

INSTITUTO FEDERAL DO ESPÍRITO SANTO
MESTRADO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

RODRIGO CESAR CAMPOS

**PREDIÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES
ELÉTRICOS COM A UTILIZAÇÃO DE TÉCNICAS DE *DEEP
LEARNING***

SERRA

2023

RODRIGO CESAR CAMPOS

**PREDIÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES
ELÉTRICOS COM A UTILIZAÇÃO DE TÉCNICAS DE *DEEP
LEARNING***

Dissertação apresentada à Coordenadoria do Curso de Mestrado em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientador:

Prof. Dr. Luiz Alberto Pinto

Prof. Dr. Gabriel Tozatto Zago

SERRA

2023

Dados Internacionais de Catalogação na Publicação (CIP)

C198p Campos, Rodrigo Cesar
2023 Predição de falhas em rolamentos de motores elétricos com a
utilização de técnicas de Deep Learning / Rodrigo Cesar Campos. - 2023.
84 f.; il.; 30 cm

Orientador: Prof. Dr. Luiz Alberto Pinto; Prof. Dr. Gabriel Tozatto Zago.

Dissertação (mestrado) - Instituto Federal do Espírito Santo, Programa
de Pós-graduação em Engenharia de Controle de Automação, 2023 .

1. Motores elétricos. 2. Aprendizado do computador. 3. Rolamentos.
4. Redes neurais (computação). I. Pinto, Luiz Alberto. II. Zago, Gabriel
Tozatto. III. Instituto Federal do Espírito Santo. IV. Título.

CDD 629

Bibliotecário: Valmir Oliveira de Aguiar - CRB6/ES 566

MINISTÉRIO DA EDUCAÇÃO
INSTITUTO FEDERAL DO ESPÍRITO SANTO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO


RODRIGO CESAR CAMPOS

PREDIÇÃO DE FALHAS EM ROLAMENTOS DE MOTORES ELÉTRICOS COM A UTILIZAÇÃO
DE TÉCNICAS DE DEEP LEARNING


Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, como requisito parcial para obtenção de título de Mestre em Engenharia de Controle e Automação.

Aprovado em 14 de julho de 2023


COMISSÃO EXAMINADORA

Documento assinado digitalmente
 **LUIZ ALBERTO PINTO**
Data: 21/09/2023 08:55:21-0300
Verifique em <https://validar.iti.gov.br>


Prof. Dr. Luiz Alberto Pinto
Instituto Federal do Espírito Santo
Orientador

Documento assinado digitalmente
 **GABRIEL TOZATTO ZAGO**
Data: 25/09/2023 13:18:00-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Gabriel Tozatto Zago
Instituto Federal do Espírito Santo
Orientador

Documento assinado digitalmente
 **DANIEL CRUZ CAVALIERI**
Data: 21/09/2023 09:08:08-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Daniel Cruz Cavalieri
Instituto Federal do Espírito Santo
Membro Interno

Documento assinado digitalmente
 **RODRIGO VAREJAO ANDRAEO**
Data: 22/09/2023 17:56:23-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Rodrigo Varejão Andreão
Instituto Federal do Espírito Santo
Membro Externo

AGRADECIMENTOS

Agradeço a Deus por ter me proporcionado chegar ao final de mais uma etapa em minha vida, sempre iluminando o meu caminho e proporcionando a sabedoria necessária para concluir cada etapa nesta jornada. Por ter me dado saúde e equilíbrio emocional em todas as dificuldades que surgiram ao longo desses últimos anos, sem ele nada disso seria possível.

Agradeço à minha esposa Rosângela e aos meus filhos Rodrigo Augusto e Rodolfo Augusto por compreenderem as várias horas em que estive ausente por causa do desenvolvimento deste trabalho.

Agradeço aos meus pais por todo o esforço investido na minha educação.

Aos meus orientadores Luiz Alberto Pinto e Gabriel Tozzato Zago, que além da orientação e capacitação, foram grandes motivadores para o término dessa fase tão relevante em minha vida.

Por último, mas não menos importante, agradeço a todos os professores do Programa de Pós-Graduação em Engenharia de Controle e Automação, IFES campus Serra, pelos conhecimentos transmitidos ao longo de todo este período.

“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito.
Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes”.

- *Marthin Luther King*

RESUMO

Os ambientes industriais são constituídos por diferentes tipos de equipamentos que compõem sistemas de produção complexos. Os mais propensos a falhas são os motores elétricos. Devido à sua natureza dinâmica, os motores elétricos estão sujeitos à ação de forças centrífugas, forças de atrito e forças resultantes da vibração das partes móveis. Este sistema de forças que atua sobre o equipamento provoca desgaste operacional nas partes móveis, que ao longo do tempo pode provocar falhas e paradas não planejadas. Desta forma, os rolamentos tornam-se parte importante dos motores. A utilização de técnicas de predição de falhas permite assegurar que os rolamentos sempre estarão em boas condições de funcionamento, garantindo a continuidade dos processos produtivos e evitando acidentes. Além disso, a implementação de estratégias preditivas em ambientes industriais pode reduzir os custos causados por paradas não programadas, bem como o tempo de parada da produção. Diversos estudos têm proposto o desenvolvimento de técnicas de predição de falhas em rolamentos, utilizando algoritmos de aprendizado de máquina. Como falhas em rolamentos modificam o regime de vibração, a aquisição e análise desses sinais podem fornecer informações importantes sobre o estado de funcionamento destes componentes. Neste contexto, este trabalho investiga o tema da predição de falhas em rolamentos a partir de sinais de vibração utilizando Long Short-Term Memory (LSTM). A etapa experimental foi realizada utilizando os sinais de vibração do conjunto de dados *Intelligent Maintenance Systems* (IMS). Os sinais de vibração do referido conjunto foram adquiridos por meio de acelerômetros na planta experimental. Para a predição das falhas, foram implementados modelos utilizando descritores extraídos considerando dois aspectos: o domínio do sinal (domínio do tempo e wavelet) e a estratégia de extração dos descritores do sinal (descritores estatísticos e descritores extraídos por meio de uma CNN). Desta forma, foram propostas quatro arquiteturas de modelos para a predição de falhas iminentes: Modelo 1 (domínio do tempo e descritores estatísticos), Modelo 2 (domínio do tempo e CNN), Modelo 3 (domínio wavelet e descritores estatísticos) e Modelos 4 (domínio wavelet e CNN). Em geral, todos os modelos se mostraram eficientes na predição de falhas, principalmente os que foram implementados utilizando o domínio wavelet e/ou CNN. Os melhores resultados foram obtidos pelo Modelo 4, com o filtro wavelet Symlet 8, no nível de resolução 4 (acurácia = 98,47%, precisão = 98,90%, sensibilidade = 90,20%, especificidade = 98,84 e F1-score = 93,47%). Os resultados indicam que o uso de LSTM combinado com o domínio wavelet e/ou CNN, com o objetivo de prever falhas em rolamentos pode melhorar a confiabilidade dos sistemas de produção, antecipando ações preventivas e reduzindo a necessidade de manutenção corretiva.

Palavras-chave: diagnóstico de falhas, predição de falhas, análise de vibração, aprendizado de máquinas, falhas em rolamentos, CNN, descritores estatísticos.

ABSTRACT

Industrial environments are constituted of different types of equipment that make up complex production systems. The most prone to failure are electric motors. Due to their dynamic nature, electric motors are subject to the action of centrifugal forces, frictional forces and forces resulting from the vibration of moving parts. This system of forces acting on the equipment causes operational wear on the moving parts, which over time can provoke failures and unplanned shutdowns. In this way, rolling bearings become an important part of motors. By using failure prediction techniques can ensure the rolling bearings will be always in good operating condition, ensuring the production processes continuity and avoiding accidents. In addition, the implementation of predictive strategies in industrial environments can reduce costs caused by unscheduled outages, as well as production downtime. Several studies have proposed the development of bearings failures prediction techniques, using machine learning algorithms. As bearing failures modify the vibration regime, the acquisition and analysis of these signals may provide important information about the operating condition of these components. In this context, this research investigates the subject of failure prediction in rolling bearings from vibration signals using Long Short-Term Memory (LSTM) networks. The experimental phase was carried out on the vibration signals from the data set Intelligent Maintenance Systems (IMS). Vibration signals of the referred data set were acquired by means of accelerometers in the experimental plant. To predicting failures, models were implemented by using descriptors extracted considering two aspects: the signal domain (time and wavelet domains) and the strategy to extract descriptors from the signal (estatistical descriptors and descriptors extracted by using a CNN). In this way, four models architectures were proposed to predicting imminent failures: Model 1 (time domain and statistical descriptors), Model 2 (time domain and CNN), Model 3 (wavelet domain and statistical descriptors) and Models 4 (wavelet domain and CNN). In general, all models show to be efficient in predicting failures, mainly those ones that were implemented by using wavelet domain and/or CNN. The best result were obtained by the Model 4, with the wavelet filter Symlet 8, at the resolution level 4 (accuracy = 98,47%, precision = 98,90%, sensibility = 90,20%, especificity = 98,84 and F1-score = 93,47%). The results indicate the use of LSTM combined together to wavelet domain and/or CNN, aiming to predicting failures in rolling bearings can improve the reliability of production systems, by anticipating preventive actions and reducing the need for corrective maintenance.

Keywords: failure diagnosis, prediction failure, vibration analysis, machine learning, rolling bearing failure, CNN, statistical descriptors

LISTA DE ILUSTRAÇÕES

Figura 1 – Assinatura vibracional por desbalanceamento.	26
Figura 2 – Desalinhamento paralelo.	27
Figura 3 – Desalinhamento angular.	27
Figura 4 – Assinatura vibracional por desalinhamento.	27
Figura 5 – Estrutura típica de um mancal de rolamento.	28
Figura 6 – Geometria dos elementos rolantes de um mancal.	29
Figura 7 – Assinaturas típicas de defeitos em rolamentos.	30
Figura 8 – Falhas devidos a assentos de eixos.	32
Figura 9 – Ajustes incorretos do eixo e da caixa de mancal	32
Figura 10 – Falhas devidos a assentos de eixos.	32
Figura 11 – Descascamento avançado causado pela fadiga.	33
Figura 12 – Neurônio biológico.	34
Figura 13 – Rede <i>MLP</i> com duas camadas intermediárias.	34
Figura 14 – Comparação das arquiteturas de uma rede neural <i>Multilayer Perceptron</i> e uma <i>Deep Neural Network</i>	35
Figura 15 – Arquitetura de rede convolucional unidimensional. Fonte: Adaptado de (KIM; GEEM; HAN, 2020)	36
Figura 16 – Rede Neural Recorrente.	40
Figura 17 – Rede Neural Recorrente Desenrolada.	40
Figura 18 – O módulo de repetição em um RNN padrão contém uma única camada.	41
Figura 19 – Estrutura da rede LSTM.	41
Figura 20 – Diagrama e fórmula do <i>forget gate</i>	42
Figura 21 – Diagrama e fórmulas do <i>input gate layer</i> e <i>tanh layer</i>	42
Figura 22 – Diagrama e fórmula do <i>cell state</i>	42
Figura 23 – Diagrama e fórmula do <i>state cell</i> , mas uma versão filtrada.	43
Figura 24 – Sinais de vibração no domínio do tempo de um mancal: (a) condição normal de operação e (b) falha na pista interna do mancal.	44
Figura 25 – Sinal de vibração no domínio do tempo.	45
Figura 26 – Sinal de vibração no domínio da frequência.	45
Figura 27 – Decomposição do sinal $f(x)$ em análise multiresolução.	47
Figura 28 – Matriz de confusão de 2 classes.	48
Figura 29 – Matriz de confusão para o exemplo de duas classes.	49
Figura 30 – Bancada experimental do Centro de pesquisa da IMS.	51
Figura 31 – Primeiras 1000 amostras de cada classe do rolamento 1 do Conjunto 1	53

Figura 32 – Fluxograma mostrando as configurações de construção dos modelos	55
Figura 33 – Arquitetura do Modelo 1 - Domínio do tempo + Descritores estatísticos	56
Figura 34 – Arquitetura do Modelo 2 - Domínio do tempo + <i>CNN</i>	56
Figura 35 – Arquitetura do Modelo 3 - Domínio <i>Wavelet</i> + Descritores estatísticos	56
Figura 36 – Arquitetura do Modelo 4 - Domínio <i>Wavelet</i> + <i>CNN</i>	57
Figura 37 – Dados Originais já padronizados	57
Figura 38 – Procedimento para transformação dos dos sinais originais com 20.480 amostras, em matrizes com 1000 colunas	58
Figura 39 – Matriz de descritores obtida a partir de um sinal de vibração do rolamento 1	59
Figura 40 – Arquitetura da rede LSTM utilizada para classificação	60
Figura 41 – Arquitetura da Rede CNN.	61
Figura 42 – Arquitetura com as redes <i>CNN</i> e <i>LSTM</i> integradas	62
Figura 43 – Gráfico de treinamento do Modelo 1 - sinais no domínio do tempo + descritores estatísticos	64
Figura 44 – Gráfico de treinamento do Modelo 2 - sinais no domínio do tempo + <i>CNN</i>	65
Figura 45 – Gráfico de treinamento do Modelo 3 - sinais no domínio <i>wavelet</i> com <i>Daubechies 4</i> + descritores estatísticos.	67
Figura 46 – Gráfico de treinamento do Modelo 3 - sinais no domínio <i>wavelet</i> com <i>Symlet 8</i> + descritores estatísticos	68
Figura 47 – Gráfico de treinamento do Modelo 3 - sinais no domínio <i>wavelet</i> com <i>Coiflet 2</i> + descritores estatísticos	69
Figura 48 – Gráfico de treinamento do Modelo 4 - sinais no domínio <i>wavelet</i> com <i>Daubechies 4</i> + <i>CNN</i>	71
Figura 49 – Gráfico de treinamento do Modelo 4 - sinais no domínio <i>wavelet</i> com <i>Symlet 8</i> + <i>CNN</i>	72
Figura 50 – Gráfico de treinamento do Modelo 4 - sinais no domínio <i>wavelet</i> com <i>Coiflet 2</i> + <i>CNN</i>	73

LISTA DE TABELAS

Tabela 1 – Classificação ISO de danos em rolamentos e modos de falha. . . .	31
Tabela 2 – Matriz confusão de classes desbalanceadas.	49
Tabela 3 – Métricas de desempenho das classes desbalanceadas.	49
Tabela 4 – Conjuntos de sinais de vibração que constituem o conjunto <i>IMS</i> . .	51
Tabela 5 – Condições de operação identificadas para o rolamento 1 do Conjunto 1	52
Tabela 6 – Parâmetros estatísticos extraídos do sinal no domínio do tempo. . .	54
Tabela 7 – Resultados do Modelo 1 - sinais no domínio do tempo + descritores estatísticos	63
Tabela 8 – Resultados do Modelo 2 - sinais no domínio do tempo + <i>CNN</i> . . .	65
Tabela 9 – Resultados do Modelo 3 - sinais no domínio <i>wavelet</i> com <i>Daubechies</i> <i>4</i> + descritores estatísticos	67
Tabela 10 – Resultados do Modelo 3 - sinais no domínio <i>wavelet</i> com <i>Symlet 8</i> + descritores estatísticos	68
Tabela 11 – Resultados do Modelo 3 - sinais no domínio <i>wavelet</i> com <i>Coiflet 2</i> + descritores estatísticos	69
Tabela 12 – Resultados do Modelo 4 - sinais no domínio <i>wavelet</i> com <i>Daubechies</i> <i>4</i> + <i>CNN</i>	71
Tabela 13 – Resultados do Modelo 4 - sinais no domínio <i>wavelet</i> com <i>Symlet 8</i> + <i>CNN</i>	72
Tabela 14 – Resultados do Modelo 4 - sinais no domínio <i>wavelet</i> com <i>Coiflet 2</i> + <i>CNN</i>	73
Tabela 15 – Resultados de todos os Modelos com os melhores resultados para comparação dos resultados	74

LISTA DE ABREVIATURAS E SIGLAS

AEMT	<i>Association of Mechanical and Electrical Trades</i>
BFDF	<i>Bearing Fundamental Defect Frequency</i>
BLS	<i>Broad Learning System</i>
BPFI	<i>Ball Pass Frequency Inner</i>
BPFO	<i>Ball Pass Frequency Outer</i>
BSF	<i>Ball Spining Frequency</i>
CNN	Rede Neural Convolutcional
EASA	<i>Electrical Apparatus Service Association</i>
F1	<i>F1-Score</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
FTF	<i>Fundamental Train Frequency</i>
IMS	<i>Intelligent Maintenance Systems</i>
ISO	Organização Internacional para Padronização
k-NN	<i>k-Nearest Neighbour</i>
LS	<i>Least Squares</i>
LSTM	<i>Long Short-Term Memory</i>
MI	Motor de Indução
MLGS	Multi-Layer Grid Search
MLP	<i>Multilayer Perceptron</i>
PNN	<i>Probabilistic Neural Network</i>
PREC	Precisão
RMS	<i>Root Mean Square</i>
RNA	Rede Neural Artificial

RNN	Rede Neural Recorrente
RRMS	<i>Relative Root Mean Square</i>
RSSD	<i>Resonance-based Sparse Signal Decomposition</i>
SMOTE	<i>Sinthetic Minority Over-sampling Technique</i>
SVM	<i>Support Vector Machine</i>
TN	<i>True Negative</i>
TP	<i>True Positive</i>
TW	Transformada <i>Wavelet</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	OBJETIVO GERAL	16
1.2	OBJETIVOS ESPECÍFICOS	16
1.3	ESTRUTURA DO RELATÓRIO	17
2	REVISÃO DO ESTADO DA ARTE	18
2.1	PESQUISAS SOBRE <i>MACHINE LEARNING</i> APLICADO AO DIAGNÓSTICO DE FALHAS	18
2.2	PESQUISAS SOBRE <i>MACHINE LEARNING</i> APLICADO À PREDIÇÃO DE FALHAS	21
3	REFERENCIAL TEÓRICO	24
3.1	DEFEITOS EM MÁQUINAS ROTATIVAS	24
3.1.1	Condição Normal	25
3.1.2	Desbalanceamento	26
3.1.3	Desalinhamento	26
3.1.4	Efeito das Vibrações sobre os Rolamentos	27
3.1.5	Falhas em rolamentos	29
3.2	REDES NEURAIIS ARTIFICIAIS	33
3.3	REDES NEURAIIS CONVOLUCIONAIS	35
3.3.1	Estrutura em Camadas das Redes Neurais Convolucionais	36
3.3.2	Métodos de Otimização	38
3.4	REDES NEURAIIS RECORRENTES	39
3.4.1	Redes <i>Long Short-Term Memory</i> - LSTM	40
3.5	EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS DE VIBRAÇÃO	43
3.5.1	Análise no Domínio do Tempo	43
3.5.2	Transformada de Fourier	44
3.5.3	Transformada <i>Wavelet</i>	46
3.6	MÉTRICAS DE DESEMPENHO	47
4	METODOLOGIA	50
4.1	DESCRIÇÃO DA BASE DE DADOS	50
4.2	DESCRITORES ESTATÍSTICOS	53
4.3	CONFIGURAÇÕES DE MODELAGEM	55
4.3.1	Pré-processamento e Organização dos Dados	57
4.3.2	Arquitetura da Rede <i>Long Short-Term Memory</i> Utilizada para Classificação	59

4.3.3	Arquitetura da Rede Neural Convolutacional Utilizada para Extração de Descritores	60
4.3.4	Configurações de Treinamento e Validação	61
5	RESULTADOS	63
5.1	RESULTADO DOS TESTES COM O MODELO 1 - SINAIS NO DOMÍNIO DO TEMPO E DESCRITORES ESTATÍSTICOS	63
5.2	RESULTADO DOS TESTES COM O MODELO 2 - SINAIS NO DOMÍNIO DO TEMPO E <i>CNN</i>	64
5.3	RESULTADO DOS TESTES COM O MODELO 3 - SINAIS NO DOMÍNIO <i>WAVELET</i> E DESCRITORES ESTATÍSTICOS	65
5.3.1	Resultados do Modelo 3 utilizando o filtro <i>wavelet Daubechies 4</i>	67
5.3.2	Resultados do Modelo 3 utilizando o filtro <i>wavelet Symlet 8</i>	68
5.3.3	Resultados do Modelo 3 utilizando o filtro <i>wavelet Coiflet 2</i>	69
5.4	RESULTADO DOS TESTES COM O MODELO 4 - SINAIS NO DOMÍNIO <i>WAVELET</i> E <i>CNN</i>	70
5.4.1	Resultados do Modelo 4 utilizando o filtro <i>Daubechies 4</i>	71
5.4.2	Resultados do Modelo 4 utilizando o filtro <i>Symlet 8</i>	72
5.4.3	Resultados do Modelo 4 utilizando o filtro <i>Coiflet 2</i>	73
5.5	MELHORES RESULTADOS OBTIDOS EM CADA ARQUITETURA DE MODELO	74
5.6	COMPARAÇÃO COM TRABALHOS CORRELATOS	74
6	CONCLUSÃO	75
7	TRABALHOS FUTUROS	77
	REFERÊNCIAS	78
	ANEXO A – Publicações	84

1 INTRODUÇÃO

Os motores de indução são os equipamentos que existem em maior número nos parques industriais. Componentes primordiais na produção, estão presentes em processos de aquecimento, refrigeração, bombeamento, tração, movimentação de carga, transporte, (SILVA; CARDOSO, 2005), entre outras tarefas. As boas condições de funcionamento desses equipamentos são indispensáveis para assegurar a continuidade operacional dos processos produtivos, bem como a qualidade dos produtos.

As condições operacionais dos motores de indução são afetadas por diversos fatores, tais como, as condições do ambiente em que operam e o estado de conservação das instalações. Motores operando em ambientes sujos e úmidos, impregnados por resíduos de lubrificantes e com elevado índice de particulados no ar e na superfície, poderão ter suas condições de resfriamento deterioradas, o que pode causar sobreaquecimento e a possível queima do equipamento. Além das condições do ambiente de operação, o estado de conservação das instalações também afetam a operação dos motores de indução. Instalações elétricas mal conservadas podem provocar falhas como curtos-circuitos nos alimentadores dos motores resultando na interrupção do funcionamento do equipamento, ou mesmo a sua queima.

