



**UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO TUCURUÍ
FACULDADE DE ENGENHARIA MECÂNICA**

**REDE NEURAL CONVOLUCIONAL PARA O DIAGNÓSTICO DE ROLAMENTOS
EM BAIXA ROTAÇÃO**

JONATAS CRUZ DA SILVA

**Tucuruí - PA
2024**



**UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITÁRIO TUCURUÍ
FACULDADE DE ENGENHARIA MECÂNICA**

**REDE NEURAL CONVOLUCIONAL PARA O DIAGNÓSTICO DE ROLAMENTOS
EM BAIXA ROTAÇÃO**

JONATAS CRUZ DA SILVA

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia Mecânica do Campus de Tucuruí, como parte dos requisitos para obtenção do título bacharel em Engenheiro Mecânico.

**Orientador:
Prof. Me. Walter dos Santos Sousa**

**Coorientador:
Eng. Me. Thiago Barroso Costa**

Tucuruí - PA

2024

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

- S586r Silva, Jonatas Cruz.
Rede Neural Convolutacional para o Diagnóstico de Rolamento em
Baixa Rotação / Jonatas Cruz Silva. — 2024.
58 f. : il. color.
- Orientador(a): Prof. Me. Walter dos Santos Sousa
Coorientador(a): Eng. Me. Thiago Barroso Costa
Trabalho de Conclusão de Curso (Graduação) - Universidade Federal
do Pará, Campus Universitário de Tucuruí, Faculdade de Engenharia
Mecânica, Tucuruí, 2024.
1. Redes Neurais Convolutacionais. 2. Diagnóstico de falha.
3. Rolamento de baixa rotação. 4. Imagem de vibração. I. Título.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS UNIVERSITARIO DE TUCURUI

TRABALHO DE CONCLUSÃO DE CURSO/TCC Nº 2 / 2024 - CTUCU (11.16)

Nº do Protocolo: 23073.032442/2024-42

Tucuruí-PA, 27 de maio de 2024.

REDE NEURAL CONVOLUCIONAL PARA O DIAGNÓSTICO DE ROLAMENTOS EM
BAIXA ROTAÇÃO

JONATAS CRUZ DA SILVA

Trabalho de Conclusão de Curso apresentado à Faculdade de Engenharia Mecânica do Campus de Tucuruí, como parte dos requisitos para obtenção do título bacharel em Engenharia Mecânica.

Data da aprovação: 24/05/2024

Conceito: Excelente

BANCA EXAMINADORA

Orientador: Prof. Me. Walter dos Santos Sousa
FEM/CAMTUC/UFPA

Coorientador: Eng. Me. Thiago Barroso Costa
Membro Externo

Membro Interno: Prof. Dr. André Luiz Amarante Mesquita
NDAE/UFPA

(Assinado digitalmente em 27/05/2024 22:54)

ANDRE LUIZ AMARANTE MESQUITA
PROFESSOR DO MAGISTERIO SUPERIOR
NDAE (11.16.16)
Matrícula: ###526#9

(Assinado digitalmente em 27/05/2024 19:26)

WALTER DOS SANTOS SOUSA
PROFESSOR DO MAGISTERIO SUPERIOR
CTUCU (11.16)
Matrícula: ###112#8

(Assinado digitalmente em 27/05/2024 19:44)

THIAGO BARROSO COSTA
DISCENTE
Matrícula: 2022#####8

Para verificar a autenticidade deste documento entre em
<https://sipac.ufpa.br/public/documentos/index.jsp> informando seu número: **2**, ano: **2024**,
tipo: **TRABALHO DE CONCLUSÃO DE CURSO/TCC**, data de emissão: **27/05/2024** e o código
de verificação: **42b3b8572c**

REDE NEURAL CONVOLUCIONAL PARA O DIAGNÓSTICO DE ROLAMENTOS EM BAIXA ROTAÇÃO

RESUMO

Este trabalho concentra-se na aplicação de redes neurais convolucionais (CNNs) no diagnóstico de falhas em rolamentos de baixa rotação, uma área crucial para garantir a segurança e a eficiência, principalmente na indústria de mineração. A utilização do sinal de vibração apresenta desafios devido ao fato de os rolamentos de baixa rotação funcionarem sob cargas consideráveis e, ocasionalmente, em condições não estacionárias. Além do mais, devido a energia associada ao sinal da falha no rolamento ser fraca, o seu monitoramento é dificultado pela presença de ruídos provenientes de outras fontes que pode mascarar o sinal da falha. Portanto, ferramentas de processamento de sinal e algoritmos de aprendizado de máquina foram propostos para lidar com essas questões. Dentre as técnicas de aprendizado de máquina, os modelos de diagnósticos baseados em aprendizagem profunda se popularizaram nos últimos anos, principalmente o modelo de rede neural convolucional devido ao seu desempenho. Assim, neste trabalho é proposto a elaboração de um modelo de diagnóstico em rolamentos de baixa rotação, baseado em uma rede neural convolucional, onde os dados de entrada são sinais de vibração que posteriormente são transformados em uma imagem na escala de cinza, denominada de imagem de vibração, e, por fim, utilizado para o treinamento do modelo. Para o treinamento e validação do modelo foram usados sinais de vibração de rolamento de um misturador de granéis que opera com rotação de 50 rpm, sendo estes sinais coletados com os rolamentos saudáveis e, posteriormente, com rolamentos defeituosos com diferentes graus de severidade e com diferentes níveis de carregamento do maquinário. Após o treinamento do modelo é analisado a acurácia para avaliar o desempenho e precisão do modelo proposto. Portanto, este trabalho visa criar uma ferramenta de diagnóstico automatizada para falha em rolamentos de baixa rotação com um elevado nível de acurácia, assim facilitando o monitoramento de maquinário que utiliza esses tipos de rolamentos garantido a eficiência e segurança nos setores industriais. Como resultado, obteve-se dois modelos de diagnóstico automatizado de falha, um multiclasse e outro binário, onde obtiveram excelentes resultados.

Palavras-chave: *Redes Neurais Convolucionais, diagnóstico de falha, rolamento de baixa rotação, imagem de vibração*

CONVOLUTIONAL NEURAL NETWORK FOR LOW-SPEED BEARING DIAGNOSIS

ABSTRACT

This work focuses on the application of Convolutional Neural Networks (CNNs) in diagnosing faults in low-speed bearings, a crucial area for ensuring safety and efficiency, particularly in the mining industry. The use of vibration signals presents challenges due to low-speed bearings operating under considerable loads and occasionally under non-stationary conditions. Furthermore, because the energy associated with the bearing fault signal is weak, its monitoring is hindered by noise from other sources that can mask the fault signal. Therefore, signal processing tools and machine learning algorithms have been proposed to address these issues. Among machine learning techniques, deep learning-based diagnostic models have become popular in recent years, especially the Convolutional Neural Network model due to its performance. Thus, this work proposes the development of a diagnostic model in low-speed bearings, based on a convolutional neural network, where the input data is vibration signals that are subsequently transformed into a grayscale image, called a vibration image, and finally used for model training. For model training and validation, vibration signals from a bulk mixer operating at 50 rpm were used, with signals collected from healthy bearings and subsequently from defective bearings with varying degrees of severity and different machinery loading levels. After model training, accuracy is analyzed to evaluate the performance and precision of the proposed model. Therefore, this work aims to create an automated diagnostic tool for low-speed bearing failure with a high level of accuracy, thus facilitating the monitoring of machinery using these types of bearings, ensuring efficiency and safety in industrial sectors. As a result, two automated fault diagnosis models were obtained, one multiclass and the other binary, both achieving excellent results.

Keyword: *Convolutional Neural Networks, fault diagnosis, low-speed bearing, vibration image.*

DEDICATÓRIA

Dedico este trabalho aos meus queridos pais, Rosangela e Ernandes, cuja fé inabalável e amor incondicional me guiaram ao longo de toda esta jornada. Obrigado por cada palavra de incentivo, por cada sacrifício e por estarem sempre ao meu lado, proporcionando-me a base sólida sobre a qual construí meus sonhos. Sem vocês, este momento não seria possível.

AGRADECIMENTOS

Gostaria de fazer os devidos agradecimentos a todos que fizeram parte ao longo da minha trajetória acadêmica. Desde o princípio, inúmeras pessoas foram vitais, sempre me apoiando e garantindo que eu mantivesse o foco e a determinação. Minha gratidão eterna vai para cada uma delas, por suas contribuições fundamentais ao meu desenvolvimento e sucesso.

Primeiramente gostaria de agradecer minha família, em especial, agradeço profundamente aos meus pais, Rosangela e Ernandes, por seu amor, apoio constante e pelos valores que me transmitiram. Vocês sempre acreditaram em mim, mesmo nos momentos mais desafiadores, e foram a base sólida que me sustentou. Este trabalho é também um reflexo de todo o sacrifício e dedicação de vocês.

Além desses, gostaria de agradecer a Universidade Federal do Pará e aos seus funcionários pela oportunidade de adquirir conhecimento de qualidade. Em especial a todos os professores do curso de Engenharia Mecânica da UFPA CAMTUC, pelos conhecimentos de qualidade que foram transmitidos.

Também, gostaria de agradecer aos meus orientadores Prof. Walter Sousa e Thiago Barroso pela paciência, incentivo e ensinamentos que foram fornecidos para a conclusão desse trabalho. Ademais, ao Prof. André Mesquita por sua contribuição como coordenador do projeto UFPA-Dynamox, no qual me proporcionou o incentivo financeiro, a oportunidade de desenvolver minhas habilidades de pesquisa e contribuir significativamente na conclusão desse trabalho.

Agradecimento a Dynamox® S.A. pelo financiamento do projeto de pesquisa UFPA-Dynamox, principalmente ao Danilo Braga e à Jullyane Figueiredo por ter dado todo o suporte necessário.

Aos meus amigos de classe Pedro Henrique, Paulo Henrique, Carlos Vinicius, Larissa Pinheiro e Bruno Sacramento gostaria de agradecer-los pela amizade e companheirismo durante todos esses anos, e a todos os colegas e amigos que fiz durante a minha jornada acadêmica. Aos meus amigos de trabalho, Geovane Nascimento, Otávio Dias, Armando Sousa, Ryan Louzada, Alex Lopez, Hermeson Wanzeler, Danielle Baia, Madalena Silva, Daniela Baena, Arthur Fontana, Danilo Santos, Maycon Castro, agradeço pelo companheirismo e ajuda que me deram nessa jornada.

Por fim, gostaria de agradecer a minha companheira Cristielle Furlan por todo apoio, carinho e incentivo que me proporcionou, sempre acreditando e me motivando para que nunca desistisse do que almejo.

A todos esses e os outros, que de forma direta e indireta, que contribuíram para o desenvolvimento desse trabalho, meu sincero obrigado.

“A vida é igual andar de bicicleta. Para manter o equilíbrio é preciso se manter em movimento.”

(Albert Einstein)

LISTA DE ILUSTRAÇÕES

Figura 1. Passagem do sinal no domínio do tempo para o da frequência.....	20
Figura 2. Sinal de vibração.	20
Figura 3. Espectro de Frequência.	20
Figura 4. Diagrama de rolamento de esferas: 1) Pista externa, 2) Gaiola, 3) Pista interna 4) Elemento rolante,.....	21
Figura 5. Elemento rolante lixado em diferentes graus.	23
Figura 6. Exemplo de uma RNA.	25
Figura 7. Cálculo do resultado de uma convolução para um único neurônio.	27
Figura 8. Função de ativação não linear ReLU.	28
Figura 9. Exemplo da utilização do max-pooling.....	29
Figura 10. Exemplo esquemático da função <i>Dropout</i>	29
Figura 11. Fluxograma da atualização dos pesos da rede.....	31
Figura 12. Construção das Imagens de Vibração	32
Figura 13. Matriz de Confusão no caso de duas classes.....	33
Figura 14. Misturador MT120.....	35
Figura 15. Localização do rolamento (a) Vista das disposições das pás de mistura (b) Extração do rolamento.	36
Figura 16. Posicionamento do sensor.	36
Figura 17. Esquema do posicionamento do sensor, unidades em (mm).	37
Figura 18. Sensor <i>DynaLogger HF+</i>	37
Figura 19. Detalhe da superfície da seção de 25% lesada.	39
Figura 20. Detalhe da superfície da seção de 100% lesada.	40
Figura 21. Fluxograma dos ensaios no misturador.....	40
Figura 22. Exemplo do janelamento e da criação de imagens de vibração.	41
Figura 23. Exemplos de imagens de vibração do misturador.....	42
Figura 24. Esquema da Bancada MEM.	43
Figura 25 Exemplos de imagens de vibração do sistema MEM.....	44
Figura 26. Arquitetura da Rede Neural Convolucional.	44
Figura 27. Exemplo de <i>Stride 2x2</i>	45
Figura 28. Curva de treinamento - a) Tr ; b) $1/2 Tr$ e c) $1/4 Tr$	48
Figura 29. Curva de treinamento do modelo Multiclases.	49
Figura 30. Matriz confusão do modelo Multiclases.....	50
Figura 31. Curva de treinamento do modelo binário.....	51

Figura 32. Matriz confusão do modelo binário no sistema MEM.....	51
Figura 33. Curva de treinamento do modelo binário utilizando os dados do sistema MEM. ..	52
Figura 34. Matriz confusão do modelo binário no sistema MEM.....	53

