



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

EGGLESTON PATRICIO DE OLIVEIRA SOUZA

**ANÁLISE COMPARATIVA DE MODELOS DE MACHINE LEARNING E
CONVOLUTIONAL NEURAL NETWORKS NA DETECÇÃO DE FALHAS EM
MÁQUINAS ROTATIVAS**

Caruaru

2024

EGGLESTON PATRICIO DE OLIVEIRA SOUZA

**ANÁLISE COMPARATIVA DE MODELOS DE MACHINE LEARNING E
CONVOLUTIONAL NEURAL NETWORKS NA DETECÇÃO DE FALHAS EM
MÁQUINAS ROTATIVAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia de Produção.

Áreas de Concentração: Otimização e Gestão da Produção.

Orientador: Prof^o Dr. Caio Bezerra Souto Maior

Caruaru

2024

Catálogo na fonte:
Bibliotecária – Nasaré Oliveira CRB/4 - 2309

S729a Souza, Eggleston Patricio de Oliveira.
Análise comparativa de modelos de machine learning e convolutional neural networks na detecção de falhas em máquinas rotativas. /
Eggleston Patricio de Oliveira Souza. – 2024.
53 f.; il.: 30 cm.

Orientador: Caio Bezerra Souto Maior.
Dissertação (Mestrado) – Universidade Federal de Pernambuco, CAA,
Programa de Pós- Graduação em Engenharia de Produção, 2024.
Inclui Referências.

1. Gestão de Saúde - Prognóstico. 2. Aprendizado de máquina. 3. Algoritmos de aprendizagem. 4. Vibração. I. Souto Maior, Caio Bezerra (Orientador). II. Título.

CDD 658.5 (23. ed.)

UFPE (CAA 2024-004)

EGGLESTON PATRICIO DE OLIVEIRA SOUZA

**ANÁLISE COMPARATIVA DE MODELOS DE MACHINE LEARNING E
CONVOLUTIONAL NEURAL NETWORKS NA DETECÇÃO DE FALHAS EM
MÁQUINAS ROTATIVAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de mestre em Engenharia de Produção.

Áreas de Concentração: Otimização e Gestão da Produção.

Aprovada em: 22/02/2024.

BANCA EXAMINADORA

Prof. Dr. Caio Bezerra Souto Maior (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Luciano Carlos de Azevedo Costa (Examinador Interno)
Universidade Federal de Pernambuco

Profa. Dra. Ana Cláudia Souza Vidal de Negreiros (Examinadora Externa)
Universidade Federal Rural do Semi-Árido

Agradeço a Deus,
aos meus pais e ao meu noivo
que estiveram ao meu lado em toda a dissertação

AGRADECIMENTOS

Agradeço a Deus por Sua constante proteção e por conceder-me saúde, iluminação, força, inspiração, sabedoria e tudo mais que necessito para concretizar meus planos. Sua presença é a fonte de minha gratidão e fortalece minha jornada diária.

À minha família querida, que sempre me apoiou na realização dos meus sonhos. Especialmente ao meus pais, José Elenildo e Maria de Fátima, do qual herdei a força e determinação. Ao meu irmão, Elisson Kleber, por sempre torcer por mim. À minha sobrinha, Maria Evellyn, a minha sogra Gilva Ferreira que considero como uma mãe e sempre esteve ao meu lado em todos os momentos e ao meu amor Valdemir Tavares, que esteve sempre ao meu lado dando apoio e incentivo para concluir o mestrado. Agradeço também às minhas primas Bruna Talita e Kamilly, e aos meus amigos (as) Elvis Presley, Ângelo Antônio e os demais que sabem da importância dessa dissertação para minha vida.

Ao meu dedicado orientador, Professor Caio Bezerra Souto Maior, expresso minha profunda gratidão. Foi ele quem me introduziu ao tema, despertando minha inspiração, e me guiou nos momentos desafiadores em que me sentia bloqueado, compartilhando generosamente todo o seu vasto conhecimento.

A todos os meus companheiros de Mestrado, que marcaram a minha vida e trouxeram calorosas discussões e ricas contribuições em prol de um objetivo comum. A todos que trabalham na UFPE - CAA, diretores, coordenadores e técnicos. Agradeço imensamente a todos que me ajudaram no Mestrado e fizeram e fazem parte da realização desse sonho.

RESUMO

Máquinas rotativas possuem uma importância crucial na produção industrial e sua presença é indispensável em diversas indústrias. No entanto, a suscetibilidade dessas máquinas a falhas pode resultar em problemas que variam desde a redução da eficiência até riscos de segurança e interrupção total da produção. O monitoramento contínuo é vital para identificar precocemente sinais de degradação e prevenir falhas graves. Nesse contexto, a manutenção preditiva, fundamentada no monitoramento constante das condições das máquinas, destaca-se como uma abordagem eficaz para otimizar a eficiência operacional e prolongar a vida útil dos equipamentos. Este trabalho aplica diferentes modelos de aprendizado de máquina e aprendizado profundo para o diagnóstico de falhas em máquinas rotativas. Especificamente, a dissertação realiza uma análise comparativa entre modelos de *Convolutional Neural Networks* (CNN), *Support Vector Machine* (SVM), regressão logística, *Multilayer Perceptron* (MLP) e *RandomForest* (RF), considerando a base de dados de vibração para rolamentos da *Case Western Reserve University* (CWRU). Os modelos avaliados apresentaram as seguintes acurácias para falhas em máquinas rotativas: SVM (97%), Regressão Logística (94%), MLP (96%), Random Forest (96%) e CNN (90%). Os resultados destacam a eficácia do modelo com o SVM. A avaliação do desempenho dos modelos de detecção de falhas é útil para o planejamento da manutenção, proporcionando informações sobre a eficácia de cada modelo em reconhecer diversos tipos de falhas em máquinas rotativas.

Palavras-chave: Prognósticos e Gestão de Saúde; aprendizado de máquina; vibração; Rede Neural Convolutiva.

ABSTRACT

Rotating machinery plays a crucial role in industrial production and is essential in various industries. However, the susceptibility of these machines to failures can result in issues ranging from reduced efficiency to safety risks and total production interruption. Continuous monitoring is vital for early detection of degradation signs and prevention of serious failures. In this context, predictive maintenance, based on constant monitoring of machine conditions, stands out as an effective approach to optimizing operational efficiency and extending equipment life. This work applies different machine learning and deep learning models for fault diagnosis in rotating machinery. Specifically, the dissertation conducts a comparative analysis among Convolutional Neural Networks (CNN), Support Vector Machine (SVM), Logistic Regression, Multilayer Perceptron (MLP), and Random Forest (RF) models, considering the vibration dataset for bearings from the Case Western Reserve University (CWRU). The evaluated models showed the following accuracies for faults in rotating machinery: SVM (97%), Logistic Regression (94%), MLP (96%), Random Forest (96%), and CNN (90%). The results highlight the effectiveness of the SVM model. Evaluating the performance of fault detection models is useful for maintenance planning, providing information on the effectiveness of each model in recognizing various types of faults in rotating machinery.

Palavras-chave: Prognostics and Health Management; machine learning; vibration; Convolutional Neural Network.

