na velocidade de rotação do eixo. Uma Rede Neural Artificial (RNA) com função de ativação de base Radial (RBF) é usada para automatizar o processo de detecção e diagnóstico de falhas. De acordo com os autores abordagens de redes neurais podem ser consideradas como métodos de “caixa preta”, pois não fornecem raciocínio heurístico sobre o processo de detecção de falhas. Quando devidamente ajustadas, elas podem melhorar o desempenho do diagnóstico e ser facilmente adaptadas pela incorporação de novos dados à medida que se tornam disponíveis. A RNA com função de ativação de base radial foi adotada porque é capaz de fornecer uma classificação precisa do diagnóstico de falhas, e também por suas saídas serem capazes de,

não apenas realizar detecção de falhas, mas também indicar a extensão da falha (diagnóstico). Testes experimentais levaram a resultados com um nível de precisão de 96%.

ALI *et al.* (2015) mostraram o potencial de aplicação da Rede Neural Artificial como uma ferramenta eficaz para a avaliação da degradação do desempenho de rolamentos automáticos sem intervenção humana. De acordo com as características não-estacionárias e não-lineares dos sinais de vibração dos rolamentos, o método de extração de recurso foi baseado na entropia de energia da decomposição em modo empírico (DME). Através de uma análise matemática foram selecionadas as funções de modo intrínseco mais significativas (FMIs). As características escolhidas foram usadas para treinar uma rede neural artificial (RNA) para classificar os defeitos dos rolamentos. Os resultados experimentais indicaram que o método proposto baseado em sinais de vibração de operação para falha pode categorizar de maneira confiável os defeitos de rolamento.

UNAL *et al.* (2014) realizou um estudo para extrair características de sinais de vibração para o diagnóstico de falhas de rolamento através da análise de envelope acompanhada por transformada de Hilbert e transformada rápida de Fourier (FFT). O algoritmo de detecção de falhas foi baseado em redes neurais artificiais (RNA). O desempenho da classificação foi aumentado com sucesso pela otimização do algoritmo genético (GA). Dezesesseis recursos foram usados como entradas para um modelo de RNA, fornecendo 98% de sucesso. Análise de envelope, FFT e rede de alimentação avançada com base em GA provou ser uma estratégia computacional eficaz para detecção de falhas e diagnóstico de rolamentos.

DELGADO *et al.* (2013) introduziram uma nova metodologia de diagnóstico aplicada a falhas de rolamento usando informações no tempo que se baseiam nos dados de vibração. Além de detectar defeitos locais, ou seja, falhas de pista em rolamentos, também leva em conta a detecção de defeitos distribuídos, como a rugosidade. O método inicia calculando as diferentes características do sinal de vibração, em seguida faz a seleção de dados, onde somente os dados mais significativos são selecionados durante o processo de treinamento, após essas etapas, ocorreu a redução de dados, para comprimir e manter as informações úteis para fins de diagnóstico, e, finalmente, o estágio de classificação baseado na rede neural, em que as diferentes falhas consideradas são diagnosticadas.

ZAREI (2012) Fez uso de características extraídas do sinal de vibração no domínio do tempo como: raiz média quadrada (RMS), Variância (σ^2), Torção (SK), Curtose (KU) e Sexto momento central normalizado (γ_6) como entrada RNA para simplificar e tornar o

procedimento de diagnóstico de falhas mais eficaz, quando comparados com métodos que utilizam características do sinal no domínio da frequência. As redes neurais são treinadas com um subconjunto dos dados experimentais para condições conhecidas da máquina. Duas redes diferentes foram projetadas, uma delas usa apenas dados no domínio do tempo, enquanto a outra usa dados no domínio de tempo e frequência como as entradas da rede.

GHATE e DUDUL (2011) criaram um esquema de detecção de falhas em motores de indução trifásico baseada em Redes Neurais com base na função radial-multicamadas-perceptron para os tamanhos pequeno e médio de motores. Parâmetros estatísticos simples, como desvio padrão, curtose, energia, entropia, variância, etc., da corrente do estator são considerados como recursos de entrada. Resultados experimentais são incluídos para mostrar a capacidade do classificador proposto para detectar falhas. Além disso, a rede é testada quanto à robustez aos ruídos uniformes e gaussianos.

CHO *et al.* (2010) apresentaram uma nova abordagem aplicada à detecção de falhas em um motor de indução trifásico. Essa abordagem foi baseada em uma rede bayesiana que foi usada para detectar falhas no estator e o no rolamento através do sinal de corrente. A abordagem foi feita criando um modelo neural para representar o comportamento normal do sistema e modelos adicionais para representar várias condições de falha. Os modelos neurais foram então colocados em paralelo com o sistema a ser monitorado, e a detecção de falhas foi obtida comparando as saídas dos modelos neurais com as saídas reais do sistema. O treinamento da rede neural foi obtido usando a aproximação estocástica simultânea de perturbação (SPSA). A classificação de falhas foi baseada em um teste de limiar simples dos resíduos formados subtraindo cada saída do modelo neural da saída correspondente do sistema real.

SAMANTA *et al.* (2003) fez uma comparação de dois métodos para detecção de falhas em rolamentos usando dois classificadores diferentes: redes neurais artificiais (RNAs) e máquinas de vetores de suporte (SVMs), com seleção de recursos baseada em algoritmos genéticos (GA) a partir de sinais de vibração no domínio do tempo. Os classificadores foram treinados com um subconjunto dos dados experimentais para condições conhecidas da máquina e são testados usando o conjunto restante de dados. Foi concluído que o desempenho do SVM é substancialmente melhor que o da RNAs com todo o conjunto de recursos. O uso de GAs com apenas seis recursos deu 100% de classificação para as RNAs e SVMs.

KOWALSKI e KOWALSKA (2003) apresentam dois tipos de redes neurais utilizados para fins de diagnóstico de falhas em motores de indução. As redes neurais foram: PMC e redes auto-organizadas de Kohonen. Para treinamento das redes foram utilizados dados de medição de corrente de estator e espectros de vibração mecânica. Os resultados de testes experimentais mostram que as redes neurais podem ser efetivamente usadas para a cognição de estator, rotor, rolamentos e falhas de assimetria de suprimento por medições e interpretações apropriadas da análise FFT dos espectros de corrente e vibração. Foi observado também que o pré-processamento apropriado dos dados de medição permite a exclusão dos dados, que são menos característicos para uma determinada falha do motor. Este procedimento permite a minimização de um vetor de treinamento e, assim, a redução do tempo de treinamento da rede pode ser obtida.

JACK e NANDI (2002) examinam o desempenho das Redes neurais artificiais (RNAs) e máquinas de vetores de suporte (SVMs) para reconhecimento de falhas em máquinas rotativas, e apresentam tentativas de melhorar o desempenho geral de generalização de ambas as técnicas através do uso do algoritmo genético (GA) baseado no processo de seleção de características. A seleção de recursos do GA reduziu significativamente o número de entradas, resultando em uma arquitetura de rede menor, exigindo muito menos computação na fase de teste. A RNA se apresentou mais rápida de treinar e um pouco mais robusta do que a SVM neste estágio no tempo.

GAO *et al.* (2000) propôs um esquema de detecção de falhas de motores baseado em redes neurais Elman. Utilizaram Algoritmo Genético como estratégia de treinamento para a rede com intuito de melhorar a precisão da aproximação e obter um melhor desempenho de detecção. Para validação do método foram feitas simulações computacionais de uma transmissão de automóvel com uma falha artificial. Utilizando como principal critério de detecção da falha a expectativa de erro de predição quadrático do sinal de característica do motor.

SUETEKE (2012) em sua tese de doutorado implementou um sistema de monitoramento para falhas nas barras de rotores de motores de indução trifásicos, o diagnóstico da falha é feito através de uma abordagem neural mediante análise do espectro de frequência e aplicação de técnicas de análise das componentes principais. Em função do processamento dos sinais adquiridos do motor ele desenvolveu um método de monitoramento baseado em redes neurais artificiais. A técnica se apresentou robusta, principalmente em carregamentos das máquinas entre 50% a 100% do torque nominal. Em

função dos MITs serem, na prática, dimensionados para trabalhar próximo ao carregamento nominal, a aplicabilidade da técnica de identificação proposta foi válida.

Foi realizado uma busca mais específica para trabalhos que utilizaram RNA para detecção de falha exclusiva do elemento rolamento, segue a tabela 3.1.

Tabela 3.1 - Pesquisa em Detecção de falha em MIT com RNA				
Autor, Ano	Tipo de falha: Rolamento	Sinal de entrada da rede	Processamento do sinal	Topologia da Rede Neural
Trabalho proposto	Rolamento: pista externa, interna e externa/interna	Emissão sonora	Wavelet	PMC e RBF
MUHAMMAD <i>et al.</i> , 2017	Rolamento: pista interna e externa	Corrente	Análise por vetor de Park	PMC
VITOR <i>et al.</i> , 2014	Rolamento, curto-circuito entre as espiras do estator, barras quebradas,	Corrente	Transformações de Clarke e Park.	RBF
KANKAR <i>et al.</i> , 2011	Rolamento, pista interna, externa e esfera	Vibração	Wavelet	Máquina vetorial de suporte (SVM), Perceptron e Mapas Auto-Organizáveis (SOM)
SAMANTA e AL-BALUSHI, 2003	Rolamento	Vibração	Filtragem de banda alta passante, desmodulação, e transformada wavelet	PMC
YAGUO <i>et al.</i> , 2009	Rolamento	Vibração	Wavelets (WPT), decomposição em modo empírico (EMD), parâmetros adimensionais,	RBF
PATEL E UPADHYAY, 2016	Rolamento	Vibração	Wavelet	PMC e Máquina De Vetores De Suporte
FENG <i>et al.</i> , 2016	Rolamento	Vibração	Fourier (FFT)	Redes Neurais Profundas (DNNs)
ZHIQIANG <i>et al.</i> , 2017	Rolamento	Vibração	Wavelet e Fourier	três modelos de redes neurais profundas (Deep Boltzmann Machines, Deep Belief Networks e Stacked Auto-Encoders)
DUY-TANG e HEE-JUN, 2019	Rolamento	Vibração	Imagem da vibração	Rede Neural Convolucional
HAIDONG <i>et al.</i> , 2018	Rolamento	Vibração	Wavelet	Codificados automático de ondas profundas (DWAE)

				com Máquina de aprendizado extrema (ELM)
GODOY <i>et al.</i> , 2013	Rolamento	Tensão e corrente	Discretização linear do sinal	PMC
KYUSUNG E PARLOS, 2002	Curto circuitos, barras quebradas, rolamento e excentricidade do entreferro.	Correntes, tensões e a velocidade do motor.	Wavelet	PMC
BUBATHI MURUGANATHAM <i>et al.</i> , 2013	Rolamento	Vibração	Análise do espectro Singular (SSA)	Backpropagation feed-forward (BPNN)
JANSSENS <i>et al.</i> , 2016	Rolamento	Vibração	FFT	Rede Neural Convolucional-Aprendizado de recurso
YANG <i>et al.</i> , 2002	Rolamento	Vibração	FFT	PMC
HWANG <i>et al.</i> , 2009	Rolamento	Vibração	Fourier- Ceptrum	Backpropagation feed-forward
LOPES <i>et al.</i> , 2017	Rolamento	Corrente	Discretização do sinal e normalização	PMC e network with random forest (RF) classifier

Diante todas essas pesquisas feitas a respeito da utilização de redes neurais artificiais para diagnóstico de falha em motores, esse trabalho propõe o desenvolvimento de uma rede neural artificial baseada em treinamento com dados de emissão sonora do motor para diagnosticar possíveis defeitos em rolamentos de motores de indução trifásicos, sendo este o diferencial em comparação com os demais.

As propriedades não-lineares de uma rede neural artificial (RNA) a tornam ideal para aplicações como monitoramento de condição de máquina onde os dados de treinamento são relativamente escassos e a rede terá que ser generalizada até certo ponto (PENG e CHAN, 2002).

A base de dados para modelagem do sistema de identificação da falha via rede neural proposta foi composta por motor em partida direta considerando também uma faixa de torque aplicado. O conjunto de aquisições foi dividido em conjunto de treinamento, validação e teste.

2.5. Contribuições do Trabalho

Como já apresentado, os MITs apresentam diversos sinais (vibração, corrente, tensão, som.) que trazem informações sobre suas condições de operação. Para aquisição desses sinais é necessário a instalação de diferentes tipos de sensores, fazendo com que surjam certas vantagens e desvantagens na aplicação de cada método.

A utilização da Transformada Wavelet (TW) no processamento do sinal para detecção e diagnóstico de falhas em MIT já é uma técnica bem consolidada (Germen, 2014; Nóbrega, 2015) apresentando bons resultados. Junto com a transformada Wavelet foi criada uma RNA utilizada como classificador das possíveis situações dos rolamentos, pois somente a TW não foi suficiente, como será apresentado posteriormente.

Utilizar as técnicas de análise sonora é a forma menos invasiva encontrada na literatura quando comparada com a análise por vibração mecânica, por corrente elétrica do motor (MCSA), por campo magnético, e por emissão acústica. Utilizando o sistema proposto, as condições do rolamento da máquina podem ser avaliadas sem qualquer contato direto e sob carga variável, possibilitando a coleta de dados em locais remotos e com difícil acesso.