Outro fator que afeta as condições operacionais é a condição de carga do motor no processo de produção. Em alguns processos de produção, os motores de indução são submetidos a sobrecargas temporárias, que têm como consequência o sobreaquecimento dos enrolamentos, e o desligamento do motor. Quando submetidos a longos períodos de sobrecarga, o isolamento dos motores podem ser danificados, alterando as condições de operação, o que pode levar à queima do equipamento. Embora os motores de indução sejam equipamentos robustos e bem projetados para suportar as severas condições de trabalho a que são submetidos, a ocorrência de falhas é inerente ao processo de funcionamento.

Devido às suas características construtivas, e à sua natureza dinâmica, quando em funcionamento os motores de indução ficam submetidos a ação de forças centrífugas, forças de atrito e forças resultantes da vibração das partes móveis ou de folgas no conjunto. Devido a esse sistema de forças atuando sobre o equipamento, as partes móveis sofrem desgastes operacionais, que com o tempo podem resultar no aparecimento de falhas e em quebras intempestivas.

Nesse contexto, os mancais de rolamento se tornam as partes mais importantes das máquinas rotativas, e dos motores de indução, em particular. Sob condições adequadas de operação e conservação os mancais de rolamento reduzem os efeitos das ações

das referidas forças sobre o conjunto, prevenindo o aparecimento de alguns tipos de falhas. De acordo com (ZHANG et al., 2019), que investigou a probabilidade de ocorrência de falhas em máquinas rotativas, problemas em rolamentos são responsáveis por cerca de 30% a 40% de todas as falhas nessas máquinas. Um estudo sobre a confiabilidade de motores (THORSEN; DALVA, 1998) afirma que os rolamentos são os componentes mais sujeitos à ocorrência de falhas em motores de indução trifásicos. Uma estatística divulgada em conjunto pela *Electrical Apparatus Service Association e Association of Mechanical and Electrical Trades (EASA/AEMT)* sobre falhas em motores elétricos mostra que 51% das falhas que ocorrem nesses equipamentos podem ou estão diretamente relacionadas aos mancais de rolamentos. Embora sejam divergentes quanto ao percentual, os trabalhos anteriores indicam ser significativo o percentual de falhas em motores de indução relacionadas aos mancais de rolamento.

Paradas não programadas em motores de indução, notadamente, as provocadas por falhas reduzem ou interrompem o processo produtivo resultando em redução da produção e prejuízos financeiros para a indústria. Dessa forma, a utilização de estratégias eficientes para estimar a ocorrência de falhas, e acompanhar sua evolução ao longo do tempo, permite que a equipe de manutenção desenvolva ações para mitigar os efeitos dessas sobre a planta e sobre a produção. Paradas programadas para a correção das falhas aumentam a disponibilidade e a confiabilidade dos equipamentos, reduzindo os impactos sobre a produção.

De forma geral, falhas em motores elétricos se manifestam ainda em estágio incipiente, afetando o seu desempenho antes mesmo de sua consolidação. Um motor em estágio de falha incipiente, pode apresentar vários indícios de funcionamento anormal, tais como, alterações no regime de vibrações mecânicas, variações na temperatura de operação e alteração da resistência de isolamento. Dessa forma, o desenvolvimento de sistemas de diagnóstico de falhas em motores elétricos através da análise dos sinais emitidos pelo processo, com a utilização de técnicas de *Machine Learning* pode identificar falhas ainda em estágio de evolução, permitindo intervenções corretivas programadas antes que as mesmas evoluam para estágios que provoquem danos nos equipamentos, comprometam a segurança de operadores e provoquem a interrupção da produção.

O monitoramento contínuo das condições de funcionamento dos motores elétricos industriais fornece informações que auxiliam no planejamento das intervenções de manutenção antes da ocorrência de falhas. Em diversos processos industriais de diferentes ramos da indústria produtiva, variáveis como temperatura, vibração, pressão, vazão e outros, estão presentes em uma variedade de equipamentos como compressores centrífugos ou parafuso, bombas centrífugas, ventiladores, motores, turbinas a gás ou vapor, entre outros. Em motores elétricos a análise de vibração tem sido aplicada em

predição de falhas iminentes. Com base no conhecimento e análise dos fenômenos medidos por sensores, é possível detectar vibrações excessivas no equipamento. A utilização de técnicas de aprendizagem de máquinas possibilita a predição precisa das falhas, bem como a elaboração da análise de tendência de sua evolução ao longo do tempo. Nesse contexto, os sinais de vibração se mostram os mais adequados tendo em vista a investigação das condições de funcionamento do equipamento, possibilitando a intervenção prévia para substituição das partes que apresentam desgaste, otimizando o processo de manutenção (MOHANTY, 2014).

A evolução da tecnologia dos sensores, do *hardware* dos computadores, e o advento das técnicas de inteligência artificial abriram um campo promissor para o desenvolvimento de sistemas para elaboração automática de diagnósticos e previsão de faltas em processos industriais. Nas últimas décadas, devido a crescente complexidade dos problemas a serem tratados e do elevado volume de dados produzidos, tornou-se necessário o uso de ferramentas computacionais mais sofisticadas que, operando de forma autônoma, possibilitem a redução da necessidade de intervenção humana e dependência dos especialistas (FACELI et al., 2011).

Um modelo eficaz de diagnóstico e predição de falhas orientado à dados envolve três etapas básicas: (1) aquisição de dados do rolamento durante a operação, (2) extração de variáveis dos sinais para caracterizar assinaturas das falhas e (3) classificação de diferentes condições de funcionamento do rolamento com base em características do processo (ISLAM; KHAN; KIM, 2016).

A proposta deste trabalho é fazer uma comparação entre os desempenhos de diferentes abordagens de modelagem, quando aplicadas à predição de falhas em rolamentos de motores elétricos. A abordagem proposta utiliza uma rede *Long Short Term Memory (LSTM)* para classificação da condição de operação. Para a construção dos modelos são utilizados os sinais de vibração do conjunto de dados do *Intelligent Maintenance Systems (IMS)*, disponibilizado pela *University of Cincinnati*. Os modelos de predição são construídos com os sinais no domínio do tempo e no domínio tempo/escala. Para a transformação dos sinais para o domínio tempo/escala são utilizados os filtros *wavelet Daubechies 4, Symlet 8 e Coiflet 2*. Os descritores são extraídos dos sinais de vibração utilizando parâmetros estatísticos, e através de uma *Rede Neural Convolutiva - RNC*. No segundo caso, os sinais de vibração brutos alimentam a entrada da *RNC*.

É importante definir o contexto de predição no âmbito dessa pesquisa. Problemas de predição clássicos consistem em, dado um conjunto de valores de uma série temporal de uma variável em instantes de tempo no passado, o objetivo é estimar os valores da variável em instantes de tempo no futuro. Contudo, na presente pesquisa, o conjunto de dados *IMS* está organizado em classes de acordo com o estágio da falha (*early, suspect, normal, suspect e imminent*), que possuem uma representação

temporal. Neste aspecto, pode-se dizer que a temporalidade está representada pelas classes. Dessa forma, de fato, o problema que é tratado na pesquisa é um problema de classificação. Contudo, ao classificar uma amostra como da classe *imminent*, por exemplo, o modelo está predizendo que uma falta está próximo de ocorrer. Nesse aspecto, o problema assume características de predição.

1.1 OBJETIVO GERAL

O objetivo geral deste trabalho é comparar o desempenho de modelos de predição de falhas em rolamentos de motores elétricos por meio de redes *LSTM*, com a utilização de descritores estatísticos extraídos nos domínios de tempo e tempo/escala e descritores extraídos diretamente dos sinais de vibração brutos utilizando *CNN*.

1.2 OBJETIVOS ESPECÍFICOS

A fim de alcançar o objetivo geral declarado, os seguintes objetivos específicos foram estabelecidos:

- Realizar uma revisão da literatura sobre o problema de predição de falhas em rolamentos de motores elétricos industriais;
- Estudar o ambiente *Matlab* para implementação dos códigos e algoritmos de predição.
- Estudar os sinais de vibração e sua utilização na predição de falhas de rolamentos de motores elétricos;
- Investigar o conjunto de descritores a serem extraídos dos sinais de vibração que resultem nos melhores desempenhos dos modelos de predição;
- Investigar a utilização de *CNNs* quando aplicadas à extração de descritores;
- Estudar e entender as arquiteturas de redes neurais *LSTM* para predição de falhas que serão utilizadas para a implementação dos modelos.

1.3 ESTRUTURA DO RELATÓRIO

Na sequência, este trabalho está constituído pelos seguintes capítulos: o Capítulo 2 apresenta uma revisão do estado da arte sobre a utilização de Aprendizado de Máquina no diagnóstico e predição de falhas em equipamentos e processos industriais. O Capítulo 3 faz uma revisão dos principais conceitos e ferramentas relacionados ao tema do trabalho. O Capítulo 4 descreve a metodologia e o conjunto de dados utilizados nos experimentos. O Capítulo 5 apresenta os resultados dos testes realizados, e o Capítulo 6 traz as conclusões e trabalhos futuros.

2 REVISÃO DO ESTADO DA ARTE

A utilização de *Machine Learning* à análise de falhas em processos e equipamentos industriais, tem despertado grande interesse da comunidade de pesquisadores da área de inteligência artificial há várias décadas. As primeiras pesquisas na área investigaram a utilização de aprendizado de máquina para fins de classificação de falhas já ocorridas. Nos anos recentes, com o advento de novos algoritmos com potencial aplicação às tarefas de predição, diversos trabalhos foram propostos sobre a predição de falhas em sistemas e equipamentos industriais. Os trabalhos até então publicados se diferenciam quanto a aplicação (classificação ou predição de falhas), quanto ao tipo de classificador/preditor utilizado (Redes Neurais Artificiais, *k-Nearest Neighbour* - *k-NN*, *Support Vector Machine* - *SVM*, Árvore de Decisão, Redes Neurais Convolucionais, *Long Short-Term Memory* - *LSTM*), quanto aos sinais do processo utilizados para o desenvolvimento dos modelos (temperatura, corrente, vibração), quanto ao domínio em que os modelos foram implementados (tempo, frequência, tempo-frequência), e quanto ao ambiente experimental utilizado para a aquisição dos sinais (planta experimental de laboratório, ambiente de simulação e planta física real).

2.1 PESQUISAS SOBRE *MACHINE LEARNING* APLICADO AO DIAGNÓSTICO DE FALHAS

Pesquisas sobre diagnóstico inteligente de falhas em rolamentos de esferas, aplicando RNA e *SVM* foram apresentadas no trabalho de (KANKAR; SHARMA; HARSHA, 2011). Através da análise e extração de descritores dos sinais de vibração, os autores investigaram diversas falhas nos rolamentos de esferas, tais como, defeitos nas pistas interna e externa, defeitos nos elementos rolantes e uma combinação de todos eles. Dados estatísticos foram utilizados para extração de descritores no domínio do tempo como a média, desvio padrão, assimetria, amplitude, curtose e o fator de crista. Técnicas de seleção de atributos aplicando algoritmos de aprendizado de máquinas, foram utilizados para reduzir a dimensionalidade do conjunto. Os resultados obtidos foram, acurácia de 71,23% para o modelo utilizando RNA e 73,97% para o modelo utilizando *SVM*. Os autores consideraram que os resultados da classificação se mostraram promissores e com grande potencial de aplicação em sistemas de diagnósticos inteligentes para prevenção de falhas.

O trabalho de (LIMA et al., 2013) aborda a identificação de falhas mecânicas em máquinas rotativas utilizando um simulador de equipamentos dinâmicos. Os autores realizaram a aquisição dos sinais de vibração em três condições de operação: (i)

operação normal, (ii) falha por desbalanceamento e (iii) falha por desalinhamento. Os vetores de características foram obtidos através do processamento dos sinais no domínio da frequência pela magnitude do espectro do sinal nas frequências de rotação desejadas. Para a classificação das falhas, os dados foram particionados em conjunto de treino, validação e teste, com, respectivamente, 70%, 10% e 20% do total das amostras. A acurácia na classificação obtida ao ser utilizado o algoritmo RNA/MLP foi 93,5%.

Em (LIU et al., 2018), os autores fizeram uma revisão da aplicação de técnicas de inteligência artificial ao diagnóstico de falhas em máquinas rotativas, apresentando a fundamentação teórica dos métodos, bem como sua aplicação na indústria. O trabalho faz uma breve introdução de diferentes algoritmos de aprendizado de máquina: *k-NN*, *SVM*, *naive bayes*, RNA e *deep learning*, e baseado em uma ampla revisão bibliográfica de trabalhos na área, desenvolve uma análise comparativa enfatizando as vantagens e as desvantagens de cada método. Como uma contribuição adicional, os autores abordam a aplicação de técnicas de processamento de sinais para a extração de descritores. Nesse aspecto, são enfatizadas as análises no domínio do tempo, no domínio da frequência, e no domínio tempo-frequência.

Uma abordagem para elaboração de diagnóstico de falhas em um *Chiller* foi apresentada por (HAN et al., 2019). Foram utilizados os classificadores *SVM*, *LS-SVM* (*Least squares - Support Vector Machine*) e *PNN* (*Probabilistic Neural Network*). O conjunto de dados é composto por sessenta e quatro descritores e oito condições de operação, sendo uma condição normal e sete condições de natureza de falha. Foram realizados testes utilizando o número total de descritores e fazendo a seleção dos oito mais relevantes do sistema. O classificador baseado no *LS-SVM*, utilizando oito atributos, apresentou desempenho superior aos demais, tanto em relação à taxa de classificação correta (99,63%), quanto em relação ao custo computacional, aspecto em que foi 36,7% mais rápido que o *SVM*.

O trabalho apresentado por (GANGSAR; TIWARI, 2019) propõe uma variação do algoritmo *SVM* para o diagnóstico de nove tipos de faltas (cinco de natureza elétrica e quatro de origem mecânica), em motores de indução. Para o diagnóstico, o método utiliza os sinais de vibração e de corrente elétrica, por estarem associados a um grande grupo de falhas, sendo também indicadores de suas severidades. As assinaturas das falhas foram extraídas para diferentes condições de carga e velocidade do motor, tendo sido as mesmas classificadas utilizando o algoritmo *SVM*. Inicialmente o diagnóstico é elaborado para as falhas nas mesmas condições de carga e velocidade em que os sinais foram obtidos. Posteriormente, uma estratégia de predição foi aplicada para estender o diagnóstico para considerar as condições intermediárias de carga e velocidade. Os resultados mostram que o método proposto é capaz de diagnosticar com precisão

todas as falhas para as mesmas condições de operação (99,7%). O desempenho na predição para as condições intermediárias (93,2%) foi considerado promissor pelos autores.

Em (ALI et al., 2019), os pesquisadores utilizaram uma bancada de testes experimentais para investigar a influência do desbalanceamento das classes na classificação de falhas. De acordo com os autores, o objetivo da pesquisa foi avaliar o desempenho de classificadores com dados desbalanceados e com dados balanceados de forma sintética com o auxílio de algoritmos de balanceamento. Para o balanceamento das classes foi utilizada a técnica *Sinthetic Minority Over-Sampling Technique (SMOTE)*. A técnica consiste em realizar uma reamostragem dos dados utilizando dados sintéticos, para isso, pode ser feita uma sobre-amostragem das classes minoritárias ou uma sub-amostragem das classes majoritárias. Os resultados obtidos utilizando RNA/MLP foram de 81,2% com as amostras desbalanceadas e 96,2% após o balanceamento das classes.

O trabalho de (LI; WANG; ZHANG, 2020) aborda o diagnóstico de falhas em uma bancada experimental que simula o comportamento de um equipamento dinâmico. A pesquisa propõe a utilização de sinais de vibração e se aplica à analisar três tipos de falhas em mancais: (i) falha no elemento rolante, (ii) falha na gaiola e (iii) falha na pista externa. Os autores propõem a utilização de uma arquitetura de rede conhecida como *Resonance-Based Sparse Signal (RSSD)* e *Broad Learning System (BLS)*, técnica conhecida como *RSSD-BLS*. Para a extração dos descritores, os sinais foram decompostos em componentes de alta e baixa ressonância pela *RSSD*, e após a decomposição, a medida de energia em cada nível de decomposição foi utilizada como descritores para o modelo de classificação. A rede *RSSD-BLS* possui uma estrutura dividida em quatro camadas: (i) camada de entrada, (ii) camada de decomposição do sinal através da *RSSD*, (iii) camada para extração de descritores e (iv) camada de saída. A camada de entrada recebe os sinais de vibração no domínio do tempo, na segunda camada é realizada a decomposição do sinal em componentes de alta e baixa ressonância, na terceira os descritores baseados na energia do sinal são extraídos de cada nível de decomposição, os descritores são utilizados como entrada para a rede *BLS* no qual tem-se como saída a classificação das amostras. Os resultados obtidos atingiram uma acurácia de 97,67% utilizando o método proposto.

Em (BIANCHINI et al., 2023) foi apresentado um modelo de simulação de falhas de rolamentos que utiliza a corrente de fase do estator para realizar análise no domínio do tempo e frequência. Os descritores foram extraídos de um conjunto de sinais de corrente, cujas faltas foram simuladas em uma bancada experimental de teste de motores. Os sinais foram coletados por meio de sensores de efeito *Hall*. As tensões de fase e as correntes de linha foram moduladas para alimentarem as entradas analógicas

de uma placa de aquisição dos sinais. Para a construção dos classificadores, descritores estatísticos foram extraídos dos sinais, tendo sido utilizados os algoritmos: Rede auto-organizável de *Kohonen*, Floresta Aleatória, k-Vizinhos Mais Próximos, *Perceptron* Multicamadas e Máquina de Vetores de Suporte. Os resultados obtidos atingiram uma acurácia e *F1-score* acima de 94% .

2.2 PESQUISAS SOBRE *MACHINE LEARNING* APLICADO À PREDIÇÃO DE FALHAS

O trabalho de (MOHAMADI; AHMADI; MOHTASEBI, 2008), proposto quando as pesquisas sobre predição de falhas em rolamentos estavam ainda no início, investigou a correlação entre a amplitude dos sinais de vibração e a extensão das falhas em rolamentos. Os experimentos foram realizados em uma bancada de testes de laboratório constituída por um motor de indução conectado mecanicamente a um rotor de um ventilador localizado na extremidade de um eixo suportado por mancal de rolamento. Para a realização dos experimentos foram utilizados rolamentos novos e rolamentos que apresentavam as falhas que se desejava estudar. Dois tipos de falhas comuns em rolamentos foram analisadas, falha na pista interna e falha na pista externa. Em cada condição de funcionamento, normal, falha na pista interna ou falha na pista externa, o rolamento correspondente foi instalado na planta experimental, e um conjunto de sensores triaxiais foram utilizados para a aquisição dos sinais de vibração gerados pelo conjunto. Os resultados foram analisados utilizando métodos de análise no domínio do tempo e no domínio espectral. Segundo os autores, a análise da forma de onda do sinal de vibração no domínio do tempo pode ser associada a severidade das vibrações nos rolamentos defeituosos e a análise do espectro de frequência do sinal de vibração identifica a exata natureza dos defeitos nos rolamentos.

Um método de predição da vida útil restante de rolamentos foi apresentado em (PAN et al., 2020). A abordagem proposta utiliza o valor da Raiz Quadrada Média Relativa (*Relative Root Mean Square - RRMS*) para classificar a condição de operação do rolamento em dois estágios: funcionamento normal e em processo de degeneração. De acordo com os autores, quando em operação normal o valor *RRMS* permanece constante, contudo, quando o rolamento entra em estado de degradação o valor *RRMS* aumenta. Um modelo *Extreme Learning Machine* com realimentação foi implementado para realizar as predições da tendência da ocorrência de defeito no rolamento em tempo real e a curto prazo. Uma vez que o valor *RRMS* do sinal de vibração indica que o rolamento entrou no estágio de defeito, 13 descritores estatísticos são extraídos dos sinais de vibração e fornecidos como entrada para uma rede neural *Extreme Learning Machine* multivariada realimentada para a predição da vida útil restante do rolamento.

Os autores argumentam que as vantagens da utilização dessa arquitetura de rede para tarefas de predição são a capacidade da realização de regressão multivariada e a realização de predições a partir de amostras pequenas. Os resultados reportados pelos autores mostram que o método proposto tem elevada acurácia na predição de curto-prazo e alta velocidade de resposta nos casos em que o tamanho das amostras de treino é limitado.

Em (GU K.; ZHANG, 2021) foi proposto uma combinação da transformada *wavelet* (TW) com uma rede neural *Long Short-Term Memory - LSTM* para predição de falhas a partir de vários sensores. O modelo designado pelos autores *DWT-LSTM* foi proposto para elaborar diagnósticos sobre o estado de degradação dos rolamentos. Inicialmente a *DWT* é empregada para extrair informações de falhas dos sinais de vibração. Em seguida a rede *LSTM* é utilizada para caracterizar as dependências de longo prazo contidas nas séries temporais representadas pelos sinais de vibração e predizer a ocorrência ou não de falhas..

Em (LIU Z. H.; MENG, 2021) os autores propuseram uma abordagem de predição da vida útil remanescente de rolamentos combinando uma *Elastic Net* com uma rede *Long Short-Term Memory - LSTM*. O algoritmo *E-LSTM*, conforme designado pelos autores, apresenta como principal diferencial o fato da correlação espaço-tempo ser levada em consideração para a predição da vida útil remanescente do rolamento através da *LSTM*. Para minimizar o problema do *overfitting* da rede *LSTM* durante o treinamento, o termo de regularização da *elastic net* é introduzido na estrutura da rede *LSTM*. Segundo os autores, o modelo *E-LSTM* caracteriza de forma mais precisa as mudanças na saída provocadas pela degradação dos rolamentos. Os autores argumentam que o modelo *E-LSTM* pode obter alta estabilidade na predição da vida útil remanescente de rolamentos.

Os autores em (LIU et al., 2021) propuseram um modelo denominado *LSS*, que combina as vantagens da *LSTM* com processos estatísticos para realizar a predição de faltas em rolamentos de turbinas aéreas que apresentam características de degradação multiestágios. Inicialmente as características de vibração no domínio do tempo são extraídas e com a utilização de análise de processos estatísticos, são separadas de acordo com o estágio de degradação do rolamento. Em seguida, os sinais categorizados em classes de acordo com o estágio de degradação são fornecidos como entrada para o modelo *LSS* para predição. Os autores reportam que o modelo proposto pode obter melhores resultados na predição do que redes neurais recorrentes, *SVR* e *LSTM*.