LISTA DE TABELAS

Tabela 1. Modos de falhas e seus subtipos.....	22
Tabela 2. Características Técnicas do Misturador.....	35
Tabela 3. Especificações técnicas do <i>DynaLogger HF+</i>	38
Tabela 4. Configurações de Coleta do <i>Dynallogger HF+</i>	38
Tabela 5. Banco de dados das Imagens.	42
Tabela 6. Configuração de Coletas na Bancada MEM.....	43
Tabela 7. Resultados dos diferentes tamanhos de lotes no treinamento.....	47
Tabela 8. Resultados dos diferentes passos.	48

SUMÁRIO

1 INTRODUÇÃO.....	15
1.1 CONSIDERAÇÕES GERAIS	15
1.2 OBJETIVOS.....	16
1.2.1 Objetivo geral.....	16
1.2.2 Objetivos específicos	16
1.3 ESTRUTURA DO TRABALHO	16
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 ANÁLISE DE VIBRAÇÃO.....	18
2.1.1 Domínio do Tempo	18
2.1.2 Domínio da Frequência	19
2.2 FALHAS EM ROLAMENTO	21
2.3 BAIXA ROTAÇÃO EM ROLAMENTOS.....	23
2.4 ANÁLISE DE DADOS.....	24
2.5 REDES NEURAS ARTIFICIAIS.....	24
2.6 REDE NEURAL CONVULUCIONAL (CNN).....	26
2.6.1 Camada de Convolução.....	27
2.6.2 Camada de Subamostragem	28
2.6.3 Dropout	29
2.6.4 Camada Totalmente Conectada.....	29
2.6.5 Retropropagação do Erro	30
2.6.6 Otimizadores	30
2.7 IMAGEM DE VIBRAÇÃO	31
2.8 MÉTRICAS DE DESEMPENHO.....	32
3 MATERIAIS E MÉTODOS	35
3.1 INFORMAÇÕES DA BANCADA (MISTURADOR MT120).....	35
3.2 BANCO DE DADOS DOS SINAIS DE VIBRAÇÃO DO MISTURADOR.....	37

3.2.1 Banco de Dados das Imagens de Vibração	40
3.3 BANCADA SISTEMA MOTOR-EIXO-MANCAL (MEM)	42
3.4 ARQUITETURA DO MODELO UTILIZADA	44
3.5 TREINAMENTO E CLASSIFICAÇÃO	45
3.6 CONFIGURAÇÕES DA MÁQUINA E FERRAMENTAS DE PROGRAMAÇÃO	46
4 RESULTADO E DISCUSSÕES	47
4.1 MODELO DE DIAGNÓSTICO DE FALHA MULTICLASSES	49
4.2 MODELO DE DIAGNÓSTICO BINÁRIO DE BAIXA ROTAÇÃO	51
5 Conclusão.....	54
5.1 SUGESTÕES PARA TRABALHOS FUTUROS	55
REFERÊNCIAS	56

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES GERAIS

Os rolamentos de baixa rotação são elementos de máquinas rotativas que exercem papel fundamental no meio industrial, em especial, em maquinário pesado. Segundo Hemmer *et al.* (2018) estes elementos são amplamente utilizados em máquinas tais como de perfuração offshore, geração de energia eólicas, guindastes e fabricas de papel. Logo, um defeito nesses rolamentos podem resultar em falhas catastróficas causando paradas não planejadas e impedindo a continuidade da cadeia produtiva, assim provocando impactos significativos no sistema como um todo. Portanto, o seu monitoramento e o diagnóstico da condição desses ativos tornam-se de suma importância.

De acordo com Stamboliska *et al.* (2015) o monitoramento de maquinário de baixa velocidade, com uma rotação de eixo inferior a 10 Hz é mais desafiador, uma vez que a energia associada a falha é menor, assim resultando em uma baixa relação do sinal em comparação aos ruídos gerados pelo próprio equipamento, com isso mascarando o sinal de interesse. Diante disso, são necessários sensores mais sensíveis e o desenvolvimento de métodos avançados de processamento de sinais para extrair assinatura de falha. A utilização de técnicas de aprendizagem de máquina, como o *Machine Learning* e *Deep Learnig*, são ferramentas poderosas para o monitoramento e diagnóstico de falha em equipamentos de baixa rotação.

No contexto de aprendizagem de máquina, as técnicas empregadas, desde as redes neurais artificiais até as redes neurais convolucionais, no campo de aprendizado profundo, oferecem a oportunidade de integrar a crescente disponibilidade de dados, adquiridos por meio de processos físicos de coleta dos comportamentos mecânicos e vibratórios dos equipamentos, com um modelo robusto de detecção de padrões (VIANA, 2023). Isso viabiliza a previsão de futuras situações vibratórias, a identificação iminente de falhas e outras características benéficas para as indústrias e seus profissionais de engenharia e gestão.

O emprego de redes neurais convolucionais para monitorar a saúde de máquinas foi examinado por Hoang e Kang (2019), os quais propõem diagnosticar falhas em rolamentos de alta rotação utilizando o sinal de vibração bruto, sem extrair parâmetros dos dados, por meio da técnica de imagens de vibração. Nesse método, o sinal é organizado em sequências de intervalos de tempo, nos quais a amplitude de vibração de cada passo temporal é inserida de forma sequencial em uma matriz, que é então plotada em um formato de intensidade de pixel.

Este estudo tem como objetivo utilizar uma técnica de aprendizado de máquina baseado em redes neurais convolucionais para o diagnóstico de falhas em rolamentos de baixa rotação,

usufruindo do método de converter o sinal de vibração em imagens de vibração, utilizando resposta de vibração originada de um misturador do modelo MT120 e avaliar seu desempenho e eficácia.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Desenvolver sistema de diagnóstico inteligente de falhas em rolamento de baixa rotação utilizando técnicas de aprendizado de máquina, baseado em redes neurais convolucionais e em métodos de análise de vibração por imagem.

1.2.2 Objetivos específicos

Os objetivos específicos são:

- Realizar metodologia para a implementação de defeitos de diferentes graus de severidade no rolamento;
- Criar um banco de dados de falhas em rolamento de baixa rotação com multiclases, diferentes níveis de falha e de carga;
- Implementar técnica de aprendizado profundo baseado em Redes Neurais Convolucionais (CNN), para o sistema de diagnóstico de falha em baixa rotação;
- Avaliar as variáveis passo e o tamanho de lotes, para determinar os melhores parâmetros da rede.

1.3 ESTRUTURA DO TRABALHO

Este trabalho é dividido nas seguintes seções: fundamentação teórica, materiais e métodos, resultado e discussões e conclusão.

A seção de fundamentação teórica aborda a estrutura básica do rolamento de esfera e a dificuldade de identificar falhas nesse ativo em baixa rotação. Além disso, essa seção tratar dos conceitos básicos de uma rede neural convolucional e suas camadas.

Na seção de materiais e métodos é mostrado as bancadas que foram usadas, as instrumentações e parâmetros utilizados para as coletas de dados de vibração das bancadas. Ademais, mostra a estrutura da rede utilizada nesse trabalho e como foi tratado os sinais de vibração.

Por fim, na seção de resultado e discussões, são analisados os parâmetros que apresentaram o melhor desempenho e os resultados de acurácia obtidos pela rede proposta neste trabalho. Os principais pontos são discutidos detalhadamente, enquanto as conclusões finais são apresentadas na última seção.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 ANÁLISE DE VIBRAÇÃO

De acordo com Rao (2008), qualquer movimento que se repita após um determinado intervalo de tempo pode ser considerado uma vibração. Um exemplo simplificado de sistema vibratório é uma massa suspensa e conectada a uma mola fixada a um ponto de referência, que se move de sua posição inicial para um limite superior e inferior, retornando em seguida à posição inicial.

A análise de vibrações como uma técnica de manutenção preditiva fundamenta-se no sinal de vibração coletado de uma máquina em funcionamento, que carrega a assinatura dos esforços dinâmicos dos diversos componentes que compõem o equipamento e avaliá-lo. O processo de análise de sinais vibratórios envolve sua representação em formas matemáticas ou estatísticas e a utilização de gráficos para visualização (DIAS, 2021). Os métodos de análise podem ser subdivididos em: análise no domínio do tempo e análise no domínio da frequência.

2.1.1 Domínio do Tempo

A análise mais comum no domínio do tempo ocorre por meio de indicadores estatísticos de condição ou índices quantitativos. Esses índices permitem calcular valores globais quantitativos e são fundamentais para entender como os dados de vibração estão distribuídos. Considerando uma vibração com uma série temporal, no qual consiste em uma sequência de valores numéricos discretos em função do tempo, dado a série representada como, x_i ($i = 1, 2, 3, \dots, N$), sendo que N é a quantidade de elementos de x_i , podemos extrair alguns indicadores, tais como:

- **Raiz Média Quadrada (RMS – Root Mens Square):** Trata-se da raiz quadrada da média dos quadrados de todos os elementos do sinal. Dessa forma, essa média pode proporcionar uma noção da energia global do sinal.

$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

- **Valor de Pico:** Corresponde ao elemento de maior magnitude em termos de valores absolutos.

$$x_{pico} = \max|x_i| \quad (2)$$

- **Fator de Crista:** Trata-se da razão entre o valor de pico e o valor RMS. Essa medida, de acordo com Caesarendra (2015), trata-se de medida de impactos, apropriada para sinais com características de picos consecutivos.

$$x_{FC} = \frac{x_{pico}}{x_{RMS}} \quad (3)$$

- **Curtose:** Segundo Caesarendra (2015), a curtose é uma medida que indica o grau de achatamento da função densidade de probabilidade em relação ao seu centro.

$$x_{curtose} = \frac{\frac{1}{N} \Sigma(x_i - x)^4}{\left[\frac{1}{N} \Sigma(x_i - x)^2 \right]^2} \quad (4)$$

2.1.2 Domínio da Frequência

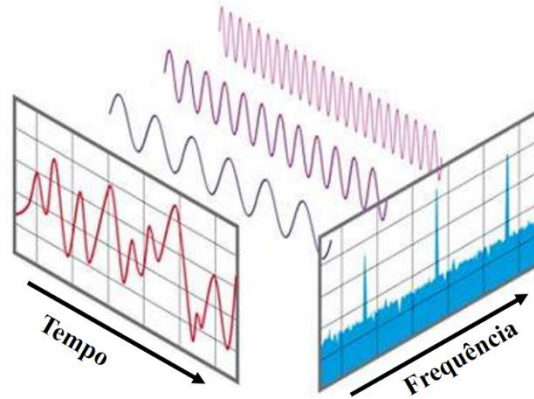
Esta análise utiliza o sinal no domínio da frequência ou espectro de frequência, representado por um gráfico que mostra a amplitude da resposta às vibrações em função da frequência. Esse tipo de análise pode fornecer diversas informações sobre a condição do equipamento, já que cada componente rotativo gera uma frequência característica. O espectro de frequência é obtido por meio de técnicas de processamento que realizam transformações entre dois espaços de definição. A técnica mais comum para realizar esse processamento é a Transformada Rápida de Fourier (Fast Fourier Transform - FFT).

A técnica conhecida como Transformada Rápida de Fourier (FFT) possibilita a análise de um sinal ao decompor suas diferentes frequências individuais. Esse método é valioso para entender a estrutura de um sinal e para extrair informações relevantes. A FFT é uma ferramenta poderosa que permite a conversão eficiente de sinais discretos do domínio do tempo para o domínio da frequência (SOUZA, 2023). Assim, dado um sinal $f(t)$ no domínio do tempo, sua transformada de Fourier (FTT) pode ser expressa da seguinte forma:

$$F(\omega) = F(f(t)) = \int_{-\infty}^{+\infty} f(t)e^{-j\omega t} dt \quad (5)$$


Sendo $f(t)$ uma função que representa o sinal no domínio do tempo, j unidade imaginária e ω a frequência angular. Nas figuras a seguir segue um exemplo de como ocorre esse processo:

Figura 1. Passagem do sinal no domínio do tempo para o da frequência.




Fonte: Adaptado de Dias (2021).

Figura 2. Sinal de vibração.



Fonte: Plataforma *DynaPredict* (2024).

Figura 3. Espectro de Frequência.




Fonte: Plataforma *DynaPredict* (2024).

2.2 FALHAS EM ROLAMENTO

O rolamento é um componente fundamental em todos os tipos de máquinas rotativas. Segundo Hemmer (2020), as principais funcionalidade de um rolamento consiste em restringir os graus de liberdade, transferir carga e reduzir o atrito das partes móveis em um sistema mecânico. Um rolamento de esfera genérico é composto por quatro partes principais: pista externa, gaiola, pista interna e elemento rolante. Na Figura 4 é mostrado um exemplo de rolamento de esfera, sendo φ ângulo de contato e d o diâmetro do elemento rolante.

Figura 4. Diagrama de rolamento de esferas: 1) Pista externa, 2) Gaiola, 3) Pista interna 4) Elemento rolante,



Fonte: Adaptado de Hemmer (2020).

Conforme Xu *et. al* (2023), a transferência de carga ocorre de uma pista para outra por meio dos elementos rolantes. Esses elementos são mantidos separados de maneira uniforme por uma estrutura chamada gaiola, que não desempenha o papel de suporte de carga. Assim, para reduzir ainda mais o atrito e o desgaste, é aplicado um lubrificante que forma um filme elastohidrodinâmico entre as partes móveis, evitando assim o contato direto entre metal-metal. As cargas aplicadas no rolamento podem ser categorizadas em direções radial e axial. A classificação do rolamento como radial ou axial depende da direção principal da carga aplicada. Na prática, muitos tipos de rolamentos são capazes de suportar cargas combinadas.