Em relação às técnicas baseadas em processamento de sinal do som encontradas na literatura, o presente trabalho apresenta pela primeira vez um sistema de detecção de falhas que usa a combinação AWM/RNA aplicado a sinais sonoros e possibilita um avanço ao estado da arte ao propor uma abordagem no domínio do tempo, de baixo custo (usando um único sensor e plataforma Arduino), capaz de diagnosticar sob carga variável e com alta possibilidade de acerto.

3. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo será abordado de forma sucinta, conceitos fundamentais para facilitar o entendimento da tese. São apresentados conceitos sobre a composição de motores de indução trifásicos, em seguida as técnicas de processamento de sinais utilizadas para detecção e diagnóstico de falhas, incluindo a transformada de Fourier e a Análise Wavelet Multiresolução (AWM). Também é feita uma breve introdução às Redes Neurais Artificiais e, por fim, a caracterização das falhas que serão detectadas pelo sistema.

3.1. Motor de Indução Trifásico

Motores elétricos têm como função transformar energia elétrica em energia mecânica, ou seja, em um motor a presença da corrente elétrica, seja corrente contínua ou alternada, garante movimento em um eixo, que pode ser utilizado em diversas aplicações. O motor de indução trifásico está presente em praticamente todos os processos industriais sendo o principal meio de conversão eletromecânica existente, apresentando como vantagens o baixo custo e a máxima eficácia com manutenção mínima, boa eficiência energética, baixo consumo nos processos de aceleração e frenagem, construção simples, robustez e durabilidade (LYRA, 2015).

Os motores de indução têm como partes constituintes principais o estator (parte fixa), o rotor (parte móvel, centrada no interior do estator com diâmetro ligeiramente menor), as bobinas e o espaço entre o rotor e o estator, denominado de entreferro (air gap). A Figura 3.1 mostra os componentes do motor de indução.

O entreferro é a interface entre a parte eletromagnética e mecânica da máquina e, embora inevitável, é indesejado, uma vez que obriga a formação de um campo magnético mais intenso, para se induzir a mesma potência no rotor, ou seja, durante o processo de conversão de energia nem toda a energia elétrica entregue ao motor é convertida em mecânica (ADISSI, 2012).




Figura 3.1- Figura de um motor de indução fechado. Fonte: FRANCISCO, 2006.

O estator é composto por chapas finas aço magnético tratadas termicamente ou de aço silício para reduzir ao mínimo as perdas por correntes parasitas e histerese, e quando em operação, cria um campo magnético. O rotor pode ser de dois tipos, o de gaiola de esquilo ou o bobinado. 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 usados, 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 *et al*, 2003).

O princípio de funcionamento dessa máquina se baseia nas leis de eletromagnetismo. Quando o motor é alimentado por um sistema trifásico, o enrolamento é percorrido por sua respectiva corrente alternada, cria-se ao redor de cada um destes um campo magnético, cuja intensidade é proporcional a corrente que o percorre. Os três campos magnéticos quando somados vetorialmente resulta em um único campo magnético que está em sincronismo com a frequência da rede elétrica de alimentação. Esse campo magnético se forma a cada instante, devido à combinação de cada um dos campos magnéticos criados por cada enrolamento monofásico e é girante com intensidade constante, pois a orientação norte-sul do conjunto gira continuamente (ADISSI, 2015).

O motor de indução funciona com velocidade constante proporcionada pelo campo magnético girante, logo sua velocidade de campo é chamada de velocidade síncrona, e é em

função de dois fatores, a quantidade dos polos e a frequência da rede elétrica. Porém a velocidade de rotação atingida será sempre menor que a velocidade síncrona, isto é o rotor desloca-se com um certo escorregamento em relação ao campo girante do estator. O escorregamento é a fração de rotação que o rotor perde a cada rotação de campo girante, ou seja, é a porcentagem de redução de velocidade no eixo em relação à velocidade síncrona devido ao aumento da carga.

Os motores de indução no meio industrial são expostos a diversas condições ambientais e estão sujeitos a falhas, essas falhas provocam alterações nas características dos seus sinais, que quando submetidos a um processamento é possível identificar essas alterações que são utilizadas para detecção e diagnóstico da falha.

3.2 Processamento de Sinais

O processamento dos sinais é utilizado para extrair informações de sinais que muitas vezes estão ocultas a uma simples avaliação visual no domínio do tempo. Para utilização de diagnóstico de falhas, a escolha da técnica adequada depende da natureza do sinal em questão.

Os sinais podem ser classificados como sinais estacionários e sinais não estacionários, o primeiro apresenta poucas variações durante um intervalo de tempo, geralmente ocorrem em máquinas de indução sob carga constante, já nos sinais não estacionários, apresentam componentes dinâmicas com variações transitórias. Diante disso, existem diversas técnicas convencionais utilizadas na detecção e diagnóstico de falhas em motores baseados na representação de um sinal durante seu processamento, estes métodos podem ser, no domínio do tempo ou no domínio da frequência (SANTIAGO e PEDERIVA, 2003).

3.3 Transformada de Fourier

A análise espectral com base na Transformada de Fourier (TF) tem sido largamente aceita como sendo o método mais confiável de diagnóstico de falhas para sinais estacionários (SANTIAGO e PEDERIVA, 2003), estabelecendo a representação de um sinal por uma soma infinita de termos em senos e cossenos.

Para um sinal contínuo no tempo $x(t)$, a transformada de Fourier $X(f)$, é definida pela equação (1) :

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (1)$$

Onde o sinal $x(t)$ é dado pela equação (2):

$$x(t) = \int_{-\infty}^{+\infty} X(f)e^{j2\pi ft} df \quad (2)$$

Tendo posse de um conjunto de pontos que represente os valores das amostras, cobrindo um período inteiro, de um sinal que é periódico e amostrado, é possível realizar o cálculo da TF desse sinal, visto que esses pontos contêm toda a informação necessária para se descrever completamente o sinal.

Uma vez que vários sinais de interesse não possuem expressões analíticas que os descrevam o cálculo prático do espectro via transformada clássica se tornam inviável. Dessa forma é utilizada a *Transformada Discreta de Fourier* (DFT) fazendo-se uso de um algoritmo conhecido como a *Transformada Rápida de Fourier* (FFT), o qual não é um tipo diferente de transformada e sim uma técnica que possibilita avaliar DFT de forma mais rápida e econômica, proporcionando um menor esforço computacional (OLIVEIRA, 2007).

Sendo Considerada N amostras do sinal no domínio do tempo, denotadas $f(k)$, com $k=0,1,2,...,N-1$, a DFT é dada por um conjunto de N amostras do sinal no domínio da frequência, denotadas por $F(n)$, $n= 0,1,2,...,N-1$ e definidas pela equação (3):

$$F(n) = \frac{1}{N} \sum_{k=0}^{N-1} f(k)e^{-j\frac{2\pi kn}{N}} \quad (3)$$

Os coeficientes espectrais do sinal em função da frequência resultam em um gráfico chamado espectro em frequência, que representa a distribuição de energia do sinal no domínio da frequência, no qual uma maior amplitude representa a maior importância da frequência para a composição do sinal.

Na análise de Fourier clássica é assumido que o sinal é estacionário, ou seja, assume-se que o espectro é independente do tempo e que todas as componentes do sinal existem em toda a duração do mesmo. A Transformada de Fourier possui, portanto, resolução máxima em frequência, mas nenhuma resolução no tempo, e a análise dos coeficientes define a frequência global do sinal.

O espectro de fase é responsável por uma parte importante da informação acerca do sinal, que apesar de muito útil é de difícil interpretação. Deste modo, para tal representação se tornar útil na análise de sinais com características de não estacionaridade ou transiente (impulsos, choques, mudanças bruscas, início e fim de eventos) será necessário o desenvolvimento de procedimentos que tornem tal informação de fácil interpretação (PINTO, 2009).

Dessa forma a abordagem do tempo é incluída na análise para processamento desses sinais não estacionários, sendo assim a transformada de Fourier foi adaptada. Nessa adaptação assume-se uma divisão do sinal em porções pequenas o suficiente para que dentro destas, o sinal possa ser tratado como estacionário. Aplica-se uma janela sobre o sinal, de forma que sejam separadas cada uma de suas porções estacionárias, tal que a DFT de cada porção obterá exatamente a frequência presente em cada uma. Essa estratégia provou-se adequada para diversas aplicações, dando origem a uma "revisão" da Transformada de Fourier que passou a ser conhecida como *Transformada de Fourier de tempo curto* (STFT).

Porém, segundo SANTIAGO (2004), a constância da largura da janela para todas as frequências se torna uma limitação da STFT, de forma que uma janela larga, formada por um maior número de amostras, permite uma boa resolução no domínio da frequência, mas uma pobre resolução no domínio do tempo, e vice-versa, portanto, a obtenção de uma boa resolução nos dois domínios de forma simultânea, se torna impossível.

Essa problemática impulsionou diversos estudos relacionados ao processamento de sinais não estacionários, dentre as técnicas, a análise via Wavelets, tem se mostrado uma ferramenta excelentes resultados no processamento desses sinais (CRUZ, 2015).

3.4 Transformada Wavelet

Uma Wavelet é uma onda curta de natureza oscilatória e energia finita, e representa o sinal como versões deslocadas e escalonadas de uma Wavelet original, chamada de Wavelet-mãe, representada por ψ (LACERDA *et al.*, 2011). A ideia fundamental da Transformada de Wavelet é que ela é uma transformada pontual e proporcional à escala. Ela analisa o sinal em escalas diferentes e se desloca analisando cada ponto do sinal (OLIVEIRA, 2007).

A Transformada Wavelet fornece a descrição tempo-escala de um sinal, com janelas onde a largura se ajusta à escala. As limitações de tempo e de frequência definidas para a análise do conteúdo de energia do sinal leva, naturalmente, a introdução da caixa de Heisenberg, associada a cada análise Wavelet. Dessa forma, as resoluções são determinadas por retângulos de dimensões $(a\Delta t, \Delta\omega/a)$ onde "a" é o fator de escala, em contraste com a TF, na qual as resoluções são $(\Delta t, \Delta\omega)$, onde Δt e $\Delta\omega$ são constantes. Na Figura 3.2a tem-se as duas interpretações respeito da STFT, e na Figura 3.2b, a interpretação do parâmetro de escala introduzida pela wavelet. Observa-se para cada caso, a região de influência de um impulso de Dirac (linhas verticais) (NÓBREGA ,2015).




Figura 3.2 - Comparação entre as resoluções da Wavelet e da STFT no plano tempo-frequência. Fonte: NÓBREGA ,2015.

A ideia fundamental por trás de Wavelets é analisar de acordo com a escala. Na verdade, alguns pesquisadores do campo Wavelet sentem que, ao usar Wavelets, está adotando uma nova mentalidade ou perspectiva no processamento de dados. Wavelets são

funções que satisfazem certos requisitos matemáticos e são usadas na representação de dados ou outras funções. Esta ideia não é nova, a aproximação com superposição de funções existe desde o início dos anos 1800, quando Joseph Fourier descobriu que ele poderia superar senos e cossenos para representar outras funções. No entanto, na análise Wavelet, a escala que usamos para analisar os dados desempenha um papel especial. Os algoritmos Wavelet processam dados em diferentes escalas ou resoluções. Se olharmos para um sinal com uma grande "janela", notaríamos características brutas. Da mesma forma, se olharmos um sinal com uma pequena "janela", notaríamos pequenos recursos. O resultado na análise Wavelet é tanto a floresta quanto as árvores, por assim dizer (GRAPS, 1995).

O procedimento de análise de Wavelets é adotar uma função de protótipo Wavelet, chamada Wavelet mãe. A análise temporal é realizada com uma versão contraída e de alta frequência da onda de protótipo, enquanto a análise de frequência é realizada com uma versão dilatada e de baixa frequência da mesma Wavelet. Como o sinal ou a função original podem ser representados em termos de expansão de Wavelet (usando coeficientes em uma combinação linear das funções Wavelet), as operações de dados podem ser realizadas usando apenas os correspondentes coeficientes de Wavelet. E se você ainda escolher as melhores Wavelets adaptadas aos seus dados ou trancar os coeficientes abaixo de um limite, seus dados são escassamente representados. Esta codificação esparsa torna as Wavelets uma ferramenta excelente no campo da compressão de dados (GRAPS, 1995).

Uma coisa a lembrar é que as transformações Wavelet não possuem um único conjunto de funções básicas como a transformada de Fourier, que utiliza apenas as funções seno e cosseno. Em vez disso, as transformações Wavelet têm um conjunto infinito de funções de base possíveis. Assim, a análise Wavelet fornece acesso imediato a informações que podem ser obscurecidas por outros métodos de tempo-frequência, como a análise de Fourier.

A transformada Wavelet pode ser aplicada continuamente (transformada de Wavelet Contínua - CWT) ou discreta (transformada de Wavelet Discreta - DWT).

Ao contrário da STFT, a TW fornece uma forma mais flexível de representação de tempo-frequência de um sinal, permitindo o uso de janelas de tamanho variável. Na TW as janelas de longo prazo são usadas para obter uma resolução de baixa frequência mais fina e janelas de curta duração são usadas para obter informações de alta frequência. Portanto, o TW fornece informações precisas de frequência em baixas frequências e informações

precisas de tempo em altas frequências. Isso torna a TW adequado para a análise de padrões de dados irregulares, como impulsos que ocorrem em várias instâncias do tempo.

