

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

YURI PICCOLO BÓRNEA

**DESENVOLVIMENTO DE SISTEMA PARA DETECÇÃO DE FALHAS EM
ROLAMENTOS DE MOTORES DE INDUÇÃO A PARTIR DE SEUS SINAIS DE
VIBRAÇÃO**

CORNÉLIO PROCÓPIO

2022

YURI PICCOLO BÓRNEA

**DESENVOLVIMENTO DE SISTEMA PARA DETECÇÃO DE FALHAS EM
ROLAMENTOS DE MOTORES DE INDUÇÃO A PARTIR DE SEUS SINAIS DE
VIBRAÇÃO**

**Development of system to detect faults in bearings of induction motors by their
vibration signals**

Dissertação apresentada como requisito para
obtenção do título de Mestre em Engenharia Elétrica
da Universidade Tecnológica Federal do Paraná
(UTFPR).

Orientador: Dr. Marcelo Favoretto Castoldi.

Coorientador: Dr. Alessandro Goedtel.

CORNÉLIO PROCÓPIO

2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite o download e o compartilhamento da obra desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-la ou utilizá-la para fins comerciais.



**Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio**



YURI PICCOLO BORNEA

**DESENVOLVIMENTO DE SISTEMA PARA DETECÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES DE
INDUÇÃO A PARTIR DE SEUS SINAIS DE VIBRAÇÃO**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas Eletrônicos Industriais.

Data de aprovação: 11 de Fevereiro de 2022

Prof Marcelo Favoretto Castoldi, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Andre Sanches Fonseca Sobrinho, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Bruno Augusto Angelico, Doutorado - Usp-Universidade de São Paulo

Prof Paulo Rogerio Scalassara, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 11/02/2022.

Dedico este trabalho à minha família, à minha mãe
Isabel Cristina Piccolo Bórnea, ao meu pai
Aparecido Sérgio Bórnea e ao meu irmão Sérgio
Henrique Piccolo Bórnea.

AGRADECIMENTOS

Apesar de solitário, a escrita do presente trabalho é resultado da ajuda e contribuição de muitas pessoas que, direta ou indiretamente, participaram da pesquisa realizada. Não há dúvidas de que estes parágrafos não irão atender a todas as pessoas que contribuíram com este sonho, e desde já peço desculpas àquelas que não são citadas, mas estejam cientes que fazem parte do meu pensamento e minha gratidão.

Em primeiro lugar, agradeço profundamente aos meus familiares que me apoiaram e prestaram toda a ajuda necessária para a realização deste projeto. Em especial, deixo meus profundos agradecimentos à minha mãe Isabel Cristina Piccolo Bórnea por todo apoio, carinho e presença, ao meu irmão Sérgio Henrique Piccolo Bórnea que sempre prestou total atenção e auxílio em todos os aspectos possíveis, e ao meu pai Aparecido Sérgio Bórnea que apesar de não poder contemplar este trabalho, me inspirou e deu forças para prosseguir com este sonho.

À minha namorada Giovana da Silva Camilo, sendo sempre muito carinhosa e atenciosa comigo, estando ao meu lado e me ajudando em diversos momentos, sendo uma grande amiga e companheira.

Ao meu orientador Prof.º Dr. Marcelo Favoretto Castoldi por me guiar e acreditar em meu trabalho, sempre me dando conselhos, auxiliando com seu conhecimento na execução deste projeto e incentivando na busca constante do saber e do desenvolvimento científico.

Ao meu coorientador Prof.º Dr. Alessandro Goedel pela ajuda no desenvolvimento deste trabalho e me auxiliar com seu conhecimento e prática, me aconselhando e dando ideias sempre que possível e incentivando também a pesquisa e a construção do saber.

Aos meus colegas de pós graduação do Laboratório de Sistemas Inteligentes (LSI), Ailton de Oliveira Louzada, Gustavo Vendrame Bárbara, Carolina Bianchini e João Paulo Vicente, pela amizade e ajuda no desenvolvimento do meu trabalho.

À todos os colegas da UTFPR que tive a oportunidade de conhecer no curso de graduação e mestrado e que tive o privilégio de estudar junto e dividir conhecimento, Anderson Honório Nunes, Guilherme Magalhães, Anderson Dionizio, Felipe Dutra Bueno, Ruhan Policarpo e Harryson Moraes.

À UTFPR, seus professores e servidores, que cederam a estrutura para eu adquirir todo o conhecimento que possuo e para o desenvolvimento da presente dissertação.

Aos meus caros amigos que muito me ajudam e que são presentes em minha vida, Julien Hervot de Mattos Vaz, Max Hervot de Mattos Vaz, Anthony Ezequiel da Silva, Denis Ribeiro Ferro, Felipe Favaretto Fittipaldi, Renê Chiquetti Rodrigues, Bruno Merotti e Graziela Martins.

Enfim, a todos os que por algum motivo contribuíram para a realização desta pesquisa.

Ao suporte financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos de Demanda Social (CAPES/DS).

RESUMO

BÓRNEA, Y. P. **Desenvolvimento de sistema para detecção de falhas em rolamentos de motores de indução a partir de seus sinais de vibração**. 2022. 117 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2022.

O presente trabalho aborda o estudo e desenvolvimento de uma metodologia capaz de identificar condições de falhas em rolamentos de motores de indução durante o funcionamento dessas máquinas através de seus sinais de vibração. São utilizados sinais de vibração do banco de dados da Case Western Reserve University, que incluem a situação de motores com rolamentos saudáveis ou com falhas. É aplicada a Transformada de Hilbert-Huang como pré-processamento de sinais seguida da extração de características no domínio do tempo e no domínio do tempo-frequência do resultado da transformada. Por fim, com o intuito de se fazer a identificação e classificação de padrões das características extraídas, é utilizada uma rede neural artificial Perceptron Multicamadas para predição de condição dos rolamentos do motor e do tipo de falha, a fim de se obter um sistema de diagnóstico de falhas eficaz. Os resultados são medidos entre rolamentos saudáveis ou defeituosos e pelo o tipo de falha acometida pelos rolamentos, sendo que o sistema proposto apresentou 100% de acurácia na classificação de padrões entre falhas e não falhas, 58,97% entre as falhas, sem diferenciar os rolamentos, 78,57% somente para falhas relacionadas ao rolamento frontal e 72,73% para falhas do rolamento traseiro.

Palavras-chave: Motores elétricos de indução, Redes neurais (Computação), Rolamentos, Localização de falhas (Engenharia).

ABSTRACT

BÓRNEA, Y. P. **Development of system to detect faults in bearings of induction motors by their vibration signals.** 2022. 117 p. Master Thesis (Master in Electrical Engineering) - Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2022.

This work brings a study and development of an approach able to identify bearing induction motor faults from the vibration signals of these machines during their operation. Vibration signals from Case Western Reserve University Bearing Data Center are used, which include motors with healthy or faulty bearings in many situations of load and damage levels. The preprocessing tool Hilbert-Huang Transform is used, followed by extraction features in time and time-frequency domains. Having the purpose to identify and classify patterns from the extracted features, it is used an artificial neural network Multilayer Perceptron in order to predict the condition of bearings and the type of fault that happens to them. The results are measured between healthy and faulty bearings and the kind of mishappen that may be on this case, presenting 100% of accuracy in the classification of healthy and faulty patterns, 58,97% between all bearing faults, 78,57% for only drive end bearing faults, and 72,73% for fan end bearing faults.

Keywords: Electric motors, Induction, Neural networks (Computer science), Bearings (Machinery), Fault location (Engineering).

LISTA DE FIGURAS

Figura 1 - Tipos de falhas presentes nos motores de indução trifásicos	22
Figura 2 - Descrição de processo para diagnóstico de falhas	25
Figura 3 - Bancada de testes utilizada para os ensaios da CWRU	30
Figura 4 - Esquemático de componentes de um rolamento	35
Figura 5 – Organograma de execução do trabalho	37
Figura 6 - Exemplo de splines cúbicas de máximos e mínimos de uma função	42
Figura 7 - Topologia de uma RNA Perceptron Multicamadas	53

LISTA DE GRÁFICOS

Gráfico 1 - FFT do sinal de vibração da pista interna.....	61
Gráfico 2 - Sinal original, 10 primeiras IMFs e resíduo do sinal de pista interna	63
Gráfico 3 - (a) FFT do sinal da pista interna com falha leve; (b) FFT da IMF5 da pista interna	64
Gráfico 4 - (a) FFT do sinal da pista externa com falha grave; (b) FFT da IMF5 da pista externa.....	65
Gráfico 5 - (a) FFT do sinal da pista externa com falha leve; (b) FFT da IMF5 da pista externa	66
Gráfico 6 - (a) FFT do sinal das esferas com falha grave; (b) FFT da IMF5 das esferas	67
Gráfico 7 - (a) FFT do sinal das esferas com falha leve; (b) FFT da IMF5 das esferas	68
Gráfico 8 - IMF5 do sinal das esferas com falha leve.....	69
Gráfico 9 - Espectro de Hilbert da IMF5 do sinal das esferas com falha leve	70
Gráfico 10 - Conjuntos dos dados da APF dos rolamentos saudáveis e defeituosos	73
Gráfico 11 - Conjuntos dos dados da APT dos rolamentos saudáveis e defeituosos	73
Gráfico 12 - Conjuntos dos dados do RMS dos rolamentos saudáveis e defeituosos	74
Gráfico 13 - Conjuntos dos dados do FC dos rolamentos saudáveis e defeituosos..	75
Gráfico 14 - Conjuntos dos dados do FF dos rolamentos saudáveis e defeituosos ..	75
Gráfico 15 - Conjuntos dos dados do FI dos rolamentos saudáveis e defeituosos ...	76
Gráfico 16 - Conjuntos dos dados do FM dos rolamentos saudáveis e defeituosos .	77
Gráfico 17 - Conjuntos dos dados de curtose dos rolamentos saudáveis e defeituosos	77
Gráfico 18 - Conjuntos dos dados de assimetria dos rolamentos saudáveis e defeituosos	78
Gráfico 19 - Conjuntos dos dados de PP dos rolamentos saudáveis e defeituosos..	79

LISTA DE TABELAS

Tabela 1 – <i>Links</i> disponíveis de falhas nos componentes de cada rolamento	29
Tabela 2 - Falhas e componentes de cada rolamento da extremidade frontal	31
Tabela 3 - Falhas e componentes de cada rolamento da extremidade traseira	31
Tabela 4 - Dimensões de cada tipo de rolamento	32
Tabela 5 - Frequências de defeito múltiplas de cada rolamento da CWRU	32
Tabela 6 - Frequências de defeito múltiplas de cada rolamento calculadas	59
Tabela 7 - Frequências de defeito múltiplas de cada rolamento calculadas	60
Tabela 8 - Resultado da primeira classificação por acréscimo de neurônios	82
Tabela 9 - Resultado da classificação de falhas por acréscimo de neurônios em uma camada	83
Tabela 10 - Resultado da classificação de falhas por acréscimo de neurônios em duas camadas	84
Tabela 11 - Melhores classificações de falhas em redes de uma camada	85
Tabela 12 - Melhores classificações de falhas em redes de duas camadas	85
Tabela 13 - Melhores classificações de falhas do rolamento frontal em redes de uma camada	86
Tabela 14 - Melhores classificações de falhas do rolamento frontal em redes de duas camadas	87
Tabela 15 - Melhores classificações de falhas do rolamento traseiro em redes de uma camada	88
Tabela 16 - Melhores classificações de falhas do rolamento traseiro em redes de duas camadas	88
Tabela 17 - Melhores classificações de falhas em redes de uma camada com Softmax	89
Tabela 18 - Melhores classificações de falhas em redes de duas camadas com Softmax	90
Tabela 19 - Melhores classificações de falhas frontais em redes de uma camada com Softmax	90
Tabela 20 - Melhores classificações de falhas frontais em redes de duas camadas com Softmax	91
Tabela 21 - Melhores classificações de falhas traseiras em redes de uma camada com Softmax	92
Tabela 22 - Melhores classificações de falhas traseiras em rede de duas camadas com Softmax	92
Tabela 23 – Melhores resultados obtidos das classificações por RNAs	94

LISTA DE ABREVIATURAS E SIGLAS

NBR	Norma Brasileira
IOT	<i>Internet Of Things</i>
SWT	<i>Stationary Wavelet Transform</i>
HHT	<i>Hilbert Huang Transform</i>
EMD	<i>Empirical Mode Decomposition</i>
CWRU	<i>Case Western Reserve University</i>
DTL	<i>Deep Transfer Learning</i>
NAP	<i>Nuisance Attribute Projection</i>
FFT	<i>Fast Fourier Transform</i>
HMM	<i>Hidden Markov Models</i>
DCN	<i>Deformable Convolution Networks</i>
IMF	<i>Intrinsic Mode Functions</i>
RNA	Rede Neural Artificial

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Justificativa.....	18
1.2	Objetivos	19
1.3	Organização do Trabalho	20
2	ESTUDO SOBRE FALHAS EM MOTORES DE INDUÇÃO	21
2.1	Condições de Falha em Motores de Indução.....	21
2.2	Diagnóstico de Falhas em Motores de Indução	23
2.3	Conclusão do Capítulo	27
3	BANCOS DE DADOS EM REPOSITÓRIOS ONLINE	28
3.1	Informações Referentes ao Banco de Dados da Case Western Reserve University	28
3.2	Estudos Utilizando Bancos de Dados em Repositórios Online	33
3.3	Conclusão do Capítulo	34
4	METODOLOGIA PROPOSTA	35
4.1	Métodos Matemáticos para Cálculo de Frequências de Falhas.....	38
4.2	Transformada de Hilbert-Huang.....	39
4.2.1	Decomposição em Modos Empíricos	40
4.2.2	Espectro de Hilbert.....	45
4.3	Extração de Características de Sinais de Vibração	48
4.4	Classificação por Redes Neurais Artificiais Perceptron Multicamadas ..	52
4.5	<i>Hardware e Software</i> Utilizados	56
4.6	Conclusão do Capítulo	57
5	RESULTADOS.....	58
5.1	Cálculo e Comparação de Frequências.....	58
5.2	Aplicação da HHT em Conjuntos de Dados	61
5.3	Extração de Características e Detecção de Falhas	71
5.4	Classificação com a Rede Neural Perceptron Multicamadas	80
5.4.1	Rede Neural Perceptron Multicamadas com Função Logística.....	81
5.4.2	Rede Neural Perceptron Multicamadas com Função Softmax.....	89
5.5	Conclusão do Capítulo	93
6	CONSIDERAÇÕES FINAIS	95
6.1	Observações e sugestões para trabalhos futuros	96

REFERÊNCIAS.....	97
APÊNDICE A – Gráficos dos Dados de Falhas	102

1 INTRODUÇÃO

Motores de indução são máquinas elétricas muito utilizadas na indústria, principalmente em se tratando de motores de indução trifásicos devido a robustez, confiabilidade e ao baixo custo que estas máquinas apresentam. Por consequência, o diagnóstico precoce de falhas destes equipamentos se mostra como um campo de estudo muito importante para estes motores devido aos fatores de redução do custo de manutenção e do tempo inativo de operação destas máquinas (RAJ; NATARAJAN; GIRIKUMAR, 2013).

De fato, como qualquer outra máquina rotativa, motores estão sujeitos a falhas, desgaste e envelhecimento, sendo que se nenhuma ação for adotada durante o processo de envelhecimento e degradação pelas condições ambientais e operacionais, em algum momento essas máquinas virão a apresentar avarias e até falhar (LOISELLE; XU; VOLOH, 2015; LEME, 2017).

Em Antonino-Daviu *et al.* (2016) é dito que as falhas em motores de corrente alternada são conhecidas, porém podem variar por diversos fatores como o tamanho destas máquinas e o tipo de indústria ou processo industrial nas quais elas operam, havendo então a dificuldade de estipular as taxas de ocorrência destes defeitos. Apesar disso, muitos trabalhos se esforçam para trazer levantamentos e estimativas para tais ocorrências e operações destes motores, havendo diversas abordagens para tais procedimentos.

Nota-se através de trabalhos e pesquisas que aferir medições de grandezas físicas de motores se mostra como um método interessante para verificar a operação destas máquinas. Um bom exemplo disso é retratado na NBR (Norma Brasileira) 17094-1/2018, que demonstra os limites de tensão e frequência elétricas na operação dos motores de indução trifásicos, destacando pontos de operação normal, com desvios de desempenho ou com iminência de danificação caso operados por um período prolongado acima dos limites estipulados (ABNT, 2018).

Além das grandezas de origem elétrica, pode-se citar também as mecânicas e térmicas como variáveis passíveis de extração e que podem ser utilizadas para identificar uma operação normal ou anormal de um motor. Em Filho (2017) e WEG (2020), por exemplo, destaca-se que um aumento de 10 graus acima do limite da classe térmica na temperatura do sistema de isolamento pode chegar a reduzir a vida

útil dos enrolamentos de um motor pela metade, comprometendo a operação desta máquina.

Em se tratando de grandezas mecânicas, a análise de vibração mostra-se como uma possível técnica de diagnóstico de falhas, sendo amplamente difundida na indústria e normalmente empregada para diagnosticar falhas como defeitos de rolamentos, desalinhamento, danos em barras de rotor ou anéis de extremidade (ANTONINO-DAVIU et. al, 2016).

O sensoriamento da vibração mecânica de um motor pode ser realizado através de acelerômetros como os piezoelétricos, por exemplo, e o tratamento dos dados coletados pode ser feito através de *softwares* próprios para isso (SAKHALKAR; KORDE, 2017).

Devido ao fato da análise de vibração se mostrar cada vez mais como uma potencial técnica para o diagnóstico de motores, surge então o interesse da indústria para o desenvolvimento de equipamentos que visem atender a esta demanda. Um exemplo disso é o WEG Motor Scan, que monitora periodicamente os dados de vibração, temperatura e tempo de funcionamento do motor elétrico que ele estiver conectado, coletando e disponibilizando estes dados para os profissionais e usuários interessados. Este equipamento é apresentado ao público como uma alternativa na otimização da manutenção industrial, uma vez que disponibiliza os dados coletados para os usuários por meio do aplicativo de *smartphone* WEG lot Platform, que recebe os dados via Bluetooth ou um acesso remoto, ou seja, uma conexão feita por roteadores, no caso do modelo Cassia X1000 (WEG, 2020).

Pode-se observar através do produto descrito acima que a manutenção se torna um conceito importante para a indústria, realizando a tarefa de predizer se o motor apresenta algum defeito ou não. Segundo Kardec, Nascif e Baroni (2002, p. 3) ainda sobre manutenção, “[...] o pessoal da área precisa estar qualificado e equipado para evitar falhas e não para corrigi-las.”

Analisando a ideia exposta em Stroker (2003) de que “O verdadeiro custo do equipamento é definido como o total das despesas de capitais iniciais somados aos custos operacionais, que incluem energia e manutenção”, verifica-se então a preocupação com o impacto da energia elétrica gasta em maquinários e sua discussão acerca da eficiência energética dos motores operando com falhas, havendo a possibilidade até mesmo de se fazer um cálculo que avalia o custo da energia elétrica desperdiçada.

Ainda pensando em manutenção, pode-se verificar em Leme (2017) que motores elétricos são equipamentos utilizados em larga escala por diferentes indústrias e em diversos processos industriais, criando-se assim a necessidade de um estoque contendo diversas peças sobressalentes e motores para substituição no caso de necessidade da manutenção destas máquinas na linha produtiva, o que se mostra uma tarefa de difícil realização. Por conta disso, o planejamento das ações da manutenção se mostra importante e de largo interesse de estudo, uma vez que há técnicas para a análise dos motores em indústria.

Deve-se porém mapear especificamente os componentes que apresentam defeitos ou falhas, tendo grandes indicativos já levantados e apresentados em outros estudos. Em Bonnett e Yung (2008), por exemplo, verifica-se que a maioria das falhas dos motores de indução podem ser atribuídas aos rolamentos e aos enrolamentos de estator, seguidos por barras de rotor e eixo, sendo que cerca de três quartos dos defeitos relacionados aos rolamentos e enrolamentos podem ser prevenidos através de medidas adequadas.

Apesar do uso da análise de vibração se mostrar complicada em motores instalados em aplicações específicas, onde estas máquinas nem sempre são facilmente acessadas, ainda assim se mostra interessante utilizar esta técnica para diagnosticar falhas mecânicas, devendo-se porém ter cuidado com o uso destes sinais para diagnosticar falhas elétricas (ANTONINO-DAVIU et. al, 2016). Vale pontuar que tanto as forças mecânicas quanto elétricas podem produzir vibração e interagir entre elas, tornando enganosa a identificação da causa principal da falha (RAJ; NATARAJAN; GIRIKUMAR, 2013).

Conforme mostrado em Maruthi e Vishwanath (2016), verifica-se a possibilidade de extrair sinais de vibração utilizando acelerômetros MEMS e analisar o espectro de frequências a fim de constatar o aumento nas amplitudes de vibração das componentes de falha de rolamentos. As magnitudes da vibração produzidas por uma máquina dependem das forças que compõem as respostas mecânicas da estrutura destes aparelhos, tanto individualmente quanto em suas montagens, já que o conjunto irá vibrar e produzir respostas em frequência (RAJ; NATARAJAN; GIRIKUMAR, 2013).

Há trabalhos na literatura indicando a utilização de estratégias em análise de tempo-frequência de sinais de vibração. Um exemplo disso é o uso das ferramentas

de Transformada Wavelet Estacionária (SWT) em Bayram e Seker (2017), e a Transformada de Hilbert-Huang (HHT) em Esfahani, Wang e Sundararajan (2014).

Em Sakhalkar e Korde (2017) é apresentada uma metodologia para a identificação de motores com barras de rotor quebradas através dos sinais de vibração de motores, sendo utilizada a *Fast Fourier Transform (FFT)* como técnica de processamento de sinais, ainda citando a possibilidade de se utilizar outras, como a Transformada Wavelet. Estas estratégias de tratamento de dados, segundo o estudo, auxiliam na análise dos sinais coletados pelos sensores e também na extração das características sensíveis com a presença das falhas nos motores de indução. O tratamento e condicionamento destes sinais podem ser feitos através de *softwares* específicos, como no caso foi feito e demonstrado no MatLab, aproveitado também para simular o sistema proposto.