Mesmo quando sujeito a cargas externas estáticas, o estresse interno do material se torna cíclico devido à transferência de carga através dos elementos rolantes em movimento. Perante a condições operacionais nominais, esse carregamento cíclico pode resultar em rachaduras por

fadiga no material, levando eventualmente ao desprendimento de partículas das superfícies de contato. Além da fadiga, a falha pode ter uma ampla gama de outras causas-raiz. Na Tabela 1 lista os principais modos de falhas e seus subtipos, conforme definido na ISO-15243. Além dos modos de falhas, a norma aborda características de falha, terminologias e causas principais da falha.


Tabela 1. Modos de falhas e seus subtipos.

Modo de Falha	Subtipo
Fadiga	Fadiga iniciada na superfície
	Fadiga iniciada internamente
Desgaste	Desgaste abrasivo
	Desgaste adesivo
Corrosão	Corrosão por umidade
	Corrosão por atrito
Erosão Elétrica	Voltagem excessiva
	Vazamento de corrente
Deformação Plástica	Deformação por sobrecarga
	Endentação por partículas
Fratura e Rachadura	Fratura forçada
	Fratura por fadiga
	Rachadura térmica

Fonte: Adaptado ISO-15243 (2017).

Este trabalho tem como foco o desgaste abrasivo na pista externa em rolamentos de esferas. É considerado desgaste abrasivo, como a remoção de material de uma superfície infligida por outro corpo de maior dureza. Esse tipo de falha pode ocorrer em rolamentos devido à contaminação por partículas externas, detritos de desgastes existente do próprio rolamento e a lubrificação insuficiente agravam o problema. Hemmer (2020) simula esse tipo de defeito utilizando papéis lixa para aço com diferentes granulometrias. Na Figura 5 é exibido a superfície de elementos rolantes de um rolamento axial do modelo 29230 M, no qual foram lixadas em diferentes granulometrias de lixas.

Figura 5. Elemento rolante lixado em diferentes graus.



Fonte: Adaptado de Hemmer (2020)

2.3 BAIXA ROTAÇÃO EM ROLAMENTOS

De acordo com Hecke *et. al* (2016), os rolamentos de baixa rotação desempenham um papel crucial em uma variedade de indústrias, onde máquinas operam em velocidades relativamente baixas, como usinas siderúrgicas, fábricas de papel, aplicações biológicas e turbinas eólicas. Nessas configurações, é fundamental garantir o monitoramento eficaz dos rolamentos, eixos e engrenagens para manter o equipamento funcionando de forma eficiente e confiável.

É considerado baixa rotação equipamentos cujo seu eixo de operação rotacione abaixo dos 10 Hz (600 rpm) (KIM *et. al*, 2008; STAMBOLISKA, 2015; HECKE *et. al*, 2016). Entretanto, não há uma definição unificada de baixa rotação. Rolamentos que operam em baixa rotação são de especial interesse, uma vez que possuem desafios adicionais para que possa ser realizado o monitoramento de falhas desse ativo. Isso está ligado ao fato que a relação sinal-ruído, que é a proporção entre a energia associada ao sinal da falha de interesse e o ruído de fundo, ser baixa. Em baixa rotação, há menos energia cinética associada ao sistema, assim os impactos decorrentes de falhas têm menos energia e por consequência gerando menores amplitudes. O ruído de fundo independente da velocidade, pode mascarar o sinal de interesse (STAMBOLISKA, 2015).

2.4 ANÁLISE DE DADOS

A classificação é um método de análise de dados que identifica padrões para descrever categorias significativas de dados (HAN; KAMBER; PEI, 2011). Cada modelo ou algoritmo de classificação tem como objetivo atribuir rótulos a dados específicos. Pesquisadores têm proposto uma variedade de métodos de classificação nas áreas de aprendizado de máquina, reconhecimento de padrões e estatística. No contexto do aprendizado de máquina, diferentes técnicas são empregadas para desenvolver modelos que classificam dados, incluindo redes neurais convolucionais, Naive Bayes, máquinas de vetores de suporte (SVM) e k-vizinhos mais próximos (kNN) (JIAO, 2020).

O reconhecimento de padrões desempenha um papel significativo na ciência de dados e análise de dados, sendo uma ferramenta fundamental. Ele analisa e categoriza os dados com base em suas características estatísticas ou em conhecimentos derivados de suas representações. Atualmente, esse tipo de reconhecimento é amplamente aplicado em diversas áreas, incluindo reconhecimento biométrico, identificação facial, processamento de imagens, processamento de áudio, entre outras aplicações (ROCHA, 2020).

A aprendizagem profunda, sendo uma das áreas mais promissoras em aprendizado de máquina, tem experimentado um crescimento notável em diversas áreas, isso se deve não apenas a fatores subjetivos, como avançadas capacidades de processamento de dados e aprendizado de característica, bem como a arquitetura inovadora, mas também a diversos fatores externos que não podem ser ignorados, como o aumento exponencial dos grandes bancos de dados industriais, avanços de hardware e as variadas demandas competitivas que são estimuladas (JIAO, 2020). Conseqüentemente, a aprendizagem profunda também tem impulsionado o desenvolvimento de sistemas de diagnóstico de falhas. Os modelos de diagnóstico baseados em aprendizado profundo incluem Autoencoder profundo (*Deep Autoencoder*), rede neural recorrente (*Recurrent Neural Network*), rede de crenças profundas (*Deep Belief Network*) e rede neural convolucional (*Convolutional Neural Network*) (JIA et. al, 2016; GAN et. al, 2016; ZHAO et. al, 2017; ZHANG et. al, 2020)

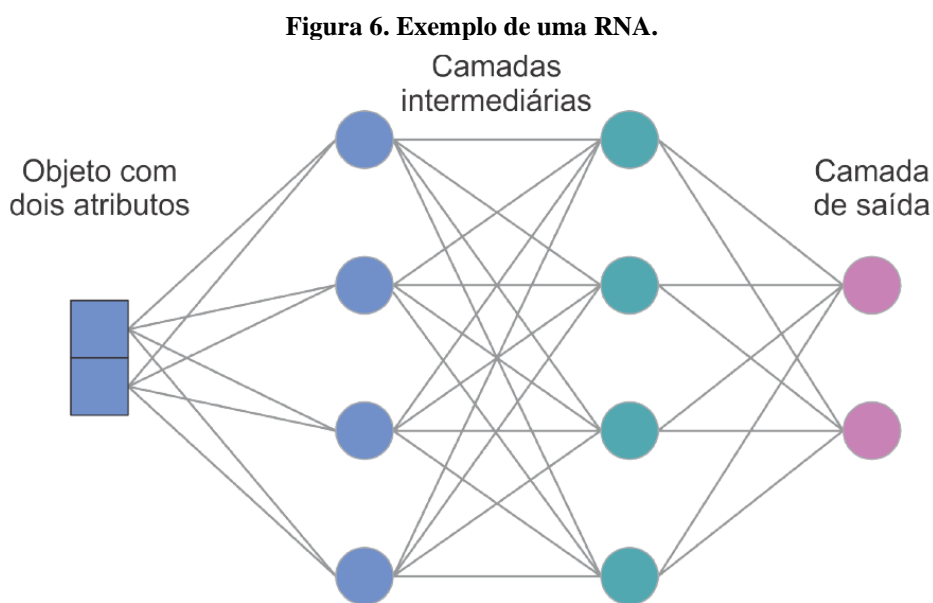
2.5 REDES NEURAIAS ARTIFICIAIS

Conforme Janiesch *et al.* (2021), as Redes Neurais Artificiais (RNA) representam uma abordagem de aprendizado de máquina que utiliza a comunicação de dados por meio de camadas, nas quais as camadas intermediárias são referidas como camadas ocultas. O aprendizado profundo é caracterizado pelo uso de redes neurais com múltiplas camadas ocultas.

Inspiradas no funcionamento biológico do sistema nervoso, as RNAs operam como neurônios interconectados, cuja comunicação, conhecida como sinapse, é estabelecida por meio de algoritmos não-lineares que mapeiam e extraem as características essenciais dos dados de entrada (BASU *et al.*, 2010). Essa abordagem busca simular a capacidade de aprendizado do cérebro humano, sendo que o sistema nervoso, composto por uma rede complexa de células. (FACELI *et al.*, 2011).

Os neurônios, basicamente, são compostos pelo corpo celular, além de dois tipos de ramificações: os axônios e os dendritos. Os dendritos desempenham o papel de captar os estímulos nervosos vindos de outros neurônios ou do ambiente. Esses estímulos são então conduzidos até o corpo celular, onde são reunidos e processados. Dependendo da força do estímulo, o corpo celular pode gerar um novo impulso nervoso, que é encaminhado ao axônio, uma extensão dos neurônios responsável pela transmissão dos impulsos para outros neurônios. A sinapse ocorre no ponto de contato entre a extremidade de um axônio e o dendrito de outro neurônio (CAMPOS, 2023).

Uma RNA com dois atributos de entrada, duas camadas intermediárias (camadas ocultas) e duas camadas de saídas é mostrada na Figura 6. Analogamente ao funcionamento de um neurônio biológico, a função dos dendritos de receber informações é representada pela entrada da rede. Esses dados são então processados por meio de funções de ativação e, em seguida, transmitidos para as camadas subsequentes da rede. À medida que o processamento avança de uma camada intermediária para a próxima, a complexidade do processo aumenta. A função global da RNA é determinada pela combinação das individuais de cada neurônio presente na rede



Fonte: CAMPOS (2023).

Para ajustar os pesos de entrada da RNA, é comum aplicar a técnica do algoritmo de retropropagação (*backpropagation*) (RUMELHART; HINTON & WILLIAMS, 1986). Nesse processo, cada neurônio na primeira camada recebe o objeto de entrada e passa pela função de ativação. O valor resultante é então usado como entrada para os neurônios na camada seguinte, e assim por diante, até que a camada de saída produza seu valor de saída.

Posteriormente, esse valor de saída é comparado com o valor desejado para a saída correspondente. A diferença entre esses valores gera o erro da rede em relação à classe específica. Esse erro é então utilizado na fase de retropropagação, na qual ocorre um ajuste dos pesos de entrada. Esse ajuste é realizado da camada de saída até a primeira camada intermediária, visando minimizar o erro da rede.

2.6 REDE NEURAL CONVULUCIONAL (CNN)

A aprendizagem profunda (*Deep Learning*), como já dito remete a uma rede neural com inúmeras camadas ocultas. De acordo com Bengio (2009), as redes neurais tradicionais contêm apenas 2 ou 3 camadas ocultas, enquanto as redes profundas podem conter várias.

Nos últimos anos, houve um aumento significativo na importância atribuída ao conceito de aprendizado profundo. De acordo com Viana (2023), com o rápido crescimento na disponibilidade de dados e no desenvolvimento de *hardware* capaz de suportar o treinamento de estruturas massivas, as redes neurais possibilitaram lidar diretamente com os dados brutos do problema, eliminando a necessidade de pré-processamento ou extração de atributos dos padrões de entrada. Para isso, esses modelos constroem uma hierarquia de representações, permitindo a aprendizagem de aspectos mais complexos das relações entre os dados a partir de características mais simples.

Conforme Jiao (2020), dentre os modelos de aprendizado profundo, a rede neural convolucional (CNN), como um modelo de aprendizado profundo, tornou-se uma técnica de referência e alcançou desempenho de ponta em várias tarefas de visão computacional e reconhecimento de padrões. Da mesma forma, as abordagens de diagnóstico de falhas usando rede convolucional também têm se desenvolvido e estudos estão sendo desenvolvidos nesse ramo.

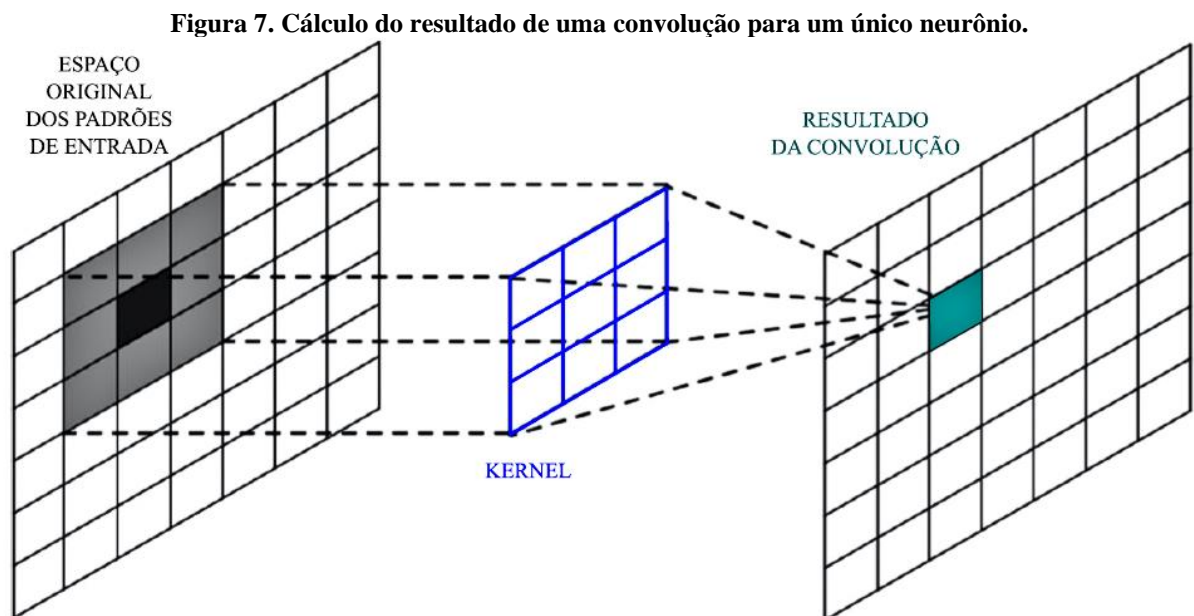
Uma CNN é uma rede com inúmeras camadas ocultas cuja a função é desenvolvida para o reconhecimento ou classificação de dados bidimensionais, além disso esse tipo de rede possui alto grau de invariância à translação, escala, inclinações e outros tipos de distorção. (HAYKIN, 2009). De modo mais específico, CNNs são redes que utilizam a operação linear convoluções

em uma das suas camadas. Uma camada convolucional possui a seguinte funcionalidade: dada uma matriz com dados de entrada, faz-se a convolução desta por matrizes de menor ordem (*kernels*). A CNN pode possuir diversas camadas, as camadas utilizadas no presente trabalho são explicadas nos tópicos a seguir:

2.6.1 Camada de Convolução

Uma importante camada de uma CNN é a camada de convolução. Essa camada é responsável por realizar a operação linear denominada por convolução. Essa operação é realizada por meio de *kernels*. O *kernel* é uma matriz de parâmetros, comumente chamados de pesos, ajustáveis pelo algoritmo de aprendizado, que percorre todo padrão de entrada. Assim é extraído as características relevantes dos dados de entrada a cada posição do filtro, tendo a resposta do neurônio e criando os mapas de características (*features maps*) (ROCHA, 2020).