A transformada de ondas contínuas de um sinal $x(t)$ é definido pela equação (4):

$$CWT(a, b) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (4)$$

Onde ψ é a função Wavelet mãe. O parâmetro b é chamado de coeficiente de translação e avança ou atrasa a posição da wavelet no eixo do tempo t , ou seja, está relacionado com a localização da “janela”. Este parâmetro, é responsável por mover a função moduladora $\psi_{a,b}(t)$ sobre o eixo horizontal, a fim de alcançar todo o sinal (NÓBREGA, 2015).

O parâmetro a de escalonamento designa o tamanho da função janela, corresponde ao processo de compressão e dilatação do sinal, onde para valores pequenos a TW aumenta a resolução de um pequeno detalhe do sinal $x(t)$. As escalas e as frequências de um sinal têm associação inversa entre si. A faixa específica da frequência é relacionado ao tamanho do detalhe; por exemplo, se for variado o parâmetro a , a função $x(t)$ pode ser examinada em diferentes frequências. Se a escala aumenta, $\psi_{a,b}(t)$ aumenta (dilata) no tempo, capturando comportamentos de tempo longo. Se a escala diminui, $\psi_{a,b}(t)$ sofre uma contração no tempo, capturando comportamentos de tempo curto, transitórios. Escala grande, significa visão global, enquanto que escala pequena significa visualização dos detalhes (DAUBECHIES, 1992).

O escalamento possibilita a compressão ($a < 1$) ou dilatação ($a > 1$) da wavelet-mãe $\psi(t)$.

Calcular os coeficientes Wavelet em todas as escalas possíveis é computacionalmente uma tarefa muito dispendiosa. Logo para aplicação prática da transformada Wavelet a sua discretização é necessária, pois na CWT, o sinal mapeado no domínio Wavelet é representado por uma função de duas variáveis contínuas, e, nem todas as transformações são possíveis, dada a necessidade de uma forma analítica que as represente.

$$DWT(j, k) = \frac{1}{\sqrt{|2^j|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t - kb_0 a_0^j}{a_0^j}\right) dt, \quad j \text{ e } k \in \mathbb{Z} \quad (5)$$

Onde os parâmetros de escala e translação a e b são funções dos parâmetros discretos j e k , sendo o primeiro chamado de nível, determinando a escala *wavelet*, enquanto o segundo indica a posição desta. Os parâmetros a_0 e b_0 são respectivamente, os coeficientes de passo discreto de escala e de translação da DWT, tal que $a = a_0^j$ e $b = kb_0 a_0^j$, permitindo uma expansão da família originada pela *wavelet*-mãe, gerando filhas com $a_0 > 1$ e $b_0 > 0$ (NÓBREGA, 2015).

Para de facilitar os cálculos computacionais, é comumente adotado, o escalonamento binário e a translação unitária. Ou seja, atribui-se $a_0 = 2$ e $b_0 = 1$. Assim as escalas e deslocamentos são baseada na potência de dois, as chamadas escalas e posições diádicas, a análise de Wavelets se torna muito mais eficiente. Tal análise é obtida do DWT que é definido pela equação (6):

$$DWT(j, k) = \frac{1}{\sqrt{|2^j|}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t - 2^j k}{2^j}\right) dt \quad (6)$$

Onde a e b são substituídos por 2^j e $2^j k$, respectivamente. Mallat em 1989 enxergou uma analogia bastante apropriada entre o algoritmo de decomposição diádico e o uso de um banco de filtros, conceito este oriundo da teoria geral de processamento de sinais, e desenvolveu essa análise conhecida como, Análise Wavelet Multiresolução (AWM), dessa forma o sinal pode ser apresentado em duas componentes conhecidas como aproximação e detalhe, podendo também ser reconstruído por meio delas. Uma maneira eficiente de implementar esse esquema é passando o sinal através de uma série de pares de filtro passa-baixa (LP) e passa-alta (HP), dessa forma a aproximação contém informações de baixa frequência do sinal original e o detalhe contém as informações de alta frequência deste mesmo sinal. Na figura 3.3 é apresentado o processo de decomposição Wavelet Discreta Multiresolução.




Figura 3.3- Processo de decomposição Multiresolução. Fonte: Autor.

No primeiro passo do processo, o sinal é passado simultaneamente para os filtros LP e HP, sendo a frequência de corte a quarta da frequência de amostragem. As saídas dos filtros baixo e alto são referidas como coeficientes de aproximação (A1) e detalhes (D1) do primeiro nível, respectivamente. Os sinais de saída com metade da largura de banda de frequência do sinal original podem ser reduzidos em dois, de acordo com a regra de Nyquist. O mesmo procedimento pode ser repetido para a aproximação de primeiro nível e os coeficientes de detalhes para obter os coeficientes de segundo nível. Em cada etapa desse processo de decomposição, a resolução de frequência é duplicada por meio de filtragem e a resolução de tempo é reduzida pela metade pela redução da amostragem.

A função de dilatação da DWT pode ser representada como uma árvore de filtros passa-baixa e alta, com cada passo de transformação do filtro passa-baixa, como apresentado na Figura 3.4.




Figura 3.4 - Banco de filtros e árvore de filtros com decomposição em três níveis. Fonte: NÓBREGA, 2015.

Observando a figura 3.4 o sinal S originalmente discreto é decomposto no primeiro nível em duas componentes, por um filtro passa-baixa e um passa-alta, respectivamente. O A_1 , é chamado de aproximação do sinal e D_1 , é chamado de detalhe do sinal. Para o segundo nível, a aproximação é agora decomposta em uma nova aproximação, A_2 , e um detalhe D_2 . Este procedimento pode ser repetido para o terceiro nível, quarto, até um nível n qualquer. O sinal original é uma composição de todos os detalhes e a aproximação número n .

Um exemplo de AWM aplicado no sinal sonoro do motor pode ser observado na figura 3.5.




Figura 3.5 - Princípio da decomposição de um sinal via análise multiresolução: Sinal original, e decomposição do sinal original em suas componentes de aproximação e detalhe em três níveis. Fonte: Autor.

Os coeficientes de detalhe e aproximação obtidos durante o processo de decomposição, pode ser utilizado novamente para se obter o sinal original. Esse processo é conhecido como reconstrução e consiste no processo inverso ao efetuado na decomposição. Ou seja, os coeficientes de A e D, irão ser sobreamostrados e, na sequência, convoluídos com filtros de reconstrução passa-baixa e alta, obtendo-se sinais com o mesmo tamanho do original (ALVES, 2017).

Na Figura 3.6 a decomposição em quatro níveis de um sinal amostrado com frequência de 5kHz e as respectivas concentrações de frequência para cada parte decomposta do sinal. Nota-se que a decomposição é efetuada sempre pelo coeficiente de aproximação, que se dividirá novamente em aproximação e detalhe.




Figura 3.6. Decomposição Wavelet com nível 4 e frequência de amostragem igual à 5 kHz. Fonte: Adaptado ALVES, 2017.

O pré-processamento dos dados a serem usados como entradas da rede através da AWM pode tornar o treinamento da rede neural mais eficiente devido a uma redução significativa da dimensionalidade dos dados de entrada (YANG, 2002).

3.5 Redes Neurais

A inteligência artificial vem sendo uma alternativa para detecção de falhas em processos industriais nos últimos anos, diante dos métodos de detecção e diagnóstico de falhas propostos atualmente, a dimensão dos dados e o tempo de processamento para um diagnóstico final é uma dificuldade encontrada. Sendo assim, as Redes Neurais Artificiais (RNA) se tornam uma boa solução.

As redes neurais artificiais são inspiradas em processos biológicos, buscando realizar, de forma análoga, as mais elementares funções do neurônio humano. O tema ganhou força na pesquisa nos anos 90, e desde então, as suas diversas aplicações que se destacam são: reconhecimento de padrões, categorização (clustering), aproximação de funções, estimação e prevenção de situações futuras e em controle de processos. Mas

especificamente, as características mais atrativas das redes neurais artificiais, tornando essa ferramenta poderosa, consiste da sua elevada habilidade em mapear sistemas não-lineares, aprendendo os comportamentos envolvidos a partir de informações (medidas, amostras ou padrões) obtidas (SILVA *et al*, 2010).

HAYKIN (2000) define rede neural artificial como um processador paralelo distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimentalmente e torná-lo disponível para uso. São consideradas modelos computacionais inspirados no sistema nervoso dos seres vivos, pois possuem a capacidade de aquisição e manutenção do conhecimento. As RNAs são um conjunto de unidades de processamento, caracterizada por neurônios artificiais, interligados por diversas conexões, sendo representadas por vetores de pesos sinápticos.

Uma Rede Neural Artificial é normalmente implementada através de componentes eletrônicos ou é simulada por programação em um computador digital. Podem ser aplicadas em problemas de aproximação de funções, controle de processos, agrupamento de dados, classificação de padrões, identificação de sistemas dinâmicos, previsão de séries temporais e memórias associativas. Neste trabalho, ela será utilizada para classificação de padrões e diagnóstico de falhas em rolamentos de motores de indução trifásicos.

Para compreensão de uma RNA é necessário entender o funcionamento de um neurônio biológico, pois um neurônio artificial é uma unidade de processamento de informação importante para a operação de uma rede neural. O neurônio biológico tem como papel conduzir impulsos sob determinadas condições de operação. É constituído por três partes: dendritos, corpo celular e axônio. A função dos dendritos é capturar os estímulos, a do corpo celular é processar essas informações advindas dos dendritos a fim de produzir um potencial de ativação, por fim, a função do axônio é conduzir os impulsos elétricos para outros neurônios.

De acordo com HAYKIN (2000), algumas das justificativas para a utilização das RNAs são: sua característica intrínseca de não-linearidade, sua capacidade de generalização e adaptabilidade, a tolerância às falhas e a facilidade para realizar o mapeamento de relações entrada-saída.

As redes neurais identificam a presença de falhas em motores, através de sua configuração como o número de camadas, número de neurônio por camadas e definição das suas funções de ativação.

O processo de treinamento da RNA faz com que a mesma adquira conhecimento do projeto. As conexões entre os neurônios são realizadas através dos pesos sinápticos, e são utilizadas para armazenar o conhecimento adquirido, que através de um procedimento, chamado de algoritmo de aprendizagem, os pesos são modificados de modo que alcance uma saída, sem ou com o mínimo de erro do projeto desejado.

A Figura 3.7 apresenta o diagrama ilustrativo de um neurônio artificial proposto por Mcculloch e Pitts. Os sinais $X_1, X_2, X_3, \dots, X_n$ são os estímulos de entrada do neurônio advindos do meio externo, tais como sinais de medidas de sensores. As variáveis $W_1, W_2, W_3, \dots, W_n$ são valores que representam os pesos sinápticos e são empregados para ponderar cada uma das variáveis da rede, permitindo-se quantificar as relevâncias dos estímulos de entrada. O símbolo (Σ) efetua a agregação dos sinais ponderados de entrada, ou seja, desenvolve a combinação linear entre os vetores de entrada e os vetores de pesos sinápticos. O limiar de ativação (θ) especifica o patamar de ativação para que o resultado do combinador linear possa produzir um valor de disparo para outro neurônio na saída. O símbolo u representa o potencial de ativação e é o resultado da diferença entre o limiar de ativação (θ) e a agregação dos sinais de entradas ponderados produzido pelo combinador linear (Σ). A função $f(.)$ refere-se à função de ativação que desenvolve o valor de saída do neurônio, cujo objetivo é limitar a saída em um intervalo determinado ou efetuar o mapeamento não linear (HAYKIN, 2000).




Figura 3.7: Neurônio Artificial. Fonte: Autor

O potencial de ativação é definido por:

$$u = \sum_{i=1}^N w * x_i - \theta \quad (7)$$

A saída do neurônio y_{RNA} é calculada através da função de ativação, conforme:

$$y_{RNA} = f(u) \quad (8)$$

O funcionamento do neurônio artificial pode ser resumido por (SILVA, 2014):

- 1) Apresentação de um conjunto de valores de entrada $(x_1; x_2; \dots x_n)$, em que x_n é o número de entradas;
- 2) Multiplicação de cada entrada do neurônio pelo respectivo peso sináptico $(w_1; w_2; \dots w_n)$;
- 3) Obtenção do potencial de ativação, onde θ é o limiar de ativação;
- 4) Aplicação da função de ativação $(f(.))$;
- 5) Compilação da saída y_{RNA} .

As redes neurais apresentam diversos benefícios, dentre eles o da generalização no qual se refere à capacidade de a rede neural produzir saídas adequadas para entradas que não foram utilizadas no treinamento. A seguir serão apresentadas as principais funções de ativações.

3.5.1 Função de ativação

A função de ativação faz a transformação não-linear nos dados de entrada, tornando a rede capaz de aprender e executar tarefas mais complexas, logo, a função de ativação se torna um elemento extremamente importante das redes neurais artificiais, basicamente decidindo se um neurônio deve ser ativado ou não. Ou seja, se a informação que o neurônio está recebendo é importante para a informação fornecida ou deve ser ignorada.

As principais funções de ativação das RNAs são do tipo linear, degrau e sigmoidal (HAYKIN, 2000).

Normalmente o estado de ativação dos neurônios podem assumir valores binários (0,1), valores bipolares (-1,1) e valores reais. E são escolhidas em função da necessidade do problema que a rede esteja resolvendo.

As funções sigmoides são funções contínuas e diferenciáveis ao longo de todo seu domínio e podem ser:

- Tangente hiperbólica assumindo valores entre -1 e 1
- Logísticas assumindo valores entre 0 e 1


Conforme:

$$f_{tanh}(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (9)$$

$$f_{logsig}(u) = \frac{1}{1 + e^{-\beta u}} \quad (10)$$

Onde β é o parâmetro de inclinação.