Pode-se ainda combinar recursos de várias ferramentas, como feito em Rai e Mohanty (2007), onde se utilizou as técnicas de Transformada Rápida de Fourier em conjunto com a Transformada Hilbert-Huang e as Funções de Modo Intrínseco obtidas através da Decomposição de Modos Empíricos (*EMD*).

Técnicas e abordagens de aprendizagem de máquina tem sido utilizadas para aplicações *off-line* e *on-line*, onde pode ser constatado o uso da inteligência artificial para o diagnóstico de falhas em sistemas de alta complexidade variantes no tempo e não lineares. Verifica-se que o contínuo avanço e aprimoramento dos algoritmos de *machine learning*, aplicações e pesquisas se direcionam para o estudo das falhas em motores de indução com grande potencial de aplicação (ALI *et al.*, 2019).

Em Seker e Kayran (2009), demonstrou-se que é possível a aplicação dos dados coletados e tratados em Redes Neurais Artificiais (RNAs), por exemplo, a fim de se fazer a identificação de falhas através da comparação entre valores de um motor com rolamentos quebrados e de um com rolamentos saudáveis. Porém, utilizam-se dos sinais de vibração e corrente elétrica no estator do motor de indução a fim de se provar a ideia proposta, sendo a rede neural utilizada baseada na arquitetura *backpropagation*.

Em Godoy *et al.* (2015), foram utilizadas três técnicas diferentes de Inteligência Artificial na classificação de falhas de curto circuito em enrolamentos de estator de motores de indução e seus desempenhos foram comparados entre si, sendo estas técnicas a Rede Perceptron Multicamadas, Máquina de Vetores de Suporte e Rede Fuzzy ARTMAP.

Em Esfahani, Wang e Sundararajan (2014), utilizou-se as Análises Discriminantes Linear e Quadrática para realizar uma classificação inicial de dados de vibração, som e corrente elétrica de um motor de indução, utilizando posteriormente um classificador de Máquina de Vetores de Suporte para identificar especificamente as falhas ocorridas.

Em posse das informações levantadas, este trabalho emerge para apresentar um sistema de diagnóstico de falhas em rolamentos de motores de indução baseada nos sinais de vibração destas máquinas, a Transformada de Hilbert-Huang para extrair características destes sinais e uma Rede Neural Artificial (RNA) Perceptron Multicamadas para classificar as condições de trabalho destes motores.

1.1 Justificativa

Verificando-se que o modo de operação de motores pode influenciar diretamente na eficiência energética dos processos industriais, se torna significativo o tratamento das falhas destes equipamentos uma vez que o setor industrial é o que mais consome energia elétrica da matriz brasileira, detendo 35,8% do consumo energético nacional (MINISTÉRIO DE MINAS E ENERGIA, 2020). Motores representam mais de 60% do consumo de energia das indústrias, o que agrava ainda mais a preocupação com essas máquinas (WEG, 2020). A parada indesejada também afeta muito a indústria, uma vez que uma quantia significativa de recursos podem ser perdidos neste tempo.

Analisa-se na bibliografia a tendência no desenvolvimento de trabalhos para diagnosticar defeitos nos rolamentos de motores de indução através dos sinais de vibração destas máquinas elétricas. Em posse da informação de que em motores de indução cerca de 51% das falhas sejam em rolamentos, verifica-se a importância deste tema (BONNETT; YUNG, 2008).

Com isso, ter um sistema de manutenção que consiga verificar uma possível falha em um motor de indução trifásico relacionada a rolamentos possivelmente danificados se torna uma ideia interessante para economizar tempo, energia e consequentemente dinheiro investido em processos produtivos.

Além destes pontos, com o advento de bancos de dados disponíveis na *Internet* através de instituições de pesquisa (universidades, por exemplo) e trabalhos

acadêmicos, torna-se atrativo utilizar estes repositórios para o desenvolvimento de técnicas.

Neste contexto, o presente trabalho tenta contribuir com o tema apresentando uma metodologia no tratamento e extração de características de sinais de vibração de motores elétricos com diversos tipos e níveis de degradação em seus rolamentos. Tais sinais de vibração são extraídos de um banco de dados disponibilizado por uma universidade.

1.2 Objetivos

O objetivo geral do presente trabalho consiste no desenvolvimento de um método para extração de características de sinais de vibração utilizando a Transformada de Hilbert-Huang e de classificação dos dados coletados com Redes Neurais Artificiais a fim de verificar defeitos em máquinas de indução.

Definido o objetivo geral do trabalho, pode-se destacar os seguintes pontos como objetivos específicos:

- Utilizar os dados contidos no repositório da *Internet* de falhas em rolamentos de motores de indução da *Case Western Reserve University* (CWRU);
- Utilizar a Transformada de Hilbert-Huang para realizar o tratamento dos sinais de vibração a fim de se fazer análise em tempo-frequência-amplitude;
- Analisar as Funções de Modo Intrínseco (IMFs) resultantes da Decomposição em Modos Empíricos (EMD) e avaliar qual será utilizada para se extrair características;
- Avaliar as características extraídas para caracterizar e detectar as falhas através do comportamento destes dados;
- Desenvolver e parametrizar uma Rede Neural Artificial Perceptron Multicamadas para realizar a classificação dos dados de rolamentos.

1.3 Organização do Trabalho

O presente trabalho foi dividido em seis capítulos, sendo que o primeiro destaca uma introdução sobre os temas relacionados, as justificativas e os objetivos do trabalho.

Logo em seguida, no Capítulo 2, é feita uma breve contextualização do cenário de estudo sobre falhas em motores de indução e algumas técnicas utilizadas em estudos do tema, além de abordar algumas metodologias interessantes já aplicadas.

No Capítulo 3 são levantadas e mostradas informações importantes do banco de dados da CWRU, que será utilizado neste trabalho como principal fonte de sinais para testar o sistema desenvolvido, e também são apresentados estudos que envolveram este e outros bancos de dados disponíveis na *Internet* a fim de verificar metodologias e resultados.

No Capítulo 4 é realizada a proposta e a análise da metodologia que se deseja adotar para a realização do presente projeto. É feita também toda a investigação e explicação dos materiais e métodos utilizados para a realização do presente projeto.

Reserva-se o Capítulo 5 para mostrar os resultados obtidos utilizando-se a metodologia proposta, sendo analisados os aspectos dos dados adquiridos durante os trabalhos e verificando-se a efetividade de cada abordagem adotada.

Por último, no capítulo 6 são apresentadas as considerações finais do trabalho e sugestões para trabalhos futuros que utilizarem de algum método aqui apresentado.

2 ESTUDO SOBRE FALHAS EM MOTORES DE INDUÇÃO

Neste capítulo será abordado o tema de falhas em motores elétricos, mostrando estudos que evidenciem a importância das pesquisas na área e que tragam fundamentação para este trabalho.

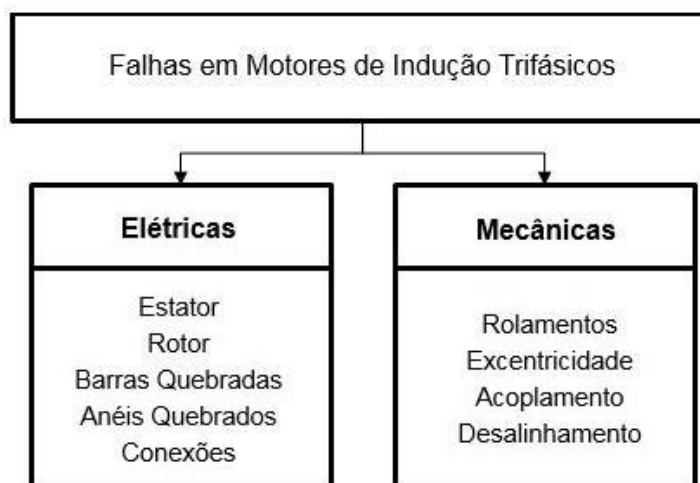
2.1 Condições de Falha em Motores de Indução

Motores elétricos estão presentes em diversas cadeias produtivas, atendendo à variados propósitos e aplicações nas indústrias e sendo utilizados de forma onipresente em qualquer segmento de manufatura. Com o crescimento rápido e o aprimoramento da ciência e da tecnologia e o desenvolvimento das indústrias modernas, as máquinas são operadas diariamente para diversas aplicações, sendo algumas destas operações conduzidas em condições desfavoráveis, promovendo a degradação da máquina e conseqüentemente do processo produtivo (NEUPANE; SEOK, 2020).

Pode-se verificar que os motores elétricos estão sujeitos a diversos tipos de falhas em seus componentes, havendo uma ampla gama de defeitos possíveis. É possível citar, por exemplo, enrolamento de estator aberto ou em curto circuito, quebra de barras ou de anéis de rotor do tipo gaiola de esquilo, danos nos rolamentos e até mesmo a falha dos componentes que servem para o acionamento e controle destas máquinas (BELLINI *et al.*, 2008).

As falhas em motores de indução trifásicos podem ser divididas em dois grandes grupos, sendo estes das falhas elétricas e das falhas mecânicas (BELLINI *et al.*, 2008; GODOY *et al.*, 2015; BAZAN, 2016). Esta divisão pode ser conferida na Figura 1.

Figura 1 - Tipos de falhas presentes nos motores de indução trifásicos



Fonte: Adaptado de Bazan (2016)

No contexto de falhas mecânicas, destaca-se os rolamentos como componentes importantes no estudo das falhas em motores de indução, uma vez que em Bellini *et al.* (2008) e Bonnett e Yung (2008) descreve-se que as falhas de rolamentos representam cerca de 51% das falhas em motores de indução em um contexto geral, e cerca de 69% das falhas em motores quando se analisa somente os componentes destas máquinas, tais como rotor, eixo, enrolamentos e os próprios rolamentos.

Alguns dos fatores que contribuem para a danificação de rolamentos e que influenciam no aumento de falha destes componentes e conseqüentemente dos motores são a contaminação e corrosão por agentes físicos ou químicos, falta ou excesso de lubrificação e até a instalação inadequada destes rolamentos no motor (NANDI; TOLIYAT; LI, 2005).

Conforme descrito em Blodt *et al.* (2008) e Gongora *et al.* (2016), as falhas no rolamento podem ser consideradas distribuídas ou localizadas, podendo-se dizer que as distribuídas são falhas que afetam uma região inteira do rolamento e mais relacionadas ao desgaste das pistas de anel externo ou interno; e as localizadas mais relacionadas à ocorrência de falha em um único ponto do rolamento, presentes com maior frequência nas gaiolas e esferas mas também podendo ocorrer nas pistas externas ou internas.

A fim de identificar e diagnosticar as falhas em motores de indução, diversas metodologias surgem para o auxílio nestas tarefas através da extração de

características de dados coletados de motores. O sensoriamento de grandezas tem grande papel nesta etapa, podendo-se citar o uso da corrente de estator como feito em Gongora *et al.* (2016), Bazan (2006), Leme (2017) e Esfahani, Wang e Sundararajan (2014); o uso de sinais de vibração tal como em Wang *et al.* (2020), Leme (2017), Esfahani, Wang e Sundararajan (2014); além de outras.

2.2 Diagnóstico de Falhas em Motores de Indução

Dentro do campo de estudo de falhas em motores, pode-se encontrar diversos estudos e métodos propostos para o diagnóstico de falhas já presentes nestas máquinas ou que estão na iminência de serem provocadas. Pode-se citar como exemplos o uso e a análise dos sinais de corrente do motor, ou em inglês *Motor Current Signature Analysis (MCSA)*, uso da temperatura, da vibração e entre outras grandezas.

A adoção de estratégias para o diagnóstico inicia-se na coleta de sinais do motor, sendo possível adotar uma vertente de multissensoriamento com diversos tipos de sensores para diferentes grandezas acoplados à máquina, ou uma que englobe a utilização de somente uma grandeza mapeada através de um ou mais sensores do mesmo tipo.

Como exemplo de multissensoriamento, pode-se citar o trabalho realizado em Esfahani, Wang e Sundararajan (2014), onde foi feito o sensoriamento da corrente, do som e da vibração de motores de indução a fim de classificar falhas relacionadas aos rolamentos e a excentricidade do rotor. Por outro lado, citando o sensoriamento de apenas uma grandeza, pode-se citar como exemplo os trabalhos feitos em Sakhalkar e Korde (2017) e Prieto *et al.* (2013), onde foram utilizados dados de vibração, ou o feito em Godoy *et al.* (2015) onde foram utilizados dados de corrente de estator.

O sensoriamento de uma grandeza específica pode trazer também dados relacionados a peças do motor de forma indireta. Como por exemplo, conforme citado em Esfahani, Wang e Sundararajan (2014), Blodt *et al.* (2008) e Schoen *et al.* (1995), frequências características das vibrações de rolamentos podem ser detectadas também nas frequências da corrente elétrica que alimenta o motor, já que a vibração leva a variações no torque do motor e que este reflete no comportamento das

correntes de estator, podendo então o espectro de frequências da corrente elétrica ser utilizado para detectar falhas em rolamentos.

Em Rai e Mohanty (2007) foram utilizados somente sinais de vibração de um motor de indução em operação com 30 Hz de rotação do eixo, sendo desenvolvida uma metodologia com a HHT para avaliação desta técnica para verificar os reflexos de falhas em rolamentos nos respectivos sinais de vibração do motor em operação. Foi demonstrada a robustez da transformada para se fazer uma verificação dos sinais de vibração no domínio da frequência, uma vez que foi feita a FFT de algumas IMFs extraídas do sinal de vibração original.

O próximo passo para o diagnóstico constitui a estratégia de tratamento de dados e extração de características a fim de evidenciar diferenças entre sinais de operação de motores, como por exemplo possibilitar a diferenciação entre um motor sem defeitos e outro com alguma peça defeituosa. Trabalhos publicados abordam diversas vertentes para a realização deste tratamento de dados, podendo-se analisar os dados no domínio do tempo, no domínio da frequência ou até no domínio do tempo-frequência, onde tem-se o objetivo de extrair as características dos sinais posteriormente.


Dentre algumas das técnicas difundidas para o tratamento de sinais pode-se citar o uso da Transformada Rápida de Fourier, como usada em Sakhalkar e Korde (2017) e em Rai e Mohanty (2007), a Transformada Wavelet conforme mostrado em Bayram e Seker (2017), ou até mesmo a combinação de técnicas como em Esfahani, Wang e Sundararajan (2014) onde foram utilizadas a Transformada de Hilbert-Huang e a Transformada Rápida de Fourier.

Por fim, pode-se utilizar técnicas de sistemas inteligentes para classificação de padrões destes dados. A área conhecida como sistemas inteligentes ou inteligência computacional é composta por uma série de técnicas, podendo-se citar as redes neurais artificiais, sistemas fuzzy, computação evolutiva e entre outras (SILVA; SPATTI; FLAUZINO, 2016).

Pode-se utilizar também de técnicas de *Deep Learning*, que conforme citado em Neupane e Seok (2020), é um ramo das técnicas de *Machine Learning* baseadas em redes neurais artificiais que permitem que modelos computacionais compostos de várias camadas de processamento aprendam o comportamento de dados com múltiplos níveis de abstração.

Na Figura 2 pode-se conferir um esquemático com os passos descritos até o momento da metodologia observada em trabalhos para o diagnóstico de falhas de motores elétricos com ferramentas de aprendizagem de máquinas.

Figura 2 - Descrição de processo para diagnóstico de falhas



Fonte: Autoria Própria

A abordagem realizada em Esfahani, Wang e Sundararajan (2014) além de incluir a extração de características por meio de diversas técnicas, também utilizou um modelo de classificador de análises discriminantes quadráticas, ou em inglês *Quadratic Discriminant Analysis* (QDA), para fazer a classificação de motor sem falhas ou com falhas em excentricidade ou rolamentos. Após isso, foi utilizada uma Máquina de Vetores de Suporte para a identificação de cada variante destas falhas, realizando a discriminação de falhas estáticas e dinâmicas de excentricidade, relacionadas à instalação e a rotação do rotor respectivamente, e falhas em pistas, gaiola, lubrificação ou múltiplos defeitos em caso de rolamento.

Em Prieto *et al.* (2013) pode-se conferir uma abordagem dada a sinais de vibração no domínio do tempo, sendo extraídas 15 características diferentes do sinal no domínio do tempo em cada um dos eixos X e Y de instalação dos sensores de vibração. Realizou-se neste trabalho uma análise discriminante para selecionar as 6 características mais interessantes para o treino de uma RNA do tipo Base Radial e para a parametrização de um Analisador de Componentes Curvilíneos, ou *Curvilinear Component Analysis* (CCA), sendo as saídas destas ferramentas os dados utilizados em uma Rede Neural Adaline que fornecerá as informações a serem classificadas por uma RNA Perceptron Multicamadas, promovendo assim o uso de redes neurais em série.

Em Godoy *et al.* (2015), por exemplo, foi realizada a classificação de falhas de curto circuito em enrolamentos de estator de motores de indução alimentados por inversores a partir do uso de sinais elétricos do motor no domínio do tempo e de

técnicas de aprendizagem de máquina diferentes, sendo elas a RNA Perceptron Multicamadas, a Máquina de Vetores de Suporte e a Rede Fuzzy ARTMAP. Pode-se observar que a classificação utilizando as redes Perceptron Multicamadas apresentaram uma porcentagem maior de acerto em todos os resultados coletados, sendo a Fuzzy ARTMAP que apresentou os piores resultados e as Máquinas de Vetores de Suporte obtendo os resultados intermediários.

Em Bazan (2016) foi feita uma metodologia que calcula a informação mútua atrasada dos sinais de corrente de alimentação de motores de indução e então utiliza estes dados para predição de classes de falha com algoritmos de Árvore de Decisão e a RNA Perceptron Multicamadas, a fim de comparar os dois classificadores. Pode-se verificar que ambas as abordagens trouxeram acurácias acima de 83,09% de acerto, mostrando que estas ferramentas de classificação se apresentam como possíveis formas de classificar falhas em motores.

Em Yu (2011) é apresentada uma abordagem que envolve Redes Neurais de Mapa Auto-Organizável a fim de classificar sinais de vibração de rolamentos em um treinamento não supervisionado. Para isso, são utilizadas as características pela análise do sinal no tempo de RMS, curtose, distorção, fatores de crista, impulso e margem, e valor pico a pico; e do sinal na frequência da relação de potência da frequência defeituosa máxima para a média.

Em Ali *et al.* (2019) foi realizada uma abordagem com ferramentas de busca por correspondência, ou *matching pursuit* do inglês, e Transformada Wavelet Discreta, ambas usadas para a extração de características de sinais de corrente e vibração adquiridos de motores de indução. No trabalho, são utilizadas ferramentas de classificação de Máquinas de Vetor de Suporte, KNN e classificação de conjuntos, podendo-se verificar boas acurácias para a maioria dos classificadores utilizados.

No estudo apresentado em Neupane e Seok (2020) é mostrada uma revisão de trabalhos nos quais foram utilizadas técnicas de *Machine Learning* e *Deep Learning* nos bancos de dados CWRU, sendo elas a Rede Auto Encoder e Auto Encoder Modificada, Rede Neural Convolucional, Rede de Crença Profunda, Rede Adversária Generativa, Rede Neural Recorrente e Método de Aprendizagem por Reforço. Nos trabalhos revisados, foi constatada uma acurácia acima de 83% das metodologias adotadas, conforme a revisão.

2.3 Conclusão do Capítulo

Neste capítulo foram apresentados trabalhos que retratam as condições de operação e falha de motores elétricos a fim de apontar aspectos importantes para o tema. Foram mostradas também algumas metodologias desenvolvidas em estudos para a classificação e identificação de padrões da operação de motores de indução a partir de técnicas de Inteligência Artificial.

Nota-se a importância da extração de características de operação da máquina, uma vez que estas podem evidenciar uma possível operação defeituosa destes motores.

No próximo capítulo serão apresentadas informações sobre o banco de dados de vibração de motores que será utilizado neste trabalho, mostrando também trabalhos que já se utilizaram dele e de outros repositórios disponíveis na *Internet*.

3 BANCOS DE DADOS EM REPOSITÓRIOS ONLINE

Neste capítulo serão apresentados os bancos de dados utilizados no presente trabalho adquiridos pelo repositório da *Case Western Reserve University*, bem como alguns trabalhos que já utilizaram estes dados em suas pesquisas. Um dos objetivos dessa análise é verificar os tratamentos de dados utilizados nos trabalhos.

3.1 Informações Referentes ao Banco de Dados da Case Western Reserve University

A seguir serão apresentadas informações pertinentes sobre o repositório da CWRU. Algumas informações foram extraídas de trabalhos já realizados, e estas serão devidamente destacadas como tal.

O *site* do banco de dados da CWRU provê acesso a dados de teste em rolamentos de esfera para rolamentos saudáveis e defeituosos. Em descrição dada no próprio *site*, estes experimentos de coleta de vibração de rolamentos de motor foram iniciados a fim de caracterizar a performance do IQ PreAlert, um sistema desenvolvido pela Rockwell para avaliação da condição do rolamento de motores (CASE WESTERN RESERVE UNIVERSITY, 2021).

A coleta de dados de vibração foi realizada utilizando acelerômetros acoplados com bases magnéticas na posição de 12 horas na extremidade frontal (lado de carga) e traseira (lado de ventoinha) da carcaça do motor, sendo que para alguns casos foi utilizado também um acelerômetro na base do motor. Especifica-se que foram utilizadas duas taxas de amostragem diferentes, 12 kHz e 48 kHz, sendo que somente alguns dos dados coletados pelo acelerômetro do lado frontal foram amostrados na frequência mais alta especificada (CASE WESTERN RESERVE UNIVERSITY, 2021).

A divisão dos arquivos é feita por meio de *links* que encaminham para os testes feitos. No caso, foram divididos os arquivos em “Dados Base Normais”, “Dados de Rolamentos de Carga Quebrados 12k”, “Dados de Rolamentos de Carga Quebrados 48k” e “Dados de Rolamentos de Ventoinha Quebrados”.

Analisando os arquivos de dados, pode-se constatar os descritivos “DE”, “FE” e “BA” nos arquivos de vibração, que se referem aos dados coletados dos acelerômetros instalados na extremidade da frente (*Drive End*), da traseira (*Fan End*)

e base respectivamente. Quase todos os arquivos disponíveis contam com os dados de acelerômetros frontal e traseiro, sendo separados pelos descritivos.