LISTA DE FIGURAS

Figura 1 - Elementos de um rolamento de elemento rolante.....	16
Figura 2 - Classificações de aprendizado de máquina.....	18
Figura 3 - Conjunto de dados	21
Figura 4 - Classificador Random Forest.....	23
Figura 5 - Rede convolucional com dois estágios	26
Figura 6 - Estrutura essencial CNN 1D.....	27
Figura 7 - Mapa de calor das cocitações no VosViewer	28
Figura 8 - Bancada de teste de rolamento.....	38
Figura 9 - Amostra dos sinais das classes.....	39
Figura 10 - Amostra dos sinais das classes (amostra com recorte de 1000)	41
Figura 11 - Recorte do Código para Treinamento e Teste	41
Figura 12 - Arquitetura do modelo CNN.....	42

LISTA DE TABELAS

Tabela 1 - Comparação entre aprendizado de máquina e aprendizado de máquina profundo.	24
Tabela 2 - Relação entre autores e publicações	30
Tabela 3 - Relações entre autores e publicações	34
Tabela 4 - Simulação de falhas na Bancada de teste CWRU	39
Tabela 5 - Métricas dos modelos SVM, Regressão Logística, MLP, Random Forest	43
Tabela 6 - Matriz de confusão dos modelos SVM, Regressão Logística, MPL e Random Forest	45
Tabela 7 - Métricas do modelo CNN.....	46
Tabela 8 - Matriz de confusão do modelo CNN.....	47

LISTA DE SIGLAS

CNN	Redes Neurais Convolucionais
RNN	Redes Neurais Recorrentes
ML	Aprendizado De Máquinas
LR	Regressão Logística
SVM	Support Vector Machine
CWRU	Case Western Reserve University
MLP	Multilayer Perceptron

SUMÁRIO

1. INTRODUÇÃO	12
1.1 OBJETIVOS	13
1.1.1 Objetivo Geral	13
1.1.2 Objetivos Específicos	13
1.2 ESTRUTURA DA DISSERTAÇÃO	14
2. FUNDAMENTAÇÃO TEÓRICA	15
2.1 MÁQUINAS ROTATIVAS	15
2.2 MANUTENÇÃO PREDITIVA	17
2.3 APRENDIZADO DE MÁQUINAS	17
2.3.1 Aprendizado não supervisionado	19
2.3.2 Aprendizado de reforço	19
2.3.3 Aprendizado supervisionado	19
2.4 APRENDIZADO DE MÁQUINA PROFUNDO PARA CLASSIFICAÇÃO	24
3. REVISÃO DE LITERATURA	28
3.1 ML PARA DIAGNÓSTICO DE FALHAS EM MÁQUINAS ROTATIVAS	28
3.2 CNN PARA O DIAGNÓSTICO DE FALHAS EM MÁQUINAS ROTATIVAS	33
4. METODOLOGIA	37
4.1 CASE WESTERN RESERVE UNIVERSITY BEARINGS DATA CENTER	37
4.2 PREPARACÇÃO PARA OS MODELOS DE ML	40
4.3 PREPARACAO PARA O METODO CNN	42
5. RESULTADOS	43
5.1 COMPARAÇÃO ENTRE OS DE ML	43
5.2 APLICANDO O MODELO CNN	45
6. CONCLUSÃO	49
REFERÊNCIAS	50

1. INTRODUÇÃO

As máquinas rotativas desempenham um papel fundamental em diversas indústrias no mundo, sendo amplamente utilizadas em setores para geração de energia elétrica, produção de alimentos e bebidas, indústria química e petroquímica, mineração e construção civil, entre outros. Essas máquinas são essenciais para a indústria moderna e oferecem benefícios como eficiência energética, confiabilidade, versatilidade e facilidade de manutenção e reparo (Bently et al., 2002).

No entanto, as máquinas rotativas estão sujeitas a falhas causadas por diversos fatores (ex., uso excessivo, problemas elétricos ou hidráulicos) e que podem resultar em problemas, como redução da eficiência, aumento dos custos de manutenção e reparo, maior tempo de inatividade, danos a outras peças da máquina, riscos de segurança para os trabalhadores e, em casos extremos, a interrupção total da produção (Pereira Junior et al., 2023). Assim, é importante o monitoramento da operação das máquinas rotativas para identificação de sinais iniciais de degradação antes que eles se tornem mais sérios (Baran & Trojan, 2013).

O diagnóstico de falhas em máquinas rotativas é uma área importante de pesquisa. Ao monitorar em tempo real parâmetros como vibração, temperatura, corrente elétrica e outros, é possível identificar padrões anormais do sistema. Usando algoritmos de análise computacional, os dados coletados são processados, analisando padrões de falhas anteriores e realizando previsões sobre possíveis falhas futuras (Althubaiti et al., 2022).

Um diagnóstico precoce de falhas em máquinas rotativas pode evitar riscos de danos e fornecer economia de recursos. Técnicas de monitoramento de condições, como análise de vibração, análise de óleo e termografia, desempenham um papel fundamental e permitem detectar falhas antes que se tornem problemas graves e causem danos irreparáveis (Jardine et al. 2006). Ao identificar problemas em alçadas iniciais, é possível tomar medidas oportunas, como minimizando os custos de atendimento, atendendo o tempo de inatividade da máquina e garantindo um ambiente de trabalho seguro para os operadores. Essa abordagem proativa na manutenção das máquinas rotativas é essencial para otimizar a eficiência operacional e prolongar a vida útil dos equipamentos.

O diagnóstico de falhas em máquinas rotativas pode utilizar a manutenção preditiva, também chamada de manutenção baseada na condição. Esse tipo de manutenção envolve o monitoramento contínuo das condições das máquinas para identificar possíveis falhas antes que elas ocorram (Trevisan & Mecânico, 2011).

Neste contexto, a aplicação de técnicas avançadas, como aprendizado de máquina e análise de dados, pode ser utilizada para prever e evitar falhas, garantindo o funcionamento ininterrupto e eficiente dessas máquinas. Com base em dados, algoritmos a partir de dados são aplicados para identificar padrões e tendências que possam indicar problemas iminentes, sendo uma abordagem eficaz para garantir a confiabilidade e eficiência das máquinas rotativas, além de maximizar sua vida útil (Lee, Yong et al., 2011).

Especificamente, modelos de aprendizado profundo podem ser empregados na análise de dados complexos e no reconhecimento de padrões em problemas de diagnóstico de falhas. Esses modelos oferecem a capacidade de aprender representações mais abstratas dos dados, contribuindo para uma maior precisão na identificação e previsão de falhas em máquinas rotativas (Sales da Cunha et al., 2022). Nesta dissertação, será adotada uma abordagem baseada em aprendizado profundo (focada em redes neurais convolucionais) para o diagnóstico de falhas em máquinas rotativas.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Aplicar modelos de aprendizagem profunda para diagnóstico de falhas em máquinas rotativas utilizando método de classificação.

1.1.2 Objetivos Específicos

- Revisão da literatura sobre *Prognostic and Health Management, Machine Learning e Vibration e Convolutional Neural Networks*.
- Analisar dados de vibração de máquinas rotativas, através de uma base de dados aberta;
- Aplicar e comparar diferentes modelos de aprendizagem de máquina e um modelo de aprendizagem de máquina profunda para a classificação de falhas em máquinas rotativas;
- Avaliar a eficácia dos modelos desenvolvidos na detecção de falhas em máquinas rotativas.