Tais funções de ativação são caracterizadas por não serem diferenciáveis em todo seu domínio e, normalmente, são empregadas para aplicações de classificação de padrões e processamento de uma RNA (SUETAKE, 2012). Na figura 3.8 podemos observar as funções.






Figura 3.8 – Principais funções de ativação. Fonte: Autor.

Como nesse trabalho será feito uma comparação com a RNA *Perceptron* Multicamadas e a Rede de Função de Base Radial (RBF) serão abordados os principais conceitos de ambas a seguir.

3.5.2 Rede *Perceptron* Multicamadas

Em 1989 foi demonstrado por HORNIK que a rede do tipo *Perceptron* Multicamadas (PMC) é capaz de aproximar qualquer função mensurável a qualquer grau de precisão desejado, em um sentido muito específico e satisfatório.

De acordo com SILVA *et al.* (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.

As redes PMC são uma arquitetura feedforward e consistem em pelo menos uma camada neural oculta e uma camada neural de saída. O processo de treinamento da rede é supervisionado e, geralmente, o algoritmo de aprendizado é a retropropagação baseada na técnica de gradiente descendente (SANTOS, 2013). No entanto, neste trabalho, o algoritmo de treinamento foi o Levenberg-Marquardt, que é baseado na otimização não linear de mínimos quadrados que acelera a convergência da rede.

A rede PMC aprende através do treinamento, que consiste em uma série de vetores de entrada e saída associados. No treinamento a rede é repetidamente apresentada aos dados de entrada e saída desejados, até que seus pesos sejam ajustados para que o mapeamento da entrada-saída desejado ocorra. Quando ocorre de uma saída da rede para um determinado valor de entrada ser diferente do esperado, durante o treinamento, um sinal de erro é gerado, sendo a diferença entre a saída desejada e a real. Durante o treinamento a magnitude desse erro é utilizado para determinar o ajuste para novos valores de pesos, dessa forma a aprendizagem é realizada modificando os pesos em iterações sucessivas, de forma que o erro seja minimizado, esse processo é conhecido como backpropagation. Uma vez treinada a PMC pode generalizar para novos dados de entrada ainda não visto.

GARDNER (1998) resume o algoritmo backpropagation em 7 etapas da seguinte forma:

- 1) Inicializar pesos de rede;
- 2) Apresentar o primeiro vetor de entrada, dos dados de treinamento, para a rede;
- 3) Propagar o vetor de entrada através da rede para obter uma saída;
- 4) Calcular um sinal de erro comparando a saída real com a saída desejada (alvo);
- 5) Propagar o sinal de erro de volta através da rede;
- 6) Ajuste dos pesos para minimizar o erro geral;
- 7) Repetir as etapas 2 a 7 com o próximo vetor de entrada, até que o erro geral seja satisfatoriamente pequeno.

A implementação do algoritmo acima é conhecida como treinamento on-line pelo qual os pesos da rede são adaptados após cada padrão ter sido apresentado. Mas esse algoritmo apresenta uma desvantagem pois tende a convergir muito lentamente, exigindo assim um alto esforço computacional. Uma solução é a aplicação do algoritmo Levenberg-Marquardt, o qual é um método de gradiente de segunda ordem, que utiliza a técnica de

otimização dos mínimos quadrados para modelos não-lineares, sendo incorporado no algoritmo backpropagation. (HAGAN e MENHAJ, 1994).

PMC é o tipo de RNA, capaz de modelar funções complexas, bom em ignorar entradas e ruídos irrelevantes, pode adaptar seus pesos e é fácil de usar.

A arquitetura dessa rede consiste em camada de entrada, camadas ocultas (pode ser mais de uma) e camada de saída como ilustra a figura 3.9.




Figura 3.9: Modelo de uma rede *Perceptron* Multicamadas. Fonte: Autor.

Nas camadas ocultas, algumas técnicas podem indicar uma estimativa para a quantidade ideal de neurônios em cada camada, assim como o número dessas camadas. As técnicas usuais para estas estimativas são baseadas em heurísticas, não permitindo assim a garantia de que a arquitetura escolhida seja aquela com melhor desempenho global (SUETAKE, 2012).

Foi realizado um levantamento de bibliografias que utilizaram a PMC para diagnóstico de falhas de MIT, e no trabalho de SILVA (2014) foi feita uma comparação entre a PMC, a Rede de Função de Base Radial (RBF) e mapas de Kohonen, utilizando o sinal de corrente do motor como entrada processado via AWM, como resultado a rede PMC apresentou melhor resultado no diagnóstico, em VITOR (2016) foi realizada a detecção de falha de curto circuito em estator utilizando a classificação através da RNA *Perceptron* multicamadas e a Rede de Função de Base Radial e concluiu que a rede PMC levou vantagem na maioria dos experimentos.

3.5.3 Rede de Função de Base Radial

Assim como as redes PMC, as Redes de Funções de Base Radial (RBF) podem ser empregadas em problemas que envolvem aproximação de funções e classificação de padrões. A rede RBF também pertence à arquitetura feedforward (SILVA, 2014).

A rede RBF é uma rede avançada com três camadas: uma camada de entrada, uma camada oculta e de saída e a principal diferença entre a PMC e a RBF é a função de ativação da camada oculta, na qual na primeira é sigmoide e na segunda é alterada por uma função Gaussiana.

A função radial de base mais utilizada é a função Gaussiana. Sua saída é determinada pela distância Euclidiana entre o centro e o vetor de entrada. Cada função requer um parâmetro vetorial - o centro, e um parâmetro escalar que define a largura da função radial. A última camada (camada de saída) transforma o espaço vetorial interno, implementando uma soma ponderada (processo linear) dos neurônios escondidos (BORS, 2001).

A função de ativação da camada oculta é uma função gaussiana definida na equação 11:

$$f(x) = e^{\left(-\frac{(x-c)^2}{2b^2}\right)} \quad (11)$$

Onde b e c são a largura e o centro da função gaussiana, respectivamente.

O treinamento da RBF é composto de duas fases. Na primeira é realizado o treinamento, onde ocorre os ajustes 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 *et al.*, 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 (SILVA, 2014).

Na entrada das RNAs criadas estará um vetor criado com os detalhes do sinal sonoro do motor gerados pela AWM, esses sinais apresentam características específicas para cada tipo de falha do motor, logo, como há um padrão pré-estabelecido no sinal sonoro do motor para os tipos de falhas, optou-se pela rede que apresenta um padrão (ou vetor) de saída desejado. Optou-se dessa forma pela rede *Perceptron* de Multicamadas e pela Rede de Função de Base Radial.

4. MATERIAIS E MÉTODOS

Nesse capítulo são descritos os métodos de sensoriamento utilizados no trabalho. Para validar a técnica apresentada foi utilizada uma bancada com diversos componentes com objetivo de aplicar diferentes configurações de falhas ao rolamento do motor de indução trifásico. Através da bancada será possível variar a carga imposta ao eixo.

4.1. Bancada de Teste

A bancada utilizada foi desenvolvida no laboratório do GPICEEMA, na UFPB. Na Figura 4.1 está ilustrada a bancada onde foram realizados os testes. A bancada consiste um motor de indução trifásico de 5 CV, acionado por partida direta; um gerador de corrente contínua (CC); um tacômetro para medida da velocidade de rotação do eixo; e um quadro de comando onde estão contidos o sistema de aquisição e o sistema de acionamento do motor de indução.

O eixo de rotação da bancada é basicamente composto pelos componentes acoplados: o motor de indução trifásico em teste (5), o mancal para apoio com dois rolamentos (4), o transdutor de torque (3), o gerador CC para aplicação da carga (2) e varivolt (1).

O gerador CC tem em seus terminais de armadura quatro resistências de 24 ohms ligadas em paralelo para dissipar a energia gerada com o movimento. O enrolamento de campo do gerador CC é alimentado através do varivolt (1) e em seus terminais foi instalada uma resistência de 50 ohms para impedir que a corrente de campo ultrapasse o seu valor nominal. Ao ser posto em movimento, a carga é imposta ao eixo do motor de indução aumentando a tensão no enrolamento de campo através do varivolt.



Figura 4.1 – Bancada para ensaios de torção em motores de indução trifásicos. Fonte: Autor.

4.2 Sistema de Acionamento

O circuito elétrico de acionamento do motor e do gerador estão no quadro de comando (Figura 4.3). O quadro contém disjuntores e contactores para proteção, seccionamento e acionamento do circuito. O quadro de comando conta ainda com espaço para o sistema de aquisição de dados de tensão e corrente elétrica.



Figura 4.2- Quadro de comando. Fonte: Autor.

4.3 Gerador CC

O gerador CC (Figura 4.3), modelo 132S, fabricante Varimot, potência nominal 7,5 CV, rotação nominal de 1800 rpm, da série BN, carcaça 132s, próprio para uso em frenagem eletromagnética, projetado para operar sob ventilação forçada através de acoplamento de motoventilador fechado e montado sobre o motor.

O gerador é utilizado para impor carga no motor de indução trifásico, que alimenta uma carga resistiva constante. A variação da potência é feita pela variação da excitação de campo usando de uma fonte de tensão alternada ajustável (varivolt). Dessa forma, a variação da excitação muda a tensão sobre os resistores que dissipam a potência recebida. Através da alteração da corrente de campo é possível obter uma carga controlável no eixo, permitindo que o motor varie sua potência mecânica em toda a faixa possível.



Figura 4.3 – Gerador de corrente contínua. Fonte: Autor.

Variando manualmente a tensão de alimentação por meio do Varivolt, aplica-se tensão aos enrolamentos de campo no gerador CC, que por sua vez, irá impor resistência à rotação dada pelo motor trifásico, aplicando assim um torque de frenagem a este. A energia gerada com o movimento é dissipada através de um banco de resistências formado por quatro resistências de $24\ \Omega$ e 2000 W ligadas em paralelo (Figura 4.4), conectadas aos terminais do gerador. Foi necessário a verificação da temperatura dos elementos resistivos para monitoramento, caso excedesse 200°C , a operação era temporariamente suspensa.



Figura 4.4 - Resistências aletadas acopladas à armadura. Fonte: Autor.

Para acionar o gerador CC é alimentada a bobina de campo com corrente contínua, gerando potência elétrica na armadura. O varivolt empregado é do tipo autotransformador monofásico cujo primário está conectado à rede elétrica e o secundário possui saída em níveis de tensão ajustáveis (Figura 4.5). Para ajustar o varivolt é realizada a variação do número de bobinas no enrolamento secundário, pois o autotransformador possui apenas um enrolamento.



Figura 4.5- Varivolt utilizado para variação da carga aplicada. Fonte: Autor.

O Varivolt fornece corrente alternada, e para excitação do gerador é necessário a conversão CA/CC, logo a corrente do varivolt passa por um circuito retificador que é composto por uma ponte de diodos e um filtro capacitivo, na figura 4.6 é observado o esquema elétrico. O controle da carga no eixo do motor é dado pelo controle do nível de tensão CC no campo do gerador. Uma resistência de $50\ \Omega$ e $600\ W$ foi colocada no circuito para limitar a corrente do campo, destacando que a corrente de campo do gerador não deve ultrapassar muito seu valor nominal.




Figura 4.6-Circuito elétrico de acionamento do gerador CC. Fonte: ADISSI, 2015.

4.4 Instrumentos de Medição

4.4.1 Torquímetro

Torquímetro é um instrumento de medição direta do torque no eixo girante. O aparelho selecionado para a bancada foi o torquímetro digital HBM T40B-200 (Figura 4.7), com acoplamento por flange, capacidade de torque nominal de 200Nm, precisão de 0,05% do fundo de escala, capacidade de medida de torque a rotações até 20.000 rpm. Utiliza uma antena circular para receber os dados da medição de torque do eixo, e possui duas formas de saída para ser ligado ao sistema de registro e análise dos dados. Sendo a primeira saída analógica um sinal de tensão, que possui uma faixa de -10V a 10V, variando de forma linear ao torque, e por fim a outra forma de saída possui um sinal de torque modulado em frequência, onde a frequência varia proporcionalmente ao torque aplicado, na faixa de 30kHz a 90Khz, sendo o valor de 60kHz equivalente a situação de torque igual a zero.



Figura 4.7 - Torquímetro digital HBM T40B. Fonte: HBM.

O torquímetro foi utilizado nos testes para medição da variação de carga, através desse sensor, foi possível controlar a carga aplicada. Para aquisição dos dados do torquímetro

foi utilizado o conversor analógico digital, modelo NI USB-6215 e possui 16 bits de resolução e pode trabalhar com uma taxa de amostragem de até 250 ksamples/s. Localizada no quadro de comando e conectado ao computador. Esse módulo oferece 16 entradas analógicas; quatro linhas de entrada digital; quatro linhas de saída digital; níveis programáveis de aquisição por canal, com tensões variando de $\pm 0,2$ V até ± 10 V e dois contadores ou timers.

4.4.2 Sistema de Aquisição de Som

O sensor para aquisição da emissão acústica produzida pelo motor foi desenvolvido por LIMA (2017) em seu trabalho de tese. É composto por uma placa modelo Arduino Due com uma frequência de amostragem de 44,1kHz, resolução de 16bits, esse modelo de Arduino possui um microcontrolador AT91SAM3X8E. O microfone é do modelo CMA-445PF-W com uma sensibilidade de 44dB e uma frequência sonora de 20Hz- 20kHz. Os arquivos gerados são armazenados no formato arquivo de som Wave. Pode ser observado na figura (4.8).