Um modelo baseado em *Maximum Correlation Kurtosis Deconvolution - MCKD* e *LSTM* foi proposto em (MA et al., 2022), para fazer predições antecipadas de falhas em rolamentos a partir do comportamento do sinal de vibração. Na primeira etapa do método o algoritmo *Cuckoo Search (CS)* é utilizado para otimizar os parâmetros,

comprimento do filtro e período de deconvolução do *MCKD*. Na segunda etapa a taxa de aprendizado da *LSTM* é configurada, de acordo com a série temporal da deconvolução, e é treinada e utilizada para realizar a predição.

Os autores em (AFRIDI et al., 2023) propuseram um sistema de diagnóstico de faltas em rolamentos utilizando redes *LSTM*. De acordo com os autores, o aspecto importante do método proposto é que para a elaboração dos diagnósticos, são utilizados os sinais de vibração brutos, eliminando a etapa característica de extração de descritores. Os modelos foram testados com sinais de vibração geradas por diferentes fontes, e, de acordo com os autores, os resultados obtidos superam os de trabalhos anteriores que utilizaram extração de características no domínio do tempo, no domínio da frequência e no domínio tempo/frequência como entrada para o modelo de classificação.

Com o advento da Indústria 4.0, e a crescente complexidade dos equipamentos e processos industriais, o tema do desenvolvimento de sistemas de diagnóstico e predição de falhas em rolamentos de motores elétricos continuará despertando o interesse de acadêmicos e profissionais das indústrias. Contextualizando a contribuição deste trabalho no universo das pesquisas sobre o tema, a presente pesquisa faz uma comparação entre o desempenho de modelos de diagnóstico/predição construídos no domínio do tempo e no domínio tempo/escala, utilizando para a construção dos modelos, descritores estatísticos e através do processamento direto do sinal de vibração bruto por redes neurais convolucionais.

3 REFERENCIAL TEÓRICO

Este capítulo descreve as ferramentas e técnicas utilizadas na elaboração deste trabalho, bem como os algoritmos e as métricas utilizadas para avaliação do desempenho dos modelos. Os defeitos mecânicos mais comuns em equipamentos dinâmicos serão abordados nesta seção, assim como as técnicas de análise de vibração aplicadas. As abordagens mais comuns para análise de sinais são apresentadas de forma resumida, além de ser feita uma breve descrição das técnicas de *Deep Learning* utilizadas para a execução dessa pesquisa.

3.1 DEFEITOS EM MÁQUINAS ROTATIVAS

Equipamentos dinâmicos possuem na sua construção, estruturas fixas e elementos internos que estão em constante movimento. Esse movimento dos elementos internos geram forças mecânicas que são transmitidas para a parte estrutural da máquina produzindo vibrações. Em condições normais de operação o nível de vibração é mantido constante. Quando ocorre alguma anormalidade ou esta começa a se manifestar, os níveis de vibração são alterados e transmitidos aos componentes adjacentes, se propagando pela estrutura mecânica da máquina resultando numa vibração complexa, composta por várias frequências próprias do equipamento.

Exemplos de falhas que resultam no aumento da amplitude do nível de vibração em máquinas rotativas incluem (NANDI; AHMED, 2020):

- Desbalanceamento.
- Desalinhamento.
- Danos em mancais e caixas multiplicadoras.
- Ressonância.
- Folgas mecânicas.
- Danos nos sistemas de transmissão (correias ou correntes).
- Danos no eixo.
- Falhas em rolamentos.

As falhas, que podem resultar em alterações nos níveis de vibração, podem ocorrer por operação inadequada, sobrecarga, desgastes de componentes, folgas mecânicas,

manutenção inadequada ou até mesmo a falta de manutenção. A identificação correta da natureza da falha é importante para que possa ser possível o planejamento de uma intervenção preventiva, ou corretiva a fim de mitigar o problema. De particular interesse para este trabalho é o estudo da correlação entre as falhas em rolamentos e a alteração do regime de vibração de um equipamento dinâmico. No contexto desse trabalho, os equipamentos dinâmicos a serem considerados são os motores elétricos.

Existem diversas técnicas para avaliar e acompanhar o comportamento dinâmico de um equipamento, dentre as quais podem ser mencionadas:

- **Nível de vibração:** método bem simples e bastante utilizado. Consiste da medição global do valor de vibração, geralmente o valor eficaz (*RMS*) proveniente de um transdutor. O nível do sinal é comparado com valores adotados por normas ou recomendações do fabricante. De acordo com o nível do sinal é possível avaliar se o equipamento está ou não apresentando alguma falha, sendo necessária uma análise mais aprofundada para identificar o tipo de falha que está ocorrendo. Os níveis de alarmes podem delimitar quatro regiões de operação, que são: (i) boa, (ii) permissível, (iii) tolerável e (iv) não permissível (RILEY et al., 1999).
- **Análise no domínio do tempo:** este tipo de análise tem como fundamentação básica o histórico temporal dos sinais de vibração do equipamento. Essa metodologia é comumente empregada para acompanhar a evolução da vibração e na decisão de parar o equipamento para manutenção. Esta técnica pode ser muito útil na previsão de fenômenos dinâmicos, como a produção de impactos transientes devido à falhas no engrenamento ou de rolamentos, dentre outros eventos relacionados à rotação como trincas no eixo ou roçamento (MITCHELL, 1993).

Uma abordagem, comumente utilizada para verificar a condição do equipamento, consiste em extrair descritores estatísticos a partir dos sinais dos sensores de vibração. Esses descritores, que, pressupostamente, podem ser correlacionados às causas das vibrações, são utilizados para a implementação de técnicas automáticas de diagnóstico e predição de falhas. (NANDI; AHMED, 2020).

3.1.1 Condição Normal

A condição normal refere-se a uma máquina nova, com o equipamento balanceado e mancais de rolamentos novos, livre de folgas excessivas e sem problemas no acionamento. Esta condição é tomada como referência associada à condição ideal de operação (ARCO-VERDE, 2008).

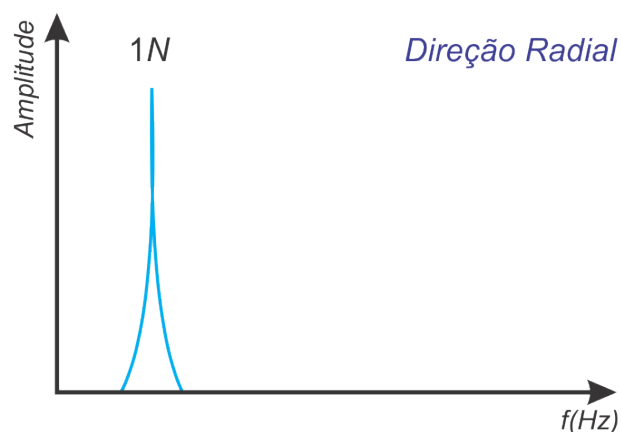
Muitos problemas estão associados diretamente à velocidade de rotação do equipamento. Diante deste fato, a frequência de rotação do equipamento é denominada de

frequência fundamental, sendo esta a principal componente de frequência presente no equipamento, e portanto, a referência para todas as demais. Neste trabalho vamos adotar a notação $1N$ para representar a frequência de rotação, onde N corresponde à frequência de rotação do equipamento.

3.1.2 Desbalanceamento

O desbalanceamento é caracterizado por uma vibração senoidal na frequência da rotação em $1N$ na direção radial, podendo também ser acompanhada por uma alta amplitude na direção axial. Um rotor está desbalanceado quando ocorre uma desigualdade na distribuição de massa em relação ao eixo de rotação. A Figura 1 apresenta a assinatura vibracional característica do defeito por desbalanceamento.

Figura 1 – Assinatura vibracional por desbalanceamento.




Fonte: (LOBÃO, 2020).

3.1.3 Desalinhamento

Muito comum em máquinas rotativas, o desalinhamento é caracterizado por uma vibração com uma componente de duas vezes a frequência de rotação, ou seja, $2N$. O desalinhamento pode ocorrer de duas formas: paralelo (horizontal) e angular (vertical). O paralelo ocorre quando não há o alinhamento entre as linhas de centro dos eixos da máquina. O desalinhamento angular ocorre quando as linhas de centro do eixo das máquinas se interceptam, formando um ângulo entre si. As Figuras 2 e 3 ilustram, respectivamente, os desalinhamentos paralelo e angular.


No desalinhamento paralelo ocorre um componente alto de $2N$ na direção radial, já no desalinhamento angular ocorre um componente alto em $1N$ na direção axial. A Figura 4 exemplifica os sinais característicos de desalinhamento.

Figura 2 – Desalinhamento paralelo.



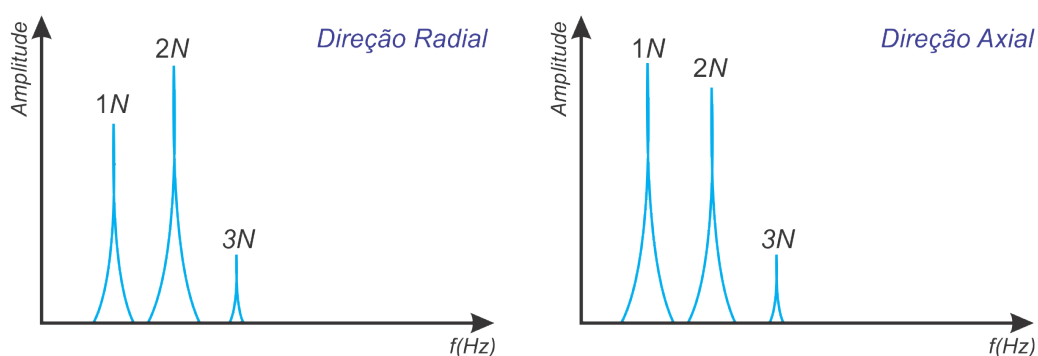
Fonte: (LOBÃO, 2020).

Figura 3 – Desalinhamento angular.



Fonte: (LOBÃO, 2020).

Figura 4 – Assinatura vibracional por desalinhamento.




Fonte: (LOBÃO, 2020).

3.1.4 Efeito das Vibrações sobre os Rolamentos

Os mancais são componentes críticos em máquinas rotativas. Existem basicamente dois tipos de mancais, (i) mancais deslizantes, que realizam movimentos através do contato deslizante e (ii) mancais de elementos rolantes, que mantêm o movimento através do contato rolante (COLLINS; BUSBY; STAAB, 2009). Os mancais de elementos rolantes são os mais utilizados e podem ser categorizados em dois grupos principais sendo (i) rolamentos de esferas e (ii) rolamentos de rolo (cilíndrico ou cônico). A Figura 5 ilustra o mancal de rolamento de esferas com seus componentes principais.

Os defeitos em mancais podem ocorrer por vários motivos, incluindo (i) fadiga devido a uma sobrecarga no rolamento, (ii) falha no sistema de lubrificação, (iii) contaminação ou corrosão e (iv) falha na instalação (NANDI; TOLIYAT; LI, 2005). As falhas nos elementos rolantes geram uma série de impulsos que se repetem periodicamente numa

Figura 5 – Estrutura típica de um mancal de rolamento.



Fonte: (AHMED; NANDI, 2018).

taxa conhecida como *bearing fundamental defect frequency (BFDF)*, aos quais estão relacionadas à velocidade de rotação do eixo, a geometria do elemento rolante e o local da falha. De acordo com a parte danificada, a *BFDF* pode ser categorizada em quatro grupos sendo (i) falha na pista externa (*BPFO - ball pass frequency outer*), (ii) falha na pista interna (*BPFI - ball pass frequency inner*), (iii) falha no elemento rolante (*BSF - ball spinning frequency*) e (iv) falha na gaiola (*FTF - fundamental train frequency*). As *BFDFs* podem ser calculadas conforme as equações 3.1, 3.2, 3.3 e 3.4.

$$BPFO = \frac{N_b S_{sh}}{2} \left(1 - \frac{d_b}{D_p} \cos \varphi \right). \quad (3.1)$$

$$BPFI = \frac{N_b S_{sh}}{2} \left(1 + \frac{d_b}{D_p} \cos \varphi \right). \quad (3.2)$$


$$BSF = \frac{D_p}{2d_b} \left(1 - \left(\frac{d_b}{D_p} \cos \varphi \right)^2 \right). \quad (3.3)$$

$$FTF = \frac{S_{sh}}{2} \left(1 - \frac{d_b}{D_p} \cos \varphi \right). \quad (3.4)$$

Aqui, N_b representa a quantidade de elementos rolantes, S_{sh} é a velocidade de rotação do eixo, d_b é o diâmetro do elemento rolante, D_p representa o diâmetro primitivo e φ é o ângulo de contato entre o elemento rolante e a pista. A Figura 6 ilustra a geometria dos elementos rolantes de um mancal de rolamento.

A degradação do rolamento pode ser iniciada na pista interna ou externa, num dos elementos rolantes ou na gaiola. Na sequência os demais componentes do equipamento irão sofrer com os danos. O processo de degradação é dividido em quatro estágios

Figura 6 – Geometria dos elementos rolantes de um mancal.



Fonte: (NANDI; AHMED, 2020).

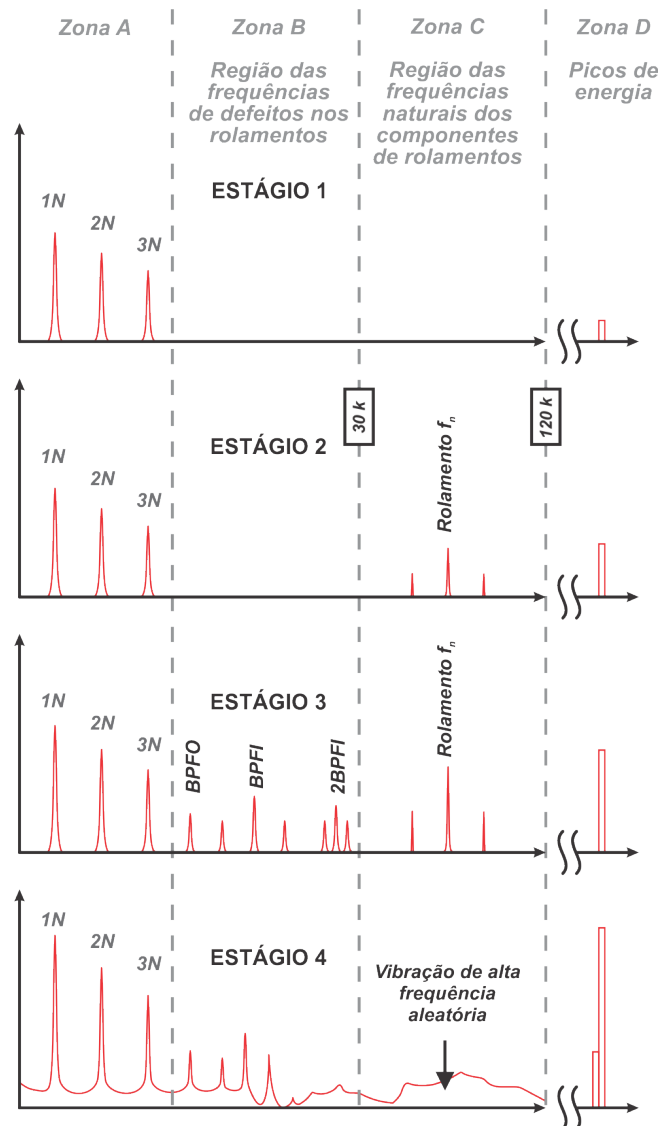
de evolução conforme apresentado pela Figura 7. No estágio 1, ocorrem vibrações elevadas em frequências de até $5N$. No estágio 2, com o surgimento de choques mecânicos nos componentes internos, frequências naturais mais elevadas surgem acompanhadas de bandas laterais espaçadas nas frequências dos impactos repetitivos. No estágio 3 surgem as componentes de frequências características do funcionamento do rolamento de forma elevada, já no estágio 4 surgem vibrações aleatórias em todas as faixas de frequências mais altas do espectro (LOUREIRO, 2009).

3.1.5 Falhas em rolamentos

Rolamentos são peças fundamentais e estão entre os componentes mais importantes dos mecanismos de alta tecnologia. Se ocorrer a falha em um dos rolamentos, podem ocorrer paradas não programadas dos equipamentos e até ocorrer grandes perdas a níveis catastróficos. Uma boa escolha ao se programar para adquirir um rolamento de alta qualidade pode garantir uma alta confiabilidade de uma máquina (SKF, 2022). Todo equipamento possui uma expectativa de vida útil, e para os rolamentos, essa expectativa se baseia em 8 hipóteses:

- Possui qualidade comprovada e não possui defeitos inerentes;
- Está corretamente especificado para a aplicação;
- As dimensões estão corretas;
- Está montado corretamente;
- Recebe lubrificação adequada, conforme indicado pelo fabricante;
- O arranjo de rolamentos está devidamente protegido (selado);

Figura 7 – Assinaturas típicas de defeitos em rolamentos.



Fonte: Adaptado de (LOUREIRO, 2009).

- As condições operacionais são compatíveis com o arranjo de rolamentos;
- A manutenção periódica recomendada é realizada.

Com uma crescente preocupação em evitar as falhas nos rolamentos, a Organização Internacional para Padronização (ISO) desenvolveu uma metodologia para classificação de falhas em motores em 6 grupos principais, e 16 subgrupos, conforme demonstrado na Tabela 1, todos esses ligados a falhas nos rolamentos após a fabricação. A norma baseia-se principalmente em características relacionadas aos elementos rolantes, como pistas e superfícies funcionais identificando os mecanismos envolvidos para cada tipo de falha.

Inspeções em rolamentos após um período de funcionamento, podem revelar várias mudanças, tais como:

Tabela 1 – Classificação ISO de danos em rolamentos e modos de falha.

Grupo Principal	Subgrupo
Fadiga	Fadiga superficial
	Fadiga subsuperficial
Desgaste	Desgaste abrasivo
	Desgaste adesivo
Corrosão	Corrosão por umidade
	Corrosão por atrito
	Corrosão por contato
	Falso brinelamento
Erosão Elétrica	Tensão excessiva
	Fuga de corrente
Deformação plástica	Sobrecarga
	Endentações por partículas
	Endentações por manuseio
Fratura e trinca	Fratura forçada
	Fratura por fadiga
	Trinca térmica

Fonte: Adaptado de (SKF, 2022).

- Descoloração no furo do anel interno e no diâmetro do anel externo.
- Corrosão por contato no furo do anel interno ou na superfície externa do anel externo.
- Áreas opacas nas pistas e elementos rolantes, algumas vezes também muito brilhantes.

Uma das formas para classificação de falhas em rolamentos agrupa as falhas em duas categorias: falhas pré-operacionais e falhas operacionais.

- **Falhas pré-operacionais:** São falhas que ocorrem devido a alguma ação antes do elemento ter sido colocado em operação e, geralmente, têm como causas: ajustes incorretos do eixo e da caixa de mancal, danos e falhas devidos a assentos de eixos ou caixas de mancal defeituosos, desalinhamento estático, práticas de montagem inadequadas, circulação de corrente elétrica excessiva através do rolamento e danos de transporte e armazenagem. As Figuras 8, 9 e 10 ilustram alguns exemplos de falhas pré-operacionais:

A Figura 8 mostra a Corrosão por contato “pesada”, que frequentemente ocorre em aplicações muito carregadas. A corrosão por contato está na zona de carga do assento do anel externo.

Figura 8 – Falhas devidos a assentos de eixos.



Fonte: (SKF, 2022) .

A Figura 9 mostra o dano causado no rolamento devido a um ajuste muito apertado da caixa de mancal de um rolamento livre, induzindo cargas axiais pesadas, o que reduz, de forma considerável, a vida útil do rolamento.


Figura 9 – Ajustes incorretos do eixo e da caixa de mancal



Fonte: (SKF, 2022) .

A Figura 10 mostra Desgaste abrasivo devido ao deslizamento do anel externo.

Figura 10 – Falhas devidos a assentos de eixos.



Fonte: (SKF, 2022) .

- **Falhas operacionais:** São falhas que ocorrem durante a operação, e tem como causas: fadiga subsuperficial (iniciada abaixo da superfície), lubrificação ineficiente,

vedação ineficiente, desalinhamento operacional e vibração (falso brenilamento). A Figura 11 mostra o descascamento avançado causado pela fadiga iniciada abaixo da superfície do material.

Figura 11 – Descascamento avançado causado pela fadiga.



Fonte: Adaptado de (SKF, 2022)

3.2 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais foram inspiradas na estrutura e funcionamento do sistema nervoso, objetivando simular a capacidade de aprendizado do cérebro humano (FACELI et al., 2011).


O sistema nervoso é um conjunto complexo de células, do qual a unidade principal é o neurônio, que se diferencia das outras células por apresentar excitabilidade, permitindo respostas a estímulos internos e externos.

Basicamente, os neurônios são compostos por dendritos, corpo celular e axônio. Os dendritos são responsáveis pela parte receptora de estímulos nervosos provenientes de outros neurônios ou do ambiente. Os estímulos são transmitidos para o corpo celular, que coleta as informações recebidas e as processa. A depender da intensidade do estímulo recebido, o corpo celular gera um novo impulso e envia para o axônio, o qual é um prolongamento dos neurônios, responsável pela transmissão dos impulsos até outros neurônios. A sinapse é o contato entre a terminação de um axônio e o dendrito de outro. A Figura 12 apresenta um neurônio biológico.

As RNAs são compostas por três elementos principais: camada de entrada, camadas ocultas e camada de saída. A primeira RNA a ser implementada foi a rede *perceptron* (ROSENBLATT, 1958). Apesar de possuir apenas uma camada de neurônio, a rede *perceptron* apresentava boa acurácia em problemas de classificação, porém se limitava apenas a problemas cujos objetos eram linearmente separáveis.

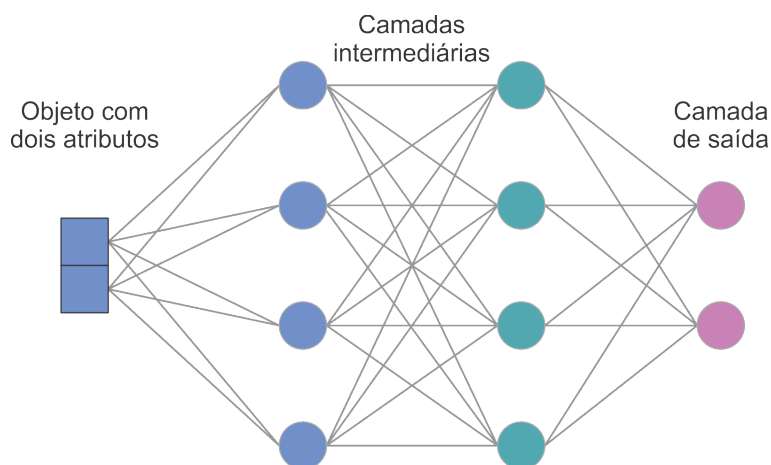
As redes *MLP* são compostas por uma ou mais camadas intermediárias de neurônios e uma camada de saída. A adição de camadas intermediárias foi a alternativa utilizada

Figura 12 – Neurônio biológico.