A Figura 7 mostra um exemplo do cálculo de resultado da convolução para um único neurônio.



Fonte: Viana (2023)

Definindo a operação de convolução $S(m, n)$ (Gonzalez e Woods, 2009), pela equação 6. O dado de entrada é representado como uma função espacial I , onde os índices (i, j) indicam a localização e I representa a intensidade, onde passa pela operação de convolução K que é o *kernel* que é uma matriz de parâmetros ajustáveis pelo algoritmo de aprendizado. A saída da operação S é dada por unidades que são organizadas em planos (ROCHA, 2020).


$$S(m, n) = \sum_i \sum_j I(i, j) K(m - i, n - j) \quad (6)$$

Após a operação de convolução, é comum utilizar uma função de ativação não linear, como a função sigmoide, a função tangente hiperbólica (tanh) e a unidade linear retificada (ReLU) (NAIR & HINTON, 2010). Comparado às funções sigmoide e tanh, a ReLU é mais amplamente utilizada em CNNs, pois aumenta a velocidade de treinamento da rede neural, devido a simplicidade que sua derivada possui. A função ReLU é dada pela equação (7) e sua derivada pela equação (8). sendo que x é a entrada e $f(x)$ é a saída da função de ativação. O seu gráfico pode ser mostrado na Figura 8.

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (7)$$

$$\frac{df(x)}{dx} = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (8)$$

Figura 8. Função de ativação não linear ReLU.
ReLU




Fonte: Rocha (2020)

2.6.2 Camada de Subamostragem

A camada de subamostragem (*subsampling*) ou *pooling* é uma etapa crucial no processo de convolução em CNN's. Seu principal objetivo é reduzir a dimensionalidade das características de entrada, tornando-as mais gerenciáveis e econômicas computacionalmente, enquanto mantém as características mais importantes (JARRET *et. al*, 2009). Há dois tipos de *pooling* que são mais comumente usados, sendo o *max-pooling* e o *average pooling*. No

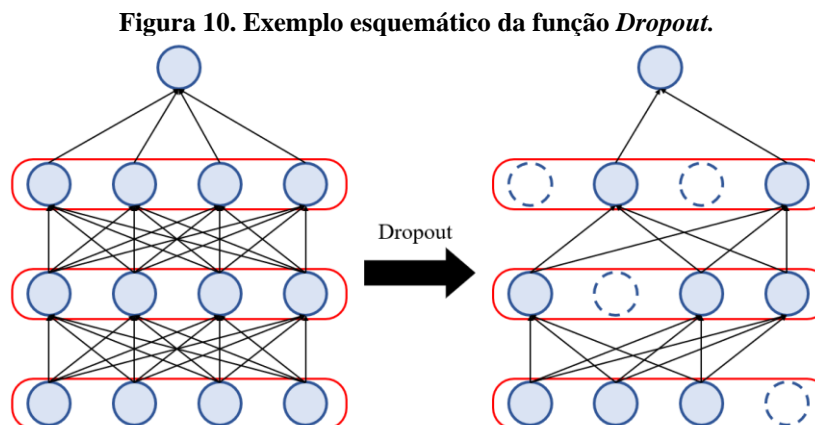
primeiro tipo, calcula-se o valor máximo para cada região de *pooling* e no segundo calcula-se o valor médio, um exemplo de uma operação de *max-pooling* é mostrado na Figura 9:



Fonte: Adaptado de Filipe (2023)

2.6.3 Dropout

O *dropout* é uma técnica que ajuda a evitar o *overfitting*, que ocorre quando a rede se ajusta muito bem aos dados de treinamento, mas não generaliza bem para novos dados. A técnica de *dropout* consiste em desativar aleatoriamente neurônios durante o treinamento da rede. Isso ajuda a evitar que a rede se torne muito dependente de neurônios específicos e, portanto, a generalizar melhor para novos dados. Durante o treinamento, cada neurônio é desativado com uma probabilidade pré-definida. Essa é uma técnica eficaz de regularização que ajuda a melhorar o desempenho da rede (JIAO, 2020). Na Figura 10 é apresentado um esquema desta operação.



Fonte: Autoria própria (2024)

2.6.4 Camada Totalmente Conectada

Essa camada desempenha um papel crucial no processamento das características extraídas pelas camadas anteriores e na geração da saída final da rede. Os neurônios nessa camada estão conectados a todos os neurônios da camada anterior e geralmente são seguidos

por uma camada de saída que produz a previsão final da rede. As características extraídas pelas camadas anteriores e são transformadas em um vetor unidimensional antes de serem inseridas na camada totalmente conectada.

Essa camada é seguida por uma função de classificação, comumente a *softmax* $\sigma(y_i)$ que é representada na Equação 9, esta função representa a distribuição de probabilidades sobre as J diferentes possibilidades de classe de saída y_i , desse modo limitando as saídas da rede entre os valores de 0 e 1, no qual o somatório dos valores de saída após o *softmax* é igual a 1 (ROCHA, 2020).

$$\sigma(y_i) = \frac{e^{y_i}}{\sum_{j=1}^J e^{y_j}} \quad (9)$$

2.6.5 Retropropagação do Erro

As principais abordagens de métodos de aprendizado em redes neurais baseiam-se no cálculo da chamada função custo. No qual, busca-se identificar o conjunto de pesos que minimize a medida de erro escolhida. Para tal, é fundamental realizar o processo de cálculo do gradiente da função de custo (VIANA, 2023). Conforme Haykin (2009) o processo de calcular o erro e sua derivada da camada de saída até as camadas anteriores é denominado de retropropagação do erro (*erro backpropagation*).

A função custo do modelo proposto nesse trabalho foi a entropia cruzada (*cross-entropy*), no qual é calculado a diferença entre duas distribuições de probabilidade nos desafios de classificação. Representado a distribuição com rótulo verdadeiro de $p(x)$ e a distribuição estimada como $q(x)$. A entropia cruzada entre $p(x)$ e $q(x)$ é definida pela Equação 10:

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (10)$$

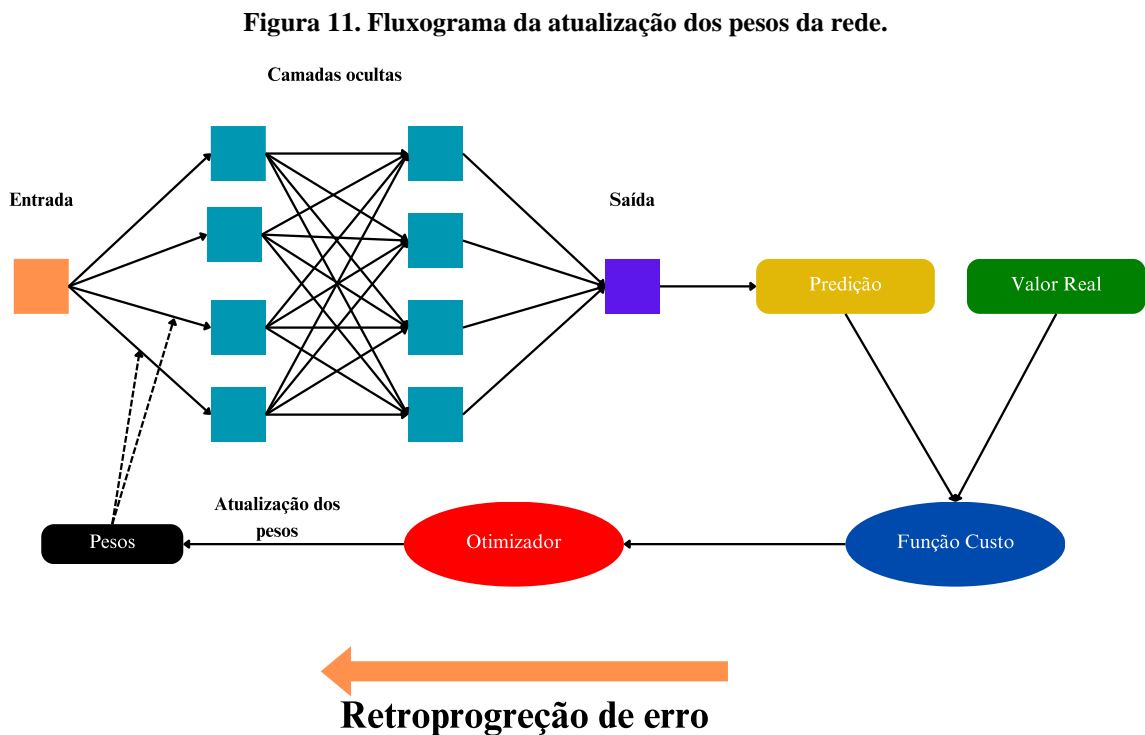
2.6.6 Otimizadores

Um aspecto crítico do treinamento da CNN é a escolha e implementação de algoritmos de otimização adequados, que permitem a atualização dos parâmetros da rede de forma a minimizar a função de perda escolhida. No entanto, o processo de otimização não é trivial e pode ser influenciado por diversos fatores, como a natureza dos dados, a arquitetura da rede e a escolha dos parâmetros (JIAO, 2020).

Conforme Ruder (2016), os métodos tradicionais de otimização, como a *Batch Gradient Descent* (BGD), a *Stochastic Gradient Descent* (SGD) e a *Mini-batch Gradient Descent*

(MBGD), têm sido amplamente utilizados, mas apresentam limitações em termos de eficiência e estabilidade. Por exemplo, o BGD calcula o gradiente usando todos os dados de treinamento, o que pode ser computacionalmente custoso, enquanto o SGD utiliza apenas uma amostra por vez, resultando em atualizações rápidas, porém sujeitas a oscilações na função objetivo.

O Adam (*Adaptive Moment Estimation*) é um otimizador amplamente utilizado em redes neurais, por sua eficiência e robustez (Kinga & Adam 2015). Ele calcula médias móveis exponenciais dos gradientes e dos gradientes quadrados, permitindo ajustes dinâmicos na taxa de aprendizado para cada parâmetro. Isso resulta em uma convergência mais rápida e robusta, adequada para problemas de grande escala e com gradientes ruidosos. Com sua eficiência computacional e adaptabilidade, o Adam tem demonstrado eficácia em diversas tarefas de aprendizado profundo (Hoang & Kang, 2019). Devido a essas características, Adam foi o otimizador escolhido na rede proposta neste trabalho. Na Figura 11 é mostrado um fluxograma de como é realizada a atualização dos pesos da rede.

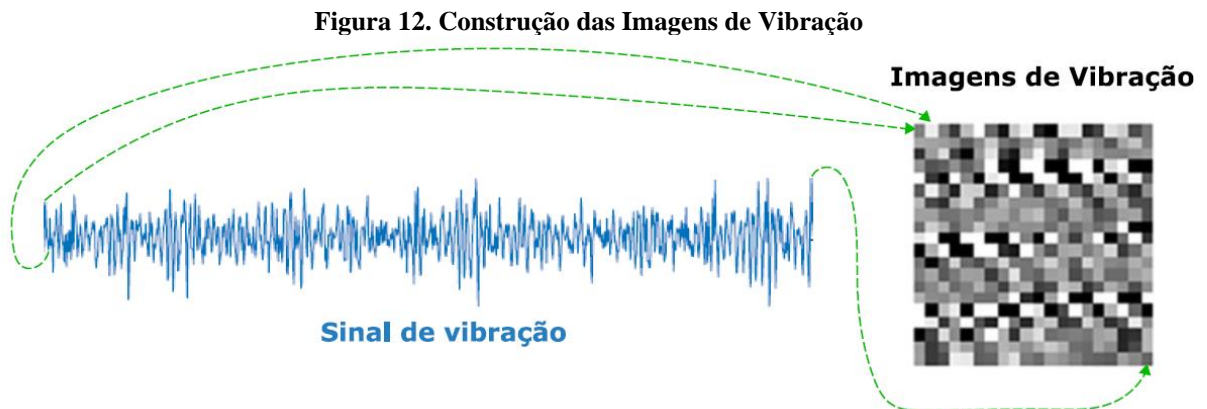


Fonte: Autoria própria (2024)

2.7 IMAGEM DE VIBRAÇÃO

De acordo com Viana (2023) a técnica conhecida como Imagem de Vibração (*Vibration Images*) visa converter um sinal de vibração unidimensional em uma série de imagens bidimensionais, permitindo a utilização de classificadores de imagens, como as CNN's, para monitorar a condição de vibração de uma máquina rotativa.