Figura 4.8 - Sensor de emissão sonora. Fonte: Autor.

4.5 Rolamento

Os rolamentos são compostos basicamente por anéis (internos e externos), elementos rolantes (esferas ou rolos) e a gaiola. Esse componente é considerado uma causa muito

comum nas falhas em máquinas rotativas. De fato, cerca de 90% dos rolamentos falham prematuramente. A falha prematura é geralmente resultado de condições operacionais inadequadas. Dentre as principais causas de falha precoce nos rolamentos destacam-se a contaminação por sujeira e água, sobrecarga do rolamento, falta de lubrificação e manuseio inadequado durante a montagem do mancal (BAILLIE e MATHEW, 1994). As principais falhas nos rolamentos ocorrem nas pistas interna e externa e nas esferas.

O processo de detecção da falha é geralmente realizado transformando o sinal de emissão sonora para o domínio da frequência. Existem várias razões pelas quais isso é feito. Em primeiro lugar, as falhas de máquinas são indicadas no espectro do sinal por picos em frequências características, já que cada componente ou falha emite uma vibração de frequência única, a intensidade da harmônica da característica fornece indicação da presença ou gravidade de tal falha.

De acordo com ARAÚJO (2011) cada elemento do rolamento, quando colocado em movimento, gera uma frequência própria. O princípio da análise no espectro do sinal sonoro consiste em detectar picos de harmônicas no espectro do sinal, diante a presença de falhas. Neste trabalho a falha analisada foi no rolamento na pista interna, externa e em ambas. Para cada falha, estará associada um conjunto de frequências no espectro, nas quais estão localizados os picos correspondentes.

A excitação e a resposta no espectro do sinal ocorrem cada vez que uma esfera rola sobre a falha na pista, se chocando com a mesma, de modo que a frequência fundamental das formas de onda de resposta é a taxa na qual os elementos rolam sobre a falha. É essa frequência que é de interesse na detecção de falhas nas pistas nos rolamentos e pode ser prevista a partir da geometria do elemento e das velocidades nas quais as pistas interna e externa se movimentam.

A AWM é realizada a partir da observação da variação do espectro de potência nos detalhes do sinal de som, de acordo com a falha que está sendo analisada, ou seja, quando uma falha acontece, ocorre uma mudança na distribuição do espectro de potência em relação ao sinal sonoro sem falha, que pode ser observada no domínio do tempo utilizando a análise AWM.

O rolamento utilizado nos testes foi da marca SKF, modelo 6206, com número de esferas (NB) igual a 9, diâmetro primitivo (Dc) de 46 mm, diâmetro da esfera (Db) de 9,525 mm, ângulo de contato da esfera (β) de 0°. Essas informações específicas sobre a construção do rolamento são necessárias para calcular as frequências características exatas dos defeitos.

As frequências de pista externa e interna são produzidas quando cada esfera passa por um defeito. Isso faz com que as frequências da pista externas e internas sejam definidas através da equação (12) (NÓBREGA, 2015).

Nessa frequência F_0 deverá aparecer o pico da falha que coincidirá com a frequência de rotação da pista externa. Ou seja, será a frequência em que uma esfera colide no ponto da falha.

$$F_0 = \frac{N_B}{2} F_R \left(1 - \frac{D_b \cos \beta}{D_c} \right) \quad (12)$$

F_0 = frequência de falha na pista externa;

N_B = número de elementos rolantes;

D_b = diâmetro da esfera

D_c = diâmetro primitivo

β = ângulo de contato com a esfera

F_r = frequência de rotação do motor;

Para falha na pista interna, a frequência onde o defeito será detectado é determinada pela equação (13) (NÓBREGA, 2015):

$$F_i = \frac{N_B}{2} F_R \left(1 + \frac{D_b \cos(\beta)}{D_c} \right) \quad (13)$$

Logo, com as equações (12 e 13) é possível conhecer as frequências esperadas para cada tipo de falhas nas pistas dos rolamentos, tornando-se possível avaliar o espectro da emissão sonora e determinar a existência de defeitos. Embora esta não seja uma falha realista do rolamento, um furo foi feito através das pistas do rolamento para simular a falha, a natureza dessas falhas produz frequências de rolamento que são isoladas para a pista externa e interna e são localizadas nos espectros de vibração sonora. Na Figura 4.9(a) está ilustrada a foto do rolamento utilizado nos testes e na 4.9(b) estão ilustradas as partes constituintes dele, que são pista interna, pista externa esfera e gaiola.




Figura 4.9 - Geometria dos elementos de um rolamento. Fonte: NÓBREGA, 2015.

Foram feitos furos nos rolamentos novos nas pistas externa e interna, para simular as falhas e ser detectada posteriormente. Os defeitos consistem em furos que foram perfurados com uma broca do tipo ponta montada como mostra a figura 4.10 e 4.11



Figura 4.10- broca do tipo ponta montada utilizada para perfuração dos furos nas pistas.

Fonte: Autor.



Figura 4.11 - Ilustra os furos nas pistas interna e externa (aproximadamente 5,8 mm de diâmetro). Fonte: Autor

4.6 Metodologia para Análise da Falha

O processo de detecção da falha no rolamento começa a partir da aquisição da emissão sonora pelo microfone. Após adquirido, o sinal sonoro é processado de forma off-line no software Matlab® através da AWM para determinação das aproximações e detalhes. Após é calculado o espectro e potência de cada detalhe gerado pela AWM.

Com o espectro de potência desses detalhes é criado um vetor que é imposto como entrada da RNA já treinada, dessa forma o software realiza a detecção e o diagnóstico do rolamento, o procedimento pode ser observado na figura 4.12.




Figura 4.12 - Diagrama do processo de diagnóstico de falha. Fonte: Autor.

4.7 Caracterização da Falha na Decomposição Wavelet

Como apresentado no capítulo 3 a decomposição de um sinal com a AWM, traz informações preciosas a respeito do seu comportamento em alta e baixa frequência. As falhas

presentes nos rolamentos geram determinadas características nos detalhes, formando assim uma assinatura correspondente a cada falha.

Para caracterizar a falha foi calculado o espectro de potência dos detalhes Wavelets de acordo com a equação 14 (LIU *et al*, 2007):

$$E = 2^{-j} \sum_n (W_{j,n})^2 \quad (14)$$

Onde j é o nível do detalhe e $W_{j,n}$ são n coeficientes do detalhe j .

Na figura 4.13 é possível perceber de forma visual como cada configuração do rolamento do motor possui um comportamento diferente para a distribuição do espectro de potência Wavelet de cada detalhe.




Figura 4.13. Espectro de potência Wavelet de cada detalhe do sinal sonoro do motor com carga aplicada de 100% para rolamento saudável, falha na pista externa, falhas na pista interna e falha na pista externa e interna. Fonte: Autor.

Nesse trabalho a frequência de amostragem foi de 44,1KHz e a correspondência dos detalhes em relação a frequência é apresentada na tabela 4.1.

Tabela 4.1 – Correspondência entre detalhe e faixa de frequência. Fonte: Autor.

Detalhe	Faixa de Frequência
D1	44KHz - 22KHz
D2	22KHz - 11KHz
D3	11KHz - 5,5KHz
D4	5,5KHz - 2,75KHz
D5	2,75KHz - 1,375KHz
D6	1375Hz - 687,5Hz
D7	687,5Hz - 343,75Hz
D8	343,75Hz - 343,75Hz
D9	171,875Hz - 85,93Hz
D10	85,93Hz - 42,96Hz
D11	42,96Hz - 21,48Hz

4.8 Descrição da Metodologia para Detecção e Diagnóstico de Falha

Esse trabalho de tese propõe o desenvolvimento de duas arquiteturas de Redes Neurais Artificiais (RNA), a *Perceptron* Multicamadas (PMC) e a Rede de função de base Radial (RBF), baseada em treinamento com dados de emissão sonora do motor para detectar e diagnosticar possíveis falhas em rolamentos de motores de indução trifásicos. Uma estrutura genérica proposta do sistema inteligente de identificação é representada pela figura 4.14.




Figura 4.14- Sistema inteligente de identificação rolamentos defeituosos de MITs. Fonte: Autor.

A primeira etapa do sistema consiste na aquisição da emissão sonora produzida pelo motor, essa aquisição foi realizada com o microfone com uma frequência de amostragem de 44,1kHz. O sinal captado pelo microfone é submetido a uma Análise Wavelet Multiresolução (AWM), na qual é calculado o espectro de potência (equação 14) de determinados detalhes e da aproximação. O espectro de potência dos detalhes é usado como entrada de uma RNA, que a partir de treinamento conseguirá realizar a detecção e diagnóstico para rolamento saudável e para diferentes tipos de falhas. O sistema neural de identificação do tipo PMC e RBF é dimensionado em termos de número de camadas neurais e de quantidade de neurônios por camada, de modo a efetuar a detecção e diagnóstico dos rolamentos defeituosos. A proposta desse estudo consiste em desenvolver uma RNA especializada para processar as informações de entrada visando estimar se o rolamento opera sob condições normais ou de falhas.

A base de dados para modelagem do sistema de identificação da falha via rede neural proposta será composta por motor em partida direta considerando também uma faixa de torque aplicado. O conjunto de aquisições será dividido em conjunto de treinamento, validação e testes.

5. RESULTADOS EXPERIMENTAIS

Neste capítulo serão apresentados e discutidos os resultados obtidos com a metodologia desenvolvida para análise das falhas simuladas em rolamentos dos motores de indução trifásicos utilizando RNA via emissão sonora.

As falhas no rolamento do MIT serão investigadas, para um acionamento do motor em partida direta, essas falhas foram na pista interna, na pista externa e em ambas as pistas do rolamento. Os ensaios foram feitos com o motor sem carga, com uma carga de média (50%) e alta (100%). O ambiente escolhido para o algoritmo de detecção da falha foi o Matlab. Para este trabalho foi escolhido um motor de indução trifásico bastante comum no mercado e que possui as seguintes características:

Tabela 5.1 – Dados de placa do motor. Fonte: WEG.

Motor WEG 22plus	
Potência	5 CV
Tensão de Trabalho	380V
Velocidade nominal	1725rpm
Frequência	60Hz
Fator de potência	0,78
Corrente	8,19A

O processo de detecção de falha é feito de forma off-line. Os dados da emissão sonora foram coletados por meio do microfone. O sinal coletado no domínio do tempo é submetido à FFT e à AWM, analisando assim o espectro para serem selecionados os melhores dados para entrada da RNA. Quanto a carga imposta ao motor, foram considerados dois tipos de acionamentos: motor em vazio e com carga, sendo a carga medida da seguinte forma:

Tabela 5.2 – Carga de Acionamento da máquina. Fonte Autor.


Motor	Situação
Sem Carga	Motor funcionando de com estrutura de acoplamento – 0% carga
Carga Média	Motor funcionando de com estrutura de acoplamento – 50% carga
Carga Alta	Motor funcionando de com estrutura de acoplamento – 100% carga

As frequências características no espectro da FFT de cada falha obtidas através das equações 12,13 podem ser observadas na tabela 5.3 abaixo.

Tabela 5.3 – Frequência Característica das Falhas. Fonte: Autor.

Tipo de falha	Frequência
Pista Externa	107,04Hz
Pista Interna	162,95Hz

Durante os testes, a frequência de vibração sonora característica e seus múltiplos eram claramente visíveis no espectro da emissão sonora do motor.






Figura 5.1 - Espectro do sinal de emissão acústico: a) Motor com o rolamento saudável com acoplamento; b) Motor com rolamento com defeito na pista externa com acoplamento; c) Motor com rolamento com defeito na pista interna com acoplamento. Fonte: Autor

Como é observado na figura 5.1 nos espectros de frequência do sinal sonoro adquirido, as harmônicas características das falhas aparecem nas frequências determinadas

destacadas nos gráficos, porém outros picos também aparecem no sinal, dificultando assim a detecção da falha.

Diante dessa dificuldade encontrada utilizando a FFT, buscou-se uma abordagem usando Análise Wavelet Multiresolução (AWM) para ser utilizada no processamento do sinal para diagnóstico da falha. Para isso é calculado o espectro de potência de cada detalhe. Na figura 5.2 nota-se a mudança do espectro de potência para o rolamento saudável e as falhas nas pistas.




Figura 5.2 - a) Espectro de potência dos detalhes 1 ao 11 para as três cargas aplicadas, para um rolamento saudável (Sau), falha na pista externa (Ext), falha na pista interna (Int) e falha em ambas as pistas (Ext/Int). Fonte: Autor.

Após feito uma análise dos diversos parâmetros obtidos dos detalhes (curtose, energia, densidade e potência) o espectro de potência foi o mais representativo das falhas no rolamento do motor. A figura 5.2 representa os detalhes do espectro de potência do sinal de emissão sonora. Do detalhe 1 ao 11, para o motor saudável, com falha na pista externa e falha na pista interna e em ambas as pistas, todos os ensaios foram realizados variando a carga em 0%, 50% e 100%. Como observado no gráfico dos detalhes no espectro de potência, cada situação de falha do rolamento apresenta uma característica, em algumas variações de carga os valores do espectro de potência dos detalhes se cruzam, ocorrendo pontos de interseção entre os tipos de falhas, sendo assim é necessário um método classificador para


detectar a falha, logo justifica-se o uso da RNA que será treinada para detectar e diagnosticar a falha do motor.