Fonte: (GÉRON, 2017).

para resolver problemas não linearmente separáveis com o uso das redes neurais artificiais pois permite a aproximação de qualquer função (CYBENKO, 1989). A Figura 13 apresenta uma RNA do tipo *MLP* com dois atributos de entrada, duas camadas intermediárias e duas camadas de saída.

Figura 13 – Rede *MLP* com duas camadas intermediárias.

Fonte: Adaptado de (FACELI et al., 2011).

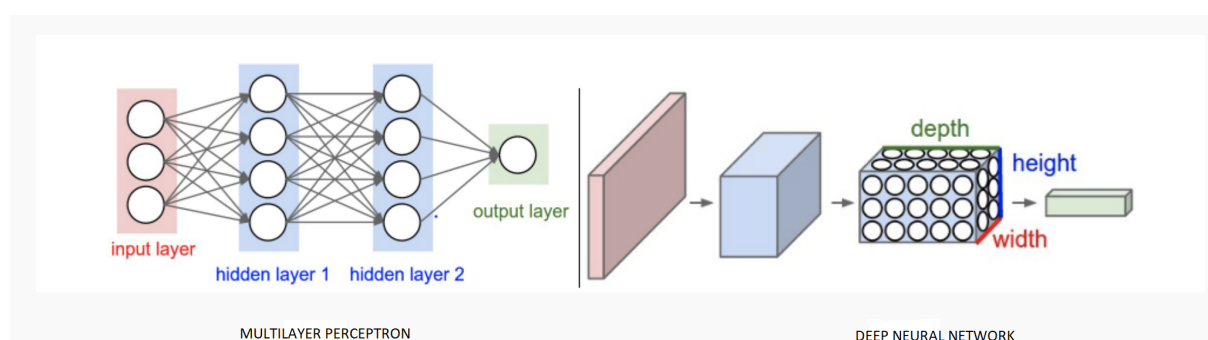
Fazendo uma analogia com o neurônio biológico, a entrada da rede realiza a função dos dendritos, os quais recebem a informação. Através de funções de ativação esses dados são processados e na sequência são transmitidos para as camadas seguintes. Esse processo vai se tornando mais complexo à medida que o processamento avança de uma camada intermediária para a camada seguinte. A função da RNA é definida através da combinação das funções desempenhadas por cada neurônio da rede.

A técnica aplicada para ajustar os pesos de entrada de uma RNA é a utilização do algoritmo *backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986). Cada neurônio da primeira camada recebe o objeto de entrada e aplica a função de ativação, o valor de saída é utilizado como valor de entrada pelos neurônios da camada seguinte. O processo continua até que a camada de saída produza seu valor de saída. Na sequência este valor é comparado ao valor desejado para a saída desse neurônio, a diferença entre o valor desejado e o valor de saída gera o valor do erro da rede em relação àquela classe. Esse erro é utilizado na fase conhecida como *backward*, na qual é realizado um ajuste que vai da camada de saída até a primeira camada intermediária com a finalidade de ajustar os pesos de entrada.

3.3 REDES NEURAIS CONVOLUCIONAIS

A aprendizagem profunda (do inglês, *Deep Learning*) é uma abordagem de aprendizagem de máquina na qual um modelo aprende a executar tarefas de classificação diretamente dos dados (*end-to-end task*), sendo geralmente implementada usando arquiteturas de redes neurais. O termo profundo refere-se ao número de camadas na rede, ou seja, quanto mais camadas, mais profunda a rede. As redes neurais tradicionais contêm apenas 2 ou 3 camadas, enquanto as redes profundas podem ter centenas (BENGIO, 2009). A Figura 14 ilustra uma comparação entre as duas abordagens de redes neurais. Enquanto a rede neural *Multilayer Perceptron* é constituída por apenas 2 camadas intermediárias completamente conectadas, a rede profunda (*Deep Neural Network*), por sua vez, é constituída por várias camadas intermediárias com diferentes funções.

Figura 14 – Comparação das arquiteturas de uma rede neural *Multilayer Perceptron* e uma *Deep Neural Network*.



Fonte: <https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>

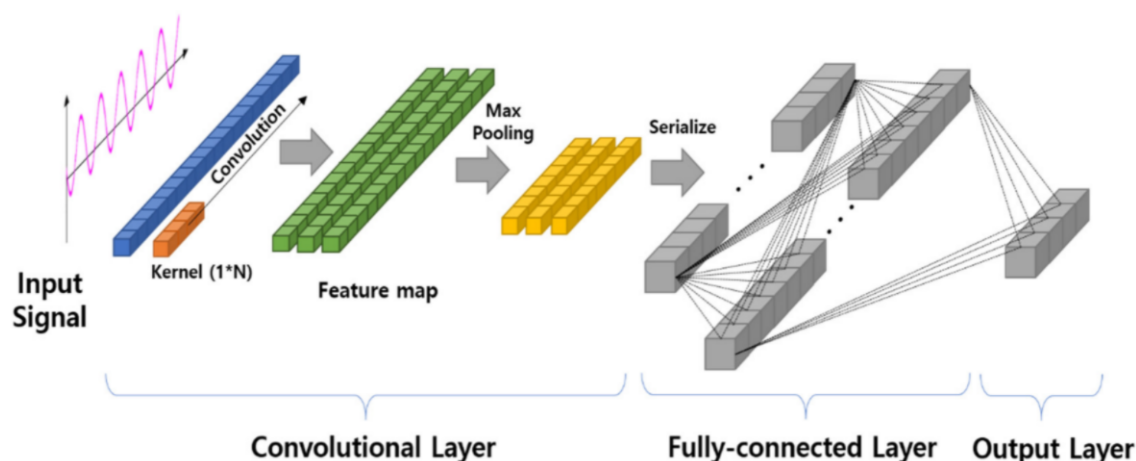
Dentre esses algoritmos, pode-se destacar as redes neurais convolucionais (RNC). Elas foram originalmente criadas para tarefas envolvendo imagens (LECUN; BOSER; DENKER, 1990), ou seja, dados em duas dimensões e são basicamente alimentadas

por dados processados através de convoluções na imagem de entrada por filtros (comumente chamados de *kernels*). Uma camada convolucional apresenta o seguinte funcionamento: dada uma matriz com dados de entrada, faz-se a convolução desta por matrizes de menor ordem (os *kernels*). No resultado desta operação, pode ser aplicado o processo de *pooling* que realiza uma redução das matrizes geradas a partir da convolução. Na sequência, a informação contida na matriz de entrada é filtrada e concentrada em uma matriz de menor ordem, chamada de *feature map* (mapas de características). Os *features maps* podem então alimentar outras camadas da rede neural.

Na análise de sinais em uma dimensão, pode-se substituir a convolução bidimensional realizada na camada convolucional por uma convolução unidimensional, operando com vetores ao invés de matrizes. O processo de convolução unidimensional está ilustrado na Fig. 15, note que a entrada da RNC é somente os dados em única dimensão que pode ou não passar por um pré-processamento.

Figura 15 – Arquitetura de rede convolucional unidimensional.

Fonte: Adaptado de (KIM; GEEM; HAN, 2020)



3.3.1 Estrutura em Camadas das Redes Neurais Convolucionais

Em RNCs unidimensionais, camadas convolucionais unidimensionais são utilizadas para extrair informações do sinal de entrada por meio dos filtros, e os dados filtrados alimentam a entrada das camadas posteriores, até que seja atribuído um label na camada de classificação (TAO et al., 2019). Podemos definir como principais camadas e funções:

- Camada Convolucional: de acordo com (CERENTINI et al., 2018), uma camada de convolução tem como objetivo aprender de forma eficiente características importantes sobre os dados. Para isso é utilizada a técnica de conectividade local,

que também é utilizada pelo córtex cerebral, onde o campo receptivo do neurônio é chamado de filtro. A tarefa do filtro é processar os dados ou a camada anterior, realizando a soma do produto de todos os valores de seu campo receptivo. Essa tarefa é executada em todas as posições de sua entrada.

- **Função de Ativação:** em redes neurais, a função de ativação, de acordo com o resultado da soma ponderada das entradas de um nó precedente, efetua a ativação de um nó consequente. Várias funções de ativação podem ser utilizadas tais como *sigmoid*, *tanh*, *softmax* e *ReLU*. Entre essas, a que tem sido utilizada com mais sucesso em redes neurais convolucionais é a *ReLU* (*Rectified Linear Unit*). A *ReLU* é uma função de ativação linear por partes, cuja saída será igual a entrada se a mesma for positiva, ou, caso contrário, a saída será igual a zero, de acordo com a Equação 3.5. Pela facilidade de treinamento e por, de forma geral, resultar em bom desempenho das redes, essa função de ativação tem sido muito utilizada em tarefas que utilizam as *RNCs*.

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.5)$$

- **Camada de *Pooling* :** a camada *pooling*, geralmente, está localizada após uma camada de convolução. Sua principal função é a redução da dimensão do *array* de dados procedente da camada convolucional anterior para a camada convolucional seguinte. Na prática, essa camada realiza uma subamostragem dividindo a entrada em regiões menores e calculando o valor correspondente de cada região. Esta operação reduz o tamanho do mapa de características removendo informações de redundância espacial. Uma das principais vantagens da utilização da camada de *pooling* é a possibilidade de aumentar o número de filtros de convolução nas camadas mais profundas sem que isso resulte no aumento considerável do esforço computacional. A abordagem mais comumente utilizada para a implementação da camada *pooling* é o *Max Pooling*. Nesse caso, no processo de subamostragem será considerado o maior valor da região. De forma análoga, uma camada *Average Pooling* realiza a subamostragem calculando o valor médio da região ao invés do valor máximo, sendo possível ainda a implementação do *Min Pooling*, nesse caso o menor valor da região será selecionado.
- **Camada de Classificação :** A camada de classificação é a última camada da rede e é responsável por categorizar a entrada em uma das classes disponíveis com base nos processamentos realizados nas camadas anteriores.
- **Camada de Normalização em Lote:** utilizada para reduzir a faixa de variação dos valores das unidades das camadas ocultas, o que resulta na aceleração do treinamento da rede, na redução da sua sensibilidade aos pesos iniciais, além de

possibilitar que cada camada da rede aprenda de forma mais independente das demais (IOFFE; SZEGEDY, 2015).

- **Camada Totalmente Conectada:** a camada totalmente conectada é colocada antes da camada de saída da rede e possui todos os seus neurônios conectados a todos neurônios da camada anterior, combinando, dessa forma, todas as características aprendidas pelas camadas anteriores para o mapa de características que melhor represente a imagem. Em problemas de classificação, a última camada totalmente conectada combina as características para classificar as imagens. Dessa forma, o tamanho da saída da última camada totalmente conectada é igual ao número de classes do *dataset*.
- **Camada de Classificação:** em problemas de classificação, a utilização da função de ativação *Softmax* associada a camada de classificação deve vir após a última camada totalmente conectada. A função de ativação *Softmax* normaliza a saída da camada anterior. Sua saída consiste de números positivos cuja soma é igual a 1. Estes números podem ser usados como probabilidades pela camada de classificação. A Camada de Classificação é a camada final da rede e infere a quantidade de classes a partir do tamanho da saída da camada anterior. As probabilidades retornadas pela função de ativação *Softmax* para cada entrada são utilizadas para uma classe entre as várias possíveis.

3.3.2 Métodos de Otimização

Segundo (TAQI et al., 2018), uma rede neural precisa que as variáveis de cada camada sejam alteradas de forma que esta funcione melhor no processo de classificação. Para esta tarefa é importante que o desempenho da rede seja continuamente medido através da comparação entre o resultado obtido e o resultado esperado. Sendo o objetivo da otimização minimizar o resultado da função *cross-entropy* (entropia cruzada), que é sempre positiva e se torna zero quando o resultado obtido é exatamente o mesmo resultado esperado. De acordo com (RUDER, 2016), o algoritmo Gradiente Descendente é um dos métodos mais populares utilizados na tarefa de otimizar redes neurais. A seguir estão apresentados três formas de implementação do algoritmo Gradiente descendente:

- **Stochastic Gradient Descent with Momentum (SGDM) :** O método *SGDM*, proposto por (SUTSKEVER et al., 2013), executa uma atualização de parâmetros para cada amostra de treino e de cada rótulo. O *SGDM* executa uma atualização de parâmetro por vez, o que o torna, geralmente, um algoritmo rápido e que pode ser utilizado

para aprendizado online. Esse algoritmo realiza atualizações com uma alta variância que leva a função objetivo a sofrer grandes flutuações (RUDER, 2016).

- *Root Mean Square Propagation (RMSPROP)* : O método *RMSPROP*, proposto por (HINTON; SRIVASTAVA; SWERSKY, 2012), é um método de taxa de aprendizagem adaptativa que combina os objetivos, utilizar apenas o sinal do gradiente e adaptar separadamente o tamanho de passo para cada peso. Segundo (TAQI et al., 2018), a média de execução num tamanho de passo depende da média anterior e do gradiente atual. Esse algoritmo divide a taxa de aprendizado por uma média exponencial decrescente do quadrado dos gradientes (RUDER, 2016).
- *Adaptive Moment Estimation (ADAM)* : *ADAM*, proposto por (KINGMA; BA, 2014), é um método de otimização que calcula as taxas de aprendizado adaptativas para cada parâmetro. Segundo (TAQI et al., 2018), *ADAM* mantém uma média exponencial decrescente dos gradientes anteriores, realizando estimações do primeiro momento, a média, e no segundo momento, realiza a variação não centralizada dos gradientes respectivamente.

Considerando as diferentes configurações que podem ser obtidas para as RNCs pela combinação dos diferentes tipos de camadas e pela quantidade de cada uma delas, o principal esforço para a utilização dessas redes deve ser direcionado à busca pela melhor arquitetura para o problema em questão. Neste trabalho, RNCs serão utilizadas exclusivamente para fins de extração de descritores, portanto, suas arquiteturas não utilizarão todas as camadas descritas anteriormente.


3.4 REDES NEURAIIS RECORRENTES

Redes neurais recorrentes possuem loops, o que possibilita a retenção de informações ao longo do tempo. No diagrama da Figura 16, é uma parte da rede neural, que possui uma entrada X_t e saída h_t . O loop da figura indica que a informação pode ser passada de um ponto da rede para o próximo.

Uma rede neural recorrente pode ser pensada como várias cópias da mesma rede, cada uma passando uma mensagem para um sucessor. A Figura 17 mostra como seria a estrutura de uma rede recorrente se ela fosse representada de forma linear, isto é, se o loop fosse aberto.


Essa cadeia mostra que as redes neurais recorrentes estão intimamente relacionadas a sequência e laços. Porém, essa arquitetura de rede recorrente natural ainda deixa lacunas quando se deseja utilizar informações anteriores à atual para predição. Para

Figura 16 – Rede Neural Recorrente.



Fonte: (OLAH, 2015).

Figura 17 – Rede Neural Recorrente Desenrolada.



Fonte: (OLAH, 2015).

este tipo de abordagem, estão sendo muito utilizadas as redes com arquitetura do tipo *LSTM*.


3.4.1 Redes *Long Short-Term Memory* - *LSTM*

Redes *LSTM* são um tipo especial de Redes Neurais Recorrentes, capaz de aprender dependências de longo prazo (SUN; ZHAO, 2021). Eles foram introduzidos por Hochreiter & Schmidhuber (1997).

Lembrar de informações por longos períodos de tempo é praticamente o comportamento padrão das redes *LSTMs*. Todas as redes neurais recorrentes têm a forma de uma cadeia de módulos repetidos de rede neural. Em *RNNs* padrão, esse módulo de repetição terá uma estrutura muito simples, como uma única camada de *tanh*, demonstrada na Figura 18.

Ela resolve o problema da redundância de informações adicionando uma estrutura de “*gate*” no local apropriado, permitindo que a informação seja, de forma seletiva, retida ou esquecida à medida que vai fluindo através de cada neurônio. Conforme (GU et al., 2021), isto é devido a *LSTM* possuir a capacidade de fortalecer o peso da informação primária e enfraquecer o peso da informação irrelevante, tal como problemas de desaparecimento de gradiente, explosão de gradiente e incapacidade de lidar com dependências de longo alcance em redes neurais recorrentes tradicionais.


Figura 18 – O módulo de repetição em um RNN padrão contém uma única camada.



Fonte: (OLAH, 2015)

Segundo (LIU et al., 2021) a rede *LSTM* consiste em portão de entrada (*input gate*), portão de saída (*output gate*), portão de esquecimento (*forget gate*) e estado da célula (*cell state*). O portão de entrada é quem controla a quantidade dos novos dados que podem ser adicionados ao estado da célula, já o portão de saída controla os dados de saída da célula, o portão de esquecimento controla as informações que são salvas pelo estado da célula e esse é adotado para manter informação útil. A Figura 19 mostra a estrutura da rede *LSTM*.

Figura 19 – Estrutura da rede *LSTM*.



Fonte: (GU et al., 2021).

A seguir será dada uma breve explanação de como se comporta, ou qual é o caminho percorrido pela rede *LSTM*. Primeiramente é definido quais informações devem ser descartadas, e isso é feito por uma camada sigmoide chamada de "portão de esquecimento", conforme Figura 20, ela verifica h_{t-1} e x_t , gerando na saída um número entre 0 e 1 para cada saída do estado da célula C_{t-1} , onde 0 é representa "esquecer completamente" e 1 representa "manter completamente", descrita na equação equação 3.6.

Onde:

h_t e C_t : Vetores de camadas ocultas;


x_t : Vetor de entrada;

b_f, b_i, b_c, b_o : Vetor de viés (*bias vector*);

W_f, W_i, W_c, W_o : matrizes de parâmetros;

σ e \tanh : Função de ativação.

Figura 20 – Diagrama e fórmula do *forget gate*




$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.6)$$

Fonte: (OLAH, 2015)

O próximo passo é para definir quais novas informações deverão ser armazenadas no estado da célula. Primeiro a camada sigmoide chamada "Portão de Entrada", decide quais informações serão atualizadas. Em seguida é criado um vetor pela *tanh layer* com novos valores candidatos, \check{C}_t . A Figura 21 mostra essas informações e assim como as equações 3.7 e 3.8.

Figura 21 – Diagrama e fórmulas do *input gate layer* e *tanh layer*




$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.7)$$

$$\check{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.8)$$

Fonte: (OLAH, 2015)

O próximo passo é a atualização do antigo Estado da célula, C_{t-1} , no novo estado da célula, C_t , Figura 22. Nos passos anteriores já foi decidido se precisamos realmente fazê-lo. Neste caso, deve-se multiplicar o antigo estado por f_t , esquecendo as outras coisas que foi decidido esquecer em um passo anterior. Aí adiciona-se $i_t * \check{C}_t$, conforme equação 3.9. Esses são os novos valores candidatos, quando for decidido por atualizar cada valor de estado.

Figura 22 – Diagrama e fórmula do *cell state*




$$C_t = f_t * C_{t-1} + i_t * \check{C}_t \quad (3.9)$$

Fonte: (OLAH, 2015)

Finalmente, será decidido o que irá ser produzido. Essa saída será baseada em nosso estado da célula, mas será uma versão filtrada. Corremos por uma camada sigmoide que decide quais partes do estado da célula vamos produzir. Então, colocamos o estado da célula através de \tanh e multiplique-o pela saída do sigmoide, de modo que apenas produzamos as partes que foi decidida pela camada sigmoide, conforme mostrado na Figura 23 e as equações 3.10 e 3.11.

Figura 23 – Diagrama e fórmula do *state cell*, mas uma versão filtrada.



$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.10)$$

$$h_t = o_t * \tanh(C_t) \quad (3.11)$$

Fonte: (OLAH, 2015)

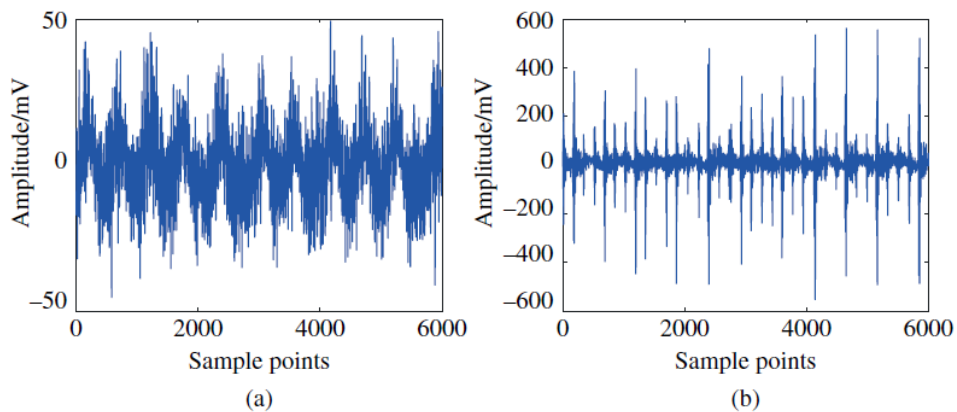
3.5 EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS DE VIBRAÇÃO

Diversas técnicas são disponíveis para processamento de sinais de vibração para extração de descritores com a finalidade de construção de modelos. A análise no domínio do tempo se baseia no cálculo de parâmetros estatísticos, que podem ser associados a comportamentos de falhas, e, que, portanto, podem fornecer informações sobre a natureza de operação do equipamento. Descritores relevantes também são obtidos pela transformada de *Fourier* (RAHMAN, 2011), através do qual é gerado o espectro de frequência do sinal. Descritores também podem ser extraídos pela análise no domínio tempo-frequência através da transformada *Wavelet*(TW) (MALLAT, 2009).

3.5.1 Análise no Domínio do Tempo

Os sinais dos sensores de vibração são coletados no domínio do tempo e fornecem um histórico temporal do comportamento operacional da máquina. Baseado nesse comportamento, é possível extrair atributos estatísticos que representam uma assinatura condicional do equipamento. A Figura 24 apresenta o comportamento de um sinal de vibração no domínio do tempo em duas condições de operação, sendo (a) operação normal (sem falha) e (b) falha na pista interna do mancal. É possível observar que o comportamento do sinal é diferente para as duas condições apresentadas, mostrando diferenças em suas amplitudes e na forma de onda do sinal.