1.2 ESTRUTURA DA DISSERTAÇÃO

Além desta Introdução, os capítulos subsequentes deste documento seguem uma progressão lógica no desenvolvimento desta dissertação. O Capítulo 2, dedicado à Fundamentação Teórica, aprofunda-se nos conceitos essenciais do campo de estudo, estabelecendo uma base robusta que sustenta a pesquisa. No Capítulo 3, intitulado Revisão da Literatura, são apresentados trabalhos relacionados com o tema. O Capítulo 4, oferece uma detalhada exposição da Metodologia, destacando a abordagem aplicada, especialmente os detalhes relacionados à base de dados utilizada. O Capítulo 5 explora os Resultados, apresentando e discutindo as conclusões derivadas da experimentação proposta no capítulo da Metodologia. Por fim, o Capítulo 6, denominado Conclusão, sintetiza os principais achados do estudo e propõe sugestões para orientar futuras pesquisas.

2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão apresentados os conceitos relevantes para o desenvolvimento da dissertação. Inicialmente, serão abordados os fundamentos das máquinas rotativas, conceitos-chave da manutenção preditiva e seus componentes. Em seguida, serão discutidos os tópicos relacionados ao aprendizado de máquina, incluindo os modelos empregados.

2.1 MÁQUINAS ROTATIVAS

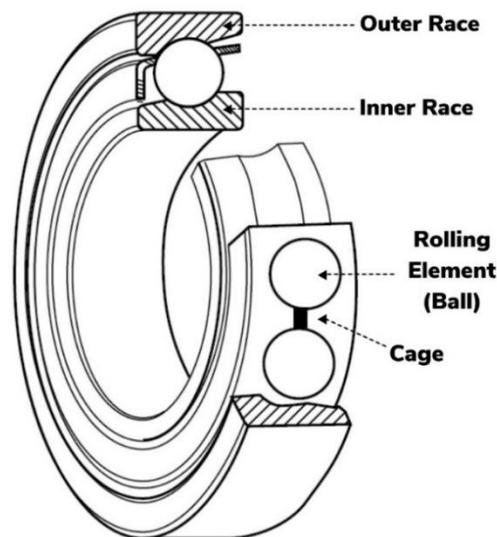
As máquinas rotativas desempenham um papel significativo na conversão de energia entre diferentes formas, desfrutando de ampla utilização nos setores industriais. Com componentes móveis fundamentais para seu funcionamento, essas máquinas são capazes de converter energia mecânica em energia elétrica (ou vice-versa) e desempenham papel na conversão e transferência eficiente de energia, gerando movimento e força através da rotação de um elemento central em relação a um componente fixo. Essas máquinas têm aplicações abrangentes, sendo empregadas em sistemas de transporte, geração de energia elétrica e diversos outros processos industriais (Stephen J. Chapman, 2013).

As máquinas rotativas são compostas por três componentes fundamentais: o rotor, os mancais e a estrutura de suporte. Esses elementos desempenham papéis essenciais no funcionamento dessas máquinas. O rotor é o componente central que realiza a rotação em torno de seu eixo, convertendo energia de uma forma para outra. Os mancais são responsáveis por sustentar e guiar o rotor de maneira estável, reduzindo o atrito e permitindo um movimento suave. Já a estrutura de suporte proporciona a base sólida para a fixação dos mancais e do rotor, garantindo a estabilidade e a integridade estrutural da máquina rotativa como um todo, conforme mencionado por Friswell et al. (2010).

Nesse contexto, destaca-se o papel crucial dos rolamentos, que, como componentes específicos dos mancais, buscam minimizar o atrito e promover um funcionamento eficiente. Os rolamentos contribuem significativamente para a sustentação das cargas e para a estabilidade do sistema rotativo, desempenhando um papel essencial na eficácia e confiabilidade das máquinas em diversas aplicações industriais (Georgoulas et al., 2015). Essa interligação entre rolamentos, mancais e demais componentes destaca a complexidade e a importância integrada desses elementos no contexto das máquinas rotativas.

A estrutura dos rolamentos (Figura 1) é composta por peças internas e externas. Anéis, separados por pequenas esferas ou rolos, formam essa estrutura. Essas partes reduzem o atrito, possibilitando um movimento rotativo eficiente entre os anéis. Para manter as esferas ou rolos uniformemente espaçados, são usadas gaiolas, garantindo um funcionamento suave. Além disso, a presença de selos ou proteções nos rolamentos evita a entrada de contaminantes, assegurando uma lubrificação adequada e contribuindo para a durabilidade e desempenho eficaz desses componentes em diversas situações industriais. Assim, a estrutura dos rolamentos, de maneira simples, está diretamente ligada à sua função vital nas máquinas rotativas, destacando a importância desses componentes para o bom funcionamento desses sistemas segundo Bezerra et al. (2004).

Figura 1. Elementos de um rolamento de elemento rolante.



Fonte: Adaptado Bezerra (2004)

Ao longo do tempo, avanços tecnológicos têm impulsionado melhorias significativas na eficiência e desempenho das máquinas rotativas. Graças a materiais mais resistentes, métodos de controle sofisticados e técnicas de fabricação avançadas, essas máquinas tornaram-se mais eficientes e duráveis. No entanto, é importante reconhecer que o desgaste, a degradação e as falhas podem ocorrer ao longo do tempo, resultando em paradas não programadas, perda de produtividade e custos elevados de manutenção. Nesse contexto, a manutenção preditiva, combinada com o uso de técnicas avançadas de aprendizado de máquinas, tem se mostrado uma abordagem eficaz para lidar com os desafios de detecção

precoce de falhas e a implementação de ações de manutenção adequadas (Maasoum et al., 2020).

2.2 MANUTENÇÃO PREDITIVA

A manutenção preditiva é implementada para identificar uma tendência de degradação iminente em um equipamento específico. Essa abordagem avalia as condições reais das máquinas com base em dados que indicam seu desgaste (ou processo de degradação) permitindo prever o tempo de vida útil dos componentes e possibilitando a otimização do uso desses componentes (Tran & Yang, 2012).

Dessa maneira a manutenção preditiva utiliza monitoramento periódico das máquinas para identificar sinais de estágios iniciais. No entanto, para garantir a qualidade da predição, é necessário considerar uma série de elementos. Por exemplo, é crucial que os dados coletados sejam precisos e estejam disponíveis, o que requer o uso de sensores adequados para cada tipo de informação coletada, tais como vibração, aceleração, temperatura, entre outras. Além disso, é fundamental assegurar que o desempenho do método de predição seja avaliado de maneira adequada, minimizando assim a ocorrência de rastreamento de falhas incorretas (Lauro Xavier Nepomuceno, 2018).

A manutenção preditiva, apresenta vantagens significativas na gestão de ativos, impulsiona a eficiência operacional ao minimizar imprevistos e reduzir o tempo de inatividade. Essa estratégia não apenas maximiza o tempo de atividade dos ativos, proporcionando uma visão em tempo real de sua condição e resultando em interrupções mínimas na produtividade, mas também otimiza o tempo dedicado a procedimentos de manutenção, ao uso de peças de reposição e à confiabilidade global do ativo. No entanto, é vital considerar desvantagens como os custos iniciais elevados, a necessidade de equipamentos e software específicos, e a demanda por habilidades especializadas para a interpretação e análise dos dados coletados. Apesar desses desafios, os benefícios substanciais tornam a manutenção preditiva uma estratégia valiosa para assegurar a eficácia e longevidade dos ativos ao longo do tempo (Achouch et al., 2023).