Na Figura 12 é representado o procedimento de construção das imagens de vibração, a partir de um sinal genérico de vibração unidimensional. Cada ponto do sinal completo é normalizado no intervalo de $[-1,1]$, antes de ser atribuído a um pixel com intensidade correspondente a aquela amplitude, em escala de cinza (KANG & HOANG, 2019). Assim, todo sinal é convertido em imagens bidimensionais à medida que cada ponto de amplitude é processado.



Fonte: Viana (2023).

A Equação 11 descreve o cálculo para converter a amplitude normalizada no pixel correspondente (NGUYEN *et al.*, 2013). Isso resulta em uma imagem de vibração com dimensões $M \times N$, sendo que $i=1:N$; $j=1:M$; $P[i, j]$ representa a intensidade do pixel (i, j) e $A[.]$ a amplitude normalizada do sinal de vibração:

$$P(i, j) = A[(i - 1) * M + j] \quad (11)$$

Segundo Viana (2023), essa técnica traz diversas vantagens para a implementação de um modelo de classificação CNN. Sendo uma delas a simplicidade da transformação direta além de reduzir o custo computacional no armazenamento do novo banco de dados. Outra vantagem, se dar ao modelo ganhar em velocidade de processamento e também na acurácia da classificação, uma vez que os dados de entrada se tornam mais consistentes em comparação com os gráficos originais do sinal de vibração, no qual são mais desafiadores para uma rede neural devido à de escalas variáveis, valores atípicos e formas altamente diversas.

2.8 MÉTRICAS DE DESEMPENHO

Em análise de desempenho de classificadores é muito comum a utilização da matriz de confusão (LOBÃO, 2020). Essa uma ferramenta é crucial para avaliar o desempenho de modelos de classificação em aprendizado de máquina. Ela fornece uma representação detalhada

das previsões feitas pelo modelo em relação às classes reais dos dados. A matriz é uma tabela bidimensional onde as linhas representam as classes verdadeiras e as colunas representam as classes previstas pelo modelo. Cada célula da matriz contém o número de instâncias que foram corretamente ou incorretamente classificadas.

A Figura 13 é apresentado a matriz de confusão para o caso de classificação de duas classes, a classe positiva e classe negativa:

Figura 13. Matriz de Confusão no caso de duas classes.

	Predição Positiva	Predição Negativa
Classe Positiva	VP	FN
Classe Negativa	FP	VN

Fonte: Autoria própria (2024).

- **VP (Verdadeiro Positivo):** São o número de classes positivas corretamente classificadas como positiva.
- **VN (Verdadeiro Negativo):** São o número de classes negativas corretamente classificadas como negativa.
- **FP (Falso Positivo):** São o número de classes negativas incorretamente classificadas como positiva.
- **FN (Falso Negativo):** São o número de classes positivas incorretamente classificadas como negativa.

A partir da matriz de confusão, outras medidas de desempenhos podem ser retiradas, neste trabalho é utilizada a acurácia, dada pela equação (12). Ela representa a proporção de predições realizadas corretamente pelo modelo em relação ao número total de elementos da matriz.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (12)$$

Além da acurácia a outras métricas tais como:

- **Precisão:** é a proporção de exemplos positivos previstos corretamente em relação ao total de exemplos positivos previstos pelo modelo.

$$Precisão = \frac{VP}{VP + FP} \quad (13)$$

- *Recall*: é a proporção de exemplos positivos previstos corretamente em relação ao total de exemplos positivos no conjunto de dados

$$Recall = \frac{VP}{VP + FN} \quad (14)$$

- *F1-score*: é a média harmônica ponderada da precisão e do *recall*.

$$F1 = \frac{2 * precisão * recall}{precisão + recall} \quad (15)$$

3 MATERIAIS E MÉTODOS

Neste capítulo são apresentados os materiais e metodologias utilizadas para o desenvolvimento do sistema de diagnóstico proposto, baseado em CNN. São apresentados detalhes sobre o equipamento utilizado para realização das coletas de sinais de vibração, condição das coletas, informações sobre o banco de dados e arquitetura utilizadas.

3.1 INFORMAÇÕES DA BANCADA (MISTURADOR MT120)

O Misturador do modelo M120 BETOMAQ está localizado no Laboratório de Fluidodinâmica e Particulados (FuidPar), no campus da Universidade Federal do Pará (UFPA) em Tucuruí (CAMTUC). Este é utilizado para ensaios no qual envolve a preparação de minérios. A Figura 14 é ilustrado o equipamento.

Figura 14. Misturador MT120.



Fonte: BETOMAQ (2024).

Informações das características técnicas da máquina pode ser vista na Tabela 2:

Tabela 2. Características Técnicas do Misturador.

Características Técnicas do Misturador MT120		
Descrição	Valor	Un.
Capacidade	100	L
Potência do Motor	3	hp
Torque Máximo	418,2	N.m
Granulometria Máxima	12	mm

Rotação	50	RPM
Peso	220	kg

Fonte: A autoria própria (2024).

Este equipamento possui um rolamento do modelo 6308 2RS, localizado conforme a Figura 15 (a) e (b), na qual é mostrado seu posicionamento:

Figura 15. Localização do rolamento (a) Vista das disposições das pás de mistura (b) Extração do rolamento.



Fonte: A autoria própria (2024).


Já nas Figuras 16 e 17, é identificado o posicionamento do sensor *DynaLogger HF+* da empresa *Dynamox* em relação ao rolamento e o eixo de acionamento:

Figura 16. Posicionamento do sensor.



Fonte: A autoria própria (2024).

Figura 17. Esquema do posicionamento do sensor, unidades em (mm).



Fonte: Autoria própria (2024).

3.2 BANCO DE DADOS DOS SINAIS DE VIBRAÇÃO DO MISTURADOR

O sensor utilizado para realizar a coleta das respostas de vibração da máquina foi o *DynaLogger HF+*, Figura 18, da empresa *Dynamox*®, no qual é parceira desse trabalho. O *DynaLogger HF+* é um dispositivo de sensoriamento MEMS que registram temperatura e vibração triaxial, em três eixos, instalados de forma fixa nos equipamentos. O sensor coleta dados conforme sua frequência de amostragem, no qual pode ser ajustável, e podem ser fixados à carcaça do equipamento por meio de cola ou parafuso. Neste trabalho o sensor foi colado diretamente na luneta do equipamento. Os dados são armazenados internamente até que sejam enviados para a Plataforma Web na nuvem por um coletor externo, como um aplicativo celular ou gateway. Isso permite o monitoramento remoto dos ativos, eliminando a necessidade de deslocamento para coleta no campo e fornecendo ao analista acesso a informações constantemente atualizadas, economizando tempo. As especificações técnicas desse sensor estão disponíveis na Tabela 3.

Figura 18. Sensor *DynaLogger HF+*.



Fonte: Site DYNAMOX (2024).

Tabela 3. Especificações técnicas do DynaLogger HF+.

Informações Gerais	
Modelo	HF+
Dimensão	39 mm x 39 mm x 35mm
Peso	67g
Material	LEXAN™
Fixação	Parafuso ou colado
Memória	51.200 amostras
Bluetooth	BLE 53 / 2.400 - 2.483,5 MHz
Tensão	3 V
Autonomia	3 a 5 anos
Alcance	100 m
Comunicação com App	Android e iOS
Temperatura	
Temperatura	$-20^{\circ}\text{C} \leq T \leq 84^{\circ}\text{C}$
Resolução de temperatura	0,01°C
Vibração	
Acelerômetro	MEMS triaxial
Bandas de frequência	2 Hz a 13 kHz (configurável)
Resposta em frequência (± 3 dB)	7,6 kHz
Faixa de amplitude	Até ± 16 g
Taxa de amostragem	Até 26 kHz
Linhas de Resolução (LOR)	98 304 (uniaxial) e 32 768 (triaxial)
Frequência Máxima	571 Hz a 13 kHz (configurável)

Fonte: Autoria própria (2024).

O sensor foi configurado apenas para realizar coletas uniaxial na direção radial em relação ao rolamento. As configurações do *setup* do sensor utilizadas nos ensaios podem ser vistas na Tabela 4:

Tabela 4. Configurações de Coleta do Dynallogger HF+

Configurações de Coleta (DynaLogger HF+)		
Descrição	Valor	Un.
Tempo de Coleta (T_s)	14,96	s
Faixa de Frequência (Máx.)	6.572	Hz
Frequência de Amostragem	13.145	Hz
Nº Pontos (N)	196.608	ad


Fonte: Autoria própria (2024).

Os experimentos consistiram em principalmente avaliar os rolamentos sem e com defeito, variando o nível de carga do misturador. Com isso, foram utilizadas 3 condições de cargas: sem carga e com 40% e 80% da capacidade total do misturador, conforme informação

da Tabela 2. A falha no rolamento foi artificialmente introduzida na pista externa do rolamento. Com o objetivo de introduzir danos iniciais, optou-se por simular arranhão ou riscos na superfície. Esse tipo de dano está associado a má lubrificação do filme lubrificante entre os componentes do rolamento, onde inicialmente são identificados tais arranhaduras. Gerar essa simulação de defeito inicial no rolamento é importante pois, associada a operação do equipamento sob altas cargas, esse desgaste pode evoluir para condições de falhas mais severas, tais como o superaquecimento, trincas, fraturas, entre outras.


Com isso, adotou-se algumas sessões de lixamento utilizando lixas para metais com granulometria ISO/FEPA P60. Ademais, foram utilizados 3 graus de severidade do problema neste trabalho: o primeiro grau consistiu em lixar 25% área da pista externa do rolamento, para o segundo grau lixou 50% da seção e por fim 100% da pista externa. O processo das seções de lixamento da superfície seguiu padrões similares, com intuito de manter uma certa uniformidade das seções lesadas. Assim, foram retiradas fotografias da pista externa de duas seções diferentes da superfície onde-se realizaram esse processo, sendo que na região de 25%, Figura 19 (a) e (b), são exibidas características semelhantes de riscos e arranhões aos observados na região de 100%, Figura 20 (a) e (b).

Figura 19. Detalhe da superfície da seção de 25% lesada.



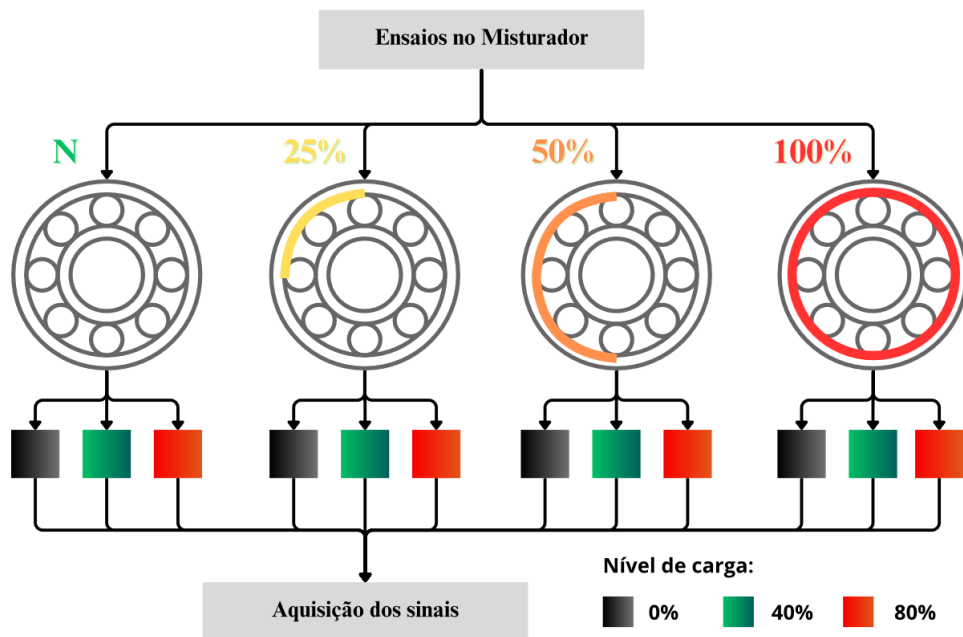
Fonte: Autoria própria (2024).

Figura 20. Detalhe da superfície da seção de 100% lesada.



Fonte: Autoria própria (2024).

Figura 21. Fluxograma dos ensaios no misturador.



Fonte: Autoria própria (2024).