Figura 24 – Sinais de vibração no domínio do tempo de um mancal: (a) condição normal de operação e (b) falha na pista interna do mancal.



Fonte: (NANDI; AHMED, 2020).

3.5.2 Transformada de Fourier

A *Transformada de Fourier* realiza a separação da energia do sinal em cada componente de frequência, provendo o conjunto de relações de *amplitude* \times *frequência*, a fim de determinar o tipo de defeito presente no equipamento. A transformada de Fourier de um sinal $s(t)$ no domínio do tempo é definida na equação 3.12.

$$\mathcal{F}\{s(t)\} = S(f) = \int_{-\infty}^{\infty} s(t)e^{-i2\pi ft} dt. \quad (3.12)$$


A *Transformada de Fourier* pode ser reescrita como um somatório ponderado de funções seno e cosseno. As funções senoidais de mesma frequência se agregam para calcular a amplitude total na referida frequência. Além da frequência, a fase do sinal também possui uma relação com a onda senoidal, porém para o diagnóstico através da análise de vibração é suficiente somente o espectro de *amplitude* \times *frequência*. A equação 3.13 apresenta a Transformada de Fourier utilizando senos e cossenos.

$$S(f) = \int_{-\infty}^{\infty} s(t) \cos(-2\pi ft) dt + i \int_{-\infty}^{\infty} s(t) \sin(-2\pi ft) dt. \quad (3.13)$$

A *Transformada de Fourier* se baseia em sinais contínuos e periódicos. Para o caso de sinais discretos existe uma modificação chamada Transformada Discreta de Fourier, ou *DFT (Discrete Fourier Transform)* (RADER, 1968). O número de cálculos necessários para executar a *DFT* foi drasticamente reduzido pelo algoritmo chamado Transformada Rápida de Fourier, *FFT (Fast Fourier Transform)* (COCHRAN et al., 1967). Em termos práticos, a *FFT* utiliza menor esforço computacional, sendo portanto, o algoritmo mais indicado para a extração de características no domínio da frequência. A Figura 25 apresenta o sinal de um acelerômetro no domínio do tempo com duração de 0,5

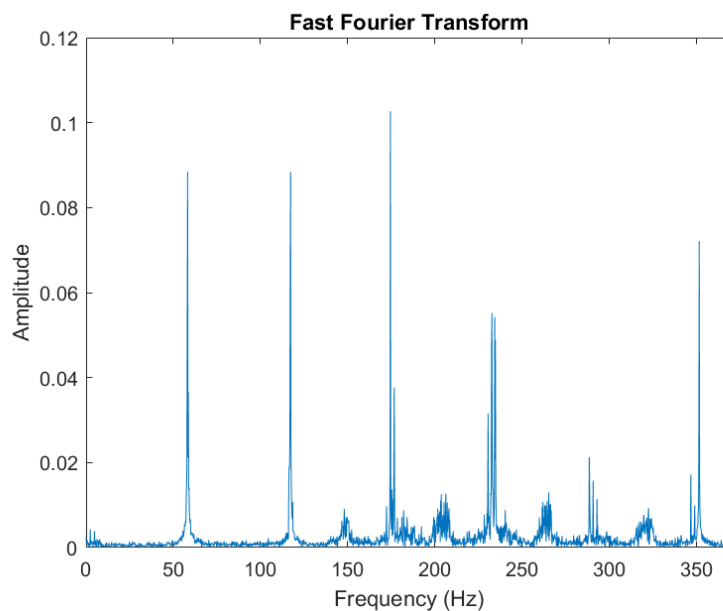
segundos, já a Figura 26 apresenta este mesmo sinal no espectro de frequência após aplicação da *FFT*.

Figura 25 – Sinal de vibração no domínio do tempo.



Fonte: Autoria própria.

Figura 26 – Sinal de vibração no domínio da frequência.



Fonte: Autoria própria.

3.5.3 Transformada *Wavelet*

A Transformada *Wavelet* (TW) (MALLAT, 1989) é uma ferramenta matemática eficiente para processamento de sinais, notadamente quando aplicada a sinais não estacionários. Uma das vantagens de sua utilização é a possibilidade de, ao mesmo tempo, analisar um trecho específico, ou um intervalo do sinal, retendo as informações espectrais importantes e não visíveis no domínio original, característica que pode ser vantajosa para aplicações de detecção de falhas

(AL-BADOUR; SUNAR; CHEDED, 2011).

A Transformada *Wavelet* Contínua (TWC) (STRANG; NGUYEN, 1996), pode ser definida pela Equação (3.14):

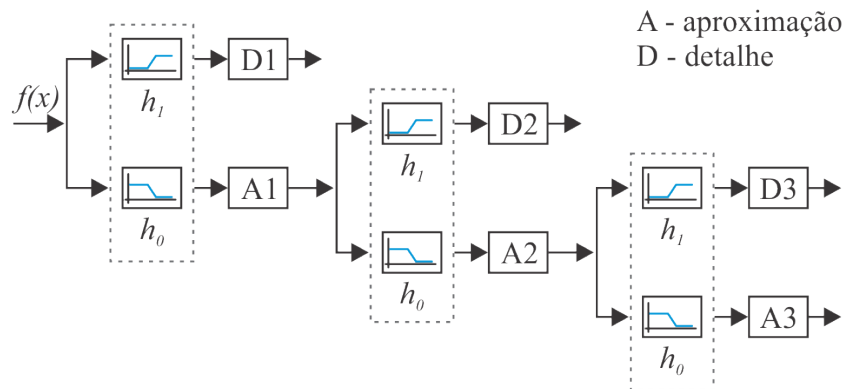
$$TWC(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \psi \left(\frac{t - b}{a} \right) dt, \quad (3.14)$$

com $a \neq 0$, onde $x(t)$ é o sinal a ser analisado e a função $\psi(t)$ é denominada *wavelet*-mãe. A equação 3.14 pode ser interpretada como a convolução do sinal no domínio do tempo. A função $\psi(t - b/a)$ corresponde a *wavelet*-mãe dilatada/contraída pela escala a e transladada pelo fator b (STRANG; NGUYEN, 1996). O termo $1/\sqrt{|a|}$ é utilizado para assegurar que os valores da TWC em todas as escalas possam ser diretamente comparados, mantendo constante a energia (STRANG; NGUYEN, 1996).

A versão discreta da transformada pode ser diretamente obtida da TWC pela discretização dos parâmetros a e b , fazendo $a = a_0^j$ e $b = kb_0a_0^j$, sendo j, k valores inteiros e $a_0 > 1, b_0 > 0$. Fazendo $a_0 = 2$ e $b_0 = 1$, obtém-se um caso particular de discretização denominado discretização diádica (STRANG; NGUYEN, 1996). Neste caso, pode-se obter a Transformada *Wavelet* Discreta de forma computacionalmente eficiente através do uso de bancos de filtros digitais passa-altas e passa-baixas. A Fig. 27 apresenta o esquema dos bancos de filtros de decomposição para cálculo da TWD. Nesse exemplo, foi considerado três níveis de resolução para a decomposição do sinal de entrada $f(x)$.

A estrutura do banco de filtros de decomposição consiste de um par de filtros, sendo um passa-baixas (h_0) e um passa-altas (h_1), seguidos por operações de subamostragem. As saídas subamostradas dos filtros passa-baixas e passa-altas são denominadas coeficientes de aproximação e detalhe, respectivamente. As operações de filtragem/subamostragem podem ser reaplicadas, recursivamente, aos coeficientes de aproximação até o número de níveis de resolução especificado pelo analista. Os filtros h_0 e h_1 são de comprimento finito e, portanto, cada coeficiente de aproximação e detalhe corresponde a um trecho do sinal original. Como já anteriormente destacado, esta característica de localização espacial é uma das principais vantagens da Transformada *Wavelet* sobre a

Figura 27 – Decomposição do sinal $f(x)$ em análise multiresolução.



Transformada de *Fourier*.

Para a decomposição do sinal de vibração serão utilizados os filtros *Symlet 8*, *Daubechies 4* e *Coiflet 2*. A escolha desses filtros considerou a sua ampla utilização na modelagem de sinais de vibração.

3.6 MÉTRICAS DE DESEMPENHO

Em problemas de classificação é muito comum o uso da matriz de confusão para verificar o desempenho dos modelos. Essa matriz reúne as informações sobre o número de predições corretas e incorretas de cada classe. A partir da matriz de confusão várias outras métricas podem ser obtidas para a análise de desempenho dos classificadores.

A Figura 28 apresenta a matriz de confusão num problema de duas classes no qual a classe positiva é denotada pelo sinal (+) e a classe negativa é denotada pelo sinal (-), dessa forma:

- TP (*True Positive*): corresponde ao número de exemplos da classe positiva classificados corretamente.
- TN (*True Negative*): corresponde ao número de exemplos da classe negativa classificados corretamente.
- FP (*False Positive*): número de exemplos que pertencem à classe negativa mas foram classificados incorretamente como sendo da classe positiva.
- FN (*False Negative*): número de exemplos pertencentes à classe positiva que foram incorretamente classificados como sendo da classe negativa.

Sendo n o número total de amostras, então $n = TP + TN + FP + FN$.

Figura 28 – Matriz de confusão de 2 classes.

		Classe Predita	
		+	-
Classe Verdadeira	+	TP	FN
	-	FP	TN

Fonte: (LOBÃO, 2020) .

A partir da matriz de confusão, várias outras medidas de desempenhos são derivadas, entre elas temos:

- *Accuracy* ou acurácia: corresponde à taxa de acerto, calculada pela soma dos valores da diagonal principal, dividido pelo número total de elementos da matriz.

$$acurácia = \frac{TP + TN}{n}. \quad (3.15)$$

- *Precision* ou precisão: quantidade de exemplos positivos classificados corretamente entre todos aqueles preditos como positivos.

$$precisão = \frac{TP}{TP + FP}. \quad (3.16)$$

- *Recall*, revocação ou Sensibilidade: corresponde à taxa de acerto na classe positiva.

$$Sensibilidade = \frac{TP}{TP + FN}. \quad (3.17)$$

- *Specificity* ou especificidade: avalia a capacidade do método de detectar resultados negativos.

$$especificidade = \frac{TN}{TN + FP}. \quad (3.18)$$

- *F-measure* ou *f1-score*: média harmônica ponderada da precisão e revocação.

$$F_1 = \frac{2 \times prec \times recall}{prec + recall}. \quad (3.19)$$

As métricas citadas podem ser generalizadas em problemas que envolvem mais de duas classes. Para isso, a classe que está sendo observada é vista como positiva e as demais são consideradas negativas, desta forma, o cálculo das métricas podem ser realizados para cada tipo de classe.

Como exemplo, vamos considerar a matriz de confusão da Figura 29. Para a Classe 1, 46 amostras foram classificadas corretamente e quatro foram incorretamente classificadas como pertencentes à Classe 2. Já para a Classe 2, trinta e seis amostras foram classificadas corretamente e quatorze foram preditas como sendo da Classe 1. A

Figura 29 – Matriz de confusão para o exemplo de duas classes.

		Classe Predita	
		Classe 1	Classe 2
Classe Verdadeira	Classe 1	46	4
	Classe 2	14	36

Fonte: (LOBÃO, 2020) .

acurácia e o *f1-score* referente à classe 1, calculadas conforme equações 3.15 e 3.19, respectivamente, são iguais a 0.8200 e 0.8364.

A Tabela 2 apresenta a matriz de confusão de um problema envolvendo três classes desbalanceadas. Para a classe *C1*, é possível notar que o modelo acertou somente uma das dez predições. Os valores de acurácia, precisão, revocação e *f1-score* são apresentados na Tabela 3. Mesmo que a classe *C1* tenha obtido um valor de acurácia igual a 77%, isso não reflete o real desempenho do modelo. Situações que envolvem conjuntos de dados desbalanceados, a métrica *f1-score* é a mais adequada para representar o desempenho do classificador (GÉRON, 2017). Observe que para a classe *C1* a métrica *f1-score* obteve um desempenho de apenas 10% devido aos baixos valores da precisão, que mede a efetividade das classes que classificaram corretamente, e da revocação, que mede a frequência em que os exemplos de uma classe realmente pertence à esta classe. Neste trabalho foi utilizado o *f1-score* como medida de desempenho pelo fato de já reunir informações sobre a precisão e a revocação.

Tabela 2 – Matriz confusão de classes desbalanceadas.

	<i>C1</i>	<i>C2</i>	<i>C3</i>	FN
<i>C1</i>	1	1	8	9
<i>C2</i>	5	50	5	10
<i>C3</i>	5	5	45	10
FP	10	6	13	29

Fonte: (LOBÃO, 2020) .

Tabela 3 – Métricas de desempenho das classes desbalanceadas.

	Acurácia	Precisão	Revocação	<i>f1-score</i>
<i>C1</i>	0,74	0,09	0,10	0,10
<i>C2</i>	0,84	0,89	0,83	0,86
<i>C3</i>	0,77	0,78	0,82	0,80

Fonte: (LOBÃO, 2020) .

4 METODOLOGIA

Este capítulo descreve as etapas da metodologia aplicada para a realização da pesquisa. Inicialmente, a base de dados utilizada para a construção dos modelos é apresentada. Na sequência são descritas as etapas de pré-processamento e preparação dos dados. Por fim, são apresentadas as arquiteturas das redes *LSTM* e *CNN* que constituíram os modelos de classificação e extração de descritores, respectivamente.


4.1 DESCRIÇÃO DA BASE DE DADOS

Para a realização dos experimentos foi utilizado o conjunto de dados produzido pelo *Intelligent Maintenance Systems of the University of Cincinnati - IMS* (LEE et al., 2015), que pode ser gratuitamente adquirido em <https://www.kaggle.com/datasets/vinayak123tyagi/bearing> dataset. A planta experimental a partir da qual os sinais que constituem o conjunto de dados *IMS* foram adquiridos, está mostrada na Figura 30. O aparato experimental consistiu em quatro rolamentos tipo *Rexnord ZA-2115*, com duas pistas de rolamentos. Os rolamentos foram instalados sobre um eixo acoplado a um motor elétrico por correias, e lubrificados por meio de um sistema de lubrificação forçada que regulava o fluxo e a temperatura do óleo lubrificante. Os sinais de vibração foram gerados por um conjunto de acelerômetros *ICP*, de quartzo, de alta sensibilidade, instalados na caixa dos rolamentos.

Durante os experimentos o eixo foi mantido com velocidade constante em 2000 rpm. Uma força radial de 6.000 lbs foi aplicada sobre o eixo e o rolamento por um mecanismo de mola. Os sinais de vibração foram colhidos em um teste denominado “funcionar até falhar”. Nestes testes, os quatro rolamentos foram instalados no aparato no início de sua vida útil (sem utilização precedente), e funcionaram até que, um entre os quatro fosse danificado.

Para a aquisição dos sinais de vibração, três experimentos foram realizados, em datas e períodos diferentes. Como resultado da realização dos três experimentos, foram gerados três conjuntos de dados, designados, Conjunto 1, Conjunto 2 e Conjunto 3. Os sinais do Conjunto 1 foram produzidos por dois acelerômetros instalados sobre a caixa de cada um dos quatro rolamentos, nas posições dos eixos x e y , deslocados entre si por um ângulo de 90° . Por sua vez, os sinais dos conjuntos 1 e 2 foram produzidos por apenas um acelerômetro em cada rolamento. Os conjuntos de dados armazenam uma quantidade específica de sinais, cada sinal correspondendo a 1 segundo de aquisição do sinal de vibração, constituído por 20.480 amostras, coletadas a uma taxa

Figura 30 – Bancada experimental do Centro de pesquisa da IMS.



Fonte: (LEE et al., 2015).

de amostragem de 20kHz. A Tabela 4 apresenta as informações sobre a constituição dos conjuntos de dados 1, 2 e 3, produzidos nos experimentos realizados, e que constituem o conjunto de dados *IMS*. Na Tabela 4 a coluna “Período” indica o período em que os testes foram realizados; a coluna “Número de Arquivos”, indica o quantidade de sinais de vibração que foram produzidos no conjunto correspondente. A coluna “Tipo de Falha”, apresenta a(s) falha(s) que ocorreu(ram) que provocou(ram) a paralisação do teste.

Tabela 4 – Conjuntos de sinais de vibração que constituem o conjunto *IMS*

Teste	Período	Número de Arquivos	Tipo de Falha
Conjunto 1	22 de Outubro até 25 de Novembro (2003)	2.156	Falha na pista interna no rolamento 3 e elemento de rolete no rolamento 4.
Conjunto 2	12 fevereiro até 19 fevereiro (2004)	984	Falha na pista externa no rolamento 1.
Conjunto 3	4 de março até 4 de abril (2004)	4.448	Falha na pista externa no rolamento 3.

Fonte: Autoria própria.

Como decisão de projeto, nessa pesquisa foram utilizados os sinais de vibração do conjunto de dados 1. Como pode ser visto na Tabela 4, o Conjunto 1 contém 2.156 arquivos por rolamento (cada arquivo armazena um sinal com 20.460 amostras). Para esse conjunto, o teste foi encerrado por falha na pista interna do rolamento 3 e falha no elemento rolante (rolete) do rolamento 4. Ao final do teste, os sinais referentes às condições de operação (normal ou falha), foram identificadas para cada rolamento. Por exemplo, para o rolamento 1 foram identificadas cinco condições operacionais. As con-

dições operacionais identificadas constituíram as classes do problema de classificação formalizado: *early* (Classe 1) - condição inicial de funcionamento; *suspect* (Classe 2) - condição de suspeição de estado de funcionamento anormal (falha); *normal* (Classe 3) - condição de operação normal; *suspect* (Classe 4) - idem classe 2 e *imminent failure* (Classe 5) - operação em situação de falha iminente. A Tabela 5 apresenta as cinco condições de falha identificadas no rolamento 1 do Conjunto 1.

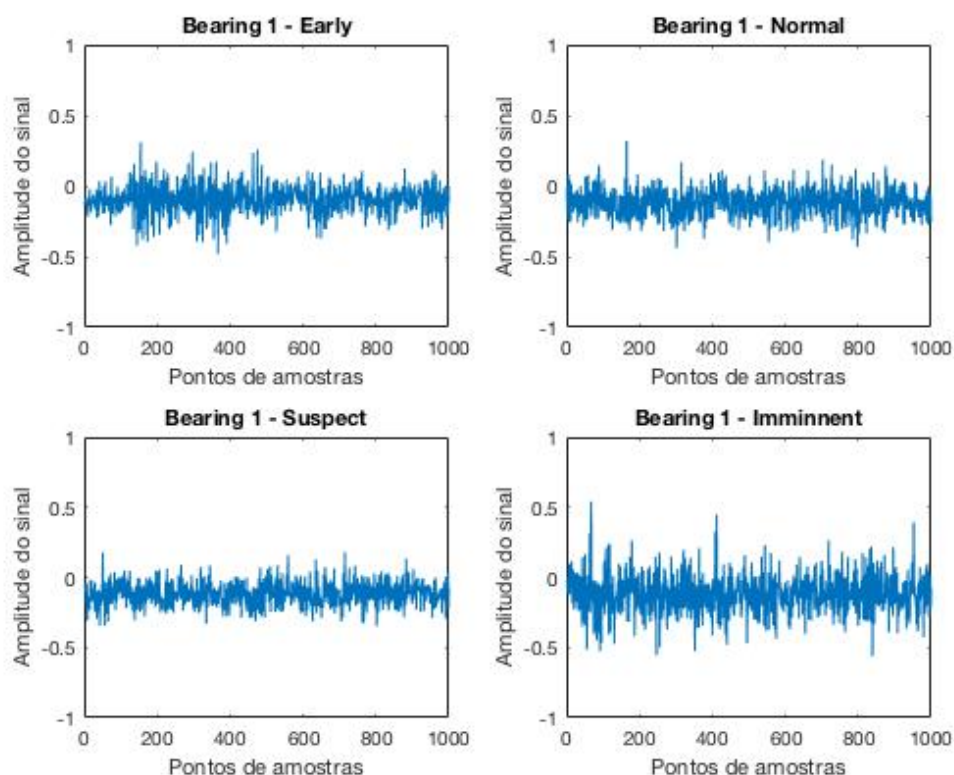
Tabela 5 – Condições de operação identificadas para o rolamento 1 do Conjunto 1

Classe	Descrição da Etapa	Nº de amostras
<i>Early</i>	Condição inicial normal	150
<i>Suspect</i>	Condição suspeita	460
<i>Normal</i>	Condição normal	900
<i>Suspect</i>	Condição suspeita	600
<i>Imminent</i>	Condição de falha Iminente	56
<i>Total</i>		2156

Fonte: Autoria própria.

De acordo com (LEE et al., 2015) após apresentarem condição de funcionamento de suspeita de falha (*suspect* - Classe 2), os rolamentos voltaram a funcionar em condição de funcionamento normal (*normal* - Classe 3), o que os autores denominam autocura. Como as condições de funcionamento reveladas pelos sinais colhidos do processo para as classes 2 e 4 eram semelhantes, ao longo da realização deste trabalho serão utilizados somente os sinais da Classe 4. Portanto, em todas as etapas que se seguiram foram utilizadas quatro classes: Classe 1 - *early*, Classe 3 - *Normal*, Classe 4 - *Suspect* e Classe 5 - *Imminent*. A Figura 31 ilustra as primeiras 1000 amostras dos sinais de vibração de cada uma das quatro classes constituídas para o rolamento 1 do conjunto de dados 1.

Figura 31 – Primeiras 1000 amostras de cada classe do rolamento 1 do Conjunto 1



Fonte: Autoria própria.