2.3 APRENDIZADO DE MÁQUINAS

O aprendizado de máquinas (*Machine Learning* - ML) é uma área da inteligência artificial dedicada ao desenvolvimento de algoritmos e modelos capazes de adquirir

conhecimento e habilidades a partir de dados, sem depender de programação explícita. Essa abordagem permite que os sistemas aprendam e melhorem suas próprias capacidades ao longo do tempo, adaptando-se a diferentes contextos e tarefas e realizando previsões sobre eventos futuros (Katti Faceli, 2011). No contexto da manutenção preditiva, o ML é frequentemente usado para construir modelos capazes de diagnosticar e prognosticar falhas em máquinas rotativas com base em dados de sensores e monitoramento (Lemley et al., 2017).

Os modelos de ML são treinados utilizando conjuntos de dados históricos, nos quais são apresentados exemplos e informações relevantes sobre o problema. Por meio do processamento desses dados, os algoritmos são capazes de identificar padrões, tendências e relações ocultas, o que lhes permite fazer previsões ou tomar decisões com base em novos dados de entrada. A principal vantagem desse tipo de abordagem é a capacidade de lidar com problemas complexos e não lineares, nos quais as regras e relações não são facilmente definidas por meio de programação tradicional. Além disso, o ML permite lidar com grandes volumes de dados e explorar informações de forma mais eficiente, auxiliando na descoberta de percepções valiosas e na tomada de decisões decisivas (Katti Faceli, 2011).

Há uma variedade de modelos de ML disponíveis, e a escolha do mais adequado para cada situação depende da natureza dos dados envolvidos (Nacchia et al., 2021). Geralmente, os modelos são classificados em três principais grupos: (i) aprendizado não-supervisionado, (ii) aprendizado por reforço e (iii) aprendizado supervisionado (Figura 2).

Figura 2. Classificações de aprendizado de máquina



Fonte: Adaptado de Nacchia et al. (2021)

2.3.1 Aprendizado não supervisionado

No aprendizado não supervisionado, não há rótulos ou valores alvo fornecidos no conjunto de dados de treinamento. O objetivo principal é identificar padrões, estruturas ou relações intrínsecas nos dados. Os modelos de aprendizado não supervisionado exploram a estrutura dos dados para agrupar instâncias semelhantes em clusters, reduzir a dimensionalidade dos dados ou encontrar associações entre as variáveis. Algoritmos comuns de aprendizado não supervisionado incluem análise de cluster, como o k-means, análise de componentes principais (PCA) e algoritmos de associação, como regras de associação e a priori (Han et al., 2011).

2.3.2 Aprendizado de reforço

O aprendizado por reforço é um tipo de algoritmo de aprendizado de máquina que permite que agentes de software e máquinas avaliem e aprendam automaticamente o comportamento ideal em um determinado contexto ou ambiente. Ele se baseia em uma abordagem orientada ao ambiente, em que o agente interage com o ambiente e recebe recompensas ou penalidades com base em suas ações (Celiberto et al., 2007). O aprendizado por reforço é comumente aplicado em situações em que não há um conjunto prévio de exemplos rotulados para treinar o agente, mas sim a necessidade de interagir com o ambiente para aprender a melhor estratégia.

2.3.3 Aprendizado supervisionado

No aprendizado supervisionado, os modelos são treinados usando um conjunto de dados rotulados. Cada exemplo de treinamento é composto por um conjunto de características (inputs) e uma etiqueta ou valor alvo correspondente (output). O objetivo do modelo é aprender uma função que mapeie corretamente os *inputs* para os *outputs* com base nos exemplos de treinamento. Em outras palavras, o modelo aprende a fazer previsões ou classificações com base em padrões identificados nos dados rotulados. Exemplos de algoritmos de aprendizado supervisionado incluem regressão linear, regressão logística, árvores de decisão e redes neurais (Lemley et al., 2017).

O objetivo principal do aprendizado supervisionado é desenvolver um modelo capaz de aprender com os exemplos rotulados e fazer previsões precisas em novos dados não rotulados (Mohsin Abdulazeez et al., 2020). Esse processo é realizado por meio de

algoritmos que buscam extrair padrões e relacionamentos nos dados de treinamento, permitindo que o modelo generalize e faça demonstrações corretas em novas situações. Existem dois tipos principais de aprendizado supervisionado: classificação e regressão.

No problema de classificação, o objetivo é atribuir uma categoria (classe) a uma instância de dados com base em suas características. De acordo com Mohsin Abdulazeez et al. (2020), o modelo aprende a distinguir entre diferentes classes e, em seguida, pode classificar corretamente novos exemplos não rotulados em uma das classes aprendidas. Exemplos comuns de problemas de classificação incluem detecção de spam em e-mails, diagnóstico médico, reconhecimento de imagens e detecção de fraudes. Alguns exemplos de algoritmos: *Naive Bayes* (NB), *Logistic Regression* (LR), *K-Nearest Neighbours* (KNN) e *Support Vector Machine* (SVM).

No aprendizado de regressão, o objetivo é prever um valor numérico contínuo com base nas características de entrada. O algoritmo é treinado usando um conjunto de dados de treinamento rotulados, onde cada exemplo possui um valor de saída numérica correspondente. O modelo aprende a relação entre as características e os valores de saída e, em seguida, pode fazer previsões precisas em novos exemplos, estimando um valor numérico. Exemplos de problemas de regressão incluem previsão de preços de imóveis, previsão de vendas com base em variáveis de mercado e previsão de demanda de produtos. Alguns exemplos de algoritmos: *Logistic Regression* (LR), *Linear Regression*, *Principal Components Regression* (PCR) (Mohsin Abdulazeez et al., 2020).

A escolha entre classificação e regressão depende da natureza da variável de saída desejada. Se a variável em questão for discreta, apresentando classes ou categorias, então o aprendizado de classificação é a abordagem adequada. Por outro lado, se a variável de saída for contínua e representa um valor numérico, então o aprendizado de regressão é mais adequado. Essa distinção entre classificação e regressão permite selecionar a técnica correta para lidar com diferentes tipos de variáveis de saída, garantindo uma modelagem mais precisa e eficaz dos dados. No presente trabalho, o enfoque principal será no aprendizado supervisionado, com ênfase na aplicação de métodos de classificação.