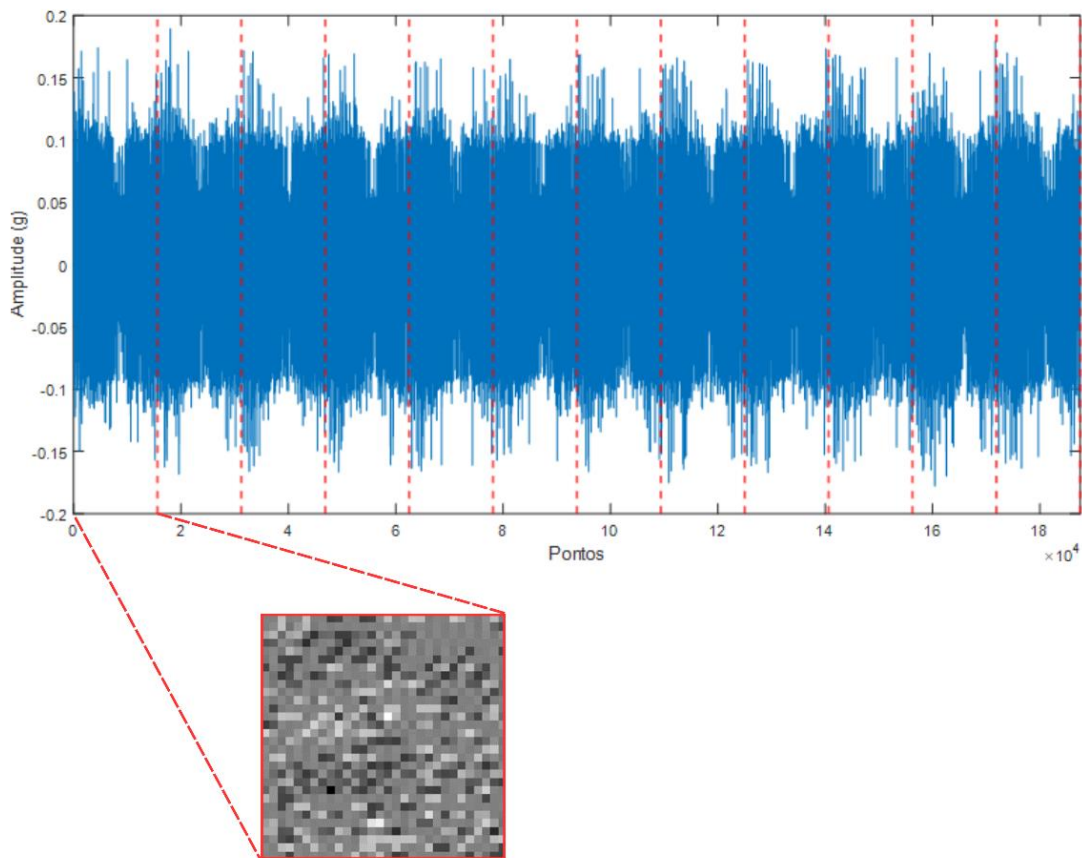
Com isso, foram realizadas 20 coletas de sinais de vibração utilizando as configurações anteriormente descritas na Tabela 4, para cada uma das 12 condições de ensaios, conforme previsto na Figura 21.

3.2.1 Banco de Dados das Imagens de Vibração

De acordo com a Tabela 4, os resultados na aquisição dos sinais é uma série de $T_s = 14,96$ s e tamanho $N = 196.608$ pontos. Com isso o período de aquisição equivale a 12

revoluções completas do rolamento, uma vez que o misturador rotaciona a uma velocidade em torno de 50 rpm. A partir disso, optou-se por realizar janelamento do sinal no qual o tamanho dessa janela equivale a uma revolução completa (T_r) do eixo, para assim realizar as imagens de vibração explicados na Seção 2.5 deste trabalho. Para as imagens de vibração, foi escolhido uma matriz de tamanho 125 x 125 onde vai conter 15625 pontos que irão ser convertidos em pixels. Este processo é exemplificado em um sinal sendo convertido para imagem de vibração na Figura 22:

Figura 22. Exemplo do janelamento e da criação de imagens de vibração.



Fonte: Autoria própria (2024).

Além disso, foi avaliado a utilização de um passo. O passo consiste no quanto a janela se desloca para a criação das imagens. O passo da janela da Figura 22 equivale a um período T_r , além desse foi utilizado dois passos diferentes, um de $\frac{1}{4}$ (um quarto) de T_r e outro de $\frac{1}{2}$ (um meio) de T_r . Informações do banco de dados das imagens de vibração dos diferentes passos pode ser encontrada na Tabela 5.

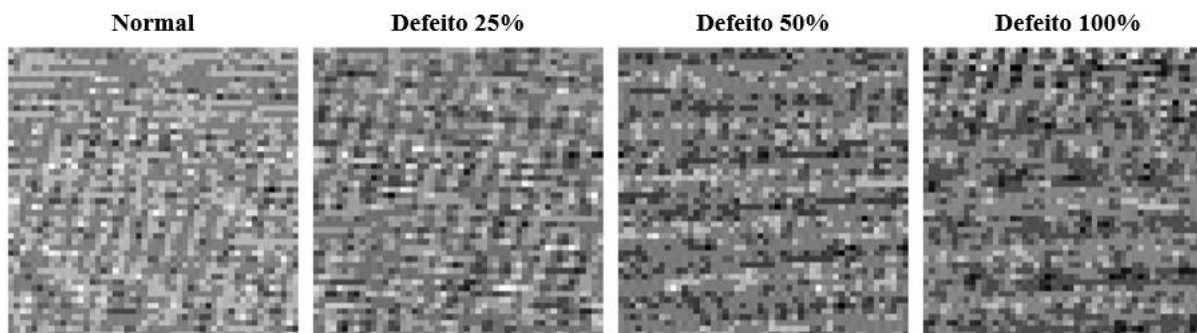
Tabela 5. Banco de dados das Imagens.

Imagens de Vibração Passo (T_r)	
Condição	Nº de Imagem
Normal	720
Defeito 25%	720
Defeito 50%	720
Defeito 100%	720
Imagens de Vibração Passo ($1/2 T_r$)	
Condição	Nº de Imagem
Normal	1440
Defeito 25%	1440
Defeito 50%	1440
Defeito 100%	1440
Imagens de Vibração Passo ($1/4 T_r$)	
Condição	Nº de Imagem
Normal	2880
Defeito 25%	2880
Defeito 50%	2880
Defeito 100%	2880

Fonte: Autoria própria (2024).

Na figura 23 é observado exemplos de imagens de vibrações de cada uma das classes.

Figura 23. Exemplos de imagens de vibração do misturador.



Fonte: Autoria própria (2024).


3.3 BANCADA SISTEMA MOTOR-EIXO-MANCAL (MEM)

A bancada mostrada na Figura 24 é constituída por um sistema mecânico rotativo de natureza relativamente simples. Essa bancada se localiza no Laboratório de Vibrações e Acústica da Faculdade de Engenharia Mecânica na cidade de Tucuruí, no estado do Pará. Esse sistema é composto essencialmente por um motor elétrico trifásico AC de indução de 2 pares de polos, com uma potência de 3 hp, no qual está conectado a um inversor de frequência WEG

CFW08. Este motor está acoplado a um eixo que é sustentado por um mancal de rolamento do tipo 6202z.

Com relação aos ensaios e aquisição das respostas de vibração, foram adquiridas informações dos dados de vibração de apenas duas classes, sendo elas a condição do rolamento com defeito e sem defeito, a uma velocidade de rotação de 60 rpm, formando um sistema binário de classes. Em relação ao defeito, trata-se de uma falha incipiente que foi simulada em um ponto específico da pista externa do rolamento. Foram coletadas 125 respostas de vibração para cada uma das condições do rolamento, resultando em um total de 250 coletas. Por fim, a Figura 24 evidencia a posição de fixação de um acelerômetro, de sensibilidade 101 mV/g, ligado ao sistema de aquisição de dados modelo NK820 da marca TEKNIKAO, na posição vertical sobre o mancal.

Figura 24. Esquema da Bancada MEM.



Fonte: Autoria própria (2024).

Os parâmetros de aquisição configurados para coletas dos sinais são mostrados na Tabela 6:

Tabela 6. Configuração de Coletas na Bancada MEM

Configurações de Coleta (TEKNIKAO)


Descrição	Valor	Un.
Rotação	60	rpm
Faixa de Frequência	0,1 - 5000	Hz
Frequência de Amostragem	12.500	Hz
Período de Aquisição	1,3106	s

Fonte: Autoria própria (2024).

Com relação as imagens de vibração obtidas das medições nessa bancada, como a configuração do analisador foi setada para um período de 1,3 s, o que equivale a um pouco mais que uma volta completa, não houve o processo de janelamento do sinal. Logo, cada observação equivale a uma imagem de vibração, isso resulta em 125 imagens de vibração na condição de

rolamento normal e 125 imagens de vibração na condição com defeito. Na Figura 25 é mostrado exemplos das imagens de vibração dessa bancada.

Figura 25 Exemplos de imagens de vibração do sistema MEM
Normal Defeito




Fonte: Autoria própria (2024).

3.4 ARQUITETURA DO MODELO UTILIZADA

Os experimentos para a categorização das imagens de vibração utilizando redes neurais convolucionais são conduzidas com arquitetura ilustrada na Figura 26. Essa arquitetura é composta por 8 camadas. São duas camadas visíveis, que consistem na entrada e saída da estrutura. A entrada é composta por imagens de vibração com dimensões de 125 x 125 e a camada de saída possui a função *softmax*, a qual mostra a distribuição de probabilidades (Equação 4) da imagem em pertencer a uma das classes.

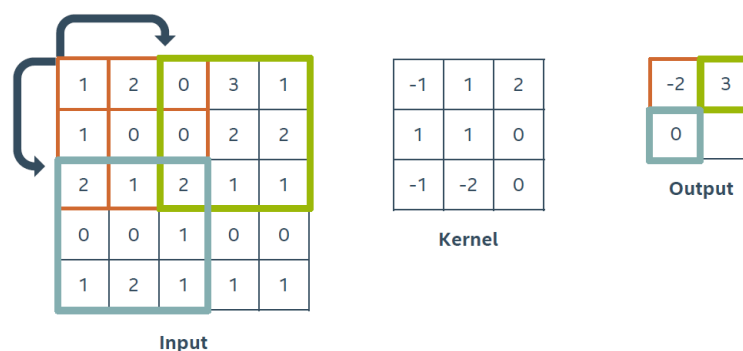
Figura 26. Arquitetura da Rede Neural Convolucional.



Fonte: Autoria própria (2024).

Além disso, o sistema possui duas camadas convolucionais, seguidas por camadas de subamostragens que utiliza o *max-pooling*, uma camada de *dropout* e uma camada totalmente conectada com 128 neurônios. A primeira camada convolucional possui 32 *kernels* de tamanho 5x5 e *stride* 2x2. O *stride* equivale ao tamanho do salto que o *kernel* realiza enquanto passa pela imagem. Na Figura 27 é exemplificado esse processo. Logo após tem uma camada de *max-pooling* com *kernel* 2x2 e *stride* 2x2.

Figura 27. Exemplo de *Stride* 2x2.



Fonte: Adaptado de Filipe (2023)

A segunda camada convolucional possui 64 *kernels* de tamanho 3x3 e *stride* 2x2 e segue com uma camada de subamostragem também a *max-pooling* com *kernel* 2x2 e *stride* 2x2. Em seguida há uma camada de *dropout* onde vai desligar 30% dos neurônios. Conforme Hoang e Kang (2019), uma estrutura com mais camadas não garante um melhor desempenho na classificação, e uma estrutura muito superficial limita a capacidade do modelo em aprender características complexas dos dados. Dessa forma, foi selecionada essa estrutura do modelo de rede, seguindo a mesma estrutura de Hoang e Kang (2019).

Das camadas da rede, três delas possui a função de ativação ReLU (Equação 7), sendo as duas convolucionais e a totalmente conectada. Foi escolhida esta função de ativação por motivos ser simples e demandar pouco poder computacional, assim aumentando a velocidade de aprendizagem do modelo.

3.5 TREINAMENTO E CLASSIFICAÇÃO

No processo de treinamento do modelo, foi utilizado o algoritmo de aprendizagem de retropropagação de erro cujo a função custo é a entropia cruzada com otimizador “Adam”. Durante o processo de aprendizagem, os parâmetros dos neurônios são atualizados com base de um tamanho determinado de lote. O lote é a divisão do conjunto de dados de treinamento. Essa abordagem possui vantagens, tais como: eficiência dos recursos computacionais, melhor

estabilidade durante o treinamento e capacidade de treinar modelos com grandes números de dados.

O tamanho do lote é um hiperparâmetro ajustável, no qual foi avaliado 5 diferentes configurações (8, 16, 32, 64 e 128). A rede é treinada em 15 épocas, sendo uma única época definida como a passagem completa de todo o conjunto dados destinados ao treinamento.

O conjunto de dados foi dividido em duas partes, sendo uma destinada para o treinamento e outra para validação. Os dados de treinamento são utilizados para ajustar os parâmetros da rede, enquanto os dados de validação são exclusivos para avaliar o desempenho do modelo sem alterar os parâmetros de treinamento. Foi utilizado uma relação 70% do conjunto total para treinamento e 30% pra validação.

3.6 CONFIGURAÇÕES DA MÁQUINA E FERRAMENTAS DE PROGRAMAÇÃO

Os Testes foram conduzidos em uma máquina com sistema operacional Windows 11 64 bits, processador *Intel Core i5* com 1,6 – 2,0 GHz, memória RAM de 8 GB com velocidade de 2400 MHz.

A linguagem de programação utilizada foi a Python (versão 3.10). Para a computação científica empregou-se a biblioteca Numpy (versão 1.26.2). Os gráficos foram criados com a biblioteca Matplotlib (versão 3.5.2). No que diz respeito ao aprendizado de máquina, Scikit-learn (versão 1.3.2) foi utilizado para funcionalidades mais gerais, enquanto para o aprendizado profundo com CNNs, empregou-se o Keras (versão 2.15.0). Para o treinamento de modelos de aprendizado de máquina em nível mais baixo, foi utilizado o TensorFlow (versão 2.15.0).

4 RESULTADO E DISCUSSÕES

Primeiramente, foi analisado o hiperparâmetro tamanho do lote e sua influência no aprendizado do modelo de diagnóstico. Assim, como já dito anteriormente, foram estudados 5 tamanhos diferentes de lotes para os dados destinados ao treinamento, sendo eles: 8, 16, 32, 64 e 128. Com isso, analisou-se 3 diferentes métricas: a acurácia do treinamento, a acurácia dos dados de validação, denominada de validação da acurácia, e o tempo de treinamento que o modelo utilizou para treinar. Foi utilizado como entrada do modelo as imagens de vibração com passo igual a T_r com 4 classes diferentes: Normal, Defeito 25%, Defeito 50% e Defeito 100%. Cada classe possui 720 imagens, como mostrado anteriormente na Tabela 5. Nota-se que o modelo foi classificado apenas na condição do rolamento e não pelo nível de carga que o equipamento se encontra, ou seja, para cada condição de rolamento engloba os 3 níveis de carga para o qual o rolamento foi ensaiado conforme é mostrado no fluxograma da Figura 21. Os resultados dos diferentes tamanhos de lotes são mostrados na Tabela 7:

Tabela 7. Resultados dos diferentes tamanhos de lotes no treinamento.