4.2 DESCRITORES ESTATÍSTICOS

De acordo com (NANDI; AHMED, 2020), o monitoramento automático de processos no domínio do tempo, pode ser realizado de uma forma eficiente através de parâmetros estatísticos. Os autores em (RAUBER; DE ASSIS BOLDT; VAREJÃO, 2015), (NAYANA; GEETHANJALI, 2017) e (TAHIR et al., 2017), afirmam que comportamentos de falhas em sinais de vibração podem ser adequadamente descritos por parâmetros estatísticos. A eficiência dos parâmetros estatísticos aumenta quando aplicados para extrair descritores de sinais não estacionários. Dessa forma, para a representação dos sinais de vibração, neste trabalho foi utilizados um conjunto de 13 descritores estatísticos que são descritos na sequência: valor médio (X_m), valor de pico (X_{peak}), amplitude da raiz (X_{root}), desvio padrão (X_{std}) e raiz quadrada média (X_{rms}). Tais atributos refletem as variações na intensidade das falhas consolidadas, contudo, não são sensíveis à falhas nos estágios iniciais. Para compensar a baixa sensibilidade dos descritores previamente mencionados a falhas em estágios iniciais, outras medidas estatísticas foram incluídas, tais como, skewness ($X_{skewness}$), curtose ($X_{kurtosis}$), fator de crista (X_{crest}), fator de folga ($X_{clearance}$), fator de forma (X_{shape}), fator de impulso ($X_{impulse}$), valor de pico a pico ($X_{peak2peak}$) e a raiz da soma dos quadrados (X_{rss}). A escolha

desses descritores foi baseada em trabalhos correlatos cujo objetivo era a modelagem de sinais não estacionários. A utilização dos referidos parâmetros para representar sinais de vibração no domínio do tempo, pode resultar em sistemas de diagnósticos de falhas sensíveis à falhas em estágios iniciais, mas que ainda apresentam bom desempenho à medida que a falta se torna mais severa. A formulação matemática de cada um dos descritores estatísticos mencionados está mostrada na Tabela 6.

Tabela 6 – Parâmetros estatísticos extraídos do sinal no domínio do tempo.

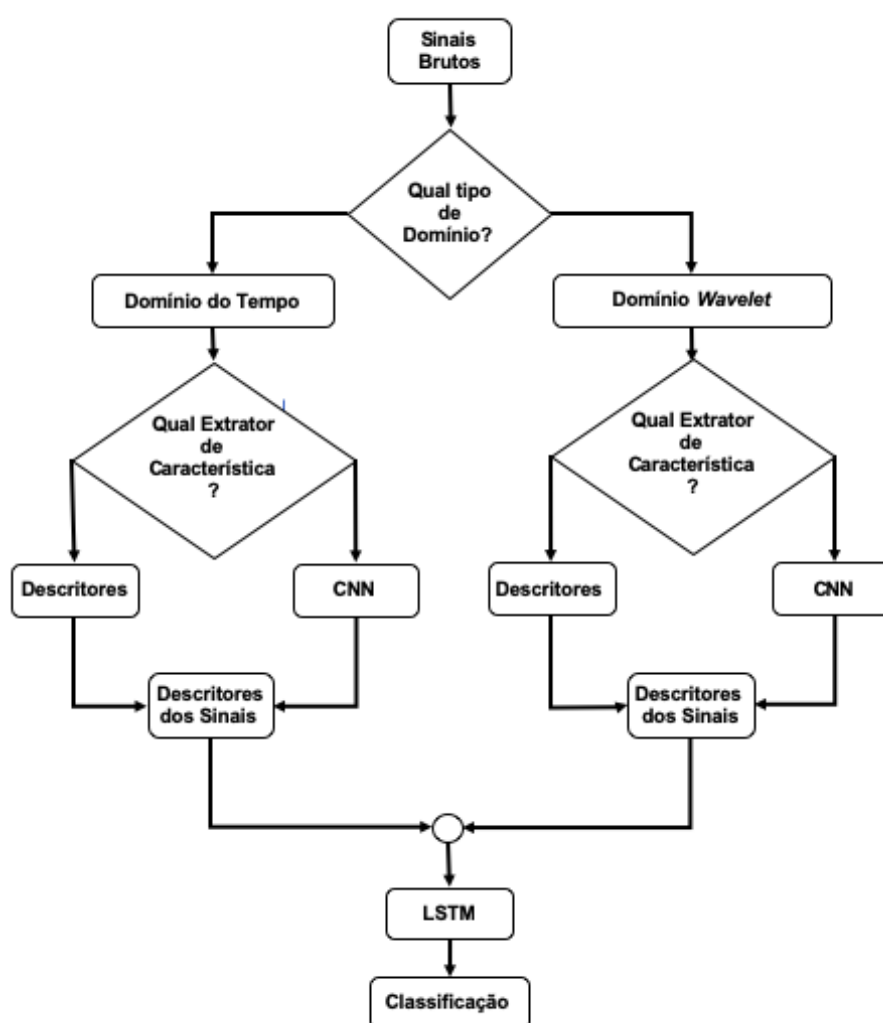
Parâmetro	Descrição Matemática
Valor médio	$X_m = \frac{\sum_{n=1}^N x(n)}{N}$
Valor de pico	$X_{peak} = \max x(n) $
Amplitude da raiz	$X_{root} = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2$
Desvio padrão	$X_{std} = \sqrt{\frac{\sum_{n=1}^N (x(n) - X_m)^2}{N-1}}$
Raiz quadrada média	$X_{rms} = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$
Skewness	$X_{skewness} = \frac{\sum_{n=1}^N (x(n) - X_m)^3}{(N-1)X_{std}^3}$
Curtose	$X_{kurtosis} = \frac{\sum_{n=1}^N (x(n) - X_m)^4}{(N-1)X_{std}^4}$
Fator de crista	$X_{crest} = \frac{X_{peak}}{X_{rms}}$
Fator de folga	$X_{clearance} = \frac{X_{peak}}{X_{root}}$
Fator de forma	$X_{shape} = \frac{X_{rms}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Fator de impulso	$X_{impulse} = \frac{X_{peak}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
Valor de Pico a Pico	$X_{peak2peak} = 2 \cdot X_{peak}$
Raiz da Soma dos Quadrados	$X_{rssq} = \sqrt{\sum_{n=1}^N x_n ^2}$

Fonte: Adaptado de (LOBÃO, 2020).

4.3 CONFIGURAÇÕES DE MODELAGEM

Para a construção dos modelos foram implementadas quatro configurações, combinando o domínio do sinal de vibração (domínio do tempo ou domínio *wavelet*) e o método de extração de descritores para classificação (descritores estatísticos ou descritores extraídos pela rede *CNN*). Em todos os casos a classificação foi realizada por uma rede *LSTM* com camadas de classificação em sua saída. A Figura 32 ilustra as combinações de domínio de modelagem e descritores utilizados na modelagem.

Figura 32 – Fluxograma mostrando as configurações de construção dos modelos



Fonte: Autoria própria.

As combinações entre domínio de modelagem e método de extração de características produziram quatro arquiteturas de modelos, designados Modelo 1, Modelo 2, Modelo 3 e Modelo 4, que estão apresentados a seguir. Para os modelos que foram construídos por meio de descritores estatísticos, foi necessária uma etapa de extração de descritores dos sinais de vibração. Nesse caso, os descritores utilizados para a construção dos

modelos foram extraídos por meio dos 13 parâmetros estatísticos apresentados na Seção 4.2. Por sua vez, para os modelos que forma construídos com os descritores extraídos pela *CNN*, os sinais alimentaram a entrada da *CNN*. Para a construção dos modelos no domínio wavelet, os sinais de vibração foram transformados com a utilização de três filtros, *Daubechies 4*, *Symlet 8* e *Coiflet 2*. Os sinais foram decompostos em todos os níveis de resolução possíveis. Em cada nível de resolução foi construído um modelo de classificação.

Modelo 1: Sinais de vibração no domínio do tempo com descritores estatísticos, Figura 33.

Figura 33 – Arquitetura do Modelo 1 - Domínio do tempo + Descritores estatísticos



Fonte: Autoria própria.

Modelo 2: Sinais no domínio do tempo com extração de descritores por uma rede *CNN*, Figura 34.

Figura 34 – Arquitetura do Modelo 2 - Domínio do tempo + *CNN*



Fonte: Autoria própria.

Modelo 3: Sinais transformados para o domínio wavelet com descritores estatísticos, Figura 35.

Figura 35 – Arquitetura do Modelo 3 - Domínio *Wavelet* + Descritores estatísticos



Fonte: Autoria própria.

Modelo 4: Sinais transformados para o domínio wavelet com extração de descritores por uma rede *CNN*, Figura 36.

Na construção dos modelos 3 e 4, a transformação dos sinais de vibração para o domínio *wavelet* se deu com a utilização dos filtros *Daubechies 4 (db4)*, *Symlet 8*

Figura 36 – Arquitetura do Modelo 4 - Domínio *Wavelet* + *CNN*




Fonte: Autoria própria.

(*sym8*) e *Coiflet 2* (*coif2*). Em todos os casos os sinais foram decompostos em todos os níveis de resolução possíveis. Em cada nível de resolução, para a construção dos modelos foram utilizados todos os coeficientes de aproximação e detalhe.

4.3.1 Pré-processamento e Organização dos Dados

Os sinais disponíveis no conjunto de dados *IMS* foram previamente normalizados para todos os rolamentos, por ocasião da realização do experimental que o produziu, não tendo havido a necessidade da realização dessa etapa na fase de preparação dos dados para a modelagem, executada neste trabalho. A Figura 37 apresenta o *boxplot* de uma amostra do sinal de cada um dos quatro rolamentos utilizados neste experimento. Como pode ser notado, o *boxplot* mostra a variação dos valores das amostras no intervalo de -1,0 e 1,0 .

Figura 37 – Dados Originais já padronizados .

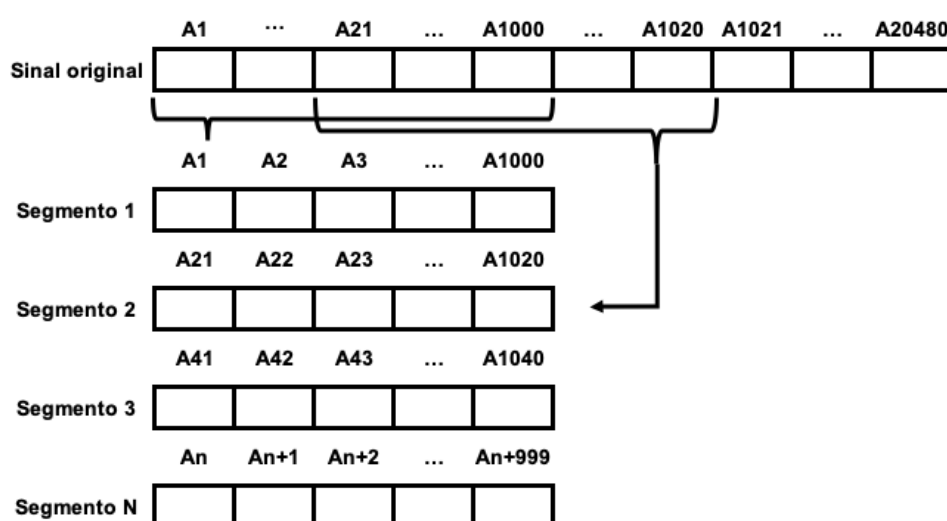


Fonte: Autoria própria.

Para a construção do arranjo de descritores que foi utilizado na etapa de classificação, os seguintes procedimentos foram realizados. Inicialmente, os sinais originais (sinais constituídos por 20.480 amostras) do rolamento 1, do Conjunto 1, foram segmentados

em segmentos com 1000 amostras, que foram obtidas com deslocamentos de 20 amostras no sinal original. A Figura 38 mostra o procedimento para extração dos segmentos de 1000 amostras do sinal original. O Segmento 1 foi constituído pelo intervalo entre a amostra 1 (A1) e a amostra 1000 (A1000). Para a extração do Segmento 2 foi feito um deslocamento de 20 amostras sobre o sinal original, e o Segmento 2 ficou constituído pelo intervalo entre a amostra 21 (A21) e a amostra 1020 (A1020), e assim por diante.


Figura 38 – Procedimento para transformação dos dos sinais originais com 20.480 amostras, em matrizes com 1000 colunas



Fonte: Autoria própria.

Após realizada a etapa de segmentação, os segmentos do sinal de vibração foram empilhados, constituindo uma matriz de 975 x 1000, que foi denominada matriz de sinais de vibração (Figura 38). Para cada linha da matriz de sinais de vibração, os 13 descritores estatísticos apresentados na Seção 4.2 foram calculados, resultando na matriz de parâmetros estatísticos. A Figura 39 mostra a matriz de descritores relacionada a um único sinal do rolamento 1. Como pode ser observado, a matriz de descritores é a versão transposta da matriz de parâmetros estatísticos obtida na etapa anterior. Tal procedimento foi replicado para todos os sinais do Conjunto 1. A matriz de descritores resultante que alimentou a rede *LSTM* foi obtida pela concatenação das matrizes de descritores de todos os rolamentos. Dessa forma, a matriz de descritores resultante ficou constituída por 52 linhas com quatro classes, *early*, *normal*, *suspect* e *imminent*.

Figura 39 – Matriz de descritores obtida a partir de um sinal de vibração do rolamento 1



Fonte: Autoria própria.

4.3.2 Arquitetura da Rede *Long Short-Term Memory* Utilizada para Classificação

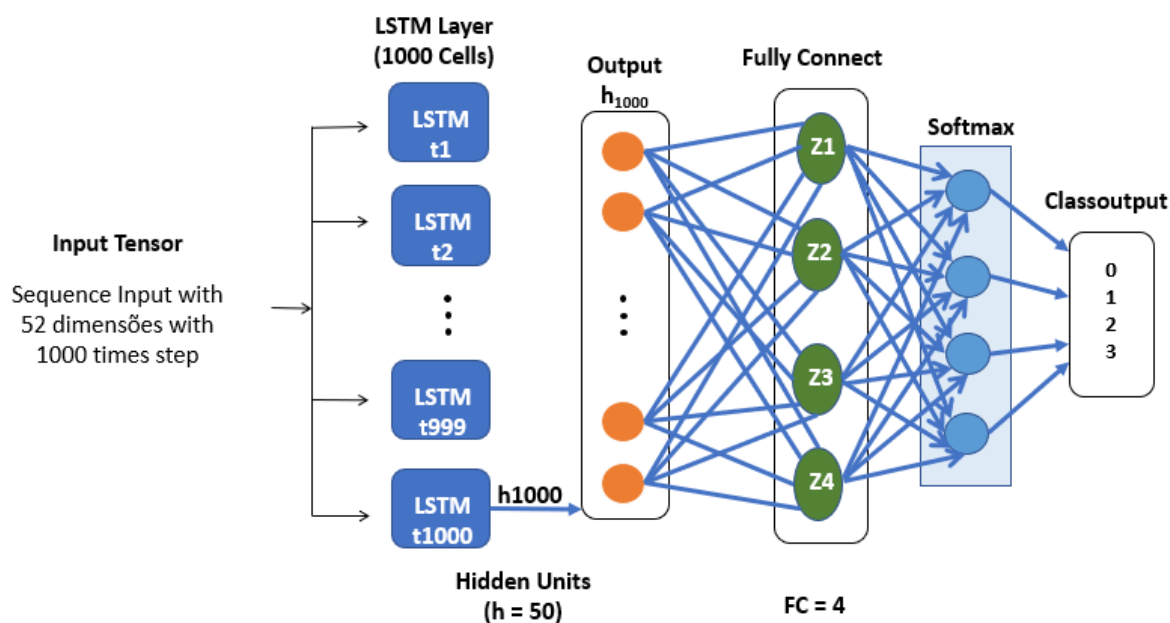
A arquitetura da rede utilizada consistiu em 50 camadas *LSTM* ocultas, uma camada *Fully Connected* com 4 neurônios, seguida por uma camada *softmax* e uma camada de classificação. O método de otimização utilizado foi o *Adam* pois, de acordo com (KINGMA; BA, 2014), esse é o método mais apropriado para problemas em que os sinais são não estacionários.

A Figura 40 mostra a estrutura de rede *LSTM* com um *Tensor* de entrada com 52 dimensões, com tamanho de sequência *Times Steps* igual a 1000. Uma estrutura de camadas *LSTM* com 1000 células e 50 camadas ocultas. Uma camada totalmente conectada (*Fully Connect*) com 4 neurônios e uma camada *Softmax* para predição das classes.

Uma das principais características das redes *LSTM*, é a sua capacidade de modelar fenômenos temporais, contudo, deve ser destacado que no presente problema as representações temporais estão representadas, implicitamente, pelas classes que estão relacionadas a diferentes estágios de falha dos rolamentos, desde o início de funcionamento, até estágios de danos mais severos. Nesse contexto, o problema objeto deste trabalho não se constitui um problema de predição clássico, em que a partir

de ocorrências de um evento em instantes de tempo anteriores, pode-se prever o comportamento do processo em instantes de tempos no futuro.

Figura 40 – Arquitetura da rede LSTM utilizada para classificação



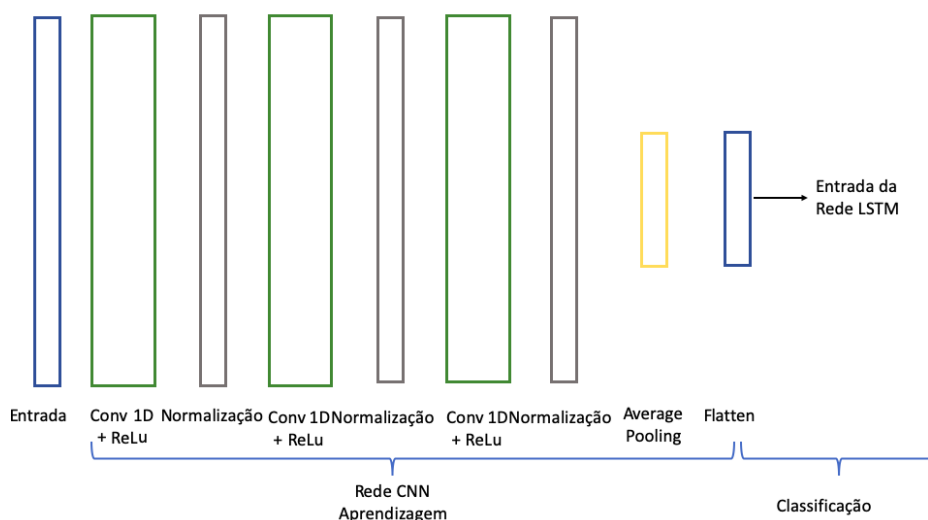
Fonte: Adaptado de (GAGLIANO et al., 2019)

4.3.3 Arquitetura da Rede Neural Convolucional Utilizada para Extração de Descritores

A Figura 41 apresenta, de forma simbólica, a arquitetura da rede *CNN* utilizada para a extração de descritores nos modelos 2 e 4. Como pode ser notado, além da entrada, onde os sinais serão alimentados, a rede é constituída por três conjuntos compostos por uma camada convolucional 1D com função de ativação *ReLU*, seguida por uma camada de normalização. A primeira camada convolucional é formada por 64 filtros de comprimento igual a 5. As demais camadas convolucionais são formadas por 128 filtros, também de comprimento igual a 5. Na saída da sequência dos conjuntos convolucional/normalização uma camada *Average Pooling* reduz a dimensão da estrutura de dados alimentado na entrada da rede. Uma camada *Flatten*, na saída da estrutura de extração de descritores, entrega os dados processados na etapa anterior para a rede *LSTM*.

A rede neural convolucional foi utilizada neste trabalho com a finalidade de extrair descritores dos sinais de vibração, que, em uma etapa seguinte, foram classificados pela rede *LSTM*. Como visto na Seção 4.2.1, os modelos 2 e 4 utilizaram essa estrutura para extração de descritores. A Figura 42 mostra a arquitetura das redes *CNN* e *LSTM* integradas.

Figura 41 – Arquitetura da Rede CNN.

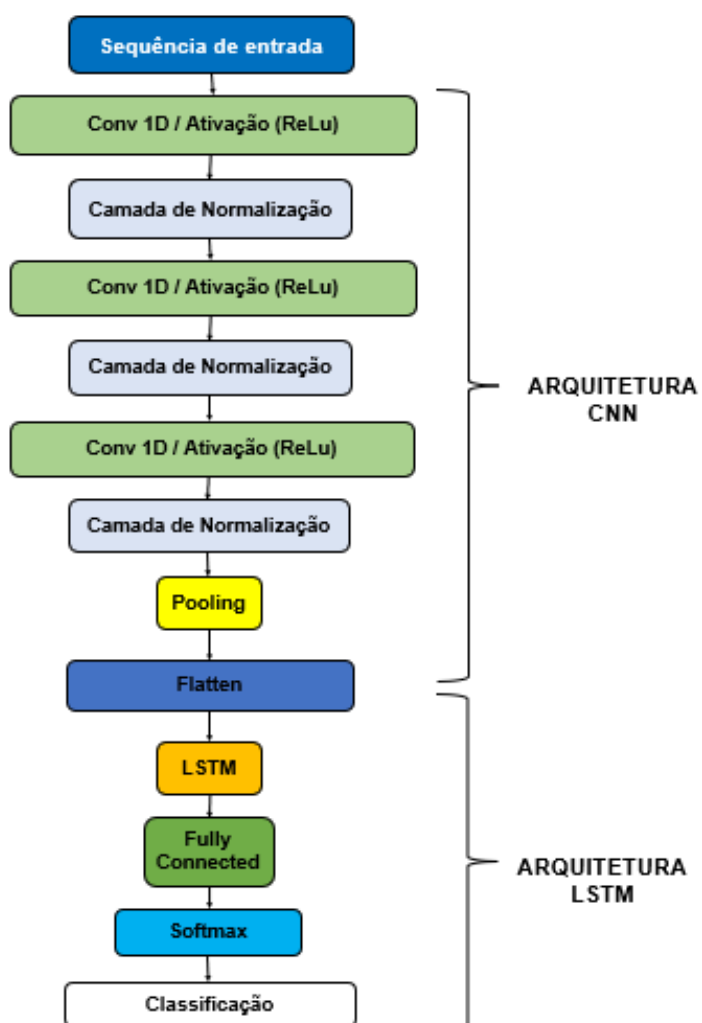


Fonte: Autoria Própria

4.3.4 Configurações de Treinamento e Validação

Para a separação dos conjuntos de treinamento e teste, o método *holdout* foi utilizado para particionar os dados em 70% das amostras para a fase de treino e 30% para a fase de validação.

Todos modelos foram treinados com, no máximo, 100 épocas, com um total de 1.800 iterações, sendo 18 por época. Para interromper o treinamento, caso a saída se apresentasse estável, foi inserido o mecanismo de *Early Stopping*. Neste caso, se o valor do erro da rede sobre o conjunto de validação se mantivesse durante 5 épocas consecutivas, o treinamento seria interrompido. Em todos os testes a taxa de aprendizado foi mantida constante em 0,001. Todos os testes foram realizados no *Matlab 2020a*.