Na tabela 5.4 foi feito uma comparação entre a média do espectro de potência dos detalhes 4 e 5 dos sinais de emissão sonora adquiridos nos ensaios, onde PE é pista externa, PI é pista interna e PEI é pista interna e externa.

Tabela 5.4- Média do espectro de potência para os detalhes 4 e 5. Fonte: Autor

Detalhes	Saudável	PE	PI	PEI
D4	4783,63	2264,66	2203,90	2615,56
D5	1958,53	1220,50	2352,01	2087,82

Como observado a evolução do espectro de potência dos detalhes, cada estado do rolamento apresenta uma assinatura do espectro de potência característico. Uma análise importante se baseia na constância que essa característica tem nos detalhes para várias aquisições realizadas. Como pode ser observado na figura 5.3, 5.4 e 5.5.











Figura 5.3- Espectro de potência dos detalhes para um rolamento saudável, com falha na pista externa, na pista interna e na pista externa e interna juntas sem carga, para três ensaios feito no motor com aquisições da emissão sonora. Fonte: Autor.











Figura 5.4- Espectro de potência dos detalhes para um rolamento saudável, com falha na pista externa, na pista interna e na pista externa e interna juntas com carga média (50%), para três ensaios feito no motor com aquisições da emissão sonora. Fonte: Autor.








Figura 5.5- Espectro de potência dos detalhes para um rolamento saudável, com falha na pista externa, na pista interna e na pista externa e interna juntas com carga alta (100%) para três ensaios feito no motor com aquisições da emissão sonora. Fonte: Autor.

Com esses gráficos apresentados pode-se concluir que os espectros de potência dos detalhes são constantes para dados de aquisições diferentes, implicando assim em uma assinatura, implicando em um possível sucesso na análise de diagnóstico com rede neurais, logo foram usadas como entradas da Rede Neural e utilizadas para realizar o treinamento dessa rede.

Perante todos os trabalhos apresentadas nos Capítulos anteriores, verifica-se que as redes PMC e RBF proporcionam resultados satisfatórios para diversas situações de detecção de falhas às quais foram aplicadas. Sendo, portanto, as redes escolhidas para realizar a classificação de padrões de rolamentos defeituosos.

Na criação da topologia de uma RNA existem diversos parâmetros a serem ajustados para um bom desempenho, portanto a escolha da topologia mais adequada é feita de forma empírica. Uma forma para definir a melhor topologia consiste em aplicar o algoritmo de treinamento em um conjunto de topologias pré-escolhidas. Finalizada a fase de treinamento para cada rede, avalia-se o potencial de generalização aplicando-se os subconjuntos de validação em cada topologia candidata, e, com isso, seleciona-se aquela que obtiver o melhor desempenho (VITOR,2015).

A classificação dos sinais é dividida em duas etapas. Na primeira realizou a separação das amostras em 3 classes: rolamentos saudáveis, rolamento com falha na pista externa e rolamento com falha na pista interna, criando assim uma rede do tipo PMC. Nessa análise o vetor de entrada era composto pelos detalhes D4 e D5 gerados pela AWM. Na segunda etapa foi inserido mais um tipo de falha na metodologia, além das já citadas na primeira etapa, a falha na pista externa e interna (em um único rolamento) foi inserida, ficando assim os dados em 4 classificações, para essa etapa foram criadas uma rede PMC e uma RBF a fins de comparação. As seções a seguir, apresentam os resultados obtidos em cada uma dessas etapas.

5.1. Resultados da PMC para dois tipos de falhas

Como já apresentado a análise dos detalhes do espectro de potência dos sinais sonoros, e concluído que os detalhes D4 e D5 para cada situação do motor eram os mais representativos das características, foi criado o vetor de entrada da RNA com esses dois detalhes, que continham dados do motor saudável, falha na pista externa e falha na pista interna, como apresentado na figura 5.6. Os conjuntos utilizados no vetor de entrada dos detalhes do rolamento saudável, rolamento falha na pista externa e rolamento falha na pista interna continham informações do motor sem carga, com carga média e com carga alta. A rede apresenta duas entradas (D4 e D5) e 3 saídas: motor saudável, falha na pista interna e falha na pista externa. A RNA é do tipo PMC e foi criada 2 topologias variando o número de neurônio da camada oculta, ambas têm como algoritmo de treinamento Levenberg Maquardt, função de ativação adotada foi a tangente hiperbólica, uma vez que esta contribui para melhorar o processo de convergência da rede pelo fato de ser uma função ímpar, e a função do neurônio camada de saída é linear.

O vetor de entrada é composto pelos detalhes D4 e D5 do espectro de potência do motor sem carga, com carga de 50% e com 100% da carga (figura 5.6). O intuito de misturar os dados de cargas diferente no vetor de entrada é que a rede tenha sucesso para detectar falhas nos rolamentos de MITs com variação de carga em sua operação.

A classificação da existência ou não de falhas nos sinais foi possível através de lógica combinacional. A Tabela 5.5 apresenta as possíveis saídas da rede para a etapa de

classificação em três padrões, onde Y1, Y2 e Y3 são as possíveis saídas da rede, de acordo com a situação de falha ou não que o rolamento se encontra.

Tabela 5.5: Criação do vetor de Saída da RNA. Fonte: Autor.

Situação do rolamento	Saída da RNA		
	Y_1	Y_2	Y_3
Sem falha	1	0	0
Falha pista externa	0	1	0
Falha pista interna	0	0	1

$$X = \left[\begin{array}{ccc|ccc|ccc} D_4^1 & D_4^2 & D_4^{119} & D_4^1 & D_4^2 & D_4^{119} & D_4^1 & D_4^2 & D_4^{119} \\ D_5^1 & D_5^2 & \dots & D_5^1 & D_5^2 & \dots & D_5^1 & D_5^2 & \dots & D_5^{119} \end{array} \right]$$

$\longleftrightarrow$ Detalhes sem falha $\longleftrightarrow$ Detalhes falha pista externa $\longleftrightarrow$ Detalhes falha pista interna

Figura 5.6 – Vetor de entrada utilizado para treinamento, validação e testes da rede. Fonte: Autor.

$$T = \left[\begin{array}{ccc|ccc|ccc} 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & \dots & 0 & 1 & 1 & \dots & 1 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 \end{array} \right]$$

$\longleftrightarrow$ Saída sem falha $\longleftrightarrow$ Saída falha pista externa $\longleftrightarrow$ Saída falha pista interna

Figura 5.7 – Vetor de saída utilizado para treinamento, validação e testes da rede. Fonte: Autor.

No treinamento o vetor de entrada e suas respectivas saídas (figura 5.7) são apresentadas para a rede, como é um treinamento supervisionado, os pesos são ajustados a cada interação a fim de ajustar os erros gerados entre a entrada e saídas desejadas. Os

hiperplanos de separação da rede PMC tendem a se mover continuamente durante esse processo de ajuste dos pesos, até que ocorra a separação das 3 classes.

Foram utilizadas no treinamento 357 amostras de dados, das quais 119 do motor saudável, 119 do motor com rolamento com falha pista externa e 119 com rolamento com falha na pista interna. Desse total, 250 amostras foram utilizadas para treinamento, 53 para validação e 54 para teste. É necessário atribuir valores para a saída desejada das redes, no caso “0” e “1”. Dessa forma, T representa as saídas desejadas para fase de treinamento e validação, de acordo com a Figura 5.7.

As duas topologias que foram escolhidas para análise variavam a quantidade de neurônios na camada oculta, uma é composta por 3 e a outra por 4 neurônios.

A rede com 3 neurônios na camada oculta teve 30 épocas e a matriz de confusão na figura 5.8.a já a rede com 4 neurônios na camada oculta a rede teve 17 épocas, e a matriz de confusão 5.8.b apresenta o desempenho da rede em cada etapa: treinamento, validação e teste. Observa-se que a rede obteve 100% de acerto para todas as classes, no treinamento, teste e validação, para a segunda topologia.




Figura 5.8 – Matrix de Confusão da RNA para 3 classificações (a) 3 neurônios na camada oculta; (b) 4 neurônios na camada oculta. Fonte: Autor.

O treinamento da Rede foi realizado no software MATLAB ao longo de 17 interações (épocas) como observado na figura 5.9 para a rede com 4 neurônios na camada oculta. O

desempenho da rede se aprimora a cada época. O conjunto de dados foi dividido em três conjuntos, são eles: conjunto de treinamento, validação e teste, efetuando-se assim o procedimento de parada antecipada (early stopping). Na figura 5.9 nota-se que o erro médio quadrático do treinamento, teste e validação vai decaindo à medida que as épocas vão passando. Desta forma, na RNA o critério de parada antecipada é utilizado junto com as configurações dos parâmetros livres da RNA (pesos sinápticos e limiares) de 17 épocas, assumindo-se que a rede não estará sobre-ajustada e apresentará uma melhor capacidade de generalização.




Figura 5.9 - Desempenho da rede a cada interação (época), o gráfico representa os erros médios quadráticos (MSE) dos conjuntos de treinamento, validação e testes. Fonte: Autor.

A capacidade de generalização de uma rede de acordo com HAYKIN (2001) se refere ao fato da mesma, poder produzir saídas adequadas para entradas que não estavam presentes durante o treinamento. Dessa forma após o treinamento da rede com o intuito de explorar ainda mais sua potencialidade foi realizado simulações com outros arquivos adquiridos na bancada, ou seja, dados originados de ensaios distintos dos utilizados no treinamento, os vetores criados para simulação tinham 119 elementos e dois detalhes D4 e D5, e foram criados 3 vetores (119x2) com dados coletados para cada possível classificação do motor. O vetor entrada 1 com características do rolamento saudável sem carga, com 50% de carga e 100% de carga, o vetor entrada 2 com características do rolamento com falha na pista externa

sem carga, com 50% de carga e 100% de carga e o vetor entrada 3 com características do rolamento com falha na pista interna sem carga, com 50% de carga e 100% de carga. Após a criação dos vetores foi realizada a simulação na rede, tendo como resultado apresentado na tabela 5.6.

Tabela 5.6- Resultado de simulação para Rede PMC para 3 classificações. Fonte: Autor.

Neurônios na camada oculta	SAUDÁVEL	PE	PI
3 neurônios	100%	94,1%	100%
4 neurônios	100%	100%	100%

PE: falha na pista externa

PI: falha na pista interna

Os resultados do desempenho da rede são descritos em taxas de acertos na tabela 5.6, mostram que a RNA para detecção de falhas em rolamentos foi capaz de mapear o limiar de classificação das falhas e generalizar a regra para dados que não foram utilizados no treinamento. Observa-se que a RNA foi capaz de diagnosticar rolamentos com falhas adequadamente tanto com os dados de treinamento quanto com os dados de testes. A rede com 3 neurônios teve 94,1% de acerto no caso de falha na pista externa e a rede com 4 neurônios teve 100% de acerto em todos os casos.

5.2. Resultados da PMC e RBF para três tipos de falhas

Nessa etapa foram criadas duas arquiteturas de RNA, a PMC e a RBF. A arquitetura da rede PMC constitui em 20 neurônios na camada oculta, com o algoritmo de treinamento Levenberg Maquardt, como função de ativação foi adotada a tangente hiperbólica.

A rede RBF desenvolvida gera uma rede neural de regressão generalizadas que é um tipo de rede de base radial, frequentemente usada para aproximação de funções. A configuração dessa rede é bem simples, é ajustado o valor do *spread*, o valor utilizado foi de 1. Quanto maior o *spread*, mais suave a aproximação da função. No entanto, como a dispersão dos neurônios de base radial é muito baixa, a rede requer muitos neurônios. A rede RBF continha 476 neurônios na sua camada.

No treinamento foram utilizadas 476 amostras de dados, das quais 119 do motor saudável sem carga, com carga 50% e carga de 100%, 119 do motor com rolamento com

falha pista externa sem carga, com carga 50% e carga de 100%, 119 com rolamento com falha na pista interna sem carga, com carga 50% e carga de 100%, e 119 com falha em ambas as pistas sem carga, com carga 50% e carga de 100%. No treinamento da rede PMC desse total, 333 amostras foram utilizadas para treinamento, 71 para validação e 72 para teste. Essas amostras foram selecionadas de forma randômica.

A análise feita das redes PMC e RBF, foi realizada da seguinte forma: avaliar o desempenho das redes para uma variação de quantidades de detalhes utilizados no vetor de entrada, para isso foi criado vetores de entrada com dimensões como segue na tabela 5.7, em seguida foi treinada uma rede com esses vetores de entrada variando a quantidade de detalhes de 2 a 11. Pode ser observado um exemplo de vetor na figura 5.10.

Tabela 5.7 – Vetores de entrada para treinamento das redes PMC e RBF. Fonte: Autor.

Vetor de entrada	Dimensão
Vetor com 11 detalhes	476x11
Vetor com 10 detalhes	476x10
Vetor com 9 detalhes	476x9
Vetor com 8 detalhes	476x8
Vetor com 7 detalhes	476x7
Vetor com 6 detalhes	476x6
Vetor com 5 detalhes	476x5
Vetor com 4 detalhes	476x4
Vetor com 3 detalhes	476x3
Vetor com 2 detalhes	476x2




Figura 5.10: Modelo de Vetor de Entrada para dois Detalhes gerados pela AWM do sinal sonoro. Fonte: Autor.