De acordo com Han et al. (2011), o desempenho do modelo é avaliado com base em métricas específicas para problemas de classificação, sendo crucial para entender a capacidade do modelo de distinguir corretamente entre diferentes classes e identificar possíveis pontos ausentes ou áreas de melhoria. Existem vários tipos de algoritmos de aprendizado de máquina supervisionado comumente utilizados para problemas de

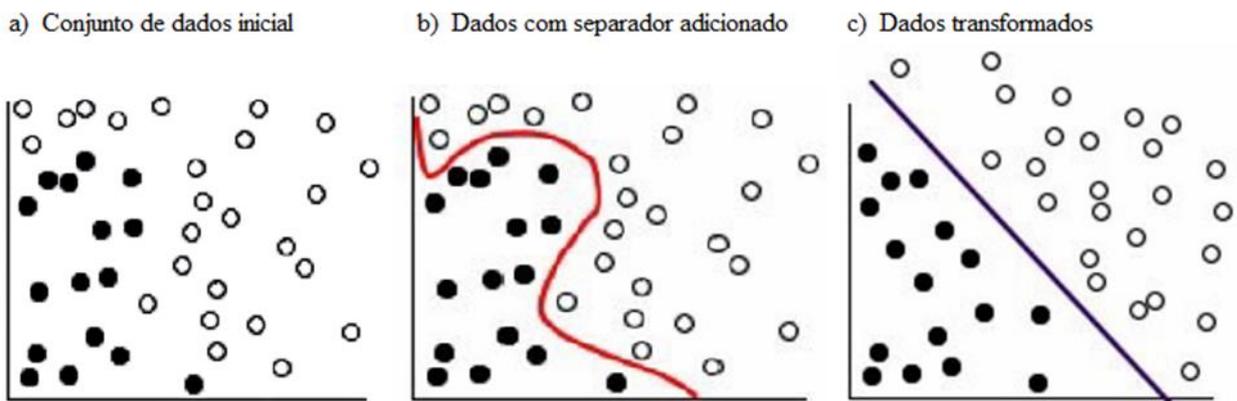
classificação. Abaixo está uma breve descrição dos principais tipos que serão utilizados nessa dissertação.

- Máquinas de Vetores de Suporte (SVM)

O SVM desempenha o papel de classificador em cenários que envolvem a categorização de grupos distintos utilizando um modelo capaz de receber vetores não linearmente mapeados e os projetando em uma dimensão superior, onde podem ser mapeados linearmente. Para efetuar esse mapeamento, torna-se essencial pré-processar os dados, garantindo que seus padrões sejam representados em uma dimensão superior a original. Esse aumento de dimensão é realizado por meio da aplicação de uma função não linear, conhecida como kernel, responsável por mapear os dados para essa dimensão superior e viabilizar a separação entre eles. A divisão das informações ocorre através de um hiperplano, que representa um espaço vetorial ou um subespaço em uma dimensão (Duda et al. 2012).

Um exemplo visual é ilustrado na Figura 3, na qual pontos dispersos são atribuídos a uma de duas categorias possíveis. a) as categorias podem ser visualmente distintas ao longo de uma curva. b) posteriormente, o limite entre essas categorias pode ser estabelecido de forma linear após a transformação, utilizando um hiperplano. c) A transformação é realizada por meio de uma função matemática chamada função kernel, a qual pode assumir características lineares, polinomiais, entre outras.

Figura 3. Conjunto de dados



- Regressão Logística

A Regressão Logística é uma técnica estatística dedicada a modelar a probabilidade de eventos em termos de variáveis independentes, especialmente empregada em problemas de classificação binária. Ao contrário da regressão linear, que lida com valores contínuos, a regressão logística utiliza a função logística para converter uma combinação linear de variáveis em uma probabilidade entre 0 e 1. Esta probabilidade é posteriormente transformada em uma decisão de classificação com base em um limiar, frequentemente estabelecido em 0,5. Durante o treinamento, os parâmetros são ajustados para maximizar a verossimilhança dos dados observados, minimizando a função de custo que penaliza desvios entre as probabilidades previstas e os rótulos reais de acordo com Russell et al. (2002).

- Multilayer Perceptron

MLP é um tipo de rede neural artificial que consiste em várias camadas de neurônios interconectados, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada neurônio em uma camada está conectado a todos os neurônios na camada seguinte, e essas conexões são associadas a pesos que são ajustados durante o treinamento da rede. Essa estrutura permite que o MLP aprenda padrões complexos e relações não lineares nos dados.

Segundo Martínez Álvarez et al. (2015) MLP opera em diferentes camadas, começando pela camada de entrada, que recebe as características do conjunto de dados. As camadas ocultas, responsáveis por transformações não lineares nas entradas, combinam informações da camada anterior com pesos ajustáveis. Cada neurônio nessas camadas aplica uma função de ativação para introduzir não linearidades. A última camada, de saída, gera as previsões ou classificações finais. Durante o treinamento, algoritmos de otimização, como o gradiente descendente, ajustam os pesos para minimizar a diferença entre as previsões do modelo e os rótulos reais do conjunto de treinamento. Essa capacidade de aprender representações não lineares complexas torna o MLP eficaz em problemas de classificação e regressão em diversos domínios.

- Random Forest

O Random Forest é uma técnica desenvolvida de aprendizado de máquina que se destaca por sua habilidade em lidar com uma ampla gama de tarefas, desde classificação até regressão. É considerado um dos métodos mais poderosos e versáteis disponíveis na área de aprendizado de máquina. Ao contrário de modelos individuais que podem ser suscetíveis a *overfitting*, o

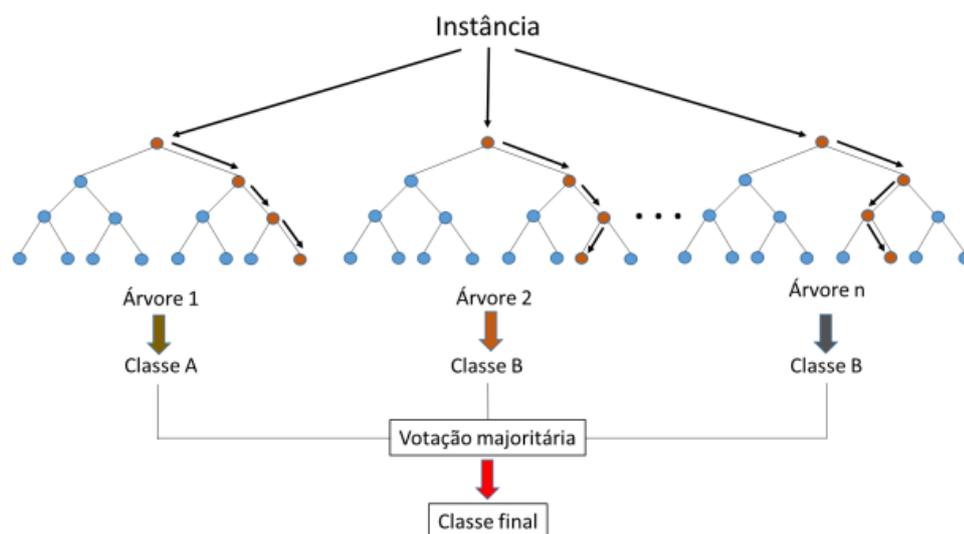
Random Forest baseia-se na combinação de múltiplas árvores de decisão para fornecer especificações mais robustas e precisas. Cada árvore é treinada em uma subamostra de dados, e a diversidade entre elas é garantida pela seleção selecionada de características em cada divisão (Murphy, 2012).

Uma característica distintiva do Random Forest é sua habilidade em avaliar a importância das características durante o processo de classificação. Essa capacidade oferece insights valiosos sobre quais aspectos dos dados são mais informativos para o modelo, proporcionando uma maior compreensão e interpretabilidade. O Random Forest é aplicável em uma ampla gama de domínios, desde a classificação de imagens, detecção de fraudes, até análise de texto e bioinformática. Sua versatilidade ao lidar com diferentes tipos de dados e sua eficácia em grandes conjuntos de dados o tornam uma escolha popular entre cientistas de dados e engenheiros de aprendizado de máquina (Breiman, 2001).