Figura 42 – Arquitetura com as redes *CNN* e *LSTM* integradas

Fonte: Autoria Própria

5 RESULTADOS

Este capítulo apresenta os resultados obtidos com os quatro modelos, cujas arquiteturas foram descritas na Seção 4.3. Os modelos 1 e 2 foram construídos com os sinais no domínio do tempo e os modelos 3 e 4 com os sinais transformados para o domínio *wavelet*. No domínio *wavelet*, os modelos foram construídos com os filtros *Daubechies 4*, *Symlet 8* e *Coiflet 2*, em todos os níveis de resolução possíveis.

5.1 RESULTADO DOS TESTES COM O MODELO 1 - SINAIS NO DOMÍNIO DO TEMPO E DESCRITORES ESTATÍSTICOS


A Figura 43 mostra o resultado na etapa de treino/validação no Modelo 1, e a Tabela 7 apresenta os resultados do desempenho na etapa teste. Analisando a Figura 43 nota-se que em torno de 650 épocas o modelo convergiu, apresentando um valor de Loss em torno de 0,25%. Embora, de forma geral, o modelo tenha apresentado bom desempenho se for considerado o valor da acurácia (92,62%), o valor da sensibilidade foi baixo (79,80%). Considerando que a sensibilidade mede a capacidade do modelo para detectar, com sucesso, condições de funcionamento normal, baixos valores de sensibilidade indica que se operando em um sistema real, poderá ocorrer uma quantidade indesejada de falsos positivos.

Tabela 7 – Resultados do Modelo 1 - sinais no domínio do tempo + descritores estatísticos

<i>Acurácia</i>	<i>precisão</i>	<i>Sensibilidade</i>	<i>Especificidade</i>	<i>F1score</i>
0,9262	0,9193	0,7980	0,9237	0,8461

Fonte: Autoria própria.

Figura 43 – Gráfico de treinamento do Modelo 1 - sinais no domínio do tempo + descritores estatísticos



Fonte: Autoria própria.

5.2 RESULTADO DOS TESTES COM O MODELO 2 - SINAIS NO DOMÍNIO DO TEMPO E CNN

A Figura 44 mostra o resultado na etapa de treino/validação no Modelo 2, e a Tabela 8 apresenta os resultados do desempenho na etapa teste. Comparando o desempenho no treinamento do Modelo 2 com o Modelo 1, observa-se que, embora o Modelo 2 tenha precisado de maior número de iterações (em torno de 800) do que o Modelo 1, o valor do *Loss* (perda) foi menor no Modelo 2, (em torno de 0,1). O custo computacional mais elevado do treinamento do Modelo 2 pode ser justificado pela utilização da rede neural convolucional para extração dos descritores. Contudo, o menor valor da perda indica que os descritores extraídos pela *CNN*, melhor representam os estados do processo.

Os valores das métricas de desempenho mostrados na Tabela 8 indicam que o Modelo 2 apresentou desempenho consideravelmente superior ao Modelo 1. Para o Modelo 2, os valores de todas as métricas foram superiores a 95%, sendo o valor da acurácia 97,65%. Além de apresentar uma melhora da acurácia, quando comparado ao Modelo 1, a sensibilidade do Modelo 2 (95%) foi muito superior à obtida pelo Modelo 1. Deve-se destacar também o excelente desempenho do modelo quando considerado o valor da especificidade (97,41%). Como a especificidade avalia a capacidade do modelo para


detectar falhas que efetivamente ocorrerão, a utilização do Modelo 2 em aplicações reais na indústria aumenta a segurança dos processos e equipamentos.

Tabela 8 – Resultados do Modelo 2 - sinais no domínio do tempo + CNN

Acurácia	precisão	Sensibilidade	Especificidade	F1score
0,9765	0,9835	0,9502	0,9741	0,9656

Fonte: Autoria própria.

Figura 44 – Gráfico de treinamento do Modelo 2 - sinais no domínio do tempo + CNN.



Fonte: Autoria própria.

5.3 RESULTADO DOS TESTES COM O MODELO 3 - SINAIS NO DOMÍNIO WAVELET E DESCRITORES ESTATÍSTICOS

Os resultados do desempenho do Modelo 3, construído com os sinais transformados para o domínio *wavelet* serão apresentados separadamente para cada filtro utilizado. As tabelas com as métricas incluirá o resultado de todos os modelos, contudo, será apresentado apenas o gráfico do treinamento do modelo com melhor desempenho.

As tabelas 9, 10 e 11 contém os valores das métricas de desempenho dos modelos construídos no domínio *wavelet*, com os filtros *Daubechies 4*, *Symlet 8* e *Coiflet 2*, respectivamente, utilizando descritores estatísticos. Para o filtro *Daubechies 4* foram construídos 11 modelos, um para cada nível de resolução em que os sinais foram

decompostos. Para os filtros *Symlet 8* e *Coiflet 2*, por sua vez, foram construídos 10 modelos cada.

Analisando os valores das métricas obtidas pelos modelos em todos os níveis de decomposição para os três filtros utilizados, pode-se observar que os melhores modelos foram construídos nos níveis de resolução intermediários (nível 6 para a *Daubechies 4*, nível 4 para a *Symlet 8* e nível 7 para a *Coiflet 2*). O que é uma evidência de que as regiões de frequência, e os eventos temporais associados a esses níveis são mais efetivos para a extração de descritores para a construção dos modelos.

O modelo que apresentou melhor desempenho na configuração do Modelo 3 foi construído utilizando o filtro *wavelet Symlet 8* no quarto nível de decomposição. Nesse caso, o valor da acurácia foi 98,41%, além disso o referido modelos apresentou a melhor especificidade (98,50%) entre todos os modelos, e os valores das demais métricas foram comparáveis às dos melhores modelos construídos no domínio *wavelet* com descritores estatísticos.

Quando comparado com o Modelo 2, modelo que apresentou melhor desempenho com dados no domínio do tempo, o melhor modelo construído com a arquitetura Modelo 3, apresenta desempenho equivalente. Esse resultado pode ser interpretado, no contexto desta pesquisa, como a utilização da *CNN* para extração de descritores dos dados originais (Modelo 2) e a utilização de descritores estatísticos em sinais transformados pela transformada *wavelet* (Modelo 3), sejam opções de modelagem similares. Contudo, se for considerado que a utilização da transformada *wavelet* representa uma etapa de filtragem dos sinais, anterior a construção dos modelos, pode-se argumentar, nesse caso, que os modelos construídos no domínio *wavelet*, de forma geral, são mais robustos à presença de ruídos nos sinais.

Os gráficos das figuras 45, 46 e 47 mostram os gráficos dos treinamentos dos modelos com melhor desempenho em cada filtro. Para o filtro *Daubechies 4* o melhor nível foi o 6, e para os filtros *Symlet 8* e *Coiflet 2* foram os níveis 4 e 7, respectivamente. Pode ser notado nos gráficos que o número de épocas de treino para os modelos da arquitetura Modelo 3, foi muito superior aos modelos das arquiteturas dos Modelos 1 e 2. Conclui-se que a utilização da transformada *wavelet* aumenta o custo computacional para a construção dos modelos, o que pode não ser uma desvantagem, se for considerado que o treinamento de modelos se dá de forma *off-line* para ajustes dos pesos.


5.3.1 Resultados do Modelo 3 utilizando o filtro *wavelet Daubechies 4*

Tabela 9 – Resultados do Modelo 3 - sinais no domínio *wavelet* com *Daubechies 4* + descritores estatísticos

Nível de Resolução	Acurácia	precisão	Sensibilidade	Especificidade	F1score
<i>n1</i>	0,9493	0,9572	0,8540	0,9459	0,8891
<i>n2</i>	0,9391	0,9271	0,8733	0,9509	0,8905
<i>n3</i>	0,9698	0,9794	0,9010	0,9681	0,9326
<i>n4</i>	0,9338	0,9498	0,8508	0,9459	0,8811
<i>n5</i>	0,9709	0,9797	0,8659	0,9757	0,9107
<i>n6</i>	0,9709	0,9657	0,9247	0,9693	0,9439
<i>n7</i>	0,9032	0,9429	0,6175	0,9175	0,6410
<i>n8</i>	0,9566	0,9671	0,8802	0,9586	0,9161
<i>n9</i>	0,9590	0,9672	0,8702	0,9670	0,9027
<i>n10</i>	0,9693	0,9770	0,8886	0,9718	0,9220
<i>n11</i>	0,9700	0,9603	0,9329	0,9710	0,9453

Fonte: Autoria própria.

Figura 45 – Gráfico de treinamento do Modelo 3 - sinais no domínio *wavelet* com *Daubechies 4* + descritores estatísticos.



Fonte: Autoria própria.


5.3.2 Resultados do Modelo 3 utilizando o filtro *wavelet Symlet 8*

Tabela 10 – Resultados do Modelo 3 - sinais no domínio *wavelet* com *Symlet 8* + descritores estatísticos

Nível de Resolução	Acurácia	precisão	Sensibilidade	Especificidade	F1score
<i>n1</i>	0,9569	0,9433	0,9148	0,9665	0,9226
<i>n2</i>	0,9636	0,9712	0,8927	0,9690	0,9243
<i>n3</i>	0,8916	0,0000	0,9685	0,8937	0,0000
<i>n4</i>	0,9841	0,9724	0,9434	0,9850	0,9569
<i>n5</i>	0,9705	0,9618	0,9589	0,9661	0,9597
<i>n6</i>	0,8951	0,0000	0,6872	0,8976	0,0000
<i>n7</i>	0,9365	0,9515	0,8581	0,9482	0,8904
<i>n8</i>	0,9402	0,9556	0,8502	0,9324	0,8902
<i>n9</i>	0,9781	0,9831	0,9112	0,9815	0,9399
<i>n10</i>	0,9564	0,9713	0,8576	0,9536	0,9024

Fonte: Autoria própria.

Figura 46 – Gráfico de treinamento do Modelo 3 - sinais no domínio *wavelet* com *Symlet 8* + descritores estatísticos



Fonte: Autoria própria.


5.3.3 Resultados do Modelo 3 utilizando o filtro *wavelet Coiflet 2*

Tabela 11 – Resultados do Modelo 3 - sinais no domínio *wavelet* com *Coiflet 2* + descritores estatísticos

Nível de Resolução	Acurácia	precisão	Sensibilidade	Especificidade	F1score
<i>n1</i>	0,9595	0,9421	0,8504	0,9671	0,8824
<i>n2</i>	0,9499	0,9687	0,8666	0,9431	0,9102
<i>n3</i>	0,9209	0,9406	0,8223	0,9117	0,8706
<i>n4</i>	0,7976	0,7860	0,7656	0,8482	0,7087
<i>n5</i>	0,9494	0,9412	0,8807	0,9606	0,8979
<i>n6</i>	0,9663	0,9727	0,8914	0,9747	0,9202
<i>n7</i>	0,9763	0,9825	0,8946	0,9793	0,9277
<i>n8</i>	0,9577	0,9680	0,8605	0,9605	0,8989
<i>n9</i>	0,8620	0,9069	0,7759	0,8788	0,8053
<i>n10</i>	0,9728	0,9573	0,9534	0,9791	0,9545

Fonte: Autoria própria.

Figura 47 – Gráfico de treinamento do Modelo 3 - sinais no domínio *wavelet* com *Coiflet 2* + descritores estatísticos



Fonte: Autoria própria.

5.4 RESULTADO DOS TESTES COM O MODELO 4 - SINAIS NO DOMÍNIO WAVELET E CNN

Os resultados do desempenho do Modelo 4, construído com os sinais transformados para o domínio *wavelet* serão apresentados separadamente para cada filtro utilizado. As tabelas com as métricas incluirá o resultado de todos os modelos, contudo, será apresentado apenas o gráfico do treinamento do modelo com melhor desempenho.

As tabelas 12, 13 e 14 contém os valores das métricas de desempenho dos modelos construídos no domínio *wavelet*, com os filtros *Daubechies 4*, *Symlet 8* e *Coiflet 2*, respectivamente, com extração de descritores da CNN dos sinais de vibração transformados para o domínio *wavelet*. Para todos os três filtros, os melhores modelos foram obtidos no segundo nível de resolução da transformada. O que mostra uma clara predominância da faixa de frequência associada a esse nível para os três filtros. É importante observar também que o desempenho dos modelos construídos no segundo nível de resolução é muito superior a maioria dos demais modelos obtidos nos outros níveis de resolução.

Quando a CNN foi utilizada para extração de descritores dos sinais no domínio *wavelet*, o melhor modelo foi construído com o filtro *Daubechies 4*, no segundo nível de resolução, com uma acurácia de 98,76%, sendo esse o melhor resultado entre todos os modelos, considerando o domínio do sinal e o método de extração de descritores.

Os gráficos das figuras 48, 49 e 50 mostram os gráficos dos treinamentos dos modelos com melhor desempenho em cada filtro. Para os três filtros o melhor nível foi o 2. Aspecto importante a ser destacado nos gráficos do treinamento, é que nas três configurações do Modelo 4, o treinamento convergiu mais rapidamente que em todos os outros modelos, o que representa uma vantagem computacional dos modelos que utilizam essa arquitetura.


5.4.1 Resultados do Modelo 4 utilizando o filtro *Daubechies 4*

Tabela 12 – Resultados do Modelo 4 - sinais no domínio *wavelet* com *Daubechies 4* + *CNN*

Nível de Resolução	Acurácia	precisão	Sensibilidade	Especificidade	F1score
<i>n1</i>	0,9744	0,9662	0,9723	0,9842	0,9545
<i>n2</i>	0,9876	0,9900	0,9581	0,9899	0,9729
<i>n3</i>	0,7280	0,0000	0,2500	0,7500	0,0000
<i>n4</i>	0,7551	0,0000	0,4778	0,7679	0,0000
<i>n5</i>	0,9026	0,8986	0,8258	0,9086	0,8505
<i>n6</i>	0,9164	0,9257	0,8285	0,8986	0,8642
<i>n7</i>	0,9358	0,9526	0,8282	0,9320	0,8689
<i>n8</i>	0,9251	0,9413	0,8355	0,9219	0,8729
<i>n9</i>	0,9386	0,9081	0,8884	0,9330	0,8972
<i>n10</i>	0,9200	0,9349	0,8668	0,9231	0,8927
<i>n11</i>	0,9469	0,9661	0,8917	0,9353	0,9219

Fonte: Autoria própria.

Figura 48 – Gráfico de treinamento do Modelo 4 - sinais no domínio *wavelet* com *Daubechies 4* + *CNN*



Fonte: Autoria própria.

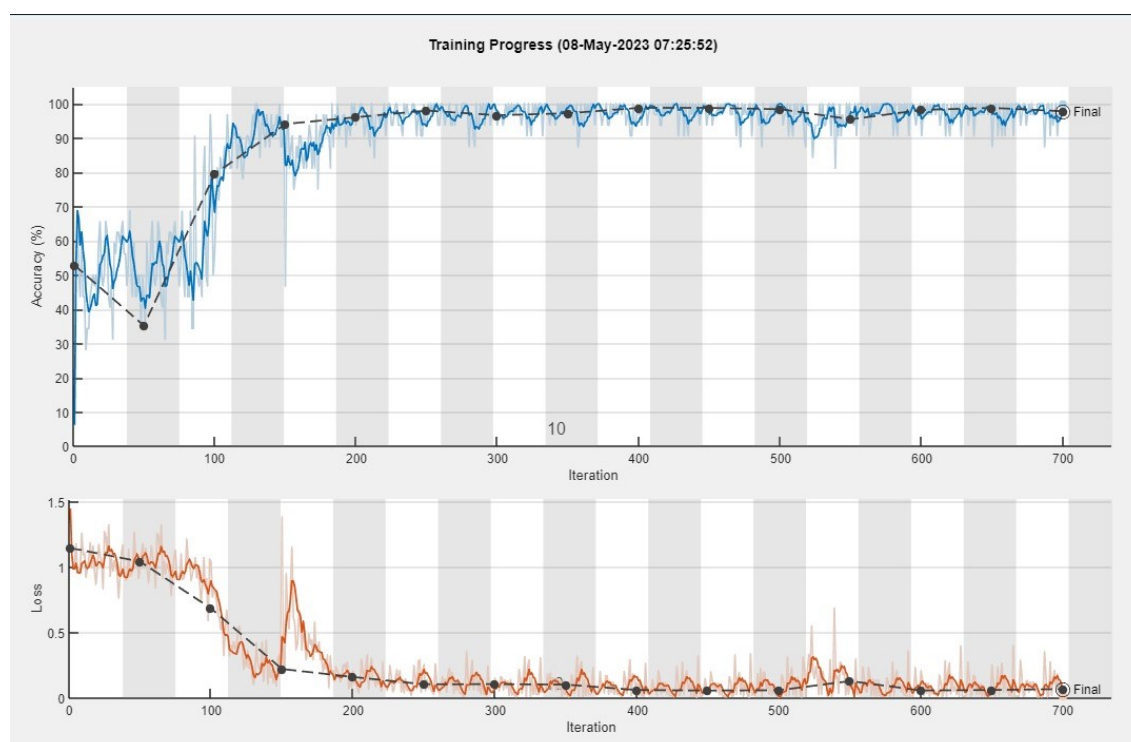
5.4.2 Resultados do Modelo 4 utilizando o filtro *Symlet 8*

Tabela 13 – Resultados do Modelo 4 - sinais no domínio *wavelet* com *Symlet 8* + *CNN*

Nível de Resolução	Acurácia	precisão	Sensibilidade	Especificidade	F1score
<i>n1</i>	0,9748	0,9599	0,9107	0,9813	0,9309
<i>n2</i>	0,9847	0,9890	0,9020	0,9884	0,9347
<i>n3</i>	0,7280	0,0000	0,2500	0,7500	0,0000
<i>n4</i>	0,7280	0,0000	0,2500	0,7500	0,0000
<i>n5</i>	0,9166	0,8806	0,8846	0,9080	0,8816
<i>n6</i>	0,8208	0,0000	0,5638	0,8109	0,0000
<i>n7</i>	0,7276	0,0000	0,2500	0,7495	0,0000
<i>n8</i>	0,9215	0,8790	0,8589	0,9140	0,8674
<i>n9</i>	0,8912	0,9189	0,7934	0,8701	0,8298
<i>n10</i>	0,9361	0,9305	0,8865	0,9368	0,9062

Fonte: Autoria própria.

Figura 49 – Gráfico de treinamento do Modelo 4 - sinais no domínio *wavelet* com *Symlet 8* + *CNN*



Fonte: Autoria própria.

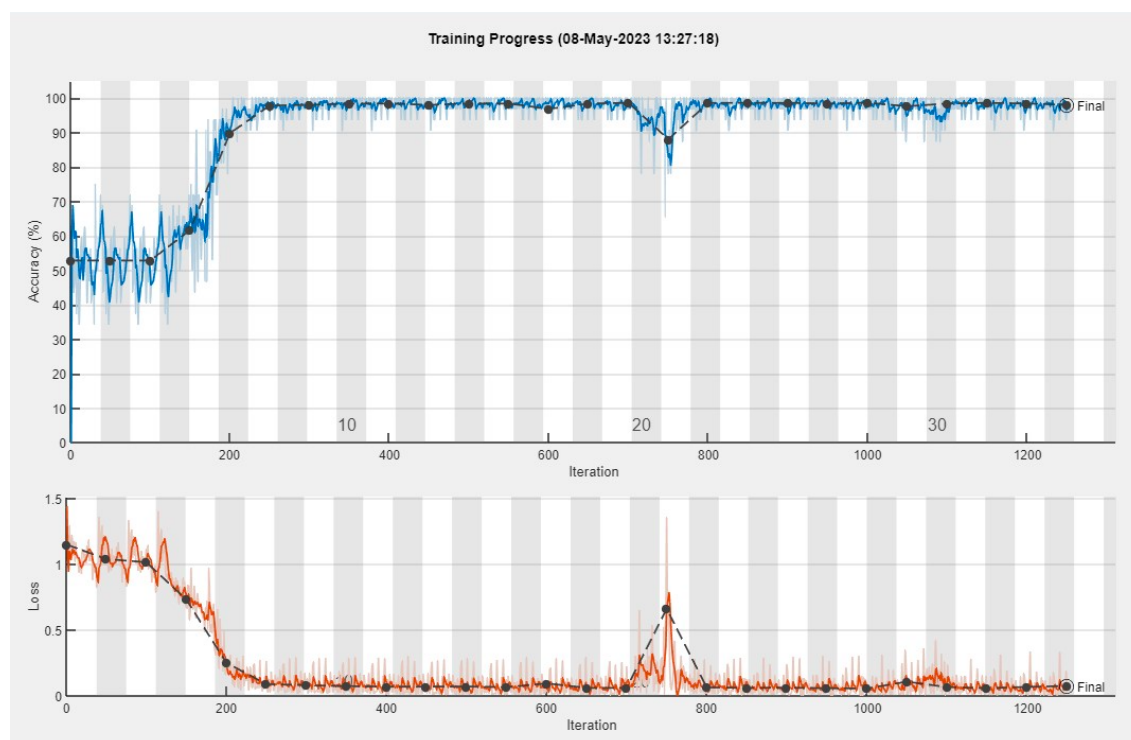
5.4.3 Resultados do Modelo 4 utilizando o filtro *Coiflet 2*

Tabela 14 – Resultados do Modelo 4 - sinais no domínio *wavelet* com *Coiflet 2* + *CNN*

Nível de Resolução	Acurácia	precisão	Sensibilidade	Especificidade	F1score
<i>n1</i>	0,9195	0,0000	0,7274	0,9257	0,0000
<i>n2</i>	0,9720	0,9773	0,8946	0,9791	0,9246
<i>n3</i>	0,9586	0,8508	0,9248	0,9698	0,8755
<i>n4</i>	0,7280	0,0000	0,2500	0,7500	0,0000
<i>n5</i>	0,9205	0,9489	0,8225	0,9043	0,8651
<i>n6</i>	0,7280	0,8822	0,8267	0,9106	0,8481
<i>n7</i>	0,7280	0,0000	0,2500	0,7500	0,0000
<i>n8</i>	0,9234	0,9475	0,7998	0,9158	0,8549
<i>n9</i>	0,9221	0,9465	0,8505	0,9074	0,8879
<i>n10</i>	0,9413	0,9585	0,8319	0,9366	0,8732

Fonte: Autoria própria.

Figura 50 – Gráfico de treinamento do Modelo 4 - sinais no domínio *wavelet* com *Coiflet 2* + *CNN*



Fonte: Autoria própria.