Resultados			
Lote	Acurácia (%)	Val. Da Acurácia (%)	Tempo
8	97,97	94,44	11m31s
16	98,07	96,41	7m43s
32	99,65	96,53	6m07s
64	97,77	95,25	5m25s
128	90,97	89,47	4m56s

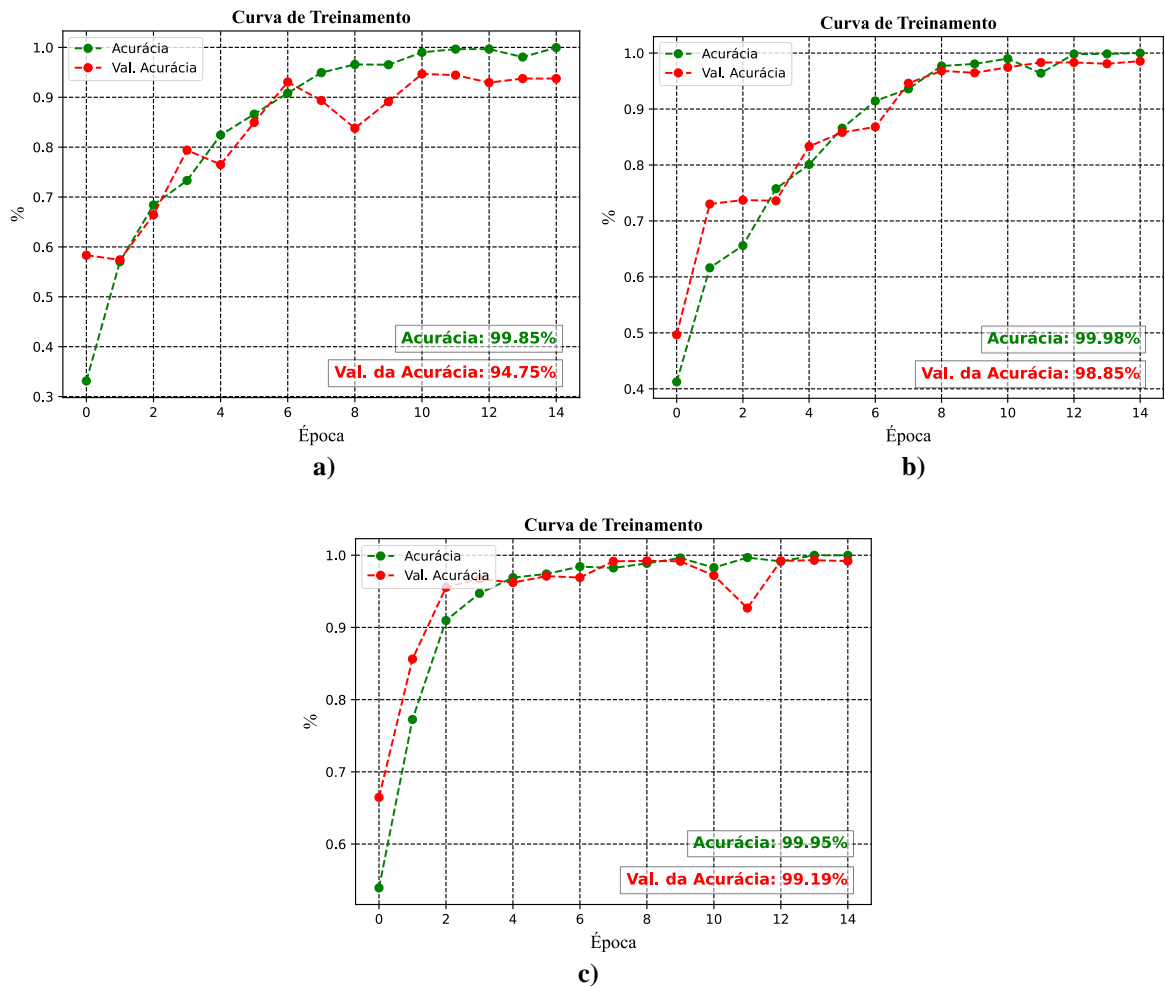
Fonte: Autoria própria (2024).

Diante dos resultados da Tabela 7, o tamanho de lote que apresentou melhor desempenho, tanto em relação à acurácia quanto à validação da acurácia, foi o de tamanho 32, respectivamente com 99,65 % e 96,53. Já em relação ao tempo de treinamento, o maior lote (128) foi o que apresentou o menor tempo de treinamento, com 4 minutos e 56 segundos, porém seu desempenho em relação as outras métricas foi a pior diante dos outros parâmetros estudados. Com isso, escolheu-se o tamanho de lote igual a 32, pois foi o que apresentou melhores resultados na acurácia e na validação da acurácia, além de apresentar uma diferença considerada aceitável no tempo de treinamento quando comparado com o menor tempo, sendo de 71 segundos.

Em uma segunda análise do experimento, avaliou-se o passo das janelas do sinal utilizadas para realizar a imagem de vibração. Dessa forma, usando passos menores como $\frac{1}{4}$ (um quarto) de T_r e $\frac{1}{2}$ (um meio) de T_r , ocorre o aumento do número de imagens, conforme

mostrado na Tabela 5. Com isso, foi analisado a eficiência da mesma forma que anteriormente, empregando a acurácia, validação da acurácia e o tempo gasto no treinamento. Ademais, para uma análise da evolução do treinamento durante as épocas, empregou-se dos recursos de gráficos. Nas Figuras 28 a), b) e c) são apresentadas as curvas de treinamento dos diferentes passos onde no eixo horizontal apresenta os números de épocas iniciada a primeira época com o valo 0 e a última com o valor 14 totalizando 15 épocas e no vertical apresenta a acurácia em determinada época, além disso os resultados são resumidos na Tabela 8.

Figura 28. Curva de treinamento - a) T_r ; b) $1/2 T_r$ e c) $1/4 T_r$.



Fonte: Autoria própria (2024).

Tabela 8. Resultados dos diferentes passos.

Resultados			
Passo	Acurácia (%)	Val. Da Acurácia (%)	Tempo
T_r	99,85	94,75	5m57s
$1/2 T_r$	99,98	98,85	11m38s
$1/4 T_r$	99,95	99,19	23m54s


Fonte: Autoria própria (2024).

Realizando uma análise gráfica, nota-se que o modelo da Figura 28 c) ultrapassou os 99% de acurácia utilizando menos épocas em comparação aos outros modelos que utilizam passos maiores, mostrando um melhor desempenho, sendo que esse resultado é esperado por possuir mais dados para treinar por época. No entanto, quando se observa o final do treinamento após 15 épocas, os 3 passos atingem bons resultados, acima dos 99%, tendo valores bem próximos. O passo que apresentou a melhor acurácia foi o de $1/2 T_r$, com 99,98%, já a métrica de validação da acurácia foi o de $1/4 T_r$, com 99,19%, e o que possui o menor tempo foi o passo equivalente a T_r , com 5 minutos e 57 segundos, contudo em relação as outras métricas foi o que apresentou os piores resultados. Com isso, foi selecionado para o modelo de diagnóstico o passo igual a $1/2 T_r$ uma vez que apresentou bons resultados de acurácia e validação da acurácia, além disso levou menos da metade do tempo do modelo utilizando passo de $1/4 T_r$.

4.1 MODELO DE DIAGNÓSTICO DE FALHA MULTICLASSES

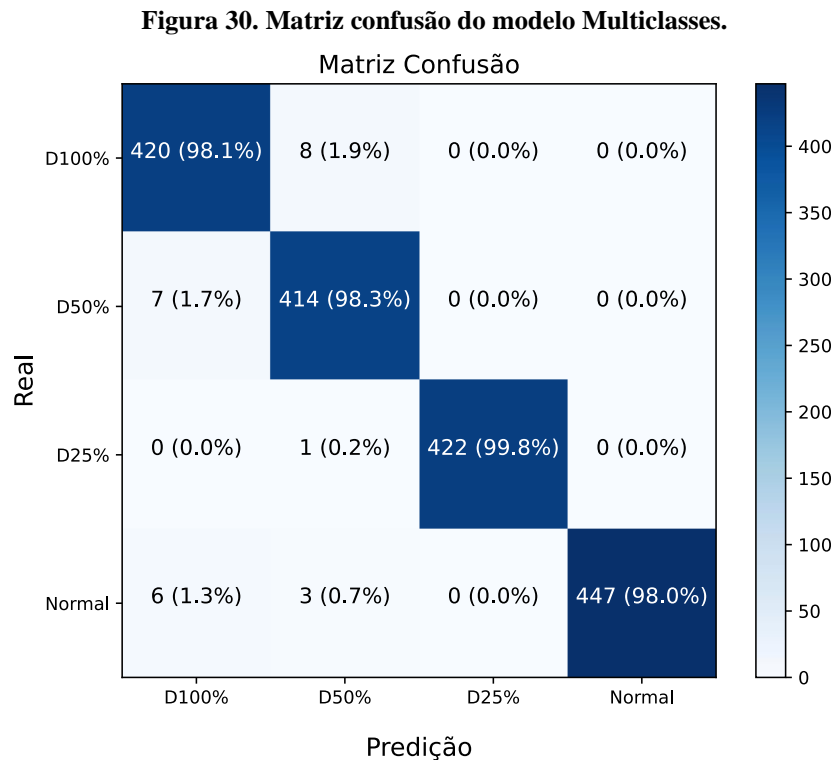
Para o modelo de diagnóstico multiclases foi utilizado o banco de imagens com o passo $1/2 T_r$, usando as 4 classes, sendo elas: Defeito 100% (D100%), Defeito 50% (D50%), Defeito 25% (D25%) e Normal. Foi empregado o tamanho de lote igual 32. Com isso, observa-se os seguintes resultados da curva de treinamento do modelo de diagnóstico apresentado na Figura 29.

Figura 29. Curva de treinamento do modelo Multiclases.



Fonte: Autoria própria (2024).

O modelo de diagnóstico de falha multiclases apresentou acurácia de 99,97% e validação da acurácia de 98,95%, conforme mostrado na Figura 29. Além disso, usou-se a matriz confusão para visualizar quais classes o modelo tem mais dificuldade ou facilidade de diagnosticar. A matriz de confusão desse modelo dos dados destinados a teste é apresentada na Figura 30.



Fonte: Autoria própria (2024).


Conforme a matriz confusão, as imagens utilizadas para a validação foram previstas da seguinte forma: as imagens da classe defeito 100% (D100%) foram acertados 98,1% na predição do modelo, sendo os 1,9% classificados como defeito 50% (D50%). Já a classe de D50% o algoritmo obteve sucesso de prever em 98,3% das imagens, sendo os outros 1,7% classificados como D100%. Ademais, a classe de defeito 25% (D25%) foi a que obteve melhores resultados com 99,8% dos dados foram classificados corretamente, onde os outros 0,2% classificados como D50%. Por fim, a classe Normal foi a que a rede obteve o pior desempenho com 98,0%, tendo errado com 0,7% na classe de D50% e 1,3% na classe de D100%. Com isso, é evidente que o algoritmo conseguiu distinguir bem os diferentes níveis de severidade no rolamento do misturador, além disso vale notar através da matriz de confusão que não houve nenhuma classificação de D100%, D50% e D25% como condição Normal,

sendo essa observação muito importante do ponto de vista da manutenção, evitando-se equívocos de indicativos de "falso normal" no diagnóstico.

4.2 MODELO DE DIAGNÓSTICO BINÁRIO DE BAIXA ROTAÇÃO

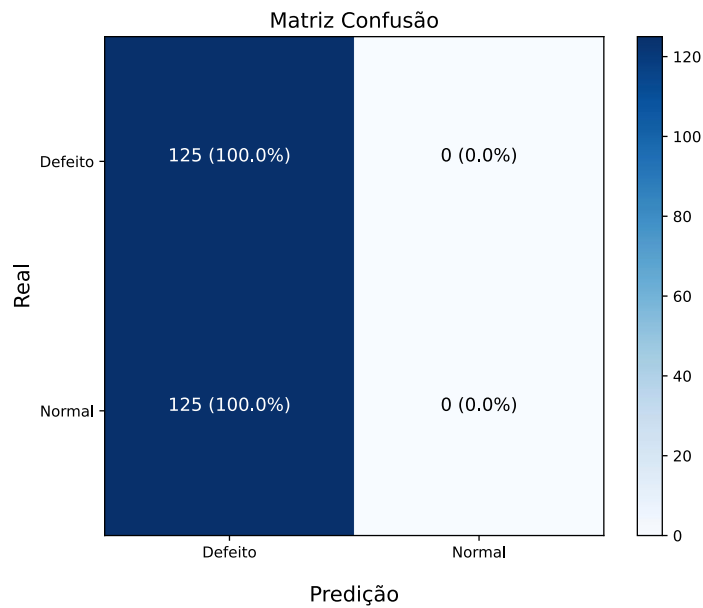
Nesse cenário, foi decidido treinar um modelo de classificação binária para detectar falhas na pista externa do rolamento em baixa rotação, utilizando os dados de coletados no misturador. O treinamento seguiu utilizando os dados das classes Normal e Defeito 25% utilizando o passo $1/2 T_r$. Essas classes foram selecionadas devido a primeira se tratar de uma condição “saudável” do rolamento, enquanto a segunda representa uma falha mais incipiente, com o objetivo de treinar um modelo sensível a estágios iniciais de falha.