Como saída desejada na rede foi criado o vetor da figura 5.11.

$$T = \begin{bmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \dots & 0 & 1 & 1 & 1 & \dots & 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix}$$

$\longleftrightarrow$
 Detalhes
sem Falha

$\longleftrightarrow$
 Detalhes falha
pista externa

$\longleftrightarrow$
 Detalhes falha
pista interna

$\longleftrightarrow$
 Detalhe falha
pista ext/int

Figura 5.11- Vetor de saída desejado para treinamento da Rede PMC e RBF. Fonte: Autor.




Figura 5.12- Performance da rede PMC para treinamento com o vetor de entrada composto por 11 detalhes. Fonte: Autor.

A Rede PMC teve 27 épocas, a cada época em relação ao conjunto de treinamento a rede vai tendo um melhor desempenho.

A tabela 5.8 mostra o percentual de acerto das redes para falha no rolamento na pista externa, interna e externa e interna juntas. Essa tabela foi gerada com dados totalmente distintos dos dados utilizados no treinamento, para análise da generalização da rede.

Foi feita uma variação na quantidade de detalhes do espectro de potência utilizados como entrada, para avaliar a quantidade mínima de detalhes que a rede apresenta um bom desempenho. A variação dos detalhes foi de 2 detalhes até 11 detalhes para entrada da rede. Lembrando que para cálculo do detalhe D2 o software calcula o D1, para o D3 é calculado o D1 e D2 e assim sucessivamente, diante disso é avaliado o esforço computacional, para gerar os detalhes.

Na tabela 5.8 Desempenho da rede PMC e RBF para diferentes quantidades de detalhes. Fonte: Autor.

Número de detalhes no vetor de entrada	PMC				RBF			
	SAUDÁVEL	PE	PI	PEI	SAUDÁVEL	PE	PI	PEI
2	84%	78,20%	100%	47,10%	76,5%	74,8%	100%	42,9%
3	91,60%	78,20%	100%	66,40%	84%	76,50%	100%	48,7%
4	98,30%	68,10%	100%	95%	96,6%	67,20%	100%	79%
5	99,20%	72,30%	100%	97,50%	99,2%	67,2%	100%	94,1%
6	100%	89,10%	100%	97,50%	99,2%	67,2%	100%	94,1%
7	100%	69,70%	100%	95%	99,2%	67,2%	100%	94,1%
8	95,8	85,70%	100%	97,50%	99,2%	67,2%	100%	94,1%
9	99,20%	93,30%	100%	99,20%	99,2%	67,2%	100%	94,1%
10	83,20%	66,40%	100%	97,50%	99,2%	67,2%	100%	94,1%
11	92,40%	85,70%	100%	97,50%	99,2%	67,2%	100%	94,1%

Onde

PE: falha na pista externa;

PI: falha na pista interna;

PEI: falha na pista externa e interna.

Como observado, a rede RBF tem um resultado constante até a utilização de 6 detalhes, a partir disso ocorre uma queda no percentual de acerto da rede. Já a rede PMC apresenta pouca variação em virtude da quantidade de detalhes, e com 6 detalhes apresentou

melhor resultado quando comparada com a RBF. É importante destacar que quanto maior o número de detalhes, maior será o esforço computacional.

Outro resultado interessante para se destacar é que ambas as redes obtiveram um índice de 100% de acerto para o rolamento com falha na pista interna.

Os resultados apontam que o sistema neural de classificação de falhas em rolamentos foi capaz de mapear o limiar de classificação das falhas e generalizar a regra.

Se for pensar em aplicação em sistema embarcado é interessante avaliar a quantidade de detalhes utilizados na rede levando em consideração as limitações de memória e processamento impostas pelo sistema.

6. CONCLUSÕES

Neste trabalho foram apresentados os resultados da análise do método de detecção e diagnóstico de falhas nos rolamentos dos motores de indução trifásicos via emissão sonora através da criação de uma Redes Neurais Artificiais (RNA). Os experimentos do projeto foram realizados de forma *off-line*, fazendo o uso de um microfone com placa de aquisição e armazenamento para medir a emissão sonora e um posterior tratamento dos dados. Foram analisados rolamentos com falha na pista interna, na pista externa e em ambas as pistas.

Para as falhas foram realizados acionamento do MIT com partida direta e variação da carga. O processamento do sinal sonoro foi realizado utilizando a Análise Wavelet Multiresoluções (AWM) gerando assim funções chamadas de aproximação e detalhes da Wavelet, no qual foi calculado o espectro de potência e dessa forma notou-se uma assinatura característica do sinal para cada tipo de falha no rolamento. E, principalmente, uma constância nesses dados, fundamental para treinamento da rede neural. Os espectros de potência dos detalhes foram utilizados como entrada de RNA. Foi criada duas topologias diferentes de rede para comparação do tipo: PMC e RBF.

A classificação das amostras foi dividida em duas etapas: na primeira foi analisado a classificação do rolamento do MIT saudável, com falha na pista externa e falha na pista interna, com a rede do tipo PMC. Na segunda etapa foi analisado a classificação do rolamento saudável, com falha na pista interna, falha na pista externa e falha em ambas as pistas. Para esse caso foi criada duas topologias de redes a PMC e a RBF. Após treinada calculou-se a eficiência dos métodos para a identificação correta do tipo de falha. Esse cálculo foi obtido pelos percentuais de acerto das classificações. Para primeira etapa a PMC com 4 neurônios na camada oculta apresentou 100% de acerto na detecção e na segunda etapa, o melhor resultado foi apresentado utilizando 6 detalhes no vetor de entrada para rede PMC levando em consideração o esforço computacional no processamento do sinal via AWM.

Esse trabalho usa uma metodologia que apresentou resultados satisfatórios nas etapas de detecção e diagnóstico das falhas impostas nos rolamentos. Os testes foram realizados considerando topologias de redes neurais classificadoras.

A metodologia proposta para detecção e diagnóstico 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 e processamento impostas pelo sistema. Os treinamentos das redes neurais foram realizados de maneira offline, a etapa de teste considera as matrizes de pesos sinápticos obtidas nos treinamentos e 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.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDULLAH, M.; AL-GHAMD; DAVID MBA, 2006. "A Comparative Experimental Study on the use of Acoustic Emission and Vibration Analysis for Bearing Defect Identification and Estimation of Defect Size". Mechanical Systems and Signal Processing, Vol. 20, pp. 1537 – 1571.

ADISSI M. O., 2015. " Sistema de Monitoramento da Eficiência Energética em Motores Elétricos na Indústria". Tese- Doutorado. UFPB/CT, Programa de pós-graduação em Engenharia Mecânica, João Pessoa- PB.

AHAMED, S.K.; KARMAKAR, S.; MITRA, M.; SENGUPTA, S., 2010. "Novel Diagnosis Technique of Mass Unbalance in Rotor of Induction Motor by the Analysis of Motor Starting Current at No Load Through Wavelet Transform". 6th International Conference on Electrical and Computer Engineering, pp. 474 – 477.

ALI J.B., FNAIECH N., SAIDI L., CHEBEL-MORELLO B., FNAIECH F., 2015. "Application Of Empirical Mode Decomposition And Artificial Neural Network For Automatic Bearing Fault Diagnosis Based On Vibration Signals" Appl. Acoust., 89 (2015), pp. 16-27.

ALVES D. A., 2017. " Técnicas De Detecção De Falhas Em Barras Do Rotor Nos Motores De Indução Trifásicos". Programa De Pós-Graduação Em Engenharia Elétrica – PPGEL, UFSJ, São João del-Rei, MG.

ARAÚJO, R. de., 2011. "Desgaste Prematuro E Falhas Recorrentes Em Rolamentos De Motores". Dissertação de Mestrado. CPDEE - Centro de Pesquisa e Desenvolvimento em Engenharia Elétrica. Belo Horizonte. Universidade Federal de Minas Gerais.

BAILLIE, D., & MATHEW, J., 1994. "Diagnosing Rolling Element Bearing Faults With Artificial Neural Networks". Australian Acoustic Society, volume 22 nº3 .

BALLAL M., KHAN Z., SURYAWANSHI H., SONOLIKAR R., 2006. "Induction motor: fuzzy system for the detection of winding insulation condition and bearing wear". *Electr Power Compon Syst* 34(2):159–171.

BALLAL M.S., KHAN Z.J., SURYAWANSHI H.M., SONOLIKAR R.L., 2007. "Adaptive neural fuzzy inference system for the detection of inter-turn insulation and bearing wear faults in induction motor". *IEEE Trans Ind Electron* 54(1):250–258

BENBOUZID M, NEJJARI H., 2001. "A simple fuzzy logic approach for induction motors stator condition monitoring". In: *Electric machines and drives conference. IEMDC*, pp 634–639, IEEE

BESSAM B., MENACER A., BOUMEHRAZ M., CHERIF H., 2016. "Detection Of Broken Rotor Bar Faults In Induction Motor At Low Load Using Neural Network". *ISA Trans* 1–6.

BIN G., GAO J., LI X., DHILLON B., 2012. "Early fault diagnosis of rotating machinery based on wavelet packets empirical mode decomposition feature extraction and neural network." *Mechanical Systems and Signal Processing*, Volume 27, Pages 696-711.

BONALDI, E.L., 2005. "Diagnóstico Preditivo de Avarias em Motores de Indução Trifásicos com MCSA e Teoria de conjuntos Aproximados". Tese de Doutorado em Engenharia Elétrica. Universidade Federal de Itajubá.

BORS, G., 2001. "Introduction of the Radial Basis Function (RBF) Networks." Department of Computer Science University of York York, YO10 5DD, UK

BUBATHI M., SANJITH M.A., KRISHNAKUMAR B., MURTY S.A.V. S., 2013. "Roller element bearing fault diagnosis using singular spectrum analysis, *Mechanical Systems and Signal Processing*". Volume 35, Issues 1–2, 2013, Pages 150-166.

CHOUDHURY, A; TANDON, N., 2000 " Application of Acoustic Emission Technique for the detection of Defects in Rolling Element Bearings". *Tribology International*, Vol 33, pp. 39- 45.

CHOUDHARY A., GOYAL D., SHIMI S. L., AKULA A., 2018. "Condition Monitoring and Fault Diagnosis of Induction Motors: A Review" Archives of Computational Methods in Engineering, CIMNE, Barcelona, Spain.

CHO H. C., KNOWLES J., FADALI M. S. E LEE K. S., 2010. "Fault Detection and Isolation of Induction Motors Using Recurrent Neural Networks and Dynamic Bayesian Modelin". in IEEE Transactions on Control Systems Technology, vol. 18, no. 2, pp. 430-437, March 2010.

CRUZ, A.G.A., 2015." Sistema Híbrido para diagnóstico de falhas em motores de indução trifásicos com base no método vibracional, corrente de armadura e Lógica Fuzzy". Tese de Doutorado em Engenharia Mecânica. Universidade Federal da Paraíba, Brasil.

DAUBECHIES, I. "Ten Lectures on Wavelets". Philadelphia: SIAM Books, 1992, page 357.

DE OLIVEIRA, T. M., 2007. "Manutenção Preditiva de Motores de Corrente Contínua com Ênfase em MCSA – Motor Current Signature Analysis". Dissertação de Mestrado em Engenharia Elétrica. Universidade Federal de Itajubá. Brasil.

DELGADO M. D. P., CIRRINCIONE G., ESPINOSA A. G., ORTEGA J. A., HENAO H., 2013. "Bearing Fault Detection by a Novel Condition-Monitoring Scheme Based on Statistical-Time Features and Neural Networks". in IEEE Transactions on Industrial Electronics, vol. 60, no. 8, pp. 3398-3407, Aug.

DELGADO-ARREDONDO P. A, MORINIGO-SOTELO D., OSORNIO-RIOS R. A., AVINA-CERVANTES J. G., ROSTRO-GONZALEZ H., ROMERO-TRONCOSO R. J., 2017 "Methodology for fault detection in induction motors via sound and vibration signals". Mechanical Systems and Signal Processing, vol. 83, pp. 568 – 589, 2017.

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

DUY-TANG H., HEE-JUN K., 2019. "Rolling element bearing fault diagnosis using convolutional neural network and vibration image". Cognitive Systems Research, Volume 53, 2019, Pages 42-50.

FENG J., YAGUO L., JING L., XIN Z., NA L., "Deep Neural Networks: A Promising Tool For Fault Characteristic Mining And Intelligent Diagnosis Of Rotating Machinery With

Massive Data”. Mechanical Systems and Signal Processing, Volumes 72–73, 2016, Pages 303-315.

FRANCISCO A. M. S., 2006, “Motores de Indução Trifásicos”, editora: ETEP -Edições Técnicas e Profissionais, 2º edição.

FISER R., FERKOLJ S., 2001 "Application of A Finite Element Method To Predict Damaged Induction Motor Performance" in *IEEE Transactions on Magnetics*, vol. 37, no. 5, pp. 3635-3639.

FITZGERALD, A. E., KINGSLEY JR., C., UMANS, S.D.,2006, “Máquinas Elétricas”, 6 ed. Bookman, Porto Alegre, RS, Brasil.

GAO X. Z., OVASKA S. J. AND DOTE Y., 2000. "Motor fault detection using Elman neural network with genetic algorithm-aided training". Systems, Man, and Cybernetics, 2000 IEEE International Conference on, Nashville, TN, 2000, pp. 2386-2392 vol.4.