Cada algoritmo tem suas próprias características, pontos fortes e limitações, e a escolha do algoritmo certo depende da natureza do problema, do tamanho do conjunto de dados e de outros fatores relevantes.

O algoritmo Random Forest tem atraído crescente interesse devido à sua precisão e robustez em comparação com classificadores individuais. Ele opera eficientemente em grandes conjuntos de dados, sendo capaz de processar milhares de variáveis de entrada sem a necessidade de exclusão. Adicionalmente, apresenta uma carga computacional mais leve em comparação com outros métodos baseados em conjuntos de árvores (Figura 4).

Figura 4. Classificador Random Forest



2.4 APRENDIZADO DE MÁQUINA PROFUNDO PARA CLASSIFICAÇÃO

O aprendizado supervisionado profundo utiliza redes neurais artificiais profundas para aprender representações complexas e abstratas dos dados de forma automática. Diferentemente do aprendizado tradicional, onde a definição manual de características era comum, o aprendizado profundo automatiza esse processo, permitindo que as redes neurais identifiquem e aprenda representações em diferentes níveis de complexidade e abstração de dados. Elas são especialmente eficazes em problemas com grande quantidade de dados e tarefas que envolvem dados de natureza complexa, como imagens, áudio ou texto. Na Tabela 1, é mostrado uma comparação sucinta entre aprendizagem de máquina e aprendizagem de máquina profundo (Sales da Cunha B. et al., 2022).

Tabela 1. Comparação entre aprendizado de máquina e aprendizado de máquina profundo.

	Aprendizado de máquina	Aprendizado de máquina profundo
Quantidade de dados	É possível realizar previsões com base de dados reduzidos.	Para fazer previsões precisas, geralmente, é necessário ter um grande conjunto de dados de treinamento.
Requisitos de hardware	É viável utilizar em máquinas com recursos limitados. Não requer um poder computacional significativo.	Requer o uso de computadores avançados, pois envolve um grande número de operações de multiplicação de matrizes. Uma GPU pode otimizar essas operações de forma eficiente.
Abordagem de aprendizagem	Desmembra o processo de aprendizado em etapas mais curtas e, posteriormente, combina os resultados de cada etapa em uma saída.	Aborda o processo de aprendizado ao resolver o problema de forma abrangente, desde o início até a conclusão.
Execução	Apresenta um tempo de treinamento relativamente curto, variando de alguns segundos a algumas horas.	Normalmente, o treinamento pode ser demorado devido à presença de muitas camadas em um algoritmo de aprendizado profundo.
Resultado	O resultado geralmente é expresso como um valor numérico, como uma pontuação ou uma classificação.	A saída pode ser apresentada em diversos formatos, como texto, pontuação ou som, dependendo do contexto e da aplicação.

Fonte: O Autor, 2023

De acordo com Xin et al. (2018) uma das principais vantagens do aprendizado supervisionado profundo é sua capacidade de aprender características e padrões diretamente dos dados, eliminando a necessidade de engenharia manual de recursos. As redes neurais

profundas podem aprender representações hierárquicas para melhorar a classificação em diversas situações. Entretanto, o aprendizado profundo demanda grande quantidade de dados rotulados e considerável poder computacional para treinar modelos complexos.

Assim, o aprendizado supervisionado tradicional recorre a algoritmos simples e regras manualmente definidas, enquanto o aprendizado supervisionado profundo utiliza redes neurais profundas para aprender automaticamente representações complexas de dados, sendo eficaz em grandes conjuntos e dados complexos, como imagens, áudio ou texto. Existem vários exemplos de algoritmos de aprendizado profundo para classificação, que são o foco nesse trabalho. A seguir, está um exemplo amplamente utilizados e que será utilizado nesse trabalho.

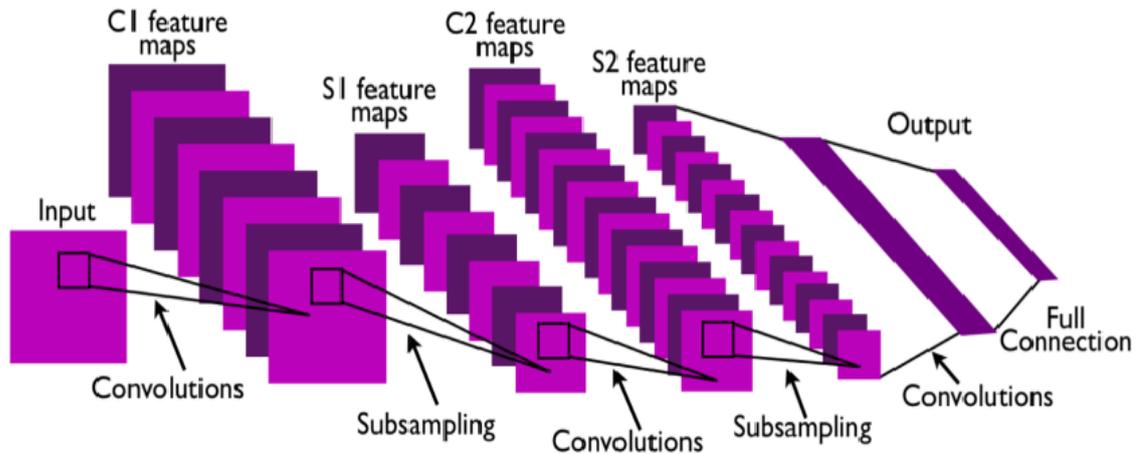
- Redes Neurais Convolucionais (CNN)

As CNNs foram um marco significativo no campo do aprendizado de máquina e processamento de imagens. Desde sua introdução, as CNNs têm demonstrado um desempenho excepcional em tarefas de visão computacional, incluindo reconhecimento de objetos, detecção de características e classificação de imagens (Johnson et al., 2021). A definição central das CNNs é sua capacidade de aprender automaticamente características e padrões relevantes em dados. Ao contrário das redes neurais tradicionais, que requerem uma representação manual de recursos, as CNNs são capazes de aprender de forma independente as características importantes em diferentes níveis de abstração. Essa habilidade é alcançada por meio do uso de camadas convolucionais, que aplicam filtros para extrair características locais das imagens e, em seguida, combinam essas informações em camadas subsequentes (Johnson et al., 2021).

Redes convolucionais são arquiteturas de aprendizado de máquina compostas por vários estágios. Cada estágio recebe uma entrada e produz uma saída composta por conjuntos de matrizes chamados de mapas de recursos. A estrutura dos mapas de recursos depende do tipo de entrada que está sendo processada. Por exemplo, se a entrada for uma imagem colorida, cada mapa de recursos será uma matriz 2D contendo informações sobre um canal de cor específico. No caso de áudio ou sinais de vibração, cada mapa de recursos será uma matriz 1D, enquanto em vídeos ou imagens volumétricas, será uma matriz 3D. Cada mapa de recursos de saída representa um recurso específico extraído de toda a entrada (Lecun et al. 2010).