Ao abrir um arquivo de alguma falha específica pode-se encontrar os dados coletados dos acelerômetros instalados na frente e na traseira e o valor da velocidade de rotação do eixo coletado através do transdutor de torque que foi inserido manualmente no arquivo.

Foram contabilizados um total de 161 *links* de conjuntos de dados, sendo somente 4 de dados de vibração de motores com rolamentos saudáveis. Dentre os 157 de falhas, pode-se separar entre grupos de 40 *links* de falhas em pista interna, 77 de pista externa e 40 de esferas. Vale ressaltar que cada *link* possui os dados dos acelerômetros instalados nas extremidades frontal e traseira, alguns possuindo ainda os dados do acelerômetro da base do motor.

Cada ensaio foi feito em condições de carga no eixo diferentes, podendo-se verificar que estes foram realizados com torques de 0 até 3 HP. Ou seja, para cada condição de quebra do rolamento, há também a mudança de carga de um ensaio para outro.

É possível conferir na Tabela 1 a discriminação dos dados contida no *site* de forma mais detalhada com relação aos locais de falha dos rolamentos. Nos casos destacados de pista externa verifica-se os posicionamentos da falha nesta pista com relação a zona de carga, tendo rolamentos com falha centralizada, ortogonal e oposta à zona de carga.

Tabela 1 – *Links* disponíveis de falhas nos componentes de cada rolamento


Rolamento/ Amostragem	Pista Interna	Esferas	Pista Externa (Centralizado)	Pista Externa (Ortogonal)	Pista Externa (Oposta)
Frontal – 48k	12	12	12	8	8
Frontal – 12k	16	16	12	8	8
Traseiro – 12k	12	12	6	11	4

Fonte: Autoria Própria

Entretanto, o *site* não dispõe de maiores informações sobre os equipamentos. Somente é possível ver a bancada montada com componentes utilizados para os ensaios, como um motor elétrico de 2HP Reliance, um transdutor/encoder de torque e um dinamômetro, podendo estes serem visualizados na Figura 3. Importante

destacar que os controladores eletrônicos dos componentes não constam na foto, sendo somente citadas a existência de tais equipamentos sem maiores informações.

Figura 3 - Bancada de testes utilizada para os ensaios da CWRU



Fonte: Adaptado de Case Western Reserve University (2021)

As falhas nos rolamentos foram causadas propositalmente utilizando uma máquina de descarga elétrica, e o processo foi realizado de forma a provocar erosões pontuais em cada parte do rolamento de forma individual, sendo padronizados os diâmetros de cada falha para cada rolamento. Vale ressaltar que no caso específico das falhas em pista externa, o rolamento com este dano foi instalado em locais diferentes em três diferentes ensaios, ou seja, o rolamento foi instalado com o dano em uma posição de 3 horas diretamente na zona de carga, de 6 horas ortogonal à zona de carga e à 12 horas.

Alguns arquivos de falhas não estão disponíveis, como por exemplo os realizados com um diâmetro de 0,7112 mm que foram feitos somente em pista interna e esferas de rolamentos frontais, especificamente na taxa de amostragem de 12 kHz. Na Tabela 2 são apresentados os dados referentes aos rolamentos instalados na frente do motor, em seu eixo de carga.

Tabela 2 - Falhas e componentes de cada rolamento da extremidade frontal

Diâmetro x Profundidade da Falha (em milímetros)	Locais de Falha	Fabricante
0,1778 x 0,2794	Pista Interna, Pista Externa, Esferas	SKF
0,3556 x 0,2794	Pista Interna, Pista Externa, Esferas	SKF
0,5334 x 0,2794	Pista Interna, Pista Externa, Esferas	SKF
0,7112 x 1,27	Pista Interna	NTN
0,7112 x 3,81	Esferas	NTN
1,016 x 1,27	Pista Externa	NTN

Fonte: Case Western Reserve University (2021)

Seguindo a mesma lógica da Tabela 2, pode-se observar na Tabela 3 os dados referentes aos rolamentos instalados na traseira do motor, do lado da ventoinha. Estes também foram expostos ao procedimento e tiveram falhas instaladas em suas peças.

Tabela 3 - Falhas e componentes de cada rolamento da extremidade traseira

Diâmetro x Profundidade da Falha (em milímetros)	Locais de Falha	Fabricante
0,1778 x 0,2794	Pista Interna, Pista Externa, Esferas	SKF
0,3556 x 0,2794	Pista Interna, Pista Externa, Esferas	SKF
0,5334 x 0,2794	Pista Interna, Pista Externa, Esferas	SKF

Fonte: Case Western Reserve University (2021)

Além disso, o *site* ainda disponibiliza alguns dos modelos exatos dos rolamentos e suas dimensões, e as supostas frequências de defeito múltiplas da velocidade de operação dos motores. Estas frequências serão recalculadas e utilizadas no presente trabalho para a avaliação de sinais e de alguns dos métodos propostos.

Os rolamentos mais utilizados na coleta dos bancos de dados tanto na frente quanto na traseira do motor são, respectivamente, dos modelos 6205-2RS JEM SKF e 6203-2RS JEM SKF, sendo citado o uso de um rolamento da NTN mas sem informar o seu modelo.

As dimensões de cada rolamento identificado e descrito podem ser conferidas na Tabela 4, sendo alguns destes dados não disponíveis no *site* da CWRU, fazendo-se necessário buscar as informações faltantes em *sites* da fabricante SKF.

Tabela 4 - Dimensões de cada tipo de rolamento

Modelo	Diâmetro Interno (mm)	Diâmetro Externo (mm)	Diâmetro da Pista (mm)	Diâmetro das Esferas (mm)	Ângulo de Contato (°)	Nº de Esferas
6205-2RS JEM SKF	25	52	39,0398	7,94	0	9
6203-2RS JEM SKF	17	40	28,5	6,7462	0	8

Fonte: Case Western Reserve University (2021), SKF (2022) e SKF (2022)

As frequências de defeito múltiplas descritas anteriormente e que foram fornecidas no site são apresentadas na Tabela 5. A fim de conferir estes dados, posteriormente serão feitos cálculos das frequências das falhas dos rolamentos com o intuito de se verificar os aspectos metodológicos adotados.

Tabela 5 - Frequências de defeito múltiplas de cada rolamento da CWRU

Modelo	Anel Interno (Hz)	Anel Externo (Hz)	Gaiola (Hz)	Elemento Rolante (Hz)
6205-2RS JEM SKF	5,4152	3,5848	0,39828	4,7135
6203-2RS JEM SKF	4,9469	3,053	0,3817	3,9874

Fonte: Case Western Reserve University (2021), SKF (2022) e SKF (2022)

As frequências de defeito múltiplas são as frequências características das peças de cada um dos rolamentos. Diz-se múltiplas porque para verificar a frequência de vibração específica da operação de um rolamento, deve-se agregar o valor da velocidade de giro do eixo do motor ao cálculo.

Devido ao fato de a velocidade de rotação do eixo de cada ensaio ser diferente, fica difícil estabelecer um padrão e apontar que nos ensaios com determinada carga no eixo a sua velocidade será sempre a mesma para todos eles. Porém, com o intuito de fazer uma avaliação mais minuciosa dos dados, alguns dos bancos serão analisados e suas frequências características apontadas respectivamente nos resultados.

Vale pontuar que os bancos não tem o mesmo tamanho de amostras, o que dificulta o processamento dos dados de forma uniforme e acaba exigindo o *download*, a abertura e a extração de cada um dos arquivos de forma individual.

3.2 Estudos Utilizando Bancos de Dados em Repositórios Online

No presente item deste trabalho, será possível ter pontos de referência sobre as metodologias aplicadas em trabalhos envolvendo estes bancos de dados citados anteriormente, ou relacionados aos desenvolvedores destes bancos.

A bancada mencionada no site da CWRU e mostrada na Figura 3 foi utilizada em Ocak e Loparo (2004) num estudo que envolveu o desenvolvimento de dois algoritmos para estimar a operação de rolamentos, sendo que um estimou a velocidade de rotação de um rolamento instalado em um eixo de um motor e outro estimou o diâmetro de pista de rolagem e o diâmetro e número das esferas de um rolamento, tudo através dos sinais de vibração do rolamento em operação. Verificou-se também neste trabalho a possibilidade da identificação das frequências de falha dos componentes dos rolamentos a partir dos valores estimados, calculando-se estas frequências.

O uso de repositórios de bancos de dados públicos mostra-se como uma ferramenta nos estudos de motores de indução. Em Neupane e Seok (2020), onde foi feita uma revisão de trabalhos envolvendo os bancos de dados da CWRU, é possível verificar a existência de outros repositórios além deste, tais como o Paderborn University Dataset, FEMTO Dataset, MFPT Dataset e o IMS Dataset. Pode-se citar também o banco de dados *XJTU-SY* apresentado em Wang *et al.* (2020) e em Wang e Lei (2021).

Em Smith e Randall (2015), pontua-se que os dados da CWRU se mostram como uma referência na área de falhas em rolamentos, uma vez que na última década os estudos vem se utilizando destas informações para testar seus algoritmos. Vale citar que neste trabalho foi feito um estudo sobre os dados da CWRU, aplicando-se métodos de análise de dados com a intenção de se avaliar o repositório, citando, por exemplo, a existência de sinais não estacionários e fazendo recomendações para trabalhos futuros envolvendo estes bancos de dados, uma vez que foram identificados sinais no banco que não puderam ser diagnosticáveis pelas ferramentas utilizadas.

No trabalho realizado em Wen, Gao e Li (2019), foram utilizados os dados coletados dos rolamentos frontais do motor disponíveis no repositório da CWRU, mais especificamente os dados que contém as condições normais de operação e de falhas em 0,18, 0,36 e 0,54 mm, com os quatro tipos de cargas disponíveis e amostrados em

12 kHz, sendo a ferramenta aplicada para o tratamento das informações desejadas a *Deep Transfer Learning* (DTL).

Em Neupane e Seok (2020) é feita uma revisão de trabalhos que utilizaram os dados da CWRU, mais especificamente dos dados referentes aos defeitos do rolamento da frente do motor e dos dados normais sem falhas, e que envolveram algoritmos de *Machine Learning* e *Deep Learning* para a detecção e diagnóstico de falhas em motores. Por se tratar de uma análise de diferentes trabalhos, pode-se verificar pela apresentação feita nesta revisão que os algoritmos destes trabalhos demonstraram taxas de acurácia diferentes, dependendo de cada metodologia e ferramental adotados, variando entre 84,2% até 100%.

Em Jiang *et al.* (2020), propõem-se uma abordagem para um modelo robusto baseado nas ferramentas *Student's t-hidden Markov model* (*Student's t-HMM*) e *Nuisance Attribute Projection* (*NAP*), com o intuito de avaliar o processo de degradação de objetos, utilizando o banco de dados *XJTU-SY* para validar os resultados obtidos experimentalmente.

O trabalho de Zhao *et al.* (2020) se utilizou dos bancos de dados da *CWRU* e da *XJTU-SY* como referências na condução de seus estudos para o desenvolvimento de uma metodologia baseada em Mapeamento de Espaço e *Deformable Convolution Networks* (*DCN*), fazendo o tratamento dos dados através da combinação de algumas ferramentas e se utilizando dos dados dos bancos para fazer o treinamento e a validação do sistema proposto.

3.3 Conclusão do Capítulo

Foram apresentadas neste capítulo informações sobre o uso de bancos de dados em pesquisas e estudos científicos, sendo que estes bancos podem ser acessados por qualquer usuário da internet. Estes trabalhos apresentam abordagens diferentes, porém nota-se que a aplicação de métodos baseados em inteligência artificial são difundidos na maioria.

Devido ao interesse de utilizar os dados oferecidos pelo banco da *CWRU*, realizou-se a introdução teórica e o levantamento de informações mais pertinentes a este banco. No próximo capítulo serão descritas informações importantes acerca da metodologia que se pretende adotar neste trabalho.


4 METODOLOGIA PROPOSTA

Neste capítulo será apresentada a metodologia proposta para o tratamento dos dados e a aquisição das suas características, além da elaboração de um método para classificação das informações adquiridas.

Os rolamentos são compostos por diversas partes mecânicas que podem apresentar falhas, como pode-se observar na abordagem dada na seção 3.1 onde foram mostrados diferentes tipos de falhas no banco de dados de interesse deste trabalho. Neste banco de dados da CWRU, as falhas nas diferentes partes dos rolamentos são pontuais, ou seja, ocorreram em um único ponto de alguma peça do rolamento, seja em pista externa, pista interna ou esferas. Segundo Esfahani, Wang e Sundararajan (2014), estes defeitos pontuais em componentes do rolamento podem gerar frequências de vibração muito específicas destas peças, as quais consequentemente fazem o rolamento vibrar também e que podem ser identificadas.

Na Figura 4, pode-se conferir um rolamento de elementos esféricos comum com suas peças componentes, conforme Onel e Benbouzid (2008).

Figura 4 - Esquemático de componentes de um rolamento



Fonte: Adaptado de Onel e Benbouzid (2008)

Conforme mostrado no capítulo 3, a CWRU fornece um total de 161 *links* de *download*, sendo que cada um destes possui os dados dos acelerômetros instalados

na extremidade da frente, de trás e em alguns casos na base do motor. Tomou-se como padrão para o trabalho utilizar somente os dados do acelerômetro frontal.

Porém, pode-se observar que somente 4 dos 161 *links* são referentes ao motor sem problemas nos rolamentos. É possível constatar que há uma quantidade de cerca de 39 vezes maior dos dados com falhas, o que não é interessante para uma avaliação gráfica ou ainda para uma RNA classificar. Por este motivo foram exploradas estratégias para um melhor aproveitamento dos dados saudáveis.

Uma primeira ação feita foi a de comparar os dados do acelerômetro frontal e traseiro dos rolamentos saudáveis, sendo possível constatar que os sinais de ambos os acelerômetros mostravam semelhanças de amplitude. Com isso tomou-se a decisão de utilizar estes dados coletados pelo acelerômetro traseiro, aumentando para 8 o número de sinais.

Porém, constata-se que ainda há um número muito grande de sinais de falha quando comparados aos saudáveis. Por esta razão, os sinais saudáveis foram divididos em vários sinais de 1 segundo, fazendo com que, por exemplo, um sinal com duração de 10 segundos seja convertido em dez sinais de um segundo cada, resultando em 155 sinais de rolamento saudável.

O próximo passo para o desenvolvimento do trabalho foi a avaliação visual dos sinais através de alguma técnica que permitisse verificar e evidenciar a eficácia da EMD, pois deseja-se extrair a IMF que apresente a parte do sinal que contenha as frequências mais próximas das frequências de falha características. Com isso, a FFT foi utilizada para analisar os resultados da EMD e verificar a existência destas frequências, devido ao fato desta ferramenta trazer resultados mais simples para visualização gráfica. Por fim, a análise apontou para a escolha da IMF5 da EMD de cada sinal para ser utilizada na extração de características, sendo esta etapa descrita com maiores detalhes no capítulo 5.

Por fim, os resultados finais serão destacados em dois blocos:

- O primeiro mostrará identificação das falhas através de gráficos, ou seja, será feita a análise das características extraídas das IMF5 com o intuito de verificar se alguma característica tem maior potencial de discriminação entre rolamentos quebrados ou saudáveis e das falhas em específico posteriormente;

- O segundo focará na classificação propriamente dita das diferentes condições dos rolamentos, mostrando as abordagens de RNA com duas funções de ativação diferentes, a logística e a Softmax.

Pode-se conferir um organograma das etapas do trabalho na Figura 5, onde é possível ver o passo a passo executado neste trabalho. A etapa de extração de características e detecção das falhas será a primeira destacada nos resultados, seguida então da classificação das falhas por RNAs.

Figura 5 – Organograma de execução do trabalho



Fonte: Autoria Própria

Após a última etapa mostrada no organograma, serão feitas as considerações finais sobre o trabalho e sugestões para trabalhos futuros. Os algoritmos utilizados no trabalho foram desenvolvidos através do *software* MatLab.

4.1 Métodos Matemáticos para Cálculo de Frequências de Falhas

As falhas dos rolamentos em localizações pontuais em suas partes podem apresentar uma frequência de vibração específica, sendo possível a realização do cálculo destas frequências através de métodos matemáticos e que são amplamente utilizados e citados em diversos trabalhos. Uma metodologia possível para abordar estas vibrações é através do cálculo das frequências de vibração de alguns dos componentes de um rolamento, conforme apresentado em Blodt *et al.* (2008), Soualhi, Medjaher e Zerhouni (2015) e Esfahani, Wang e Sundararajan (2014).

Conforme o exposto, pode-se calcular, por exemplo, a frequência de falha na pista interna f_{pi} através da Equação (1), onde D_p é o diâmetro da gaiola, ou do caminho médio percorrido pelas esferas, D_b é o diâmetro das esferas, f_r é a velocidade de rotação do motor em frequência, θ é o ângulo de contato das esferas com as pistas e n_b o número de esferas.

$$f_{pi} = \frac{n_b}{2} \cdot f_r \cdot \left[1 + \frac{D_b}{D_p} \cdot \cos \theta \right] \quad (1)$$

Pode-se citar também a Equação (2), que trata de calcular a frequência de falha na pista externa f_{pe} .

$$f_{pe} = \frac{n_b}{2} \cdot f_r \cdot \left[1 - \frac{D_b}{D_p} \cdot \cos \theta \right] \quad (2)$$

Para o cálculo da frequência de falha nas esferas f_{es} , pode-se utilizar a Equação (3).

$$f_{es} = \frac{D_p}{D_b} \cdot f_r \cdot \left[1 - \frac{D_b^2}{D_p^2} \cdot \cos^2 \theta \right] \quad (3)$$

Mais especificamente em Neupane e Seok (2020), o estudo abrange as equações (1) e (2) mencionadas anteriormente e traz também uma abordagem para o cálculo da frequência de falha f_{cg} da gaiola do rolamento, na Equação (4).

$$f_{cg} = \frac{f_r}{2} \cdot \left[1 - \frac{D_b}{D_p} \cdot \cos \theta \right] \quad (4)$$

A frequência de velocidade f_r , ou rotações por segundo, pode ser obtida através da Equação (5), sendo n a rotação do eixo do motor em rotações por minuto.

$$f_r = \frac{n}{60} \quad (5)$$

A partir destas equações e dos dados expostos na Tabela 4, na seção 3.1, pode-se então prosseguir com os cálculos dos valores das frequências de falha, contando a possibilidade de comparar os resultados com os valores já mostrados pelo banco de dados da *CWRU* para seus respectivos rolamentos.

Em teoria, deve ser possível identificar componentes de amplitude considerável para os correspondentes valores de frequência calculados por meio destas equações, principalmente quando se tratar dos rolamentos com falhas. Deve-se, porém, ter atenção no uso deste método, já que estes valores das frequências podem variar devido a diversos fatores, especialmente com a variação da velocidade do eixo, algo que pode dificultar na análise dos sinais já que no caso dos bancos da *CWRU* cada sinal foi feito com uma velocidade de giro de rotor diferente.

4.2 Transformada de Hilbert-Huang

Conforme visto em itens anteriores, o uso da análise em frequência mostra-se como uma possível ferramenta na análise dos sinais de vibração, uma vez que os espectros de frequência destes dados podem ser extraídos por meio de diversas ferramentas, sendo uma destas a Transformada de Hilbert Huang que permite a análise de um sinal não somente no domínio da frequência, mas também no domínio do tempo.

Conforme apresentado em Saidi, Ali e Fnaiech (2014), sinais de vibração de rolamentos são quase sempre não estacionários, uma vez que estes equipamentos apresentam comportamentos inerentemente dinâmicos devido a suas mudanças de velocidade e carga. Segundo Yan e Gao (2006), sinais de vibração estacionários e não estacionários podem ser encontrados em motores elétricos, sendo os não

estacionários de natureza “transitória”, com duração geralmente mais curta do que o intervalo de observação, sendo a quebra de uma pista de um rolamento um exemplo de fonte de sinais com essa característica.

Há na literatura estudos que mostram a possibilidade de trabalhar com sinais de vibração por meio de análises com a *FFT*, a *HHT* ou até as Transformadas Wavelet. Neste trabalho será abordada a Transformada de Hilbert-Huang.

Em Huang *et al.* (1998) e Yan e Gao (2006), define-se que a HHT representa uma análise de um sinal no domínio do tempo-frequência através da combinação da *Empirical Mode Decomposition* (EMD) com a Transformada de Hilbert.

Esta ferramenta, proposta em Huang *et al.* (1998), consiste em uma metodologia baseada na análise de dados não lineares e não estacionários, sendo a chave do método da EMD, ou Decomposição em Modos Empíricos em português. A EMD pode decompor conjuntos de dados em um número finito de *Intrinsic Mode Functions* (IMFs), ou Funções de Modo Intrínseco em português, que admitem Transformadas Hilbert mais comportadas em relação às frequências instantâneas, já que a EMD provoca uma filtragem das frequências mais altas de um sinal.

Os resultados finais desta transformada são distribuições em energia-frequência-tempo, também chamadas de Espectro de Hilbert, sendo a grande vantagem deste método a introdução e o uso das frequências instantâneas em conjuntos de dados de grande complexidade, sendo que isto pode remover a necessidade de harmônicas para representar sinais não estacionários e não lineares (HUANG *et al.*, 1998).

4.2.1 Decomposição em Modos Empíricos

A Decomposição em Modos Empíricos (EMD) consiste em uma técnica de decomposição de um sinal em um número de IMFs, e então utiliza-se destas funções para se aplicar a Transformada de Hilbert a fim de se adquirir o Espectro de Hilbert (HUANG *et al.*, 1998; YAN; GAO, 2006).

A aplicação da EMD é feita a partir de uma série de passos, seguindo um algoritmo para a aplicação das técnicas de forma iterativa. Segundo Huang *et al.* (1998) e Yan e Gao (2006), para se aplicar a EMD é necessário se basear em três suposições sobre o conjunto de dados alvo:

- O sinal possui, pelo menos, um máximo e um mínimo;

- A escala de tempo característica do sinal é definida pelo período de tempo entre os extremos, ou seja, entre os mínimos e máximos locais do sinal;
- Se os dados forem totalmente desprovidos de extremos, mas tiverem pontos de inflexão, então estes podem ser diferenciados uma ou mais vezes para revelar os extremos do sinal.