Diante disso, o modelo foi treinado utilizando os mesmos parâmetros do modelo multiclasse. A curva de treinamento da rede binária é mostrada na Figura 31.



Na curva de treinamento da Figura 31 é mostrado que a rede obteve tanto a acurácia quanto a validação da acurácia a classificação de 100% dos resultados. Isso está relacionado, ao fato de o modelo possuir menos classes para distinguir, diferente do multiclasse, facilitando o treinamento e classificação. Com isso, foi testado este modelo de classificação utilizando as imagens de vibração da bancada de sistema (MEM). Utilizou-se uma matriz de confusão para avaliar os resultados das predições, que é mostrada na Figura 32.

Figura 32. Matriz confusão do modelo binário no sistema MEM.



Analisando a matriz de confusão na Figura 32, observa-se que o modelo classificou 100% de forma correta das imagens na condição de defeito, porém errou 100% das imagens classificadas com normal. Assim, o algoritmo de classificação treinado com dados do misturador não teve um desempenho esperado para dados utilizando as imagens de vibração da bancada do sistema MEM. Logo, decidiu-se treinar o modelo utilizando os próprios dados da bancada do sistema MEM para avaliar o sistema de diagnóstico. A curva de treinamento e a matriz de confusão são mostradas na Figura 33 e Figura 34, respectivamente.

Figura 33. Curva de treinamento do modelo binário utilizando os dados do sistema MEM.

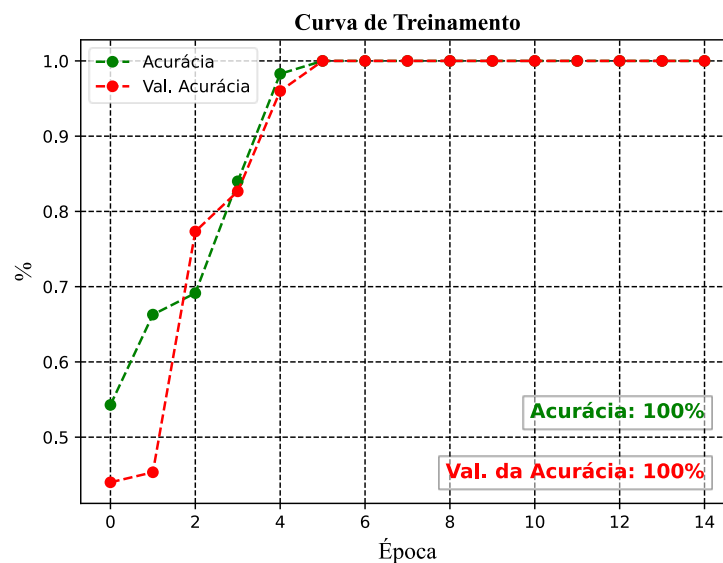



Figura 34. Matriz confusão do modelo binário no sistema MEM

Avaliando a curva de treinamento da rede, obteve-se 100% tanto da acurácia quanto na validação da acurácia. Já na matriz de confusão utilizando o modelo treinado com os próprios dados da bancada MEM, alcançou-se 100% de acerto da distinção das classes. Logo, conclui-se que o modelo deve ser treinado com os dados próprios de cada bancada, não sendo indicado o uso de dados provenientes de equipamentos com características diferentes.

5 CONCLUSÃO

O atual trabalho visou elaborar uma metodologia para diagnosticar defeitos em rolamentos de baixa rotação usando um algoritmo de aprendizado profundo baseado em redes neurais convolucionais (CNN), utilizando dados de vibração do misturador MT120. Com isso, para o modelo de classificação foram implementados diferentes níveis de falha no rolamento do misturador com diferentes condições de carga. Na alimentação da rede foram utilizadas imagens de vibrações na escala de cinza que se originou a partir da resposta de vibrações. Além disso, utilizou-se diferentes tamanhos de lote para determinar o que possui o melhor desempenho no treinamento. Ademais, foi avaliado como a utilização de diferentes passos para a criação das imagens influenciou no treinamento da rede. Ao final, modelos de classificação CNN foram testados e avaliados utilizando os dados de outra bancada experimental.

Inicialmente, foram implementados defeitos considerados abrasivos na pista externa do rolamento de modelo 6308 2RS. O defeito foi simulado utilizando lixa de aço, onde foram lixadas 25% da área da pista externa do rolamento e progredindo para 50% e 100% da área. Além disso, foram utilizados diferentes níveis de carga do misturador, formando assim um banco de dados com diferentes níveis de carga e falha.

Posteriormente, utilizando diferentes tamanhos de lotes para avaliar qual se comportaria melhor no treinamento do modelo de diagnóstico de baixa rotação, dentre os 5 diferentes tamanhos estudados, o melhor resultado foi o que possui o tamanho de 32. Com esse tamanho, obteve-se elevada acurácia de 99,65% e validação da acurácia de 96,53%. Além disso, na etapa de treinamento, obteve-se um bom desempenho com relação ao tempo de treinamento, sendo de 6 minutos e 7 segundos.

Também, considerou-se a utilização de diferentes passos na criação das imagens de vibração utilizando o banco de dados do misturador. Diante disso, foi determinado que o melhor desempenho foi com o passo de $1/2 T_r$, obtendo-se acurácia de 99,98%, validação de acurácia de 98,85% e tempo de treinamento de 11 minutos e 38 segundos. Assim, após determinar os parâmetros ótimos do modelo, foram treinados dois modelos: um multiclasse e outro binário.

Para o modelo de classificação multiclasse, obteve-se excelentes resultados, obtendo uma acurácia de 99,97% e validação da acurácia de 98,95%, concluindo que o algoritmo de aprendizado profundo conseguiu distinguir bem as classes mesmo sobre diferentes níveis de carga. Já o modelo binário alcançou bom desempenho quando o modelo criado foi utilizado para testar dados do próprio misturador, pois foi observado que quando testado em outra bancada a rede não apresentou bons resultados. Nessa ocasião, foi realizado um novo

treinamento utilizando os dados de vibração da nova bancada (MEM), sendo observado que a rede obteve um ótimo desempenho, concluindo-se, então, que não é recomendável a utilização de dados de treinamentos em equipamentos com características diferentes.

Por fim, conclui-se que o objetivo de criar modelo de diagnóstico de falha em rolamento em baixa rotação foi alcançado com a proposta de utilização da metodologia de redes neurais convolucionais, obtendo resultados promissores.

5.1 SUGESTÕES PARA TRABALHOS FUTUROS

Para trabalhos futuros, sugere-se:

- Análise do desempenho do algoritmo proposto aplicado ao diagnóstico de defeitos em outros componentes mecânico;
- Investigar técnicas de pré-processamento de dados, como remoção de ruídos para melhorar a qualidade das informações na entrada da rede neural;
- Realizar validação em ambientes industriais reais para avaliar o desempenho a aplicabilidade do modelo proposto em situações reais.

REFERÊNCIAS

BASU, Jayanta Kumar, BHATTACHARYYA, Debnath, KIM, Tai-hoon. Use of artificial neural network in pattern recognition. **International journal of software engineering and its applications**, v. 4, n. 2, 2010.

BENGIO, Yoshua et al. Learning deep architectures for AI. **Foundations and trends® in Machine Learning**, v. 2, n. 1, p. 1-127, 2009.

CAESARENDRA, Wahyu, **Vibration and acoustic emission-based condition monitoring and prognostic methods for very low speed slew bearing**, Doctor of Philosophy thesis, School of Mechanical, Materials and Mechatronic Engineering, University of Wollongong, 2015. <https://ro.uow.edu.au/theses/4479>.

CAMPOS, Rodrigo Cesar. **Predição de falhas em rolamentos de motores elétricos com a utilização de técnicas de deep learning**. 2023. Dissertação de Mestrado.

DIAS, Matheus Viégas Ferreira Bruno. **Processamento e análise de sinais de vibração para detecção de falhas em rolamentos**. 2021. Trabalho de Conclusão de Curso

FACELI, Katti et al. **Inteligência artificial: uma abordagem de aprendizado de máquina**. 2011.

FILIPE, João Luís Ferreira. **Redes Neurais Convolucionais no Diagnóstico de Falhas em Rolamentos de Motores de Indução**. 2023. Dissertação de Mestrado.

GAN, Meng et al. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings. **Mechanical Systems and Signal Processing**, v. 72, p. 92-104, 2016.

GONZALEZ, R. C., WOODS, R. E., **Digital Image Processing**, Pearson, 3^a ed., 2010.

HAN, J.; KAMBER, M.; PEI, J. **Data mining: concepts and techniques**. 3. ed. 225 Wyman Street, Waltham, MA 02451, USA: Morgan Kaufmann - Elsevier, 2011. ISBN 978-0-12-381479-1.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Upper Saddle River, N.J. 07458: Pearson Prentice Hall, 2009. ISBN 978-0-13-147139-9.

HEMMER M.; WAAG T.I.; ROBBERSMYR K.G. A Review of Methods for Condition Monitoring of Large, Slow-rotating Bearings. Presented at: **30th Conference on Condition Monitoring and Diagnostic Engineering Management**. University of Central Lancashire, Preston, UK, 2018.

HEMMER, Martin et al. Health indicator for low-speed axial bearings using variational autoencoders. **IEEE Access**, v. 8, p. 35842-35852, 2020.

HEMMER, Martin. **Condition Monitoring Methods for Large, Low-speed Bearings**. Doctoral Dissertation for the Degree Philosophiae Doctor (PhD) at the Faculty of Engineering and Science, Specialisation in Mechatronics. University of Agder. 2020.

HOANG, D. T., & KANG, H. J. Rolling element bearing fault diagnosis using convolutional neural network and vibration image. **Cognitive Systems Research**, v. 53, p. 42-50, 2019.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION (ISO). **ISO 15243:2017** - Rolling Bearings -Damage and Failures - Terms, Characteristics and Causes. Second edition, 2017.

JANIESCH, Christian. ZSCHECH, Patrick, HEINRICH, Kai, Machine learning and deep learning, **Electronic Markets**, v. 31, n. 3, p. 685-695, 2021.

JARRETT, Kevin et al. What is the best multi-stage architecture for object recognition?. In: 2009 IEEE 12th international conference on computer vision. **IEEE**, 2009. p. 2146-2153.

JIA, F., LEI, Y., LIN, J., ZHOU, X., & LU, N.. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. **Mechanical Systems and Signal Processing**, 72–73, 303–315, 2016.

JIAO, Jinyang et al. A comprehensive review on convolutional neural network in machine fault diagnosis. **Neurocomputing**, v. 417, p. 36-63, 2020.

KIM, Y. H.; TAN, A. C. C.; KOSSE, Vladis. Condition monitoring of low-speed bearings-a review. **Australian Journal of Mechanical Engineering**, v. 6, n. 1, p. 61-68, 2008.

LOBÃO, Diego Assereuy. **Técnicas de aprendizado de máquinas aplicadas ao diagnóstico de falhas em equipamentos industriais**. 2020. Dissertação de mestrado.

NAIR, Vinod; HINTON, Geoffrey E. Rectified linear units improve restricted boltzmann machines. In: **Proceedings of the 27th international conference on machine learning (ICML-10)**. 2010. p. 807-814.

NGUYEN, Dinh et al. Highly reliable state monitoring system for induction motors using dominant features in a two-dimension vibration signal. **New review of hypermedia and multimedia**, v. 19, n. 3-4, p. 248-258, 2013.

ROCHA, Rafael de Lima. **Redes neurais convolucionais aplicadas à inspeção de componentes do vagão ferroviário**. 2020. Dissertação de Mestrado

RUDER, Sebastian. An overview of gradient descent optimization algorithms. **arXiv preprint arXiv:1609.04747**, 2016.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning Internal Representations by Error Propagation, Parallel Distributed Processing, Explorations in the Microstructure of Cognition, ed. DE Rumelhart and J. McClelland. Vol. 1. 1986. **Biometrika**, v. 71, p. 599-607, 1986.

SOUZA, Elton Prestes. COB-2023-2299. **Convolutional neural networks for pattern-based fault diagnosis in low-rotation equipment**. CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA, 27., 2023, Florianópolis, SC

STAMBOLISKA, Z., RUSIŃSKI, E., & MOCZKO, P.. Proactive condition monitoring of low-speed machines (pp. 53-68). **Springer International Publishing**. 2015.

VAN HECKE, B.; YOON, J.; HE, David. Low speed bearing fault diagnosis using acoustic emission sensors. **Applied Acoustics**, v. 105, p. 35-44, 2016.

VIANA, Carlos Alberto Alves. **Método para detecção e monitoramento de falhas em máquinas rotativas utilizando aprendizado profundo e imagens de vibração**. 2023. Tese de Doutorado.

XU, Funing et al. A review of bearing failure Modes, mechanisms and causes. **Engineering Failure Analysis**, p. 107518, 2023.

ZHANG, Juan et al. Correlation analysis between AK1 mRNA expression and inosine monophosphate deposition in Jingyuan chickens. **Animals**, v. 10, n. 3, p. 439, 2020.

ZHAO, R., WANG, D., YAN, R., MAO, K., SHEN, F., & WANG, J. Machine health monitoring using local feature-based gated recurrent unit networks. **IEEE Transactions on Industrial Electronics**, v. 65, n. 2, p. 1539-1548, 2017.