A Figura 5 demonstra uma arquitetura típica de rede convolucional, também conhecida como ConvNet, é composta por um ou mais estágios de recursos. Cada estágio é composto por três camadas principais: uma camada de banco de filtros, uma camada de não linearidade e uma camada de pool de recursos.

Figura 5. Rede convolucional com dois estágios



Fonte: LECUN et al. 2010

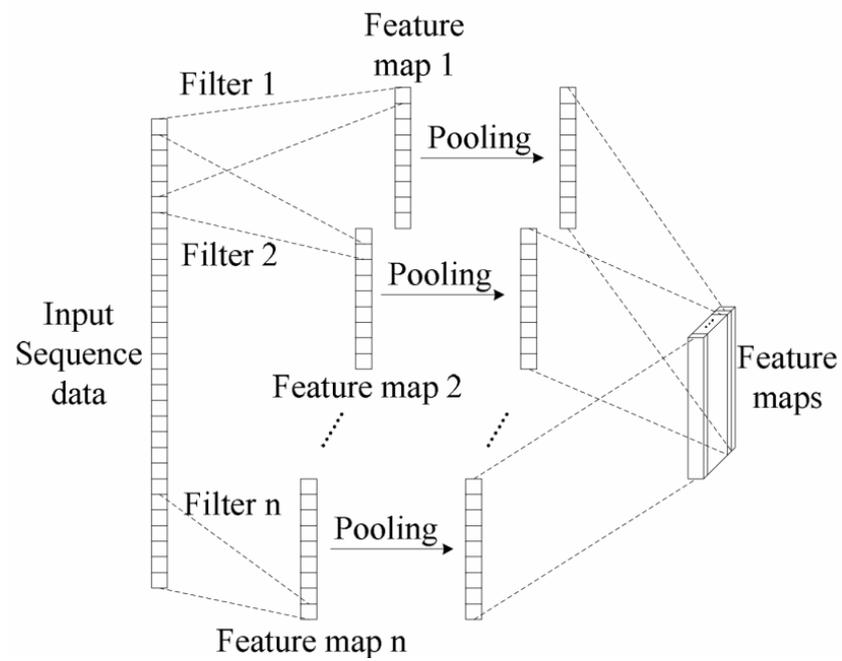
Uma arquitetura ConvNet típica é composta por um, dois ou três estágios de três camadas, seguidos por um módulo de classificação. O módulo de classificação pode ser uma ou mais camadas totalmente conectadas, responsáveis por mapear as características extraídas para as classes desejadas. Além do reconhecimento de objetos, as CNNs também são utilizadas em tarefas como detecção de características, segmentação de imagens, reconhecimento facial, tradução automática de imagens e até mesmo na geração de imagens realistas (Zhang et al., 2022).

Ainda que as principais aplicações das CNNs sejam para o reconhecimento de objetos, a mesma também pode ser uma importante ferramenta em processamento de sinais de vibração. Sua arquitetura é particularmente eficaz para lidar com sequências 1D, sendo uma escolha estratégica para análise de dados de Manutenção Preditiva, onde sinais de vibração desempenham um papel crucial (X. Li. et al., 2018).

Considerando a CNN para sinais unidimensionais (CNN 1D), a abordagem aproveita as operações de convolução e pooling para aprender padrões fundamentais nos sinais de vibração. A aplicação desta rede neural oferece eficiência computacional e capacidade aprimorada de discernir informações relevantes em meio a grandes conjuntos de dados. A

Figura 6 ilustra a estrutura essencial CNN 1D, destacando a sua importância na extração de conhecimento valioso a partir desses sinais complexos.

Figura 6. Estrutura essencial CNN 1D



Fonte: X. Li. et al., 2018

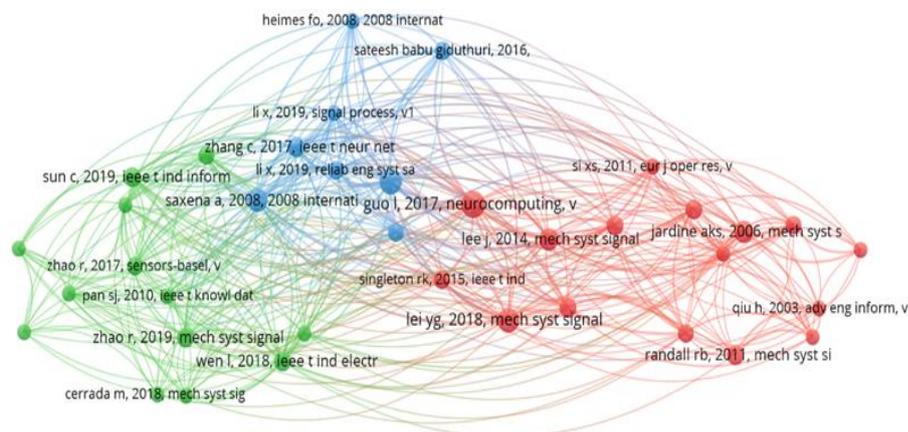
3. REVISÃO DE LITERATURA

Para conduzir uma revisão de literatura abrangente, duas partes foram realizadas utilizando o banco de dados Web of Science (WoS), uma plataforma de pesquisa que possibilita a obtenção, análise e divulgação de informações relacionadas à produção científica. O WoS desempenha um papel importante na identificação de fontes de pesquisa para a construção do referencial teórico, conforme destacado por Birkle et al. (2020). A primeira parte da revisão foi abrangente e geral sobre modelos de aprendizagem para diagnóstico de falhas em máquinas rotativas, enquanto a segunda se concentrou em uma busca específica direcionada para modelos de aprendizagem profunda do tipo CNN para o diagnóstico de falhas em máquinas rotativas.

3.1 ML PARA DIAGNÓSTICO DE FALHAS EM MÁQUINAS ROTATIVAS

Para realizar essa primeira parte da revisão, com aspecto mais geral do assunto, foram escolhidas as palavras-chave (i) 'Prognostic and Health Management', (ii) 'Machine Learning' e (iii) 'Vibration', empregadas sequencialmente em uma busca no banco de dados WoS, inicialmente a pesquisa gerou 20.856 resultados relacionados exclusivamente à primeira palavra-chave, número que diminuiu para 724 ao incluir a segunda (machine learning) e, finalmente, para 56 publicações com a adição da terceira palavra-chave (vibration), a análise abrangeu um período de 20 anos (2002-2022). Pelo fato desta revisão enfatizar aplicações, 5 artigos caracterizados como revisões bibliográficas foram retirados da análise, resultando em 51 trabalhos. Com o apoio do software VosViewer, uma segunda etapa foi realizada através de análise de cocitações com parâmetro mínimo de citações 4, resultando nas 37 publicações mais citadas (Figura 7).

Figura 7. Mapa de calor das cocitações no VosViewer



Fonte: O Autor, 2023

A seleção dos artigos mais pertinentes ocorreu por meio da leitura completa, focando em métodos e experimentos de aprendizagem de máquina para classificação e regressão usando sinais de vibração. Ao final, 10 publicações foram escolhidas. Um resumo dos artigos selecionados é apresentado na Tabela 2 descrevendo o método proposto, base de dados utilizada e tipo do problema (classificação ou regressão).