Conforme citado, a EMD é utilizada com o intuito de se obter IMFs. A essência do método é identificar os modos oscilatórios intrínsecos de sinais pelas suas características em uma escala de tempo e decompô-los de acordo com estes sinais. Uma IMF deve satisfazer duas condições (HUANG *et al.*, 1998):

- Em todo o conjunto de dados, o número de máximos e o número de cruzamentos em zero são iguais ou diferentes em no máximo um;
- Em qualquer ponto, o valor médio do envelope definido pelo máximo local e o envelope definido pelo mínimo local é zero.

Assim como demonstrado e citado em Huang *et al.* (1998) e Soualhi, Medjaher e Zerhouni (2015), a EMD decompõe o sinal em uma série de IMFs, onde a primeira destas é a decomposição da componente do sinal com o período mais curto e, conseqüentemente, a de maior frequência. O mesmo ocorre com as IMFs posteriores, ou seja, a cada peneiramento há a atenuação das componentes de maior frequência que ainda detêm alta amplitude apesar de já ter ocorrido peneiramentos. Com isso, as faixas de frequência contidas em cada IMF são diferentes de uma componente para outras de acordo com o sinal que será peneirado, sendo a identificação destas feita através da extração do Espectro Marginal de Hilbert da frequência e amplitude instantâneas das IMFs.

De fato, em outros trabalhos faz-se estas observações com relação aos efeitos da EMD para se encontrar as IMFs. Em Rai e Mohanty (2007) é apontado que as primeiras IMFs encontradas em seus trabalhos detêm as frequências mais altas, enquanto que o resíduo, ou a “última IMF” como é chamado, detêm as variações com taxa mais lenta, e portanto as frequências mais baixas.

Em Huang *et al.* (1998) e Boudraa e Cexus (2007) enfatiza-se que a Decomposição em Modos Empíricos não usa nenhum filtro ou função de wavelet pré determinada, sendo assim um método baseado puramente nos dados obtidos. Porém,

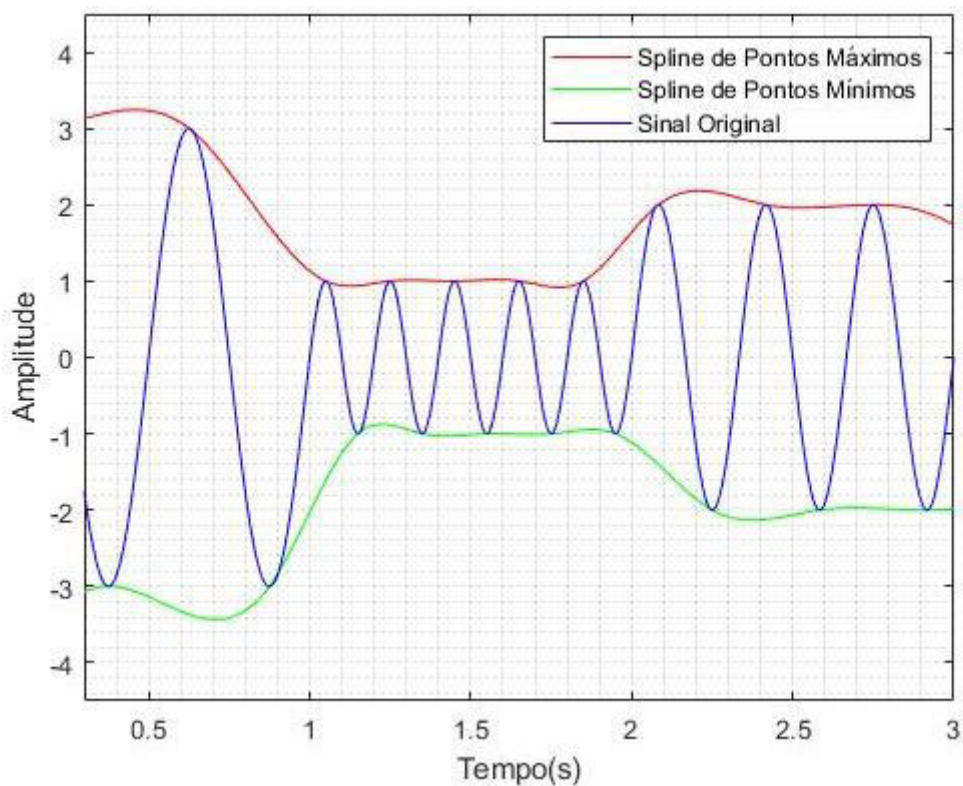
ainda em Boudraa e Cexus (2007) expõem-se que reduzir o ruído com a EMD é complicado devido ao fato de que o nível deste ruído do sinal é desconhecido.

A aplicação da EMD inicia-se com a identificação dos máximos e mínimos de um sinal $X(t)$. Em posse destes pontos, é feita uma interpolação de Linhas Splines Cúbicas deles, sendo uma Spline realizada para os pontos máximos e outra para os pontos mínimos, obtendo-se então duas curvas que percorrem os máximos e mínimos da função original. O próximo passo é extrair a média m_1 entre as Splines encontradas e subtraí-la do sinal original, formando então a componente h_1 , que é a primeira componente do peneiramento, conforme a Equação (6).

$$X(t) - m_1 = h_1 \quad (6)$$

A fim de exemplificar esta primeira etapa, a Figura 6 mostra um sinal gerado e as respectivas Splines dos pontos máximos e mínimos.

Figura 6 - Exemplo de splines cúbicas de máximos e mínimos de uma função



Fonte: Autoria Própria

Nesta etapa podem ocorrer overshoots e/ou undershoots no sinal, porém seus efeitos não são diretos para a média. Mesmo se o ajuste for perfeito, uma pequena elevação na inclinação pode ser ampliada para se tornar um extremo local (HUANG *et al.*, 1998). De fato, segundo Huang *et al.* (1998), algumas formas de onda assimétricas ainda podem existir, não importando quantas vezes os dados sejam peneirados, e esta aproximação deve ser aceita.

Se h_1 não for uma IMF, o processo de peneiramento terá sua continuação, sendo que em seu segundo passo h_1 será tratado como os dados propriamente ditos, e com isso, aplica-se a subtração deste com a sua média m_{11} extraída também através de suas Spline Cúbicas de pontos máximos e mínimos (HUANG *et al.*, 1998). Esta etapa da peneiração pode ser conferida na Equação (7).

$$h_1 - m_{11} = h_{11} \quad (7)$$

O processo de peneiração pode ser realizado k vezes, sendo que os fatores já citados referentes às características do sinal obtido como resultado da presente etapa e do peneiramento atual pode ser avaliado e tido como a IMF desejada ou não. De forma genérica, o processo de peneiramento pode ser descrito através da Equação (8).

$$h_{1(k-1)} - m_{1k} = h_{1k} \quad (8)$$

Obtém-se então, como resultado final dos peneiramentos realizados, a primeira componente c_1 de IMF a partir dos dados de entrada, conforme representado pela Equação (9).

$$c_1 = h_{1k} \quad (9)$$

O processo apresenta seu funcionamento como de fato um peneiramento, onde se separa os modos locais dos dados apenas na escala de tempo própria dos dados. Com isso, este processo apresenta os efeitos de eliminar ondas flutuantes e suavizar amplitudes desiguais, sendo que este último pode acabar por atenuar as flutuações de amplitude fisicamente significativas, e por isso é necessária cautela no

processo de peneiramento. Vale citar também que levar este processo de peneiramento a níveis extremos pode resultar em uma IMF com modulação em um sinal de frequência pura e amplitude constante (HUANG *et al.*, 1998).

Para garantir que as IMFs retenham sentido físico suficiente das modulações de amplitude e frequência frutos do processo de peneiramento, tem que ser determinado e utilizado um critério de parada, sendo que isso pode ser feito através do tamanho do desvio padrão DP calculado a partir de dois resultados de peneiramento consecutivos em todo o tempo T das funções (HUANG *et al.*, 1998). Esta formulação pode ser conferida através da Equação (10).

$$DP = \sum_{t=0}^T \left[\frac{|h_{1(k-1)}(t) - h_{1k}(t)|^2}{h_{1(k-1)}^2(t)} \right] \quad (10)$$

Seguindo conforme Huang *et al.* (1998), subtrai-se a IMF c_r dos dados de entrada ou após uma rodada de peneiramentos para se obter os resíduos r_n . Tais resíduos ainda contém informações das componentes de períodos mais longos com mais baixas frequências, e estes podem ser utilizados com o mesmo procedimento conforme a Equação (11).

$$r_{n-1} - c_n = r_n \quad (11)$$

Com isso, observa-se que o resíduo é definido como tal quando não há mais interesse de se extrair as IMFs ou quando o sinal resultante não satisfaz as condições para aplicação da EMD.

Um ponto importante a se comentar sobre o critério de parada por cálculo de desvio padrão DP é com relação à adoção de valores para a parada do peneiramento, mostrando que uma alternativa é a utilização de valores entre 0,2 e 0,3, apesar de não haver uma regra para isso (PINES; SALVINO, 2006; HUANG *et al.*, 1998).

Apesar de prática, a EMD contém limitações na teoria proposta inicialmente por Huang *et al.* (1998) que envolve as IMFs, uma vez que há dificuldade em satisfazer as duas condições para um sinal, após um peneiramento, ser classificado como uma IMF e ainda ter que satisfazer um critério de parada.

Em Pan e Li (2012), por exemplo, é destacada a dificuldade em satisfazer a segunda condição de uma IMF em aplicações práticas, uma vez que um valor médio igual a zero dos envelopes de energia para todo o tempo de um sinal é quase impossível de ser obtida. Uma alternativa apontada pelo mesmo trabalho é a de utilizar um valor de desvio padrão menos flexível que os apresentados em Huang *et al.* (1998), originalmente, como critério de parada dos peneiramentos.

Porém, não somente a condição relacionada aos envelopes de energia serem iguais a zero são as que causam controvérsias. Conseguir um sinal com o mesmo número de máximos e cruzamentos em zero ou com diferença igual a um também é algo a se notar. Trabalhos surgem então para tentar tratar destas problemáticas de forma mais cuidadosa, muitas vezes propondo novos métodos para se fazer o peneiramento de forma a conseguir IMFs por meios mais controlados e homogêneos.

Em Wang *et al.* (2010) é possível verificar outros trabalhos que discutem acerca da aplicação da EMD para obtenção das IMFs com base nas definições propostas em Huang *et al.* (1998), uma vez que os critérios para se obter as IMFs apresentam certas dificuldades para serem cumpridos em sua totalidade. Entre estes trabalhos, pode-se citar os desenvolvidos em Huang *et al.* (2003) da sequência S de peneiramentos e em Wu e Huang (2010) da fixação de peneiramentos.

Em Huang *et al.* (2003) é mostrada uma abordagem em que a EMD é executada até se obter uma quantidade S de peneiramentos consecutivos em que neles sejam satisfeitas as duas condições de uma IMF, que envolvem a média zero e o número de cruzamentos com os máximos. Este número S de peneiramentos deve ser definido pelo usuário da ferramenta.

Em Wu e Huang (2010) é realizado um estudo do comportamento dos peneiramentos promovidos pela EMD, sendo citada a possibilidade de fixar o número de peneiramentos realizados em um sinal, de acordo com a necessidade do usuário, e mostrando-se até mesmo a possibilidade de se obter um filtro diádico com a decomposição por meio desta estratégia.

4.2.2 Espectro de Hilbert

O próximo passo do método da HHT é a aplicação da Transformada de Hilbert para a obtenção do Espectro de Hilbert, que trará o significado físico da EMD (HUANG *et al.*, 1998).

O desenvolvimento da Transformada de Hilbert pode ser conferido conforme os passos a seguir da Equação (12) até a (20). De forma genérica, a Transformada de Hilbert $H[\]$ de um sinal arbitrário no tempo $x(t)$ pode ser definida conforme a Equação (12), podendo este sinal ser uma IMF e sendo P o valor principal de Cauchy (HUANG *et al.*, 1998; YAN; GAO, 2006).

$$H[x(t)] = y(t) = \frac{1}{\pi} \cdot P \cdot \int \frac{x(\tau)}{t - \tau} d\tau \quad (12)$$

Um sinal analítico $z(t)$ é um sinal de tempo complexo e que não possui frequências negativas em sua Transformada de Fourier (OPPENHEIM; SCHAFER, 2013). Este sinal pode ser expresso pela soma das suas componentes reais $x(t)$ e imaginárias $y(t)$, compondo então um par complexo conjugado (HUANG *et al.*, 1998; YAN; GAO, 2006).

A componente $y(t)$, conforme mostrado na Equação (13), é a própria Transformada de Hilbert da parte real do sinal. A representação do sinal analítico é feita na Equação (13).

$$z(t) = x(t) + j \cdot y(t) \quad (13)$$

Pode-se reescrever os termos anteriores no sistema de coordenadas polares, conforme a Equação (14), para se representar a amplitude instantânea $a(t)$ e a fase $\theta(t)$.

$$z(t) = a(t) \cdot e^{j \cdot \theta(t)} \quad (14)$$

O módulo de $a(t)$ é expresso como a raiz quadrada das somas dos quadrados das partes real e imaginária do sinal, conforme a Equação (15).

$$a(t) = \sqrt{x(t)^2 + y(t)^2} \quad (15)$$

De forma semelhante, pretende-se calcular a fase da função analítica, que é então encontrada através da Equação (16).

$$\theta(t) = \tan^{-1} \left(\frac{y(t)}{x(t)} \right) \quad (16)$$

Assim, para se obter a frequência instantânea $\omega(t)$ da fase da função analítica, calcula-se a derivada desta fase conforme a Equação (17).

$$\omega(t) = \frac{d(\theta(t))}{dt} \quad (17)$$

Conforme visto anteriormente da Decomposição em Modos Empíricos, pode-se representar o sinal original $x(t)$ conforme a Equação (18) abaixo, que somente demonstra que o somatório das IMFs com o resíduo é o sinal original.

$$x(t) = \sum_{i=1}^n c_i(t) + r_n(t) \quad (18)$$

Pode-se escrever a parte real do sinal $x(t)$ em termos da amplitude e da frequência instantânea como uma função dependente no tempo, conforme Equação (19), onde $\mathbb{R}(\cdot)$ denota a parte real da função analítica $z(t)$.

$$x(t) = \mathbb{R}(z(t)) = \mathbb{R}(a(t) \cdot e^{j \int \omega(t) dt}) \quad (19)$$

Utilizando-se das Equações (12) a (18), pode-se modificar (19) e chegar na Equação (20). O índice i diz respeito às n IMFs extraídas do sinal.

$$x(t) = \mathbb{R}(\sum_{i=1}^n a_i(t) \cdot e^{j \int \omega_i(t) dt}) \quad (20)$$

Como o MatLab detém ferramentas próprias para realizar a EMD, assim como realizar a Transformada de Hilbert-Huang, escolheu-se então fazer todo o processo de aplicação desta etapa da metodologia neste *software*.

O comando utilizado para executar a EMD no MatLab® é o “*emd*”, sendo possível extrair IMFs e o sinal de resíduo de acordo com os parâmetros adotados para

este fim, sendo possível também coletar as informações sobre cada IMF, como por exemplo, os valores médios de energia (MATHWORKS, 2021).

Para aplicação da HHT no MatLab®, utiliza-se o comando “*hht*” que retorna o Espectro de Hilbert, as frequências instantâneas e o tempo do sinal. Para isso, como parâmetros de entrada para a função deve-se escolher a IMF que se deseja extrair a HHT e a frequência de amostragem do sinal, sendo possível também limitar a faixa de frequências do sinal que se deseja extrair o espectro (MATHWORKS, 2021).

4.3 Extração de Características de Sinais de Vibração

Além do uso de ferramentas para análise em tempo e frequência, a identificação dos sinais obtidos pode ser otimizada também através da extração de características de forma matemática para facilitar no processo de diagnóstico e classificação. São recursos que podem ser ignorados, mas para uma aplicação computacional sem a intervenção humana no processo de reconhecimento tornam-se necessários.

Em Smith e Randall (2015), por exemplo, o procedimento posto visou elucidar quais sinais do banco da CWRU são passíveis de diagnóstico ou não a partir de análises de sinais por envelope de sinal cru, *Cepstrum Prewhitening* e pela separação aleatória e determinística de componentes usando separação aleatória/discreta. Por ser um trabalho de análise e observação de dados, este acaba não cedendo informações sobre características que podem ser extraídas dos sinais.

A extração de características pode ser feita com o sinal no domínio do tempo, da frequência ou do tempo-frequência, sendo que uma determinada característica pode ser adotada ou não no projeto que se almeja desenvolver dependendo dos fatores relacionados à possibilidade da implementação em algoritmo e se os testes preliminares de classificação com tais características escolhidas tiveram bons resultados ou até mesmo se há bons precedentes do uso delas.

No trabalho feito em Yu (2011), onde foram utilizadas características extraídas dos sinais de vibração no domínio do tempo e da frequência, é possível observar a diminuição da taxa de erro no treino e no teste do Mapa Auto-Organizável quando as características são selecionadas de forma inteligente, neste caso por um algoritmo específico, podendo-se verificar que utilizar todas as características extraídas inicialmente neste estudo atrapalhou o desempenho da RNA.

Alguns trabalhos envolvendo a HHT, além de apresentarem características de um sinal no domínio do Espectro de Hilbert, também mostram a possibilidade de se utilizar as IMFs para uma análise no tempo.

Em Narendiranath *et al.* (2018), por exemplo, é feito um trabalho de extração de dados de vibração de rolamentos auto alinháveis onde foram utilizadas oito características extraídas do sinal no tempo, sendo eles o valor quadrático médio ou *Root Mean Square* em inglês (RMS), curtose, assimetria, pico a pico (PP), fator de crista (FC), fator de forma (FF), fator de impulso (FI) e fator de margem (FM), sendo também propostos dois novos atributos para o cálculo de características. Além disso, é utilizado o cálculo de energia total das IMFs utilizadas no trabalho, sendo esta uma característica de análise em tempo-frequência.

No trabalho mostrado em Abreu (2019) foi utilizada a HHT em sinais de vozes de um banco de dados para a classificação de vozes com desvio de soprosidade ou saudáveis, e para isso implementou-se uma RNA Perceptron Multicamadas com as características no tempo de energia das IMFs, e no tempo-frequência de densidade de energia temporal instantânea, amplitude instantânea ponderada pelo tempo, dispersão de frequência instantânea e amplitude instantânea ponderada pela frequência instantânea. As classificações destas características foram feitas em diversas combinações, apresentando taxas de acurácia entre $91,67 \pm 4,35\%$ e $100,00\%$.

No trabalho apresentado em Rai e Mohanty (2007) é possível constatar que há de fato um processo de filtragem ao aplicar a EMD em um sinal de vibração, pois conforme os peneiramentos forem executados, as componentes de alta frequência acabam por perder significativamente suas amplitudes.

Com base no que foi exposto, torna-se atraente a possibilidade de se mesclar as abordagens dadas à extração de características dos sinais. Para as Equações (21) e (22), assume-se N como o tamanho das amostras da IMF, o índice i como o número da IMF utilizada, a como a amplitude instantânea e f como frequência instantânea.

Na Equação (21), pode-se conferir a amplitude ponderada pelo tempo (APT), utilizada em Abreu (2019) e que tem como finalidade encontrar um valor marginal referente a energia instantânea pelo tempo no Espectro de Hilbert.

$$APT_i = \frac{1}{N} \sum_{n=1}^N (a_i[n] \cdot n), i = 1, 2, 3, \dots 10 \quad (21)$$

De forma análoga à APT, pode-se ainda calcular a amplitude instantânea ponderada pela frequência instantânea (APF) como mostrado em Abreu (2019) e representado na Equação (22). Esta tem como finalidade encontrar um valor marginal referente a energia instantânea pela frequência instantânea no Espectro de Hilbert.

$$APF_i = \frac{1}{N} \sum_{n=1}^N (a_i[n] \cdot f_i[n]), i = 1, 2, 3, \dots 10 \quad (22)$$

Em relação a coleta de características dos sinais de vibração no tempo, pode-se citar o RMS, fator de crista, fator de forma e fator de impulso. Para as Equações (23) até (30), assume-se N como o tamanho das amostras da IMF, x_i como o sinal da IMF, \bar{x} como o valor médio do sinal da IMF e σ como o desvio padrão do sinal da IMF.

Na Equação (23) pode-se conferir a formulação do RMS, utilizada nos trabalhos feitos em Narendiranath *et al.* (2018) e Yu (2011).

$$RMS = \left(\frac{1}{N} \sum_{i=1}^N x_i^2 \right)^{1/2} \quad (23)$$

Na Equação (24) pode-se conferir a forma de calcular o FC, utilizada também em Narendiranath *et al.* (2018) e Yu (2011).

$$FC = \frac{\max|x_i|}{RMS} \quad (24)$$

Na Equação (25) pode-se conferir a forma de calcular o FF, que foi utilizada em Narendiranath *et al.* (2018).

$$FF = \frac{RMS}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (25)$$

Pode-se verificar, também, através da Equação (26), a formulação para o cálculo do FI, também utilizada em Narendiranath *et al.* (2018) e Yu (2011).

$$FI = \frac{\max|x_i|}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (26)$$

Na Equação (27) pode-se verificar a formulação para o cálculo do FM, também utilizada em Narendiranath *et al.* (2018) e Yu (2011).

$$FM = \frac{\max|x_i|}{\left(\frac{1}{N} \sum_{i=1}^N |x_i|^{1/2}\right)^2} \quad (27)$$

Outra característica é representada na Equação (28), onde pode-se verificar a formulação da curtose conforme Narendiranath *et al.* (2018) e Yu (2011).

$$curtose = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{\sigma^4} \quad (28)$$

Com formulação parecida com a da curtose, a assimetria será utilizada e esta é representada na Equação (29), onde pode-se verificar sua formulação conforme Narendiranath *et al.* (2018) e Yu (2011).

$$assimetria = \frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^3}{\sigma^3} \quad (29)$$

Como última característica a ser utilizada, pode-se pontuar através da Equação (30) a formulação para o cálculo do PP, também utilizada em Narendiranath *et al.* (2018) e Yu (2011).

$$PP = \max(x) - \min(x) \quad (30)$$

Em posse destes dados, torna-se possível o aprimoramento da classificação dos dados de vibração relacionados a uma condição de defeitos ou de uma operação saudável de um rolamento.