5.5 MELHORES RESULTADOS OBTIDOS EM CADA ARQUITETURA DE MODELO

A Tabela 15 reúne os melhores resultados obtidos pelas quatro arquiteturas de modelos de predição. Para o domínio wavelet foram apresentados os melhores resultados com cada um dos filtros wavelet utilizados.

Tabela 15 – Resultados de todos os Modelos com os melhores resultados para comparação dos resultados

<i>Domínio</i>	<i>Nível</i>	<i>Descritor</i>	<i>Acurácia</i>	<i>precisão</i>	<i>Sensibilidade</i>	<i>Especificidade</i>	<i>F1score</i>
<i>Tempo</i>	–	<i>DE</i>	0,9262	0,9193	0,7980	0,9237	0,8461
<i>Tempo</i>	–	<i>CNN</i>	0,9720	0,9773	0,8946	0,9791	0,9246
<i>Daubechies 4</i>	<i>n6</i>	<i>DE</i>	0,9709	0,9656	0,9247	0,9693	0,9439
<i>Symlet 8</i>	<i>n4</i>	<i>DE</i>	0,9841	0,9724	0,9434	0,9850	0,9569
<i>Coiflet 2</i>	<i>n7</i>	<i>DE</i>	0,9763	0,9828	0,8946	0,9793	0,9277
<i>Daubechies 4</i>	<i>n2</i>	<i>CNN</i>	0,9876	0,9900	0,9581	0,9899	0,9729
<i>Symlet 8</i>	<i>n2</i>	<i>CNN</i>	0,9847	0,9890	0,9020	0,9884	0,9347
<i>Coiflet 2</i>	<i>n2</i>	<i>CNN</i>	0,9720	0,9773	0,8946	0,9791	0,9246

Fonte: Autoria própria.

5.6 COMPARAÇÃO COM TRABALHOS CORRELATOS

Diversos autores utilizaram a base de dados *IMS*, tanto para fins de diagnóstico quanto para predição de falhas em rolamentos. Entretanto, a comparação direta entre métodos não é trivial, pois ou os autores utilizaram extratos diferentes dos dados disponíveis no conjunto de dados *IMS*, ou utilizaram métricas diferentes para avaliação do desempenho dos modelos. Em (AMBIKA; RAJENDRAKUMAR; RAMCHAND, 2019) foi proposto um algoritmo denominado transformação de espalhamento, usado para diagnóstico de falhas em rolamentos. A ideia central da transformada de espalhamento está na construção de uma rede de espalhamento que é formada a partir de uma pilha de camadas de processamento de sinal de largura crescente. A principal contribuição foi o desenvolvimento de características de coeficiente de espalhamento que são invariantes à variância translacional e rotacional. De acordo com os autores, a acurácia média obtida nos testes foi de 99%.

No trabalho de (ZHAO et al., 2022) os autores utilizaram descritores estatísticos para diagnosticar falhas no conjunto de dados *IMS*. Para os testes foi utilizado o conjunto de sinais do rolamento 2. O melhor resultado relatado pelos autores, considerando a métrica *MAPE* foi 3,79%. Apesar da dificuldade da comparação direta dos resultados obtidos com trabalhos anteriores, pode-se concluir que os melhores modelos que foram construídos nesse trabalho, apresentam performance comparável aos melhores modelos propostos, que utilizaram a base de dados *IMS*.

6 CONCLUSÃO

Este trabalho fez uma análise comparativa entre quatro arquiteturas de modelos de classificação para identificar faltas iminentes em rolamentos de motores elétricos. Para os experimentos foi utilizado o conjunto de sinais de vibração *IMS*, disponibilizado pelo *Intelligent Maintenance Systems (IMS)*, da *University of Cincinnati*. Para a construção dos modelos, os sinais foram organizados em quatro classes (*early*, *normal*, *suspect* e *imminent*). As arquiteturas dos modelos (Modelo 1, Modelo 2, Modelo 3 e Modelo 4), foram constituídas por combinações entre o domínio dos sinais empregados para a construção dos modelos (domínio do tempo ou domínio *wavelet*), e a estratégia para extração dos descritores (descritores estatísticos e *CNN*).

A arquitetura que apresentou o pior desempenho foi o Modelo 1 (dados no domínio do tempo e descritores estatísticos). Embora esse modelo tenha apresentado um valor aceitável de acurácia (92,62%), os valores da sensibilidade e do *F1-score* (79,80 e 84,61, respectivamente), indicam que a utilização dessa arquitetura para implementar sistemas de diagnóstico de falhas pode ser problemática para a planta industrial. O baixo valor da sensibilidade aponta para a possibilidade da ocorrência de muitos falsos alarmes.

O desempenho do Modelo 2 (sinais no domínio do tempo e *CNN*), significativamente superior ao do Modelo 1, mostra que bons modelos podem ser obtidos no domínio do tempo, quando outras estratégias para extração de descritores são utilizadas. Os valores de todas as métricas de modelagem do Modelo 2 foram superiores a 95%, e o maior problema do Modelo 1 (falsos alarmes), foi reduzido de forma significativa pela arquitetura de Modelo 2, tendo em vista o valor da sensibilidade de 95,02%.

Analisando os resultados dos modelos construídos utilizando a arquitetura de Modelo 3 (sinais no domínio *wavelet* e descritores estatísticos), concluímos que a transformada *wavelet*, com a configuração adequada (tipo de filtro e nível de resolução), pode superar as limitações dos modelos construídos no domínio do tempo por meio de descritores estatísticos. Uma vantagem adicional da utilização da transformada *wavelet*, além da representação dos sinais de vibração em outro domínio, é que, como para a sua implementação são utilizados filtros passa-baixas (para extração dos coeficientes de aproximação) e filtros passa-altas (para extração dos coeficientes de detalhe), os sinais efetivamente utilizados para a construção dos modelos tendem a ser menos contaminados por ruídos, fato que pode resultar em modelos de classificação mais robustos.

O melhor resultado da modelagem com a arquitetura do Modelo 4 (sinais no domínio

wavelet e *CNN*), apenas ligeiramente superior ao melhor resultado obtido com a arquitetura de Modelo 3. Contudo, a utilização da transformada *wavelet* combinada com a *CNN*, melhora a filtragem dos sinais para a modelagem.

O desenvolvimento de novas tecnologias e a utilização de parques industriais cada vez mais complexos, tem aumentado o interesse pela utilização de sistemas inteligentes para monitoramento de plantas industriais. A aplicação de estratégias de inteligência artificial para monitoramento de seus parques industriais, aumenta a confiabilidade e disponibilidade operacional dos equipamentos da linha de produção. A predição de falhas através de sistemas inteligentes, possibilita intervenções programadas e reduz perdas indesejáveis, realizando manutenções somente quando necessário, aumentando, dessa forma, a vida útil dos equipamentos e reduzindo seus custos em manutenções corretivas. Nesse contexto, os resultados obtidos na presente pesquisa mostram a viabilidade da implementação da estratégia proposta para a predição de situações de falhas iminentes em rolamentos de motores.

7 TRABALHOS FUTUROS

Trabalhos futuros podem considerar: A utilização de outras arquiteturas de redes para classificação dos estados do processo, utilizando os mesmos métodos de predição proposto neste trabalho.

Desenvolvimento de variações dos modelos propostos para realização de predição clássica de falhas, isto é, utilizar o conhecimento sobre o processo em um intervalo de tempo no passado para estimar o comportamento em instantes de tempo no futuro.

Uma outra possibilidade de trabalho futuro consistiria na adaptação dos modelos aqui propostos para monitoramento de falhas em outros tipos de equipamentos industriais.

REFERÊNCIAS

- AFRIDI, Y. S. et al. Lstm-based condition monitoring and fault prognostics of rolling element bearings using raw vibrational data. *Machines*, v. 11, n. 5, 2023. ISSN 2075-1702. Disponível em: <<https://www.mdpi.com/2075-1702/11/5/531>>. Citado na página 23.
- AHMED, H. O.; NANDI, A. K. Three-stage hybrid fault diagnosis for rolling bearings with compressively sampled data and subspace learning techniques. *IEEE Transactions on Industrial Electronics*, IEEE, v. 66, n. 7, p. 5516–5524, 2018. Citado na página 28.
- AL-BADOUR, F.; SUNAR, M.; CHEDED, L. Vibration analysis of rotating machinery using time-frequency analysis and wavelet techniques. *Mechanical Systems and Signal Processing*, Elsevier, v. 25, n. 6, p. 2083–2101, 2011. Citado na página 46.
- ALI, M. A. et al. The influence of handling imbalance classes on the classification of mechanical faults using neural networks. In: IEEE. *2019 8th International Conference on Modeling Simulation and Applied Optimization (ICMSAO)*. [S.l.], 2019. p. 1–5. Citado na página 20.
- AMBIKA, P.; RAJENDRAKUMAR, P.; RAMCHAND, R. Vibration signal based condition monitoring of mechanical equipment with scattering transform. *Journal of Mechanical Science and Technology*, Springer, v. 33, n. 7, p. 3095–3103, 2019. Citado na página 74.
- ARCO-VERDE, M. M. *Identificação de falhas em sistemas rotativos empregando técnicas não-lineares*. Tese (Doutorado) — Tese de Mestrado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ . . . , 2008. Citado na página 25.
- BENGIO, Y. Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning*, v. 2, n. 1, p. 1–127, 2009. ISSN 1935-8237, 1935-8245. Citado na página 35.
- BIANCHINI, C. A. et al. *Diagnóstico de falhas localizadas de rolamento em motores de indução trifásicos a partir de um modelo matemático*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2023. Citado na página 20.
- CERENTINI, A. et al. Identificação do glaucoma em imagens do fundo do olho utilizando aprendizagem profunda. In: . [S.l.]: Universidade Federal de Santa Maria, 2018. Citado na página 36.
- COCHRAN, W. T. et al. What is the fast fourier transform? *Proceedings of the IEEE*, IEEE, v. 55, n. 10, p. 1664–1674, 1967. Citado na página 44.
- COLLINS, J. A.; BUSBY, H. R.; STAAB, G. H. *Mechanical design of machine elements and machines: a failure prevention perspective*. [S.l.]: John Wiley & Sons, 2009. Citado na página 27.
- CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals and systems*, Springer, v. 2, n. 4, p. 303–314, 1989. Citado na página 34.

FACELI, K. et al. *Inteligência Artificial: Uma abordagem de aprendizado de máquina*. Rio de Janeiro: LTC, 2011. Citado 3 vezes nas páginas 15, 33 e 34.

GAGLIANO, L. et al. Bispectrum and recurrent neural networks: Improved classification of interictal and preictal states. *Scientific Reports*, v. 9, 10 2019. Citado na página 60.

GANGSAR, P.; TIWARI, R. A support vector machine based fault diagnostics of induction motors for practical situation of multi-sensor limited data case. *Measurement*, Elsevier, v. 135, p. 694–711, 2019. Citado na página 19.

GU, K. et al. Dwt-lstm-based fault diagnosis of rolling bearings with multi-sensors. *Electronics*, MDPI, v. 10, n. 17, p. 2076, 2021. Citado 2 vezes nas páginas 40 e 41.

GU K.; ZHANG, Y. L. X. L. H. R. M. Dwt-lstm-based fault diagnosis of rolling bearings with multi-sensors. *Electronics*, v. 10, 01 2021. Citado na página 22.

GÉRON, A. *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. [S.l.]: "O'Reilly Media, Inc.", 2017. Citado 2 vezes nas páginas 34 e 49.

HAN, H. et al. Least squares support vector machine (ls-svm)-based chiller fault diagnosis using fault indicative features. *Applied Thermal Engineering*, Elsevier, v. 154, p. 540–547, 2019. Citado na página 19.

HINTON, G.; SRIVASTAVA, N.; SWERSKY, K. Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. In: . [S.l.: s.n.], 2012. v. 14, n. 8, p. 2. Citado na página 39.

IOFFE, S.; SZEGEDY, C. *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*. 2015. Citado na página 38.

ISLAM, R.; KHAN, S. A.; KIM, J.-m. Discriminant feature distribution analysis-based hybrid feature selection for online bearing fault diagnosis in induction motors. *Journal of Sensors*, Hindawi, v. 2016, 2016. Citado na página 15.

KANKAR, P.; SHARMA, S. C.; HARSHA, S. Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, v. 38, n. 3, p. 1876 – 1886, 2011. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417410007475>>. Citado na página 18.

KIM, S.-H.; GEEM, Z. W.; HAN, G.-T. Hyperparameter optimization method based on harmony search algorithm to improve performance of 1d cnn human respiration pattern recognition system. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 13, p. 3697, 2020. Citado 2 vezes nas páginas 6 e 36.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014. Citado 2 vezes nas páginas 39 e 59.

LECUN, Y.; BOSER, B.; DENKER, J. D. henderson, re howard, w. hubbard, and lj jackel. *Handwritten digit recognition with a back-propagation network*, p. 396–404, 1990. Citado na página 35.

LEE, J. et al. *Bearing Data Set. IMS, University of Cincinnati. NASA Ames Prognostics Data Repository, NASA Ames, Moffett Field, CA.* 2015. Disponível em: <<http://https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>>. Acesso em: 20 de novembro de 2020. Citado 3 vezes nas páginas 50, 51 e 52.

LI, X.; WANG, J.; ZHANG, B. Fault diagnosis of rolling element bearing weak fault based on sparse decomposition and broad learning network. *Transactions of the Institute of Measurement and Control*, SAGE Publications Sage UK: London, England, v. 42, n. 2, p. 169–179, 2020. Citado na página 20.

LIMA, A. A. de et al. On fault classification in rotating machines using fourier domain features and neural networks. In: IEEE. *2013 IEEE 4th Latin American Symposium on Circuits and Systems (LASCAS)*. [S.l.], 2013. p. 1–4. Citado na página 18.

LIU, J. et al. Fault prediction of bearings based on lstm and statistical process analysis. *Reliability Engineering System Safety*, v. 214, 2021. ISSN 0951-8320. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832021001873>>. Citado na página 22.

LIU, R. et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, Elsevier, v. 108, p. 33–47, 2018. Citado na página 19.

LIU, Z.-H. et al. A regularized lstm method for predicting remaining useful life of rolling bearings. *International Journal of Automation and Computing*, Springer, v. 18, n. 4, p. 581–593, 2021. Citado na página 41.

LIU Z. H.; MENG, X. D. W. H. L. C. L. L. B. L. W. Z. H. C. L. A regularized lstm method for predicting remaining useful life of rolling bearings. *International Journal of Automation and Computing*, v. 18, 2021. Citado na página 22.

LOBÃO, D. A. *Técnicas de Aprendizado de Máquinas aplicadas ao Diagnóstico de Falhas em Equipamentos Industriais*. 87 p. Dissertação (Mestrado Profissional em Engenharia de Controle e Automação) — Universidade Federal do Espírito Santo, Serra, 2020. Citado 5 vezes nas páginas 26, 27, 48, 49 e 54.

LOUREIRO, S. M. *Reconhecimento automático de padrões de defeitos em motobombas utilizando análise de sinais de vibração*. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, 2009. Citado 2 vezes nas páginas 29 e 30.

MA, L. et al. Fault prediction of rolling element bearings using the optimized mckd–lstm model. *Machine*, v. 10, 2022. ISSN 0951-8320. Citado na página 22.

MALLAT, S. *A wavelet tour of signal processing*. [S.l.]: Elsevier, 2009. Citado na página 43.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 11, n. 7, p. 674–693, 1989. Citado na página 46.

MITCHELL, J. S. *Introduction to machinery analysis and monitoring*. [S.l.]: PennWell Tulsa, Okla, 1993. Citado na página 25.

MOHAMADI, H.; AHMADI, H.; MOHTASEBI, S. Prediction of defects in roller bearings using vibration signal analysis. v. 4, 01 2008. Citado na página 21.

MOHANTY, A. R. *Machinery condition monitoring: Principles and practices*. [S.l.]: CRC Press, 2014. Citado na página 15.

NANDI, A. K.; AHMED, H. *Condition Monitoring with Vibration Signals: Compressive Sampling and Learning Algorithms for Rotating Machines*. [S.l.]: John Wiley & Sons, 2020. Citado 5 vezes nas páginas 24, 25, 29, 44 e 53.

NANDI, S.; TOLIYAT, H. A.; LI, X. Condition monitoring and fault diagnosis of electrical motors—a review. *IEEE transactions on energy conversion*, IEEE, v. 20, n. 4, p. 719–729, 2005. Citado na página 27.

NAYANA, B. R.; GEETHANJALI, P. Analysis of statistical time-domain features effectiveness in identification of bearing faults from vibration signal. *IEEE Sensors Journal*, v. 17, n. 17, p. 5618–5625, 2017. Citado na página 53.

OLAH, C. *Understanding LSTM Networks*. 2015. Disponível em: <<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acesso em: 12 de junho 2022. Citado 4 vezes nas páginas 40, 41, 42 e 43.

PAN, Z. et al. A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings. *Mechanical Systems and Signal Processing*, v. 144, p. 106899, 2020. ISSN 0888-3270. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327020302855>>. Citado na página 21.

RADER, C. M. Discrete fourier transforms when the number of data samples is prime. *Proceedings of the IEEE*, IEEE, v. 56, n. 6, p. 1107–1108, 1968. Citado na página 44.

RAHMAN, M. *Applications of Fourier transforms to generalized functions*. [S.l.]: WIT Press, 2011. Citado na página 43.

RAUBER, T. W.; DE ASSIS BOLDT, F.; VAREJÃO, F. M. Heterogeneous feature models and feature selection applied to bearing fault diagnosis. *IEEE Transactions on Industrial Electronics*, v. 62, n. 1, p. 637–646, 2015. Citado na página 53.

RILEY, C. M. et al. Stator current harmonics and their causal vibrations: A preliminary investigation of sensorless vibration monitoring applications. *IEEE transactions on industry applications*, IEEE, v. 35, n. 1, p. 94–99, 1999. Citado na página 25.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958. Citado na página 33.

RUDER, S. An overview of gradient descent optimization algorithms. In: . [S.l.: s.n.], 2016. Citado 2 vezes nas páginas 38 e 39.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. *Learning internal representations by error propagation*. [S.l.], 1986. v. 1, 318–362 p. Citado na página 35.

SILVA, J. L.; CARDOSO, A. M. Diagnóstico de avarias nos rolamentos de motores de indução trifásicos. *Universidade de Coimbra*, 2005. Citado na página 13.

SKF. *Manual de manutenção de rolamentos da SKF*. 2022. Disponível em: https://www.skf.com/binaries/pub45/Images/0901d1968083afa2-SKF-Bearing-maintenance-handbook---10001_1-PT-BR_tcm_45-463040.pdf. Acesso em: 20 junho 2022. Citado 4 vezes nas páginas 29, 31, 32 e 33.

STRANG, G.; NGUYEN, T. *Wavelet and Filter Banks*. [S.l.]: Wellesley: Cambridge Press, 1996. Citado na página 46.

SUN, H.; ZHAO, S. Fault diagnosis for bearing based on 1dcnn and lstm. *Shock and Vibration*, Hindawi, v. 2021, 2021. Citado na página 40.

SUTSKEVER, I. et al. On the importance of initialization and momentum in deep learning. In: PMLR. *International conference on machine learning*. [S.l.], 2013. p. 1139–1147. Citado na página 38.

TAHIR, M. M. et al. Enhancing fault classification accuracy of ball bearing using central tendency based time domain features. *IEEE Access*, v. 5, p. 72–83, 2017. Citado na página 53.

TAO, Q. et al. Air pollution forecasting using a deep learning model based on 1d convnets and bidirectional gru. *IEEE access*, IEEE, v. 7, p. 76690–76698, 2019. Citado na página 36.

TAQI, A. M. et al. The impact of multi-optimizers and data augmentation on tensorflow convolutional neural network performance. In: IEEE. *2018 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*. [S.l.], 2018. p. 140–145. Citado 2 vezes nas páginas 38 e 39.

THORSEN, O.; DALVA, M. Failure identification and analysis for high voltage induction motors in petrochemical industry. In: *Conference Record of 1998 IEEE Industry Applications Conference. Thirty-Third IAS Annual Meeting (Cat. No.98CH36242)*. [S.l.: s.n.], 1998. v. 1, p. 291–298 vol.1. Citado na página 14.

ZHANG, S. et al. Machine learning and deep learning algorithms for bearing fault diagnostics - A comprehensive review. *CoRR*, abs/1901.08247, 2019. Disponível em: <http://arxiv.org/abs/1901.08247>. Citado na página 14.

ZHAO, Y. et al. An adaptive modeling framework for bearing failure prediction. *Electronics*, v. 11, n. 2, 2022. ISSN 2079-9292. Disponível em: <https://www.mdpi.com/2079-9292/11/2/257>. Citado na página 74.

ANEXOS

ANEXO A – PUBLICAÇÕES

Com os resultados obtidos a partir desta dissertação de mestrado, os seguintes trabalhos foram realizados:

LUCAS DE OLIVEIRA SOARES; CAMPOS, R. C.; MARCO ANTÔNIO DE S. L. CUADROS; PINTO, L. A. Aplicação de redes neurais convolucionais e correntes de sequência zero para identificação de motor com fuga a terra em sistemas de baixa tensão de neutro aterrado com RAV.. In: XXIV Congresso Brasileiro de Automática, 2022, Fortaleza. Anais do XXIV Congresso Brasileiro de Automática, 2022. v. 1.

CAMPOS, R. C.; NASCIMENTO, G. P.; ZAGO, G. T.; PINTO, L. A. Uma Análise Comparativa do Desempenho de Algoritmos de Classificação no Diagnóstico de Falhas em Rolamentos de Motores Elétricos a Partir de Sinais de Vibração. In: XXIV Congresso Brasileiro de Automática, 2022, Fortaleza. Anais do XXIV Congresso Brasileiro de Automática, 2022.

CAMPOS, R. C.; ZAGO, G. T.; PINTO, L. A. Prediction failure in electric motors bearings using vibration signals and Long Short Term-memory neural networks. In: XLIII Ibero-Latin-American Congress on Computational Methods in Engineering, 2022, Foz do Iguaçu. Anais do XLIII Ibero-Latin-American Congress on Computational Methods in Engineering, 2022.

PINTO, LUIZ ALBERTO; CAMPOS, RODRIGO CESAR; ZAGO, GABRIEL TOZATTO. Integração de Redes CNN e LSTM para Predição de Falhas em Rolamentos de Motores Elétricos. In: II Congresso Brasileiro Online de Ensino, Pesquisa e Extensão, 2023. Anais do II Congresso Brasileiro On-line de Ensino, Pesquisa e Extensão, 2023.