GARCIA-PEREZ, A, ROMERO-TRONCOSO, RJ, CABAL-YEPEZ, E, *et al*, 2011. "Application of high-resolution spectral analysis for identifying faults in induction motors by means of sound". Journal of Vibration and Control, 2011.

GARDNER M.W. GARDNER, DORLING S.R.,1998. “Artificial neural networks (the multilayer perceptron) - a review of applications in the atmospheric sciences”. Science Direct.

GERMEN E., BAARAN M., FIDAN M., 2014 “Sound based induction motor fault diagnosis using kohonen self-organizingmap”. Mechanical Systems and Signal Processing, vol.46, n.1, pp.45–58,2014.

GHATE V. N. E DUDUL S. V., 2011. "Cascade Neural-Network-Based Fault Classifier for Three-Phase Induction Motor". in *IEEE Transactions on Industrial Electronics*, vol. 58, no. 5, pp. 1555-1563, May 2011.

GINDY N., AL-HABAIBEH A., 1997. “Condition monitoring of cutting tools using artificial neural networks”. In: Proceedings of the thirty-second international matador conference, pp 299–304. Springer, Berlin.

GLOWACZ A., GLOWACZ Z., 2017. "Diagnosis of the three-phase induction motor using thermal imaging". *Infrared Phys Technol* 81:7–16.

GODOY, W. F., SILVA I. N., GONGORA W. S., GOEDTEL A.; PALÁCIOS R. H. C., 2013. "Classificação de Falhas em Rolamentos de Motores de Indução Trifásicos Utilizando Redes Neurais Artificiais". In: XI Simpósio Brasileiro de Automação Inteligente, 2013, Fortaleza. *Anais do XI Simpósio Brasileiro de Automação Inteligente*. p. 1-6.

GRAPS A., 1995. "An Introduction to Wavelets". *IEEE Computational Science and Engineering*, Summer 1995, vol. 2.

H Aidong S., Hongkai J., Xingqiu L., Shuaipeng W., 2018. "Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine". *Knowledge-Based Systems*, Volume 140, 2018, Pages 1-14.

HAYKIN, S. S., 2000 "Redes neurais: princípios e prática". 2. ed. Porto Alegre: Bookman, 2000.

HBM, 2002. "Hottinger Baldwind Messtechnik GmbH, Montageanleitung Drehmoment-Messflansch" - T40B. A3452-2.0 enQde. Darmstadt, Germany.

HULUGAPPA B., PASHAB TAJMUL, RAMAKRISHNAC DR.K.M., 2012. "Condition Monitoring of Induction Motor Ball Bearing Using Monitoring Techniques". *International Journal of Scientific and Research Publications*, Volume 2, Issue 11, November.

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

HORNIK, K., STINCHCOMBE, M. AND WHITE, H., 1989. "Multi- layer feedforward networks are universal approximators. " *Neural Networks*2, 359–366.

HWANG, YR., JEN, KK. & SHEN, YT. J., 2009. "Application of cepstrum and neural network to bearing fault detection". *Mech Sci Technol* (2009) 23: 2730.

JACK L.B., NANDI A.K., 2002. "Fault detection using support vector machines and artificial neural network augmented by genetic algorithms". *Mech. Syst. Signal Process.*, 16 (2002), pp. 373-390.

JANSSENS O., SLAVKOVIKJ V., VERVISCH B., STOCKMAN K., LOCCUFIER M., VERSTOCKT S., DE WALL R. V. E HOECKE S. V., 2016. "Convolutional Neural Network Based Fault Detection for Rotating Machinery". *Journal of Sound and Vibration*, Volume 377, 2016, Pages 331-345.

KANKAR P.K., SHARMA S. C., HARSHA S.P., 2011. "Fault Diagnosis Of Ball Bearings Using Continuous Wavelet Transform". *Applied Soft Computing*, Volume 11, Issue 2, 2011, Pages 2300-2312.

KYUSUNG K., PARLOS A. G., 2002 "Induction motor fault diagnosis based on neuropredictors and wavelet signal processing". in *IEEE/ASME Transactions on Mechatronics*, vol. 7, no. 2, pp. 201-219, June 2002.

KOWALSKI, C.T. AND KOWALSKA, T.O. (2003), "Neural Networks Application For Induction Motor Faults Diagnosis"., *Mathematics and Computers in Simulation*, Vol. 63.

KUMAR S., GOYAL D., DHAMI S.S., 2018. "Statistical and frequency analysis of acoustic signals for condition monitoring of ball bearing". *Mater Today Proc* 5(2):5186–5194.

LACERDA, A. L. M.; FILHO, P. C. M. L.; PEDERIVA, R.; BRITO, J. N." Aplicação da transformada de Wavelet Packet para detecção de curto-circuitos em motores elétricos". [S.1]. 2011.

LIMA, T. L. d. V., "Desenvolvimento De Um Sistema Embarcado Para Detecção De Falhas Em Veículos Automotivos Por Meio De Análise Sonora". Tese (Relatório de Qualificação de Doutorado) — Universidade Federal da Paraíba, João Pessoa, nov. 2017.

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.

LOPES, T.D., GOEDEL, A., PALÁCIOS R.H.C, GODOY W.F., 2017. "Bearing fault identification of three-phase induction motors bases on two current sensor strategy". *Soft Comput* November 2017, Volume 21, Issue 22, pp 6673–6685.

LYRA G. J., 2015. “Análise de métodos para estimação da velocidade no eixo de motores de indução trifásicos”. Dissertação. UFPB/CT, Programa de pós-graduação em Engenharia Mecânica, João Pessoa- PB.

LU S., GUO J., HE Q., LIU F., LIU Y., ZHAO J., 2016 “A novel contact less angular resampling method for motor bearing fault diagnosis under vari-able speed”. IEEE Transactions on Instrumentation and Measurement, vol. 65, no. 11, pp. 2538–2550, Nov 2016.

MALLAT, S. (1989). "A Theory for Multiresolution Signal Decomposition - The Wavelet Representation". IEEE on Pattern Analysis and Machine Intelligence, vol. 11, N o .7, Jul. 1989, pp.674-693.

MINI V, USHAKUMARI S., 2011. “Incipient fault detection and diagnosis of induction motor using fuzzy logic. In: Recent advances in intelligent computational systems (RAICS).” pp. 675–681, IEEE.

MORHAIN A. E MBA D., 2003. " Bearing defect diagnosis and acoustic emission". Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology Vol 217, Issue 4, pp. 257 – 272.

NANDI S., TOLIYAT H.A., LI X., 2005. “Condition monitoring and fault diagnosis of electrical motors – a review”. IEEE Trans. Energy Convers. 20(2005)719–729.

NÓBREGA, C.A.S., 2015." Estudo Comparativo De Técnicas Para Diagnóstico De Falhas Em Motores De Indução Trifásicos". Tese- Programa de pós-graduação em engenharia mecânica, Universidade Federal da Paraíba. João Pessoa. 2015

NOREESUWAN T, SUKSAWAT B (2010). “Propose Of Unsealed Deep Groove Ball Bearing Condition Monitoring Using Sound Analysis And Fuzzy Logic.” International Conference On Control Automation and Systems (ICCAS), pp 409–413, IEEE

OLIVEIRA, H. M., 2007. “Análise de sinais para Engenheiros: Uma abordagem via Wavelets”. 1ª ed. Brasport, 2007. pag. 268.

ONEL IZZET, IBRAHIM SENOL, MOHAMED BENBOUZID., 2006. "Induction Motors Bearing Failures Detection and Diagnosis Using a RBF ANN Park Pattern Based Method". ICEM'06, Sep 2006, Chania, Greece. 6pp, 2006.

ONEL, I. Y.; DALCI, K. B.; SENOL, 2006. "Detection of bearing defects in three-phase induction motors using Park's transform and radial basis function neural networks". Sadhana, [S.l.], v.31, p.235{244.

ORMAN, MACIEJ; RZESZUCINSKI, PAWEL ; TKACZYK, AGNIESZKA ; *et al.*, 2015. "Bearing fault detection with the use of acoustic signals recorded by a hand-held mobile phone". International Conference on Condition Assessment Techniques in Electrical Systems, Dec. 2015, pp.252-256.

OTHMAN M.S., NUAWI M.Z., MOHAMED R., 2016. "Experimental comparison of vibration and acoustic emission signal analysis using kurtosis-based methods for induction motor bearing condition monitoring". Przegląd Elektrotechniczny 92(11):208–212.

PATEL J.P., UPADHYAY S.H., 2016. "Comparison between Artificial Neural Network and Support Vector Method for a Fault Diagnostics in Rolling Element Bearings". Procedia Engineering, Volume 144, 2016, Pages 390-397.

PENG XU, CHAN, A. K., 2002. "Fast and robust neural network based wheel bearing fault detection with optimal wavelet features." Proceedings of the International Joint Conference on Neural Networks.

PINTO, R.M.F., 2009. "Novas Abordagens ao Estudo de Sinais Biomédicos: Análise em tempo-frequência e Transformada de Hilbert-Huang". Tese de Doutorado em Engenharia Biomédica e Biofísica. Universidade de Lisboa, Portugal.

RAMAKRISHNA K.M., 2007. " Detection of Induction Motor Bearing Faults Using Condition Monitoring Techniques". Industrial Tribology, Machine Dynamics and Maintenance Engineering Centre, Indian Institute of Technology Hauz Khas, New Delhi-110016 India, February, 2007.

RAO B., PAI O.S., NAGABHUSHANA T., 2012. "Failure diagnosis and prognosis of rolling-element bearings using artificial neural networks: a critical overview." J Phys Conf Ser 364:012023.

SAAD AL-DOSSARY; RAJA HAMZAH, R. I.; MBA, D., 2009. "Observations of Changes in Acoustic Emission Waveform for Varying Seeded Defect Sizes in a Rolling Element Bearing". Applied Acoustics, Vol. 70, pp 58 – 71.

SAIDI L., ALI J.B., FNAIECH F., 2015. "Application of higher order spectral features and support vector machines for bearing faults classification". ISA Trans 54:193–206.

SAMANTA B., AL-BALUSHI K.R., AL-ARAIMI S.A., 2003. " Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection". Engineering Applications of Artificial Intelligence, Volume 16, Issues 7–8, October–December 2003, Pages 657-665.

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, Brasil.

SANTIAGO, D.F.A.; PEDERIVA, R., 2003. "Influência da Resolução TempoFrequência da Wavelet de Morlet no Diagnóstico de Falhas de Máquinas Rotativas". In: XIII Congreso Sobre Métodos Numéricos y Sus Aplicaciones - ENIEF 2003, 2003, Bahía Blanca - Argentina. Mecanica Computacional. Bahía Blanca - Argentina

SANTOS F. M. C., DA SILVA I. N., SUETAKE M., 2013. "Neural network classifier for faults detection in induction motors". International Conference on Computer Applications Technology (ICCAT).

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

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

SILVA, I.N., SPATTI, D., e FLAUZINO, R. A., 2010. "Redes neurais artificiais para engenharia e ciências aplicadas: curso prático". Artliber Editora Ltda, São Paulo.

SUETAKE M., 2012, "Sistemas Inteligentes para Monitoramento e Diagnósticos de Falhas em Motores de Indução Trifásicos". Tese- Programa de Pós-Graduação em Engenharia Elétrica e Área de concentração em Sistemas Dinâmicos, Escola de Engenharia de São Carlos da Universidade de São Paulo.

TAHA Z. e PRANOTO I., 2013." Acoustic Emission Application for Monitoring Bearing Defects". Acoustic Emission-Research and Applications, 2013 - intechopen.com.

YAGUO L., ZHENGJIA H., YANYANG Z., 2009. "Application of an intelligent classification method to mechanical fault diagnosis". Expert Systems with Applications, Volume 36, Issue 6, 2009, Pages 9941-9948.

YANG D.-M., STRONACH A.F., MACCONNELL P., PENMAN J., 2002. "Third-Order Spectral Techniques For The Diagnosis Of Motor Bearing Condition Using Artificial Neural Networks". Mechanical Systems and Signal Processing, Volume 16, Issues 2–3, Pages 391-411.

UNAL M., DEMETGUL M., ONAT M., KUCUK H., 2013. "Fault diagnosis of rolling bearing based on feature extraction and neural network algorithm". Recent Adv Electr Eng Ser 10.

UNAL M., ONAT M., DEMETGUL M., KUCUK H., 2014. "Fault Diagnosis Of Rolling Bearings Using A Genetic Algorithm Optimized Neural Network". Measurement, 58 (2014), pp. 187-196.

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

REIS, A.J.S., 2010. "Reconhecimento de Padrões de Falhas em Motores Trifásicos Utilizando Redes Neurais". Dissertação de mestrado em Engenharia Elétrica. Universidade Federal do Rio Grande do Norte. Natal, RN, Brasil.

WEIDONG Li e CHRIS K. Mechefske, 2006. " Detection of Induction Motor Faults: A Comparison of Stator Current, Vibration and Acoustic Methods". Journal of Vibration and Control Vol 12, Issue 2, pp. 165 - 188 First Published February 1, 2006.

ZAREI J., 2012. "Induction Motors Bearing Fault Detection Using Pattern Recognition Techniques" Expert Syst. Appl., 39 (2012), pp. 68-73.

ZHIQIANG C., SHENGCAI D., XUDONG C., CHUAN L., RENÉ-VINICIO S.,
HUA FENG Q., 2017. “Deep neural networks-based rolling bearing fault diagnosis,
Microelectronics Reliability”. Volume 75, 2017, Pages 327-333.