4.4 Classificação por Redes Neurais Artificiais Perceptron Multicamadas

As redes neurais artificiais são algoritmos computacionais que se inspiram construtivamente no sistema nervoso humano, podendo processar as informações que lhes são fornecidas. Em linhas gerais, essas estruturas são compostas de neurônios artificiais interligados por sinapses artificiais que conseguem adquirir conhecimento para realizar alguma tarefa, como classificar padrões de dados (SILVA; SPATTI; FLAUZINO, 2016).

As redes neurais artificiais, conforme citado em Gongora *et al.* (2016), são ferramentas computacionais que podem aprender e generalizar conhecimento adquirido através de exemplos das aplicações as quais elas estão inseridas. Pode-se conferir que a rede neural aplicada neste trabalho obteve cerca de 97% de acerto na classificação de padrões de motores com falhas em rolamentos.

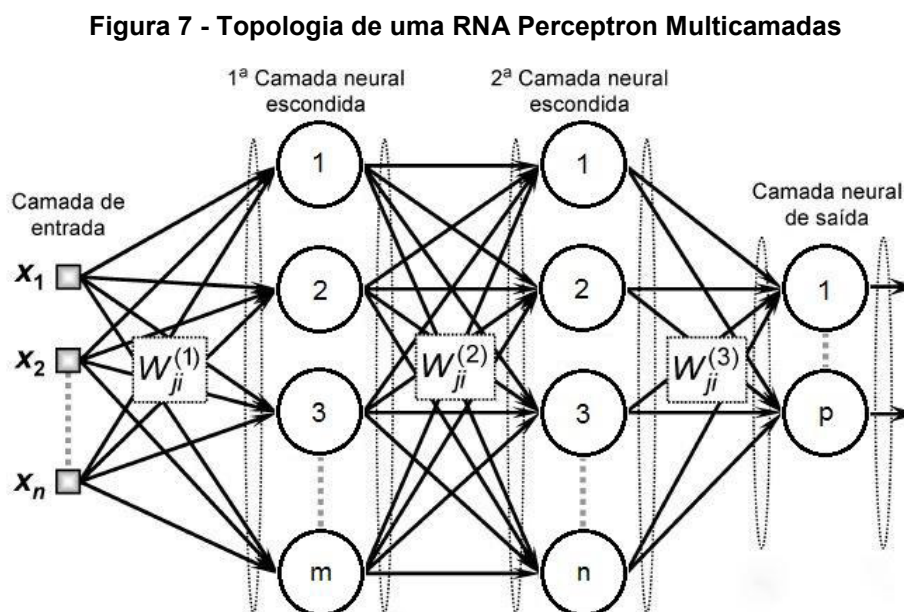
As redes Perceptron Multicamadas são caracterizadas por utilizar a arquitetura *feedforward* de camadas múltiplas com treinamento supervisionado por meio do algoritmo *backpropagation*, sendo o fluxo de informações desta arquitetura sempre no sentido da camada de entrada em direção à camada de saída, sem realimentação de valores produzidos pelos neurônios (SILVA; SPATTI; FLAUZINO, 2016).

Com isso, pode-se resumir o processo de treinamento da rede em duas fases, sendo a primeira denominada *forward*, onde os sinais de uma amostra do conjunto de treinamento são inseridos nas entradas da rede e então propagados pelas camadas da rede, do início ao fim desta, até a produção das saídas na última camada; e a segunda denominada *backward*, que consiste no ajuste dos pesos sinápticos e limiares de ativação dos neurônios de cada camada da rede para a retropropagação do erro obtido entre as saídas obtidas e as desejadas da primeira etapa de treinamento (SILVA; SPATTI; FLAUZINO, 2016).

Nesta rede, a saída de um determinado neurônio é produzida através da composição dos valores de entrada já ponderados pelos seus respectivos pesos sinápticos e da adição de um limiar de ativação que servirá para, no final do processo,

atuar na função de ativação relacionada à este neurônio (SILVA; SPATTI; FLAUZINO, 2016).

É possível ver um exemplo da estrutura de uma rede Perceptron Multicamadas na Figura 7, onde há m neurônios na 1ª camada escondida, n neurônios na 2ª camada escondida, p neurônios na camada de saída e x_n entradas.



Fonte: Adaptado de Silva, Spatti e Flauzino (2016)

Segundo Silva, Spatti e Flauzino (2016), a função de ativação limita os valores de saída dos neurônios, sendo que estas saídas passam a ser limitadas em um intervalo de valores de acordo com a função de ativação adotada. Faz-se necessário aplicar nas redes Perceptron Multicamadas somente funções de ativação totalmente diferenciáveis em seu domínio.

Uma opção para este tipo de função é a logística $g(u)$, conforme a Equação (31), que pode assumir valores entre zero e um. A constante β é responsável pelo ajuste da inclinação da função logística com base no seu ponto de inflexão, e o valor de u pode ser definido como o potencial de ativação, obtido através da diferença do valor produzido entre o combinador linear do neurônio e o seu respectivo limiar de ativação (SILVA; SPATTI; FLAUZINO, 2016).

$$g(u) = \frac{1}{1 + e^{-(\beta \cdot u)}} \quad (31)$$

Em vista da estrutura das redes Perceptron Multicamadas, torna-se atraente utilizar este tipo de classificador para o problema exposto no presente trabalho, uma vez que é possível fazer diferentes classificações dos dados utilizados como somente em sinais de rolamentos saudáveis ou defeituosos, ou ainda entre falhas de rolamentos instalados na frente ou atrás, podendo-se estender até mesmo entre os diferentes tipos de falhas existentes nas amostragens obtidas.

Conforme destacado em Silva, Spatti e Flauzino (2016), a Equação (32) representa função de erro quadrático usada medir o erro entre os resultados produzidos por cada um dos neurônios através de suas saídas e do resultado que se deseja obter. $E(k)$ é o valor de erro quadrático dos neurônios n_f da camada de saída associado à k -ésima amostra de treinamento, enquanto que $Y_j^{(L)}(k)$ é o valor produzido pelo j -ésimo neurônio de saída da rede na camada L e $d_j(k)$ é o respectivo valor desejado para a saída.

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_f} \left(d_j(k) - Y_j^{(L)}(k) \right)^2 \quad (32)$$

Com isso, segundo Silva, Spatti e Flauzino (2016), assume-se o erro global associado para todas as p amostras de treinamento por meio do erro quadrático médio E_M , representado pela Equação (33).

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (33)$$

Com isso o algoritmo executa épocas de treinamento com as amostras de forma a ajustar os pesos sinápticos e os limiares de ativação a fim de diminuir o erro entre as saídas obtidas e as desejadas até um valor definido pelo programador da rede (SILVA; SPATTI; FLAUZINO, 2016).

A fim de otimizar problemas de classificação que possam ocorrer nas amostras, como por exemplo a saída da rede colocar duas ou três falhas para uma mesma amostra ou ainda não conseguir fazer este processo de classificação, serão

aplicados conceitos de distribuição de probabilidade à rede com o intuito de satisfazer estes casos. Com isso, introduz-se a função de ativação Softmax e a entropia cruzada.

A função Softmax S torna-se interessante em aplicações de Redes Perceptron Multicamadas que envolvem várias classes, podendo ser conferida na Equação (34). Esta função é caracterizada pela ideia de uma saída ter a probabilidade ou não se estar correta conforme os ajustes da rede neural, ou seja, ela transforma as saídas dos neurônios da última camada em porcentagens de acerto da rede (BENDERSKY, 2021). Ela é construída em função dos valores k dos neurônios da camada de saída e do valor m do neurônio que se deseja obter a porcentagem em vista dos outros.

$$S = \frac{e^m}{\sum_{k=1}^N e^k} \quad (34)$$

De forma a simplificar o entendimento do funcionamento da Softmax, supõem-se que haja três saídas binárias 001, 010 e 100 possíveis da última camada de uma rede com três neurônios na saída. Ao verificar uma resposta da rede como [3,2 7,5 6,1] por exemplo, a softmax irá utilizar estes três valores para gerar as porcentagens de probabilidade de qual saída possa estar certa, retornando o vetor [0,01 0,79 0,2] e consequentemente podendo-se observar que a probabilidade de ser uma saída 010 é maior do que as outras (BENDERSKY, 2021).

A Softmax é utilizada como função de ativação somente na camada de saída da rede com o intuito de mostrar as probabilidades. Por ser uma função que retorna valores entre 0 e 1, utiliza-se no restante da rede a função logística como a mostrada na Equação (31).

O processo de *backpropagation* utilizando a Softmax é semelhante a de uma rede que contenha somente função logística, devendo-se retropropagar o erro através do gradiente desta função, que no caso gera derivadas de primeiro grau. Para saber o erro do valor desejado com o do respectivo valor produzido é feito o cálculo da entropia cruzada $Ent(d(k), Y(k))$, mostrada na Equação (35), sendo que este utiliza o valor $Y(k)$ produzido pela camada de saída da rede e $d(k)$ que é o respectivo valor desejado para a saída (BENDERSKY, 2021).

$$Ent(d(k), Y(k)) = - \sum_{k=1}^{n_f} d(k) \cdot \log_2(Y(k)) \quad (35)$$

Finalmente, para o cálculo definitivo do erro E é utilizada a Equação (36), sendo feito um somatório das entropias cruzadas de cada k amostra até p amostras. O erro quadrático médio é calculado de forma semelhante ao da Equação (33), porém desta vez com o E da entropia cruzada (ROELANTS, 2021).

$$E = -\frac{1}{p} \sum_{k=1}^p Ent(d(k), Y(k)) \quad (36)$$

A fim de aprimorar o processo de treinamento da rede, será feita a inserção do termo de *Momentum* à rede neural. Este recurso visa inserir um termo no cálculo das matrizes sinápticas que pondera a evolução entre as épocas anteriores e sucessivas destas matrizes, fazendo com que a solução final seja alcançada de forma mais acelerada através da adição de um valor proporcional desta evolução (SILVA; SPATTI; FLAUZINO, 2016).

4.5 Hardware e Software Utilizados

Para o presente trabalho utilizou-se como ferramenta principal no desenvolvimento dos algoritmos um *notebook* com as seguintes configurações de *hardware*:

- Modelo do notebook: Dell System XPS L502X;
- Processador: Intel® Core™ i7-2670QM CPU @ 2.20GHz (4 núcleos, 8 threads), 2ª Geração;
- Memória: 8192MB RAM.

Todo o desenvolvimento dos algoritmos e das técnicas necessárias para a realização deste trabalho foram feitas utilizando-se o *software* MatLab.

4.6 Conclusão do Capítulo

Neste capítulo foram apresentados os materiais e métodos utilizados para a realização do trabalho, bem como esclarecer todos os passos necessários para o seu desenvolvimento.

No próximo capítulo serão mostrados os resultados obtidos com a aplicação da metodologia proposta, avaliando-se o potencial de classificação dos dados saudáveis e com falha e nos tipos de falha.

5 RESULTADOS

Neste capítulo, serão apresentados os principais resultados obtidos através da aplicação dos métodos adotados. Em um primeiro momento serão mostrados os cálculos das frequências de cada falha com o intuito de exibir os sinais no domínio da frequência e analisar algumas IMFs após a EMD, seguindo então da aplicação da Transformada de Hilbert nestes sinais e mostrados os Espectros de Hilbert.

Por fim, para os resultados relacionados a classificação dos sinais serão separados em dois blocos: o primeiro contará com a extração de características e a detecção das falhas de forma visual através de gráficos, já o segundo será pautado na classificação dos dados executada por meio de RNA, sendo analisadas diferentes topologias de rede.

Para a devida verificação da performance de classificação via RNA Perceptron Multicamadas serão utilizados os artifícios de cálculo de acurácia, ou taxa de acertos da rede, para cada uma das topologias adotadas.

5.1 Cálculo e Comparação de Frequências

Conforme exposto no item 4.1, as frequências de defeito nas peças dos rolamentos podem ser calculadas, indicando alguma variação de amplitude que possa evidenciar o problema.

Através das Equações (1) a (4) foi possível obter os valores de frequência de vibração da pista interna, pista externa, esferas e gaiola de cada rolamento, respectivamente. Será realizada uma análise qualitativa das componentes de frequência dos sinais com a finalidade de localizar as frequências de falha, depois de calculadas em conjunto com as frequências rotacionais do eixo f_r , calculada pela Equação (5).

Os valores calculados e os obtidos através do repositório da CWRU encontram-se na Tabela 6. Vale observar que nesta tabela constam os valores múltiplos de frequência pertinentes aos rolamentos alvo deste trabalho, sendo o 6205-2RS JEM SKF utilizado na frente do motor e o 6203-2RS JEM SKF na traseira da máquina. Vale ressaltar que estes valores de frequência são os valores múltiplos das peças dos rolamentos, sendo que para se obter a frequência de falha em si tem-se a necessidade de multiplicar estes valores pela rotação do eixo do motor.

Tabela 6 - Frequências de defeito múltiplas de cada rolamento calculadas

Modelo de rolamento	Fonte do valor	Pista interna (Hz)	Pista externa (Hz)	Gaiola (Hz)	Elemento rolante (Hz)
6205-2RS	CWRU	5,4152	3,5848	0,39828	4,7135
JEM SKF	Calculados	5,4152	3,5848	0,39831	4,7135
6203-2RS	CWRU	4,9469	3,053	0,3817	3,9874
JEM SKF	Calculados	4,9468	3,0532	0,3816	3,9879

Fonte: Autoria Própria e Case Western Reserve University (2021)

Observa-se então que há coerência entre os valores entregues pela CWRU, sendo os valores calculados compatíveis com os destacados no *site*. Vale ressaltar que estes valores não estão multiplicados pela frequência rotacional do eixo f_r devido ao fato de que cada conjunto do banco de dados foi feito em uma rotação do eixo diferente.

A fim de exemplificar o que é a frequência de falha, supõem-se o conjunto de sinais de pista interna, esferas e pista externa com falhas de 0,5334 mm e 0,1778 mm com o motor operando sem carga e com carga excessiva. Cada um destes conjuntos foi coletado a velocidades constantes e diferentes entre eles, podendo estes valores serem visualizados na Tabela 7. As velocidades fornecidas foram convertidas a partir da Equação (5) e usadas para se calcular as frequências de falha com os valores múltiplos calculados disponíveis na Tabela 6.

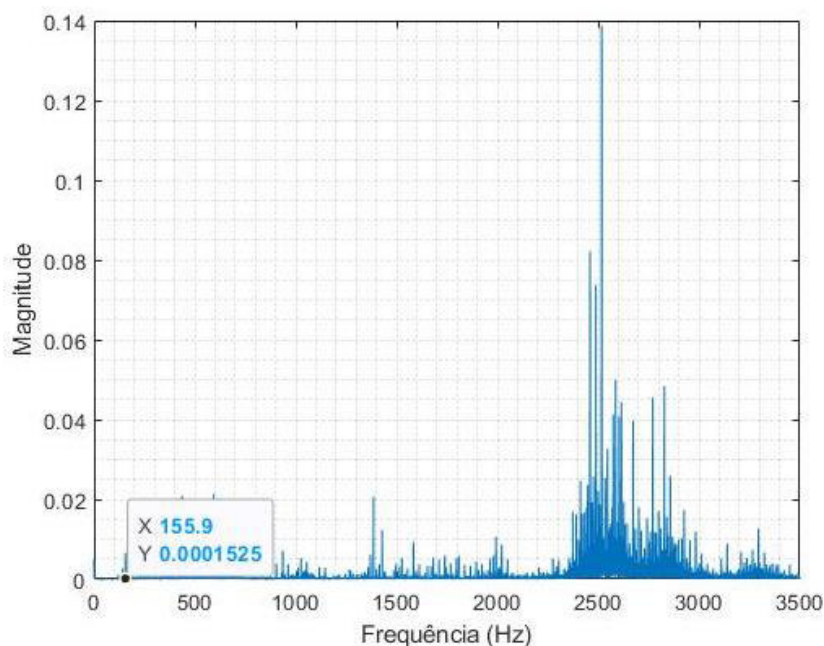
Tabela 7 - Frequências de defeito múltiplas de cada rolamento calculadas

Local de falha	Carga do teste (HP)	Grau de falha (mm)	Velocidade do eixo (RPM)	Frequência de falha (Hz)
Pista Interna	3	0,5334	1727	155,8680781
		0,1778	1721	155,3265561
	0	0,5334	1796	162,0955809
		0,1778	1796	162,0955809
Esfera	3	0,5334	1729	135,8264707
		0,1778	1721	135,1980081
	0	0,5334	1797	141,1684024
		0,1778	1796	141,0898446
Pista Externa (centralizada em 6 horas/relógio)	3	0,5334	1719	102,7039512
		0,1778	1725	103,0624292
	0	0,5334	1796	107,3044191
		0,1778	1796	107,3044191
Pista Externa (posição de 3 horas/relógio)	3	0,5334	1719	102,7039512
		0,1778	1724	103,0026829
	0	0,5334	1796	107,3044191
		0,1778	1797	107,3641654
Pista Externa (posição de 12 horas/relógio)	3	0,5334	1718	102,6442049
		0,1778	1723	102,9429366
	0	0,5334	1796	107,3044191
		0,1778	1796	107,3044191

Fonte: Autoria Própria

No Gráfico 1 pode-se verificar a FFT aplicada ao sinal de vibração do rolamento frontal em que a pista interna teve 0,5334 mm de danificação e a carga no eixo foi de 3HP. A frequência de 155,9 Hz, que é a mais próxima da frequência de 155,8681 Hz, foi marcada para sua amplitude ser analisada em comparação como restante do espectro de frequências. Nota-se que o valor desta componente de frequência tem amplitude bem abaixo de parte do restante do espectro. O eixo das abscissas foi limitado em 5000 Hz para melhor visualização.

Gráfico 1 - FFT do sinal de vibração da pista interna



Fonte: Autoria Própria

No item seguinte de resultados serão mostrados alguns sinais a fim de exemplificar a relação de frequências das IMFs, e serão demonstrados os respectivos pontos de frequência de falha destes sinais.

Outro ponto a se destacar é que o banco não fornece dados de falha de gaiola, sendo o cálculo feito apenas para comparação com os dados que constam no repositório.

5.2 Aplicação da HHT em Conjuntos de Dados

Conforme visto no item 4.2, o uso da HHT implica em uma avaliação prévia dos métodos que se pretende utilizar para promover a EMD. Tomou-se como ferramenta principal o comando “emd” do MatLab para aplicar a decomposição, adotando a sua configuração padrão para realizar os primeiros testes.

Em um primeiro momento, a limitação dos peneiramentos foi adotada como único critério de parada da decomposição, porém se mostrou de difícil aplicação. Em vista das dificuldades observou-se então a possibilidade de utilizar o critério de parada de Cauchy prestando atenção na variação dos peneiramentos para cada IMF. A abordagem de fixar em um número de peneiramentos é descrita em Wang *et al.* (2010) e é apresentada como alternativa de critério de parada para a decomposição do sinal,


visto que conforme citado no item 4.2.1 há grande dificuldade em satisfazer ambos os requisitos para se obter uma IMF.

O MatLab não possui um sistema claro e conciso que permita a limitação de peneiramentos entre IMFs de uma forma coerente com o que se obteve com o critério de Cauchy, sendo então estipulada uma quantidade aproximada de peneiramentos.

Foi adotado para o trabalho a fixação de um número aproximado de peneiramentos e que correspondam à um valor de Cauchy de 0,2, que resultaram em IMFs compostas de sinais com conteúdo de baixa frequência, especialmente as mais próximas das frequências de falhas dos rolamentos. Este procedimento visa a filtragem do sinal, uma vez que desta forma os conteúdos de altas frequências tenham suas magnitudes atenuadas.

No Gráfico 2 é possível conferir um exemplo de uma EMD que resultou em 10 IMFs do sinal de pista interna do rolamento frontal com uma falha leve, 3HP de torque no eixo e a uma velocidade de 1721 RPM. A decomposição neste sinal contou com um critério de parada de Cauchy de 0,2, onde pode-se observar que são aplicáveis 10 IMFs devido ao fato de o MatLab limitar este número, já que poderia ser aplicado ao menos mais um peneiramento no sinal de resíduo devido ao fato de que há ao menos um máximo e um mínimo neste sinal. É possível observar que conforme há o peneiramento do sinal, menos componentes de alta frequência ficam disponíveis nas IMFs, principalmente nas posteriores à IMF 5.


Gráfico 2 - Sinal original, 10 primeiras IMFs e resíduo do sinal de pista interna



Fonte: Autoria própria

Esta etapa de avaliação foi feita com o intuito de entender como os sinais podem ser avaliados através deste método de decomposição. Contudo, se mostrou difícil analisar os sinais das IMFs sem o auxílio de alguma ferramenta que permita uma observação mais minuciosa das características destes sinais. Com isso, adotou-se a FFT para a análise das frequências dos respectivos sinais, podendo-se verificar, por exemplo, a FFT do sinal original no Gráfico 3 (a) e a da IMF 5 no (b), sendo ambos os sinais extraídos do Gráfico 2.


Gráfico 3 - (a) FFT do sinal da pista interna com falha leve; (b) FFT da IMF5 da pista interna



Fonte: Autoria própria

Foi possível verificar, durante os testes, que a IMF 5 é a que detém um conteúdo de maior magnitude próxima da frequência de cada falha para a maioria dos dados analisados manualmente. A fim de ilustrar este fenômeno, pode-se verificar nos Gráficos 4 até 7, respectivamente, as FFTs dos dados de falhas de pista externa e esferas do rolamento frontal, sendo possível observar nelas um ponto destacado que trata justamente da frequência calculada da respectiva falha de rolamento no sinal. Nestes gráficos serão apresentados as FFTs das IMFs 5 e dos sinais originais limitados em espectro com o intuito de se verificar o potencial de redução das altas frequências dos sinais. Tais análises são análogas as feitas com o Gráfico 3.

Especificamente no Gráfico 4 (a) pode-se conferir a FFT do sinal original da falha de pista externa com defeito grave na posição 3 horas/relógio à 3HP de carga e rotação de 1719 RPM, e na (b) verifica-se a FFT da IMF 5 do sinal, ambos os gráficos limitados no eixo das abscissas para melhor visualização. A frequência múltipla desta falha é de 3,5848 Hz conforme a Tabela 6, e quando multiplicada pela velocidade resultante da Equação (5), tem-se então 102,704 Hz.

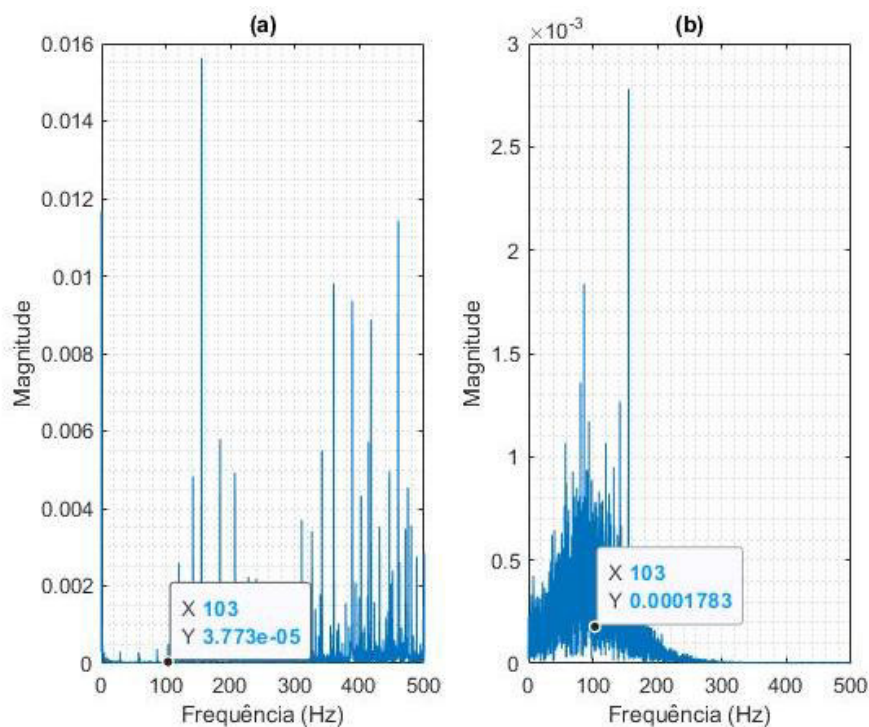
Gráfico 4 - (a) FFT do sinal da pista externa com falha grave; (b) FFT da IMF5 da pista externa

Fonte: Autoria própria

No Gráfico 5 abaixo é possível verificar, de forma análoga, a FFT do sinal original de vibração na imagem (a) e a FFT da IMF5 na imagem (b), ambas de pista externa com defeito leve na posição 3 horas/relógio à 3 HP de carga e rotação de 1724 RPM desta vez.

Como no caso anterior, os pontos selecionados se referem à frequência mais próxima da calculada para a falha em específico, onde se utilizou da informação de frequência múltipla de 3,5848 Hz e a velocidade do eixo dividida por 60 conforme Equação (5), resultando em uma frequência característica de vibração de aproximadamente 103 Hz.


Gráfico 5 - (a) FFT do sinal da pista externa com falha leve; (b) FFT da IMF5 da pista externa



Fonte: Autoria própria

É possível observar pelos Gráficos 3, 4 e 5 o potencial de redução das componentes de alta frequência contidas nos sinais originais através da EMD. Observa-se que há modificações nas amplitudes das falhas características, consequência comum em processos de filtragem de sinais onde pode-se ter atenuação ou amplificação de determinadas partes do sinal que está sendo processado.


No Gráfico 6 (a) pode ser conferido o sinal de falha em esferas no rolamento frontal, sendo neste caso o motor à 3 HP, com falha grave a velocidade de 1729 RPM, e em (b) a sua IMF 5. A frequência característica de falha é de 135,8 Hz, conforme Tabela 7, valor calculado também através da frequência múltipla e da velocidade convertida em Hz.

Gráfico 6 - (a) FFT do sinal das esferas com falha grave; (b) FFT da IMF5 das esferas

Fonte: Autoria própria

No Gráfico 7 abaixo é possível verificar, de forma análoga, a FFT do sinal original de vibração na imagem (a) e a FFT da IMF 5 na imagem (b), ambas de esferas com defeito leve à 3 HP de carga e rotação de 1721 RPM desta vez. Os pontos selecionados se referem à frequência mais próxima da calculada conforme Tabela 7.

Gráfico 7 - (a) FFT do sinal das esferas com falha leve; (b) FFT da IMF5 das esferas



Fonte: Autoria própria

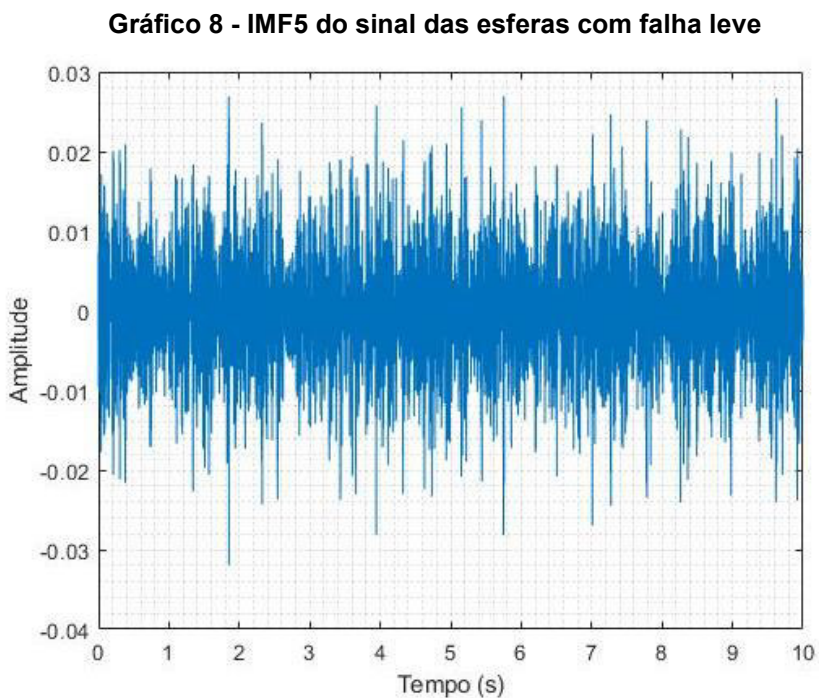
Neste caso das esferas com as duas gravidades de falha diferentes, é possível observar que há amplificação nas amplitudes após os peneiramentos, sendo que novamente a maior parte das componentes de amplitudes mais altas pós EMD se encontram mais próximas das componentes que evidenciam falhas do que nos sinais originais.

A partir da análise destes gráficos e da análise de outros sinais, adotou-se a IMF 5 como a função que será utilizada para extração de características e classificação. As IMF 5 foram obtidas por meio de valores entre 7 e 11 peneiramentos, com a condição de critério de parada de Cauchy de 0,2.

A fim de observar as amplitudes e frequências instantâneas do Espectro de Hilbert, promoveu-se a Transformada de Hilbert da IMF 5 de alguns dos sinais com o intuito de analisar e verificar o comportamento destes sinais, uma vez que as características APF e APT serão utilizadas no trabalho e estas dependem dessas frequências e amplitudes. Este Espectro é obtido através do comando “hht” presente no MatLab, representada por um gráfico em tempo e frequência.


Considera-se como exemplo o Gráfico 7 (b), onde é possível ver a FFT da IMF 5 de defeito leve nas esferas do rolamento frontal do motor à 3HP de carga. O

Gráfico 8 é essa IMF 5, porém no domínio do tempo, que será utilizada para exemplificar a análise do Espectro de Hilbert.



Fonte: Autoria própria

O Gráfico 9 mostra o Espectro de Hilbert da IMF 5 representada no gráfico anterior. Nota-se que a amplitude instantânea é representada pelas cores correspondentes na barra lateral direita.

Gráfico 9 - Espectro de Hilbert da IMF5 do sinal das esferas com falha leve

Fonte: Autoria própria

A falha característica neste caso das esferas do rolamento frontal, conforme visto anteriormente, tem ocorrência na frequência de 135,2 Hz aproximadamente. É possível verificar que durante os 10 segundos de duração do sinal da IMF5 a Transformada de Hilbert foi calculada e que o Espectro de Hilbert mostra todas as informações de amplitude e frequência instantâneas, sendo possível constatar a existência de componentes com amplitude próximas à frequência de 135,2 Hz.

Os experimentos descritos neste item 5.2 tiveram como objetivo avaliar os sinais do banco de dados através de algumas técnicas aplicadas a alguns destes sinais e traçar uma estratégia que pudesse auxiliar na aplicação da HHT em todo o banco, como foi o caso de estabelecer o critério de parada de Cauchy e avaliar a evolução da EMD a partir deste com os peneiramentos.

Com isso, foi definida a utilização da IMF 5 dos sinais por conta do conteúdo dos sinais de vibração contido nestas funções, por concentrarem amplitudes próximas das frequências de falha.

O próximo passo dos resultados é a obtenção e análise das características das IMFs escolhidas para depois serem classificadas por uma rede neural. A função 'hht' do MatLab permite a obtenção das amplitudes e frequências instantâneas de

cada instante de tempo do sinal representado no Espectro, o que será utilizado para o cálculo de algumas características.

5.3 Extração de Características e Detecção de Falhas

As características extraídas podem ser conferidas no item 4.3, sendo elas a Amplitude Ponderada pela Frequência (APF), Amplitude Ponderada pelo Tempo (APT), Valor Quadrático Médio (RMS), Fator de Crista (FC), Fator de Forma (FF), Fator de Impulso (FI), Fator de Margem (FM), curtose, assimetria, Pico a Pico (PP). Todas foram extraídas do sinal IMF 5, quando no domínio do tempo, e do espectro de Hilbert da mesma IMF quando no domínio do tempo-frequência.

Devido ao fato de estas características serem utilizadas posteriormente em uma RNA após a análise, indica-se que sejam realizadas as suas devidas normalizações. Em Silva, Spatti e Flauzino (2016) a normalização dos dados de entrada e saída da rede é mostrada como um aspecto importante na implementação das redes Perceptron Multicamadas, sendo que este processo tem o intuito de contribuir para o desempenho de treinamento da RNA e de evitar problemas que possam ocorrer com as funções de ativação, especificamente em suas regiões de saturação onde os seus valores ficam próximos dos limites que estas funções podem retornar. Por conta disso, a normalização é feita para que os dados de entrada da rede fiquem entre os limites de valores da função de ativação utilizada na rede.

A normalização pode ser definida como um processo de escalonamento dos dados que se deseja normalizar de acordo com os limites da função de ativação utilizada, escalonando estes dados entre os valores máximos e mínimos possíveis para serem adotados pela função, sendo o teorema de Tales uma das técnicas utilizadas para este processo (SILVA; SPATTI; FLAUZINO, 2016).

Neste trabalho a normalização consistiu em limitar os valores de entrada entre 0 e 1, sendo então ao menor valor de cada conjunto de características atribuído o valor zero, ou valor mínimo, e ao maior valor de cada conjunto atribuído o valor um, ou valor máximo.

A formulação da normalização utilizada pode ser conferida na Equação (37), onde x é o valor a ser normalizado, x_{min} é o valor mínimo do conjunto, x_{max} é o valor máximo do conjunto e x_{norm} é o valor já normalizado.

$$x_{norm} = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (37)$$

Definidas as estratégias para a extração de características, o próximo passo se deu executando o algoritmo desenvolvido. As extrações se deram utilizando dez segundos de cada sinal, com exceção dos que têm tamanhos menores e dos saudáveis. Isso se deu por conta da facilidade posterior da aplicação da HHT nos conjuntos de dados.


Devido ao baixo número de sinais de rolamentos sem falha em relação aos rolamentos com algum tipo de defeito, onde há 161 sinais de motor com falha e 4 sinais de motor em operação normal, executou-se a divisão dos sinais saudáveis conforme descrito no capítulo 4.

A partir da adoção destes métodos, obteve-se então de resultado 157 sinais de rolamento com falha e 155 sinais de rolamento saudável. A fim de se utilizar as características extraídas destes sinais em uma rede neural, posteriormente, atribuiu-se o número 1 para a classe dos rolamentos com falhas e 0 para a classe dos rolamentos saudáveis.

Extraindo então as características, pode-se verificar alguma que se sobressaia em termos de conseguir diferenciar um rolamento defeituoso de um saudável. Esta etapa se mostra muito importante, já que selecionar as melhores características pode facilitar o processo de aprendizagem e classificação de uma rede neural. Conforme discutido na seção 5.2, foi utilizada somente a IMF 5 dos sinais para a extração das características dos conjuntos de dados.


A primeira análise das características expostas em gráficos será relativa a discriminação entre dados de rolamentos saudáveis ou com falha, representados por 0 e 1 respectivamente. Estas características estão expostas nos gráficos de 9 a 18.

No Gráfico 10 é possível verificar os dados de APF. Nota-se que é possível visualizar a diferença de comportamento entre os rolamentos saudáveis e com falha, porém não é possível afirmar se há um padrão para a identificação das classes somente com esta característica.

Gráfico 10 - Conjuntos dos dados da APF dos rolamentos saudáveis e defeituosos

Fonte: Autoria Própria

A segunda característica, assim como a primeira mostrada, é também proveniente do Espectro de Hilbert, a APT. Como é possível ver, no Gráfico 11, esta característica também não apresenta amplitudes que permitam uma classificação certa sem o auxílio de alguma outra ferramenta de análise.


Gráfico 11 - Conjuntos dos dados da APT dos rolamentos saudáveis e defeituosos

Fonte: Autoria Própria

Expostas as características extraídas do Espectro de Hilbert, faz-se agora a análise das características extraídas das IMFs 5 no domínio do tempo. Pode-se conferir no Gráfico 12 o gráfico da RMS, que também não demonstra uma característica intrínseca de cada uma das duas classes.

Nota-se que aparentemente existe um padrão nestas três primeiras características para algumas amostras, uma vez que alguns dos valores mais altos se encontram pra mesma amostra nas três.


Gráfico 12 - Conjuntos dos dados do RMS dos rolamentos saudáveis e defeituosos



Fonte: Autoria Própria


No Gráfico 13 é possível conferir os valores da FC de cada uma das amostras. Esta característica dos sinais já demonstra uma boa diferenciação entre sinais de rolamentos saudáveis e defeituosos, uma vez que é possível identificar que a maioria dos valores mais altos se encontram em posse da classe de rolamentos com falha.

É difícil, porém, afirmar que somente isso é o suficiente para a identificação destas classes, uma vez que algumas amostras aparentemente podem ser colocadas na classe errada.

Gráfico 13 - Conjuntos dos dados do FC dos rolamentos saudáveis e defeituosos

Fonte: Autorial Própria

A característica FF se mostra provavelmente como a que menos evidencia diferenças marcantes entre as classes até o momento. No Gráfico 14 é possível conferir os valores da FF de cada uma das amostras, onde pode-se constatar alguns sinais de falha como os que possuem as amplitudes mais altas, porém com a maioria dos valores podendo ser confundidos entre as classes.


Gráfico 14 - Conjuntos dos dados do FF dos rolamentos saudáveis e defeituosos

Fonte: Autorial Própria

No Gráfico 15 pode-se verificar a FI, e é possível notar uma certa semelhança de seu comportamento quando esta é comparada com a FC. É possível visualizar que os sinais de rolamentos saudáveis possuem amplitudes mais baixas quando comparadas com os sinais de rolamentos com falhas, notando-se que somente alguns dos picos de amplitude dos saudáveis chegam a valores próximos dos com falha.


Nota-se uma grande incidência de valores acima de 0,15 para os dados com falha, o que pode representar uma boa tendência para classificação destes devido ao fato de ocorrer uma grande diferenciação das classes.

Gráfico 15 - Conjuntos dos dados do FI dos rolamentos saudáveis e defeituosos




Fonte: Autoria Própria

A próxima característica é o FM, que possui valores muito próximos dos obtidos de FI, representado no Gráfico 16. Novamente, apresenta-se valores baixos para sinais de rolamentos saudáveis, porém não é possível concluir sobre seu real potencial para a RNA fazer a classificação. Nota-se também alguns picos característicos para alguns sinais, semelhante ao ocorrido com FI.

Gráfico 16 - Conjuntos dos dados do FM dos rolamentos saudáveis e defeituosos

Fonte: Autoria Própria


No Gráfico 17 é possível conferir os valores de curtose de cada uma das amostras. Esta característica não mostra grande potencial de diferenciação, uma vez que a maioria dos valores de amplitude se encontram muito próximos, algo que não agrega resultados bons à primeira vista.

Gráfico 17 - Conjuntos dos dados de curtose dos rolamentos saudáveis e defeituosos

Fonte: Autoria Própria

A seguir é possível conferir no Gráfico 18 os pontos que representam a característica de assimetria. Dentre todos os mostrados até agora, esta é provavelmente a característica que menos apresentou distinções visíveis entre os sinais, exibindo certa homogeneidade entre as amostras.


Gráfico 18 - Conjuntos dos dados de assimetria dos rolamentos saudáveis e defeituosos



Fonte: Autoria Própria

Por último, é possível verificar no Gráfico 19 a característica PP dos sinais, não sendo possível perceber grandes diferenciações entre as classes. Nota-se que os valores de rolamento saudáveis aparentam não ter muita variação, porém não é uma análise conclusiva sobre o potencial de discriminação desta característica.

Fica claro e evidente uma dificuldade de diferenciação dos dados quando se verifica que há parte considerável dos valores de falha ocupando a faixa dos valores de rolamento saudável, o que pode dificultar o treinamento e a classificação da RNA.

Gráfico 19 - Conjuntos dos dados de PP dos rolamentos saudáveis e defeituosos

Fonte: Autoria Própria

Com base nos gráficos apresentados, é difícil concluir previamente se alguma característica sozinha pode promover, por si só, a classificação dos dados de entrada da RNA. Isso porque a detecção da condição de falha ou saudável se mostrou de difícil análise. Apesar de se mostrarem como as mais promissoras, o FC, o FI e o FM não demonstram uma diferenciação absoluta dos dados de rolamentos saudáveis e defeituosos.

A próxima análise das características extraídas será dada somente com as classes específicas das falhas, ou seja, falha em pista interna, esferas ou pista externa. O objetivo desta etapa é verificar se há alguma(s) característica(s) que possa(m) evidenciar as falhas independentemente destas terem ocorrido no rolamento frontal ou traseiro.

A análise das características no que diz respeito ao caso do parágrafo anterior será feita a partir dos gráficos expostos no Apêndice A, mais especificamente os Gráficos A.1 até A.10. Foi possível constatar que dentre todas as características, quatro mostraram grande potencial para diferenciação: FF, FI e FM mostrando que as amostras de pista interna tem certo padrão de ocorrência, e Curtose conseguindo transmitir uma possível diferenciação entre pista interna e esferas, porém com pista externa sendo caótico. As outras características não se mostraram com grande potencial na análise dos gráficos.

Feito isso, tomou-se a vertente de identificação de padrões por gráficos dividindo as falhas entre seus rolamentos, ou seja, discriminando se as falhas de pista interna, esferas ou pista externa ocorreram no rolamento frontal ou traseiro. Os gráficos A.11 até A.20 são relativos ao rolamento frontal, e ao analisá-los é possível constatar que APF e APT aparentam uma diferenciação das amostras de falha em esferas porém pouco expressivo, já FI e FM mostram certa diferenciação para as amostras de falha em pista interna, mas novamente com pouca expressividade.

Analisando as falhas nos rolamentos traseiros através dos gráficos A.21 até A.30 do Apêndice A, é possível notar que novamente nenhuma característica se mostra eficaz para se realizar a detecção das falhas. Vale citar que APT apresentou amostras de falhas em pista interna com mais alta amplitude do que esferas e pista externa, para RMS as falhas em pista externa tenderam a ter amplitudes médias comparadas as outras falhas, e PP tendeu a manter as amostras de falhas em pista externa com amplitudes menores que as outras.

Em vista da baixa eficácia na detecção das falhas por meio das características dispostas em gráficos, verifica-se grande dificuldade em prever se alguma destas características tem, sozinha, um grande potencial para a diferenciação das classes. Após esta etapa de avaliação das características, iniciou-se então os testes de classificação envolvendo as RNAs.

5.4 Classificação com a Rede Neural Perceptron Multicamadas

O passo seguinte à extração e análise de características se dá por meio da classificação destes com RNAs do tipo Perceptron Multicamadas, onde serão verificadas diferentes topologias de rede para classificações com maiores acurácias e menos épocas de treinamento.

Os resultados nesta etapa serão separados em três grupos, da mesma forma como foi feito no capítulo 5.3. A primeira parte será atribuída à classificação das classes de todas as amostras, como rolamento saudável ou rolamento com falha; a segunda será feita com as três falhas juntas, pista interna, esferas e pista externa, sem distinção de rolamento; e a terceira contará com as três falhas, porém distinguindo em qual rolamento ocorreu a falha.

Apesar das amostras estarem alinhadas em seus conjuntos de classe conforme visto nos Gráficos 9 até 18, foi desenvolvido um algoritmo que embaralha os dados de forma que 75% dos dados fiquem para treinamento da rede e 25% para o teste da rede treinada. Este algoritmo se inicia coletando os dados da planilha que contém as características extraídas por outro algoritmo. Optou-se por esta organização devido ao fato de se tornar mais simples a execução no MatLab, uma vez que dessa forma não é criada nenhuma possível interferência nas aplicações.

As topologias de RNAs Perceptron Multicamadas foram definidas a partir de testes pontuais que não serão abordados no trabalho. Os parâmetros destas topologias são os seguintes: erro de 10^{-9} , taxa de aprendizagem de 10^{-3} , coeficiente β igual a 1 para redes com função logística e igual a 2 para redes com função Softmax. A RNA também contou com o termo *Momentum*, com uma taxa de 0,1.

Para as RNAs que tiverem somente uma camada oculta, serão feitos ajustes de adição de 5 neurônios nesta camada a cada etapa de treinamento e teste. Ou seja, o primeiro treino e teste da rede será feito com 5 neurônios na camada oculta, o segundo terá uma adição de 5, ou seja, 10 neurônios, e assim por diante até atingir 50 neurônios como limite. O mesmo ocorre com RNAs com duas camadas ocultas, porém agora a segunda camada será acrescida em 5 neurônios somente quando a primeira completar o ciclo de adições até 50.

5.4.1 Rede Neural Perceptron Multicamadas com Função Logística

O primeiro grupo de classificações é composto somente das classes de sinais de rolamento com falha, composto por todas as condições de falha disponíveis no banco, e sinais de rolamento saudável. O primeiro teste com esta discriminação das classes foi feito com todas as características juntas, ou seja, dez entradas na rede.

Na Tabela 8 é possível ver os valores de épocas e acurácia alcançados por este primeiro teste, sendo que dentre as 78 amostras do conjunto de teste pós treinamento, 39 eram de rolamentos com falhas e 39 de rolamentos saudáveis.

Tabela 8 - Resultado da primeira classificação por acréscimo de neurônios

Teste	Nº de neurônios	Quantidade de épocas	Acurácia (%)
1	5	73909	100
2	10	68043	100
3	15	68912	100
4	20	70769	100
5	25	70233	100
6	30	70731	100
7	35	71904	100
8	40	2	50
9	45	2	50
10	50	2	50

Fonte: Autoria Própria

Como é possível notar, a acurácia da rede foi de 100% nas topologias de rede que continham entre 5 e 35 neurônios na única camada oculta, verificando-se que a topologia com 10 neurônios foi a que dependeu de menos épocas.

Dentre os três últimos a quantidade de épocas é muito menor e a acurácia ficou em 50%. Isso se deve pelo fato de que a saída gerada para todas as amostras de teste foram enquadradas na classe "1", ou seja, com falha. Isto pode ser um problema no processo de treinamento, uma vez que a RNA tenta encontrar o melhor mínimo local para convergir e ela tenha parado no primeiro que ela calculou.

Fez-se então mais dez testes envolvendo o mesmo conjunto de dados embaralhados, porém dessa vez mantendo 5 neurônios em todos os testes e com os mesmos parâmetros de rede. Obteve-se então a mesma acurácia de 100% em todos os dez testes, com quantidade de épocas variando entre 71556 e 73942.

O segundo grupo de classificações envolveu somente os dados de falhas, porém discriminando-os em pista interna, esferas e pista externa. Para este caso, foram necessários três neurônios na camada de saída para ser feita a classificação multiclass e novamente todas as 10 características de entrada. É possível verificar os resultados de acurácia e épocas da rede com função logística na Tabela 9.

Tabela 9 - Resultado da classificação de falhas por acréscimo de neurônios em uma camada

Teste	Nº de neurônios	Quantidade de épocas	Acurácia (%)
1	5	2688	12,8205
2	10	11386	33,3333
3	15	349997	35,8974
4	20	85557	35,8974
5	25	277985	43,5897
6	30	107370	35,8974
7	35	340466	33,3333
8	40	750731	35,8974
9	45	2	0
10	50	2	0

Fonte: Autoria Própria

O primeiro ponto a ser observado deste primeiro teste nessa nova classificação é o baixo número de acertos da rede, sendo necessários números muito altos de épocas para treinar a rede. Em posse destas informações, adotou-se uma topologia diferente de RNA, com duas camadas escondidas para um maior espectro de aprendizagem e caracterização das amostras de entrada.

Apesar desta estratégia, muitos dos testes tiveram seus resultados divergentes, sendo que algumas das topologias de rede divergiram completamente, onde o treinamento fez com que a rede fizesse as predições que todas as amostras estava com todas as falhas, ou resultado “1 1 1”, ou ainda uma divergência de treinamento em si, tendo como resultados “0 0 0”, ou seja, a rede não conseguindo fazer uma classificação plausível.

No primeiro caso citado no parágrafo anterior, as topologias apresentaram números extremamente baixos de épocas de treinamento, ficando entre uma e duas épocas e tendo maior ocorrência com redes compostas por quantidades acima de 15 neurônios em cada camada; e no segundo caso as topologias apresentaram números de cerca de 200 a 300 épocas, muito abaixo do que se obteve para as topologias com as acurácias mais altas. Ainda existem os casos onde a rede classificou todas as amostras como sendo de duas falhas diferentes, como por exemplo “1 0 1”.

A Tabela 10 apresenta as topologias que apresentaram melhores acurácias, novamente mantendo a função logística como função de saída. Observa-se que nenhuma acurácia chegou a 50%, o que não é um bom resultado em se tratando de um sistema que visa classificar e prever uma condição.

Tabela 10 - Resultado da classificação de falhas por acréscimo de neurônios em duas camadas

Teste	Neurônios 1 ^a camada	Neurônios 2 ^a camada	Quantidade de épocas	Acurácia (%)
1	5	5	131858	33,3333
2	10	5	190987	25,641
3	15	5	175482	35,8974
11	5	10	380997	33,3333
12	10	10	142257	25,6410
13	15	10	140954	35,8974
14	20	10	118508	33,3333
21	5	15	122239	33,3333
22	10	15	372414	33,3333
23	15	15	123374	30,7692
25	25	15	2778	48,7179
26	30	15	377	25,6410
30	50	15	250	48,7179
31	5	20	137776	28,2051
32	10	20	323499	30,7692
34	20	20	7431	25,6410
35	25	20	6202	48,7179
39	45	20	9953	25,6410
41	5	25	137933	35,8974
51	5	30	86488	23,0769

Fonte: Autoria Própria

Observando os resultados da classificação das falhas, tomou-se outra estratégia de classificação para uma melhor avaliação das amostras. A fim de tirar a prova do que foi observado nos gráficos no item 5.3, foram feitos experimentos com a mesma topologia de rede classificando cada uma destas características individualmente. Na Tabela 11 é possível ver os melhores resultados para redes de uma camada escondida.

Tabela 11 - Melhores classificações de falhas em redes de uma camada

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	5	5	30,7692	Nenhuma Esfera
APT	5	5	28,2051	Nenhuma Esfera e uma Interna
RMS	50	50	33,3333	Nenhuma Esfera
FC	5	5	20,5128	Só Externa
FF	20	20	10,2564	Algumas como Externa
FI	5	5	20,5128	Algumas como Externa
FM	5	5	20,5128	Algumas como Externa
Curtose	15	15	15,3846	Algumas como Externa
Assimetria	25	25	23,0769	Algumas como Externa e Interna
Pico a Pico	10	10	28,2051	Diversificado

Fonte: Autoria Própria

Como já era de se esperar, somente uma camada oculta não conseguiu fazer uma discriminação clara das classes de falhas envolvendo as características individualmente. Promoveu-se então uma camada oculta adicional na rede, e os melhores resultados de classificação nas mesmas condições podem ser visualizadas na Tabela 12.

Tabela 12 - Melhores classificações de falhas em redes de duas camadas

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	10	5	38,4615	Nenhuma Esfera
APT	5	30	33,3333	Nenhuma Esfera
RMS	15	10	38,4615	Alguns de todas
FC	40	20	48,718	Todas como Externa
FF	40	20	48,718	Todas como Externa
FI	25	25	48,718	Todas como Externa
FM	30	20	48,718	Todas como Externa
Curtose	20	20	48,718	Todas como Externa
Assimetria	30	20	25,641	Todas como Interna
Pico a Pico	40	20	48,718	Todas como Externa

Fonte: Autoria Própria

A partir dos resultados de classificação e de observação dos gráficos, é possível observar que sozinhas as características apontadas como as mais promissoras não corresponderam individualmente a um resultado melhor do que as avaliadas como não promissoras, em ambas as topologias de rede.

Foram feitas então combinações de algumas características como entradas da rede com o objetivo de obter melhores resultados, sendo a combinação de características mais promissora a junção da FF, FI, FM e Curtose em uma rede de uma camada oculta de 30 neurônios, que obteve uma acurácia de 57,1429% com os acertos bem diversificados.

Tomou-se então a terceira abordagem de classificação, onde os dados de cada rolamento foram divididos em dois conjuntos. Desta vez, a estratégia adotada foi fazer as primeiras classificações de cada uma das características a fim de confirmar de fato quais seriam as melhores características para classificação. A Tabela 13 mostra as classificações do rolamento frontal com uma rede de uma camada.

Tabela 13 - Melhores classificações de falhas do rolamento frontal em redes de uma camada

Característica	Nº de neurônios	Acurácia (%)	Observações
APF	15	57,1429	Diversificado
APT	5	53,5714	Uma Interna e restante Externa
RMS	5	60,7143	Diversificado
FC	5	28,5714	Algumas como Externa
FF	10	28,5714	Algumas como Externa
FI	30	32,1429	Algumas como Externa
FM	35	32,1429	Algumas como Externa
Curtose	5	28,5714	Algumas como Externa
Assimetria	5	21,4286	Algumas como Externa
Pico a Pico	5	50	Diversificado

Fonte: Autoria Própria

É possível observar que a característica com melhor desempenho em discriminar as amostras foi o RMS, conseguindo mostrar diversificação de predição na etapa de teste da RNA.

A fim de tentar aprimorar o aprendizado da rede e em posse das observações dos testes anteriores, adicionou-se uma camada oculta para verificar a melhora na acurácia da rede. Os melhores resultados de classificação de características podem ser vistos na Tabela 14.

Tabela 14 - Melhores classificações de falhas do rolamento frontal em redes de duas camadas

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	5	20	60,7143	Diversificado
APT	10	10	53,5714	Diversificado
RMS	10	20	71,4286	Diversificado
FC	25	20	50	Todas como Externa
FF	35	20	50	Todas como Externa
FI	50	20	50	Todas como Externa
FM	25	20	50	Todas como Externa
Curtose	5	5	28,5714	Algumas como Externa
Assimetria	50	20	50	Todas como Externa
Pico a Pico	5	5	50	Algumas como Esferas e Externa

Fonte: Autoria Própria

Como é possível observar, todas as características com exceção da APT, Pico a Pico e curtose apresentaram aumento na acurácia, se forem considerados os casos em que a rede colocou todas as amostras como sendo de alguma classe específica. Havia a expectativa de que a rede com duas camadas ocultas pudesse melhorar a acurácia da característica que melhor se saiu nos testes, no caso a RMS, e esta foi correspondida.

Com isso, foram feitos testes combinando diversas características, sendo os que mais aparentavam ser promissoras os que traziam a junção da APF, APT, RMS e Pico a Pico, e a junção de RMS e Pico a Pico. Como melhores resultados, obteve-se 64,2857% para a primeira e 67,8571% na segunda, fazendo com que ambos os testes não apresentassem vantagens quando comparadas ao RMS sozinho.

Em um outro teste, dessa vez combinando APT e RMS, demonstrou 71,4286% em uma rede com uma camada, e este foi o melhor resultado obtido combinando características. Vale citar o uso das dez características em uma rede, o que resultou um máximo de 60,7143% de acurácia.

Concluídos os testes utilizando somente as amostras do rolamento dianteiro, fez-se então os testes do rolamento traseiro partindo primeiro para a abordagem de rede com uma camada oculta. Semelhante ao rolamento frontal, nenhuma das características se mostrou promissora quando estas foram analisadas em gráfico, o que levou novamente a realizar a classificação das características individualmente em uma rede de uma camada oculta. Os melhores resultados podem ser vistos na Tabela 15.

Tabela 15 - Melhores classificações de falhas do rolamento traseiro em redes de uma camada

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	10		0	Nenhum
APT	5		27,2727	Todas como Interna
RMS	45		63,6364	Nenhuma Esfera
FC	5		0	Nenhum
FF	5		18,1818	Nenhuma Interna
FI	5		0	Nenhum
FM	45		0	Nenhum
Curtose	5		9,0909	Uma de Externa
Assimetria	35		27,2727	Três de Externa
Pico a Pico	15		0	Nenhum

Fonte: Autoria Própria

Novamente, foi testada a possibilidade da adição de uma camada na rede melhorar a taxa de acerto, sendo possível ver os melhores resultados na Tabela 16.

Tabela 16 - Melhores classificações de falhas do rolamento traseiro em redes de duas camadas

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	15	20	27,2727	Todas como Interna
APT	25	20	45,4545	Todas como Externa
RMS	10	25	27,2727	Todas como Interna
FC	5	40	45,4545	Todas como Externa
FF	25	25	45,4545	Todas como Externa
FI	25	20	45,4545	Todas como Externa
FM	50	15	45,4545	Todas como Externa
Curtose	40	15	45,4545	Todas como Externa
Assimetria	20	20	45,4545	Todas como Externa
Pico a Pico	45	20	45,4545	Todas como Externa

Fonte: Autoria Própria

É possível verificar que em todos os casos com duas camadas ocultas houve um aumento da acurácia, porém de uma forma pouco prática, uma vez que a rede está classificando as amostras sempre em um mesmo grupo, não fazendo distinções.

5.4.2 Rede Neural Perceptron Multicamadas com Função Softmax

Assim como a RNA Perceptron Multicamadas com função logística, serão apresentados os resultados obtidos com esta RNA, porém com a função Softmax como função de saída.

O passo a passo será idêntico ao apresentado no item 5.4.1. Porém, como a RNA com função logística já obteve 100% de acurácia entre classes de sinais saudáveis e com falhas em algumas de suas topologias, não serão feitos experimentos desta divisão de classes com a Softmax.

O primeiro grupo de classificações é composto somente das classes de sinais de rolamento com falhas em pista interna, esferas e externa, sem diferenciar o rolamento de origem da falha. O primeiro teste com esta discriminação das classes foi feito com todas as características separadas individualmente, pois este procedimento faz com que a análise de cada uma das características não fique totalmente dependente da etapa feita no item 5.3. Na Tabela 17 é possível observar os melhores resultados obtidos com a rede operando com uma camada oculta.

Tabela 17 - Melhores classificações de falhas em redes de uma camada com Softmax

Característica	Nº de neurônios	Acurácia (%)	Observações
APF	5	43,5897	Diversificado
APT	50	51,2821	Uma Interna e restante Externa
RMS	40	48,7179	Dificuldade com Esferas
FC	5	48,7179	Todas como Externa
FF	20	48,7179	Cinco Internas e o resto Externa
FI	30	48,7179	Todas como Externa
FM	30	48,7179	Sete Interna e o resto Externa
Curtose	5	48,7179	Oito Interna e o resto Externa
Assimetria	25	51,2821	Uma Interna e o resto Externa
Pico a Pico	5	48,7179	Variado, porém mais Externa

Fonte: Autoria Própria

Com o intuito de obter melhores resultados em taxa de acerto, fez-se então a abordagem com uma RNA de duas camadas escondidas, podendo seus melhores resultados por característica serem observados na Tabela 18.

Tabela 18 - Melhores classificações de falhas em redes de duas camadas com Softmax

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	10	45	51,2821	Quatro Interna e o resto Externa
APT	10	20	51,2821	Variado
RMS	15	20	53,8462	Bem Variado
FC	15	10	53,8462	Variado
FF	15	5	48,7179	Todas como Externa
FI	20	5	48,7179	Todas como Externa
FM	30	5	48,7179	Todas como Externa
Curtose	5	5	48,7179	Todas como Externa
Assimetria	10	25	51,2821	Uma Interna e o resto Externa
Pico a Pico	25	10	53,8462	Variado

Fonte: Autoria Própria

Além destes testes, vale ressaltar que ao utilizar todas as características foi possível obter 53,8462% de acurácia com 50 neurônios em uma camada e 56,4103% em uma rede com duas camadas, sendo a primeira com 10 neurônios e a segunda com 40. Porém, este não foi o melhor resultado, já que o ensaio feito com somente RMS e APF obteve 58,9744% com 15 neurônios na primeira camada e 30 na segunda.

Tomou-se então a segunda abordagem de classificação utilizando a Softmax, que consistiu em classificar as falhas de pista interna, esferas e pista externa por rolamento a fim de verificar melhorias no processo. Na Tabela 19 é possível observar os melhores resultados para uma rede de somente uma camada oculta classificando as falhas do rolamento frontal por característica.

Tabela 19 - Melhores classificações de falhas frontais em redes de uma camada com Softmax

Característica	Nº de neurônios	Acurácia (%)	Observações
APF	25	64,2857	Bem variado
APT	15	71,4286	Uma Interna e resto Variado
RMS	10	64,2857	Bem variado
FC	10	53,5714	Uma Interna e resto Externa
FF	5	46,4286	Nenhuma Esfera
FI	15	53,5714	Uma Interna e resto Externa
FM	15	53,5714	Uma Interna e resto Externa
Curtose	15	60,7143	Nenhuma Esfera
Assimetria	10	60,7143	Nenhuma Interna
Pico a Pico	30	60,7143	Duas Internas e resto Variado

Fonte: Autoria Própria

É possível verificar que a rede tem dificuldade em classificar as características, uma vez que a acurácia maior foi de 71,4286% e que foi atingida somente no teste envolvendo APT, sendo que nenhuma das combinações de características feitas durante os testes obtiveram resultados melhores. Na Tabela 20 tem-se os melhores resultados de classificação envolvendo duas camadas ocultas e cada uma das características extraídas do rolamento frontal.

Tabela 20 - Melhores classificações de falhas frontais em redes de duas camadas com Softmax

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	15	10	64,2857	Bem variado
APT	20	5	71,4286	Uma interna e resto variado
RMS	20	25	78,5714	Bem Variado
FC	10	5	53,5714	Uma Interna e resto Externa
FF	30	5	50	Todas como Externa
FI	25	10	53,5714	Uma Interna e resto Externa
FM	20	15	53,5714	Uma Interna e resto Externa
Curtose	5	50	60,7143	Uma Interna e resto Externa
Assimetria	5	5	60,7143	Nenhuma Interna
Pico a Pico	25	10	67,8571	Variado

Fonte: Autoria Própria

Ao combinar todas, obteve-se como melhor resultado uma acurácia de 71,4286% com 10 neurônios na primeira camada e 20 na segunda. Vale citar outros testes feitos combinando as características, e que o melhor registrado foi dado com a combinação de RMS e Pico a Pico, que com 15 neurônios na primeira camada e 40 na segunda obteve 78,5714%, semelhante ao que se obteve utilizando só o RMS com duas camadas.

Feitos os testes envolvendo as amostras do rolamento frontal chega o momento de analisar os resultados dos testes envolvendo as amostras do rolamento traseiro. Na Tabela 21 é possível verificar os testes de cada característica com redes envolvendo uma camada oculta.

Tabela 21 - Melhores classificações de falhas traseiras em redes de uma camada com Softmax

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	5	20	63,6364	Nenhuma Esfera
APT	5	5	45,4545	Todas como Externa
RMS	5	5	63,6364	Nenhuma Esfera
FC	5	5	45,4545	Todas como Externa
FF	5	15	54,5455	Nenhuma Interna
FI	5	5	45,4545	Todas como Externa
FM	5	5	45,4545	Todas como Externa
Curtose	5	5	45,4545	Todas como Externa
Assimetria	5	5	63,6364	Nenhuma Interna
Pico a Pico	10	5	72,7273	Nenhuma Esfera

Fonte: Autoria Própria

Observando os resultados obtidos com a classificação das características, pode-se observar que grande parte faz suas respectivas melhores classificações como sendo sempre de uma mesma classe, de falhas em pista externa, o que não ajuda a concluir sobre o potencial ou não de discriminação que estas redes podem fazer. Porém, atenta-se para as características de Assimetria e Pico a Pico que obtiveram 72,7273% de acurácia.

Com isso, fez-se os testes com a rede de duas camadas escondidas para as características do rolamento traseiro. Os resultados podem ser vistos na Tabela 22.

Tabela 22 - Melhores classificações de falhas traseiras em rede de duas camadas com Softmax

Característica	Nº de neurônios		Acurácia (%)	Observações
	1ª Cam.	2ª Cam.		
APF	5	20	63,6364	Nenhuma Esfera
APT	5	5	45,4545	Todas como Externa
RMS	5	5	63,6364	Nenhuma Esfera
FC	5	5	45,4545	Todas como Externa
FF	5	15	54,5455	Nenhuma Interna
FI	5	5	45,4545	Todas como Externa
FM	5	5	45,4545	Todas como Externa
Curtose	5	5	45,4545	Todas como Externa
Assimetria	5	5	63,6364	Nenhuma Interna
Pico a Pico	10	5	72,7273	Nenhuma Esfera

Fonte: Autoria Própria

Vale pontuar que o teste envolvendo todas as características apresentou uma acurácia de 72,7273%, com 5 neurônios na primeira camada e 20 na segunda, havendo variedade de acertos entre as classes. Este resultado de taxa de acerto também foi observado combinando-se APT com RMS e Pico a Pico, APT com Pico a Pico e RMS com Pico a Pico, porém em todas estas três combinações não houve classificação de falhas em esferas.

5.5 Conclusão do Capítulo

Os resultados apresentados neste capítulo demonstram que há de fato um potencial da metodologia proposta para classificar como falha e saudável cada uma das amostras apresentadas para uma RNA Perceptron Multicamadas. Apesar disso, os métodos propostos não mostraram eficácia igual quando se tratou de classificar cada tipo de falha, tanto na abordagem generalizada das amostras quanto na que os dados dos dois rolamentos foram discriminados.

A etapa de detecção das falhas através dos gráficos no item 5.3 auxiliou em um primeiro instante na observação dos padrões das características das amostras, porém as RNAs se mostraram mais eficazes nos experimentos que envolveram a classificação de cada característica individualmente, procedimento que auxiliou na combinação de características como opções de entrada de dados para as redes.

Com isso, é possível ranquear as topologias de rede que melhor classificaram as falhas, tanto em uma abordagem geral quanto discriminando as amostras dos rolamentos. É importante observar que para os resultados os fatores principais para uma boa classificação são, por ordem de relevância, a obtenção de uma maior taxa de acerto na fase de teste da rede e como as amostras foram classificadas, e em caso de haver várias topologias com desempenho semelhante será posto como melhor entre estes a que necessitou de menos épocas para treinamento. Esta escalação pode ser verificada na Tabela 23.

Tabela 23 – Melhores resultados obtidos das classificações por RNAs

Rolamento alvo	Características	Função de Ativação	Nº de neurônios		Acurácia (%)	Épocas de Treinamento
			1ª Cam.	2ª Cam.		
Ambos	APF + RMS	Softmax	15	30	58,9744	46623
Frontal	RMS	Softmax	20	25	78,5714	30227
Traseiro	“Todas”	Softmax	5	20	72,7273	20900

Fonte: Autoria Própria

Para a classificação de ambos os rolamentos, nota-se que houve um aumento de 57,1429% com quatro características (FF, FI, FM e Curtose) em duas camadas com função logística para 58,9744% com duas características (APF e RMS) com a Softmax. Apesar disso, o resultado não se mostrou como uma melhora significativa, o que remete a ideia de que as abordagens feitas neste trabalho não são suficientes para a classificação generalizada de falhas em rolamentos sem discriminação das suas respectivas amostras.

Em se tratando da classificação de falhas específicas do rolamento frontal, obteve-se um aumento da taxa de acertos com a Softmax de 71,4286% para 78,5714%, sendo que estas porcentagens foram obtidas ao classificar as falhas utilizando somente a característica RMS com ambas as funções. Vale ressaltar que o uso de outras características também obtiveram resultados semelhantes, como a utilização conjunta da RMS e Pico a Pico, que com a Softmax em uma rede de duas camadas acertou 78,5714% e com uma função logística resultou em 71,4286%.

Já para o rolamento traseiro as maiores taxas de acerto foram de 63,6364% para 72,7273% com a Softmax. Por falta de mais testes com as características do rolamento traseiro em uma rede com função logística, observou-se que somente usando RMS com uma única camada oculta retornou o resultado exposto, diferentemente da Softmax que em várias combinações, especialmente as que envolviam a característica de Pico a Pico, demonstraram a taxa de 72,7273%. Apesar disso, observou-se que incluindo todas as 10 características para o rolamento traseiro auxiliou a rede em classificar dados de falhas em esferas, algo não observado nos demais testes.

6 CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentada uma metodologia para a identificação e classificação de padrões para o diagnóstico de operação de rolamentos instalados em um motor de indução, baseada em diversas características extraídas de IMFs no tempo e de Espectros de Hilbert no tempo-frequência e classificando-as em redes neurais artificiais Perceptron Multicamadas. Os dados utilizados foram extraídos de um repositório de bancos de dados de vibração de máquinas em operações diversas, sendo cada uma caracterizada por possuir um rolamento em uma condição diferente e com diversas velocidades e cargas no eixo do motor.

Foram feitas análises de parte destes sinais do repositório a fim de fazer uma verificação prévia das frequências de falha calculadas conforme outros trabalhos, com o intuito de se verificar e confirmar o impacto da EMD em um conjunto de dados e seu poder de filtragem das altas frequências de sinais. Por fim, para a avaliação de todos os conjuntos submetidos a HHT foram feitas análises matemáticas dos seus resultados, sendo a revisão bibliográfica de suma importância para auxiliar neste processo uma vez que essa transformada é uma ferramenta empírica e por isso fez-se necessário o estudo de trabalhos que se utilizaram dela e que pudessem trazer técnicas de análise.

Na etapa de extração de características utilizou-se dez características na classificação de padrões, todas aplicadas ao sinal da IMF5 e seu respectivo espectro. É possível observar a importância na seleção de características que serão utilizadas no trabalho para a detecção de padrões das falhas, como no caso deste trabalho o uso de gráficos, mostrando-se uma etapa importante também para verificar as características mais interessantes para um algoritmo classificador.

Como classificador de padrões utilizou-se a RNA Perceptron Multicamadas com duas opções de função de ativação de saída da rede: logística e Softmax. Ficou evidente que a Softmax contornou alguns problemas de classificação de multiclases, porém a melhoria da acurácia não foi significativa ao ponto de a rede alcançar taxas de acerto tão altas quanto as classificações feitas entre dados de rolamentos saudáveis e defeituosos, que apresentaram 100% de acerto na maioria dos testes.

Apesar de algumas das análises das características terem se provado erradas, serviram de guia para testes feitos posteriormente uma vez que tomou-se a iniciativa de classificar as características uma a uma individualmente e então tomar

decisões melhores em vista dos resultados, sendo um grande exemplo o rolamento traseiro onde se verificou depois que a Assimetria sozinha apresentou acurácia de 72,7273% e APT e RMS não tiveram tal resultado nas mesmas condições.

Nenhuma característica se mostrou absoluta para a classificação das falhas de forma generalizada ou de forma a discriminar os rolamentos, fazendo com que não seja possível, até o momento com os presentes testes, elaborar uma topologia de RNA que consiga fazer a classificação nos termos propostos.

Apesar disso, foi observada uma taxa de acerto de 78,5714% para rolamento frontal e 72,7273% para rolamento traseiro utilizando somente os dados de acelerômetro instalado na dianteira do motor, próximo ao eixo. Isto demonstra que as redes tem capacidade de fazer a diferenciação entre as falhas, porém com dificuldades.

6.1 Observações e sugestões para trabalhos futuros

Em vista dos resultados obtidos com a metodologia proposta, é possível fazer apontamentos para trabalhos futuros relacionados a esta pesquisa, envolvendo bancos de dados disponíveis na *Internet* ou coletados pelo pesquisador. As intenções futuras para este trabalho envolvem os seguintes itens:

- Extrair características diferentes das utilizadas no trabalho;
- Fazer o uso de técnicas de aprendizagem de máquina ou de técnicas de análise como PCA para avaliar quais são as características mais promissoras do conjunto extraído;
- Aumentar a quantidade de camadas ocultas e neurônios da RNA a fim de tentar melhorar a performance da rede;
- Coletar e utilizar dados próprios com ferramentas em laboratório, avaliando também possíveis melhores posições para a instalação dos sensores de vibração;
- Fazer o treinamento da rede com dados *off-line* e desenvolver um sistema e aquisição para o tratamento de dados *online* para serem classificados pela RNA já treinada;
- Implementar o sistema em um *Hardware* embarcado.

REFERÊNCIAS

ABREU, S. R. **Avaliação da transformada de Hilbert-Huang na detecção de desvios vocais**. 2019. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal da Paraíba, João Pessoa, 2019.

ALI, M. Z.; SHABBIR, M. N. S. K.; LIANG, X.; ZHANG, Y.; HU, T. Machine Learning-Based Fault Diagnosis for Single- and Multi-Faults in Induction Motors Using Measured Stator Currents and Vibration Signals. **IEEE Transactions on Industry Applications**. v. 55, n. 3, p. 2378-2391, mai-jun. 2019.

ANTONINO-DAVIU, J. A.; QUIJANO-LOPEZ, A.; FUSTER-ROIG, V.; NEVOT, C. Case stories of induction motors fault diagnosis based on current analysis. **Petroleum and Chemical Industry Conference Europe (PCIC Europe)**, Berlin, p. 1-9, 2016.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 17094-1: Máquinas elétricas girantes - Motores de indução Parte 1: Trifásicos**. 3 ed. Rio de Janeiro: ABNT, 2018. Disponível em: <https://webapp.utfpr.edu.br/bibservices/gedWeb>. Acesso em: 11 abr. 2022.

BAYRAM, D.; SEKER, S. Redundancy-Based Predictive Fault Detection on Electric Motors by Stationary Wavelet Transform. **IEEE Transactions on Industry Applications**. v. 53, n. 3, p. 2997-3004, mai-jun. 2017.

BAZAN, G. H. **Medidas de Informação e Sistemas Inteligentes Aplicados no Diagnóstico de Curto-Circuito do Estator de Motores de Indução Trifásicos**. 2015. 112 f. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná, Cornélio Procópio, 2016.

BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. Advances in Diagnostic Techniques for Induction Machines. **IEEE Transactions on Industrial Electronics**, v. 55, n. 12, p. 4109-4126, dez. 2008.

BENDERSKY, E. **The Softmax function and its derivative**. Disponível em: <https://eli.thegreenplace.net/2016/the-softmax-function-and-its-derivative/>. Acesso em nov. 2021.

BLODT, M.; GRANJON, P.; RAISON, B.; ROSTAING, G. Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring. **IEEE Transactions on Industrial Electronics**, v. 55, n. 4, p. 1813-1822, abr. 2008.

BONNETT, A. H.; YUNG, C. Increased Efficiency Versus Increased Reliability. **IEEE Industry Applications Magazine**. v. 14, n. 1, p. 29-36, jan. 2008.

BOUDRAA, A.; CEXUS, J. EMD-Based Signal Filtering. **IEEE Transactions on Instrumentation and Measurement**. v. 56, n. 6, p. 2196-2202, dez. 2007.

BRASIL. Ministério de Minas e Energia. **Balanco Energético Nacional 2020: Ano Base 2019**. Disponível em: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-479/topico-528/BEN2020_sp.pdf. Acesso em: 27 jan. 2021.

CASE WESTERN RESERVE UNIVERSITY. **Bearing Data Center Website**. Disponível em: <https://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-university-bearing-data-center-website>. Acesso em: 03 mai. 2021.

ESFAHANI, E. T.; WANG, S; SUNDARARAJAN, V. Multisensor Wireless System for Eccentricity and Bearing Fault Detection in Induction Motors. **IEEE/ASME Transactions on Mechatronics**, v. 19, n. 3, p. 818-826, jun. 2014.

FILHO, J. M. **Instalações elétricas industriais**. 9. ed. Grupo GEN, 2017. Disponível em: <https://integrada.minhabiblioteca.com.br/#/books/9788521633730/>. Acesso em: 04 abr. 2022.

GODOY, W. F.; SILVA, I. N.; GOEDEL, A.; PALÁCIOS, R. H. C. Evaluation of stator winding faults severity in inverter-fed induction motors. **Applied Soft Computing**, v. 32, p. 420-431, jul. 2015.

GONGORA, W. S.; GOEDEL, A.; SILVA, S. A. O.; GRACIOLA, L. C. Neural Approach to Fault Detection in Three-phase Induction Motors. **IEEE Latin America Transactions**, v. 14, n. 3, p. 1279-1288, mar. 2016.

HUANG, N. E.; SHEN, Z.; LONG, S. R.; WU, C. M.; SHIH, H. H. ZHENG, Q.; YEN, N. C.; TUNG, C. C.; LIU, H. H. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. **Proceedings of the Royal Society of London, Series A: Mathematical, Physical and Engineering Sciences**, v. 454, p. 903-995, mar. 1998.

HUANG, N. E.; WU, M. L. C.; LONG, S. R.; SHEN, S. S. P.; QU, W.; GLOERSEN, P.; FAN, K. L. A confidence limit for the empirical mode decomposition and Hilbert spectral analysis. **Proceedings of the Royal Society a Mathematical, Physical and Engineering Sciences**, v. 459, n. 2037, p. 2317-2345, set. 2003.

JIANG, H.; YUAN, J.; ZHAO, Q.; YAN, H.; WANG, S.; SHAO, Y. A Robust Performance Degradation Modeling Approach Based on Student's t-HMM and Nuisance Attribute Projection. **IEEE Access**, v. 8, p. 49629-49644, mar. 2020.

KARDEC, A. K.; NASCIF, J.; BARONI, T.. **Gestão estratégica e técnicas preditivas**. Rio de Janeiro: Qualitymark: ABRAMAN – Associação Brasileira de Manutenção, 2002.

LEME, M. O. **Metodologia de manutenção preditiva para motores elétricos, baseada em monitoramento de variáveis físicas e análise multicritério**. 2017. Tese – Programa de Pós-Graduação em Engenharia de Produção, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2017.

LOISELLE, R.; XU, Z.; VOLOH, I. Essential motor health monitoring. **IEEE Petroleum and Chemical Industry Committee Conference**, Houston, TX, USA, p. 1-5, 2015.

MARUTHI, G. S.; VISHWANATH, H. Application of MEMS Accelerometer for Detection and Diagnosis of Multiple Faults in the Roller Element Bearings of Three Phase Induction Motor. **IEEE Sensors Journal**, v. 16, n. 1, p. 145-152, jan. 2016.

MATHWORKS. Emd: Empirical mode decomposition. Disponível em: <https://www.mathworks.com/help/wavelet/ref/emd.html>. Acesso em: 20 mai. 2021.

MATHWORKS. Hht: Hilbert-Huang transform. Disponível em: <https://www.mathworks.com/help/wavelet/ref/hht.html>. Acesso em: 20 mai. 2021.

NANDI, S.; TOLIYAT, H. A.; LI, X. Condition Monitoring and Fault Diagnosis of Electrical Motors - A Review. **IEEE Transactions on Energy Conversion**, v. 20, n. 4, p. 719-729, dez. 2005.

NARENDIRANATH, B. T.; ARAVIND, A.; RAKESH, A.; JAHZAN, M.; RAMA, P. D. Application of EMD ANN and DNN for Self-Aligning Bearing Fault Diagnosis. **Archives of Acoustics**, v. 43, n. 2, jun. 2018.

NEUPANE, D.; SEOK, J. Bearing Fault Detection and Diagnosis Using Case Western Reserve University Dataset With Deep Learning Approaches: A Review. **IEEE Access**, v. 8, p. 93155-93178, abr. 2020.

OCAK, H.; LOPARO, K. A. Estimation of the running speed and bearing defect frequencies of an induction motor from vibration data. **Mechanical Systems and Signal Processing**, v. 18, n. 3, p. 515-533, mai. 2004.

ONEL, I. Y.; BENBOUZID, M. E. H. Induction Motor Bearing Failure Detection and Diagnosis: Park and Concordia Transform Approaches Comparative Study. **IEEE/ASME Transactions on Mechatronics**, v. 13, n. 2, p. 257-262, abr. 2008.

OPPENHEIM, A. V.; SCHAFER, R. W. **Processamento em tempo discreto de sinais**. 3. ed. São Paulo: Pearson Education do Brasil, 2013.

PAN, S.; LI, X. An FPGA-Based Embedded Robust Speech Recognition System Designed by Combining Empirical Mode Decomposition and a Genetic Algorithm, **IEEE Transactions on Instrumentation and Measurement**, v. 61, n. 9, p. 2560-2572, set. 2012.

PINES, D.; SALVINO, L. Structural health monitoring using empirical mode decomposition and the Hilbert phase. **Journal of Sound and Vibration**, v. 294, n. 1-2, p. 97-124, jun. 2006.

PRIETO, M. D.; CIRRINCIONE, G.; ESPINOSA, A. G.; ORTEGA, J. A.; HENAO, H. Bearing Fault Detection by a Novel Condition-Monitoring Scheme Based on

Statistical-Time Features and Neural Networks. **IEEE Transactions on Industrial Electronics**, v. 30, n. 8, p. 3398-3407, aug. 2013.

RAI, V. K.; MOHANTY, A. R. Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform. **Mechanical Systems and Signal Processing**, v. 21, n. 6, p. 2607-2615, aug. 2007.

RAJ, V. P.; NATARAJAN, K.; GIRIKUMAR, S. T. G. Induction motor fault detection and diagnosis by vibration analysis using MEMS accelerometer, **2013 International Conference on Emerging Trends in Communication, Control, Signal Processing and Computing Applications (C2SPCA)**, Bangalore, p. 1-6, 2013.

ROELANTS, P. **Softmax classification with cross-entropy (2/2)**. Disponível em: [https://peterroelants.github.io/posts/cross-entropy-softmax/#Softmax-classification-with-cross-entropy-\(2/2\)](https://peterroelants.github.io/posts/cross-entropy-softmax/#Softmax-classification-with-cross-entropy-(2/2)). Acesso em nov. 2021.

SAIDI, L.; ALI, J. B.; FNAIECH, F. Bi-spectrum based-EMD applied to the non-stationary vibration signals for bearing faults diagnosis. **ISA Transactions**, v. 53, n. 5, 2014, p. 1650-1660.

SAKHALKAR, P. N.; KORDE, P. Fault detection in induction motors based on motor current signature analysis and accelerometer. **2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)**. Chennai, p. 363-367. 2017.

SCHOEN, R. R.; HABETLER, T. G.; KAMRAN, F.; BARTFIELD, R. G. Motor bearing damage detection using stator current monitoring, **IEEE Transactions on Industry Applications**, v. 31, n. 6, p. 1274-1279, nov.-dez. 1995.

SEKER, S.; KAYRAN, A. H. Neural network application for fault detection in electric motors. **2009 Australasian Universities Power Engineering Conference**, Adelaide. dez. 2009.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais Para engenharia e ciências aplicadas: Fundamentos teóricos e aspectos práticos**. 2 ed. São Paulo: Artliber. 2016.

SKF. **6203**: Deep groove ball bearings. Disponível em: <https://www.skf.com/us/products/rolling-bearings/ball-bearings/deep-groove-ball-bearings/productid-6203>. Acesso em: 10 jan. 2022.

SKF. **6205**: Deep groove ball bearings. Disponível em: <https://www.skf.com/us/products/rolling-bearings/ball-bearings/deep-groove-ball-bearings/productid-6205>. Acesso em: 10 jan. 2022.

SMITH, W. A.; RANDALL, R. B. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study. **Mechanical Systems and Signal Processing**, v. 64–65, p 100-131, dez. 2015.

SOUALHI, A.; MEDJAHAR, K.; ZERHOUNI, N. Bearing Health Monitoring Based on Hilbert–Huang Transform, Support Vector Machine, and Regression. **IEEE Transactions on Instrumentation and Measurement**, v. 64, n. 1, p. 52-62, jan. 2015.

STROKER, J. J. What's the real cost of higher efficiency? [electrical energy efficiency]. **IEEE Industry Applications Magazine**. v. 9, n. 3, p. 32-37, mai.-jun. 2003.

WANG, B.; LEI, Y. **XJTU-SY Bearing Datasets**. Disponível em: <https://biaowang.tech/xjtu-sy-bearing-datasets/>. Acesso em: 04 mai. 2021.

WANG, B.; LEI, Y.; LI, N.; LI, N. A Hybrid Prognostics Approach for Estimating Remaining Useful Life of Rolling Element Bearings. **IEEE Transactions on Reliability**, v. 69, n. 1, p. 401-412, mar. 2020.

WANG, G.; CHEN, X. Y.; QIAO, F. L.; WU, Z.; HUANG, N. E. On Intrinsic Mode Function. **Advances in Adaptive Data Analysis**, v. 2, n. 3, p. 277-293, 2010.

WEG. **Electric Motors**: Specification Guide. Ver. 7. 2020. Disponível em: <https://static.weg.net/medias/downloadcenter/ha0/h5f/WEG-motors-specification-of-electric-motors-50039409-brochure-english-web.pdf>. Acesso em: 06 nov. 2021.

WEG. **WEG Motor Scan**: Installation and operation manual. 2020. Disponível em: <<https://static.weg.net/medias/downloadcenter/h0b/h4b/WEG-weg-motor-scan-manual-geral-de-instalacao-e-operacao-14603136-manual-english-portuguese-spanish-web.pdf>>. Acesso em 04 out. 2021.

WEN, L.; GAO, L.; LI, X. A New Deep Transfer Learning Based on Sparse Auto-Encoder for Fault Diagnosis. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 49, n. 1, p. 136-144, jan. 2019.

WU, Z.; HUANG, N. E. On the relations of empirical mode decomposition to the Fourier transform and wavelet analysis. **Advances in Adaptive Data Analysis**, v. 2, n. 4, p. 397-414. 2010.


YAN, R.; GAO, R. X. Hilbert–Huang Transform-Based Vibration Signal Analysis for Machine Health Monitoring. **IEEE Transactions on Instrumentation and Measurement**. v. 55, n. 6, p. 2320-2329, dez. 2006.

YU, J. A hybrid feature selection scheme and self-organizing map model for machine health assessment. **Applied Soft Computing**, v. 11, n. 6, p. 4041-4054, abr. 2011.

ZHAO, Y.; ZHOU, M.; XU, X.; ZHANG, N.; ZHANG, H. Fault Diagnosis Based on Space Mapping and Deformable Convolution Networks. **IEEE Access**. v. 8, p. 212599-212607, nov. 2020.


APÊNDICE A – Gráficos dos Dados de Falhas

Gráfico A.1 - Conjuntos dos dados de APF das amostras de falha




Fonte: Autoria Própria

Gráfico A.2 - Conjuntos dos dados de APT das amostras de falha




Fonte: Autoria Própria

Gráfico A.3 - Conjuntos dos dados de RMS das amostras de falha




Fonte: Autoria Própria

Gráfico A.4 - Conjuntos dos dados de FC das amostras de falha




Fonte: Autoria Própria

Gráfico A.5 - Conjuntos dos dados de FF das amostras de falha




Fonte: Autoria Própria

Gráfico A.6 - Conjuntos dos dados de FI das amostras de falha




Fonte: Autoria Própria

Gráfico A.7 - Conjuntos dos dados de FM das amostras de falha




Fonte: Autoria Própria

Gráfico A.8 - Conjuntos dos dados de Curtose das amostras de falha




Fonte: Autoria Própria

Gráfico A.9 - Conjuntos dos dados de Assimetria das amostras de falha




Fonte: Autoria Própria

Gráfico A.10 - Conjuntos dos dados de Pico a Pico das amostras de falha




Fonte: Autoria Própria

Gráfico A.11 - Conjuntos dos dados de APF das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.12 - Conjuntos dos dados de APT das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.13 - Conjuntos dos dados de RMS das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.14 - Conjuntos dos dados de FC das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.15 - Conjuntos dos dados de FF das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.16 - Conjuntos dos dados de FI das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.17 - Conjuntos dos dados de FM das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.18 - Conjuntos dos dados de Curtose das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.19 - Conjuntos dos dados de Assimetria das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.20 - Conjuntos dos dados de Pico a Pico das amostras de falha do rolamento frontal




Fonte: Autoria Própria

Gráfico A.21 - Conjuntos dos dados de APF das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.22 - Conjuntos dos dados de APT das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.23 - Conjuntos dos dados de RMS das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.24 - Conjuntos dos dados de FC das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.25 - Conjuntos dos dados de FF das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.26 - Conjuntos dos dados de FI das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.27 - Conjuntos dos dados de FM das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.28 - Conjuntos dos dados de Curtose das amostras de falha do rolamento traseiro




Fonte: Autoria Própria

Gráfico A.29 - Conjuntos dos dados de Assimetria das amostras de falha do rolamento traseiro



Fonte: Autoria Própria

Gráfico A.30 - Conjuntos dos dados de Pico a Pico das amostras de falha do rolamento traseiro



Fonte: Autoria Própria