Tabela 2. Relação entre autores e publicações

REFERÊNCIA	TÍTULO DA PUBLICAÇÃO	MÉTODO PROPOSTO	CONJUNTO DE BASE DE DADOS	TIPO DE PROBLEMA	DESCRIÇÃO
(Lei et al. 2016)	A Model-Based Method for Remaining Useful Life Prediction of Machinery	Erro mínimo ponderado de quantização (WMQE)	PRONOSTIA	Regressão	Desenvolver um novo indicador de integridade chamado WMQE.
(Qian et al. 2019)	A New Deep Transfer Learning Network for Fault Diagnosis of Rotating Machine under Variable Working Conditions	Normalização em lote adaptável (AdaBN) e <i>stacked autoencoders</i> (SAE)	Case Western Reserve University (CWRU)	Classificação (4 Classes)	Construção de uma rede neural profunda baseada em AdaBN e SAE.
(Ben Ali et al. 2015)	Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network	Simplified Fuzzy Adaptive Resonance Theory Map (SFAM) e distribuição Weibull (WD)	Sistemas de Manutenção Inteligente (IMS)	Classificação (7 Classes)	É realizado uma combinação entre a rede neural SFAM e distribuição Weibull.
(N. Li et al. 2015)	An Improved Exponential Model for Predicting Remaining Useful Life of Rolling Element Bearings	Modelo exponencial aprimorado	PRONOSTIA	Regressão	Existem duas deficiências no modelo exponencial: (1) o primeiro tempo de previsão (FPT) é selecionado subjetivamente; e (2) erros aleatórios do processo estocástico diminuem a precisão da predição. Para lidar com essas duas deficiências, um modelo exponencial aprimorado é proposto neste artigo.
(Mao et al. 2019)	Bearing Fault Diagnosis based on Multi-task Learning	Transformada de Hilbert-Huang (HHT) e Método L2,1 Regularized Multitask Joint Feature Selection	Case Western Reserve University (CWRU)	Classificação (2 Classes)	Neste artigo, é realizado um experimento para verificar a eficiência do aprendizado multitarefa para diagnóstico de falhas. É utilizado os métodos HHT E L2,1.

(Soualhi, Medjaher, and Zerhouni 2015)	Bearing Health Monitoring Based on Hilbert–Huang Transform, Support Vector Machine, and Regression	HHT, <i>support vector machine</i> (SVM) para o monitoramento de rolamentos de esferas.	PRONOSTIA	Regressão	A abordagem proposta usa o HHT para extrair novos indicadores de saúde de sinais de vibração estacionários e não estacionários capazes de controlar a degradação dos componentes críticos dos rolamentos.
(X. Li, Zhang, and Ding 2019)	Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction	Transformada de Fourier de curto prazo (STFT).	PRONOSTIA	regressão	Neste artigo, um novo método baseado em aprendizado profundo para prognósticos é proposto. Durante a operação da máquina, o primeiro tempo de previsão é determinado em primeiro lugar.
(Ma and Mao 2021)	Deep wavelet sequence-based gated recurrent units for the prognosis of rotating machinery	Sequência wavelet baseada em rede neural fechada (WSGRU).	Não fornece detalhes sobre a origem dos dados.	Regressão	Descreve o método WSGRU profundo proposto em detalhes. É realizado os testes de funcionamento até a falha do rolamento e a previsão de RUL.
(Ding et al. 2020)	Feature Clustering Analysis Using Reference Model towards Rolling Bearing Performance Degradation Assessment	Análise de agrupamento de recursos (FCA)	Case Western Reserve University (CWRU)	Classificação (2 Classes) e Regressão	É utilizado FCA, para construir um novo esquema de monitoramento de saúde para avaliar a degradação do desempenho do rolamento.
(Qiu et al. 2003)	Robust performance degradation assessment methods for enhanced rolling element bearing prognostics	Filtro wavelet e método baseado em mapa auto-organizado (SOM)	Sistemas de Manutenção Inteligente (IMS)	Regressão	Este artigo aborda questões sobre redução de ruído e extração da assinatura fraca do sinal ruidoso para prognósticos de rolamento

Fonte: O Autor, 2023

Lei et al. (2016) desenvolveram um método abrangente para prever a vida útil restante (RUL) de máquinas, composto por dois módulos. No primeiro, introduzem o indicador inovador de saúde, erro mínimo ponderado de quantização (WMQE), derivado da abordagem de Qiu et al. (2003), para avaliar o estado operacional das máquinas. O segundo módulo utiliza o modelo Paris-Erdogan para descrever a degradação, e a previsão da RUL é realizada através de um algoritmo de filtragem de partículas (PF) proposto por Arulampalam et al. (2002). Em contraste, Qian et al. (2019) propõem uma abordagem para o diagnóstico de falhas em máquinas rotativas sob condições operacionais variáveis. Seu método incorpora Adaptive Batch Normalization (AdaBN) e stacked autoencoders (SAE) na construção de uma rede profunda, eliminando a necessidade de múltiplos treinamentos. O estudo segue três etapas, incluindo a geração de amostras de domínio de frequência mais regulares a partir de sinais de vibração, a pré-treinagem de uma rede neural profunda (DNN) baseada em AdaBN com quatro camadas usando SAE, e a adaptação da rede treinada a diferentes condições de trabalho, sem a necessidade de treinamentos adicionais.

Ben Ali et al. (2015) introduziram uma abordagem inovadora que combina a distribuição Weibull e uma rede neural artificial para prognóstico, usando sinais de vibração relacionados à rotação de ativos mecânicos. O foco central desse estudo é a criação de uma nova feature destinada a aprimorar a descrição de rolamentos com falha, através de uma tarefa de classificação. Em outra frente, N. Li et al. (2015) desenvolveram um modelo exponencial aprimorado para prever a vida útil remanescente (RUL) de rolamentos de elementos rolantes, visando superar as limitações do modelo exponencial original. As melhorias incluem a redução dos erros aleatórios do processo estocástico por meio do filtro de partículas (PF) e a implementação de uma abordagem adaptativa na seleção do primeiro tempo de previsão (FPT). Por sua vez, Mao et al. (2019) descreveram um método de detecção de falhas em rolamentos de máquinas rotativas, utilizando aprendizado de máquina baseado em multitarefa. O método proposto integra a transformada de Híbert-Huang (HHT), uma técnica de análise tempo-frequência para sinais de vibração não estacionários, com a seleção de recursos conjuntos multitarefa usando o método L2,1 Regularized Multitask Joint Feature Selection.

O método proposto por Soualhi, Medjaher, and Zerhouni (2015) para monitorar a saúde de rolamentos combina a transformada de Hilbert-Huang (HHT) e máquinas de vetores de suporte (SVM). O HHT é utilizado para extrair características dos sinais de vibração dos rolamentos, que são então empregadas como entrada para o SVM e a regressão. Em contrapartida, no trabalho de X. Li, Zhang, and Ding (2019) os autores introduzem um método de prognóstico baseado em aprendizado profundo para estimar o status de degradação de

máquinas. Utilizando a transformada de Fourier de curto prazo (STFT) para obter informações tempo-frequência dos dados brutos, o método emprega a extração de recursos multiescala por meio de operações convolucionais, uma classe de redes neurais artificiais feed-forward comumente aplicada em processamento e análise de imagens digitais. Já os autores Ma and Mao (2021) desenvolvem uma rede de aprendizado, chamada Rede Neural de Unidade Recorrente Fechada com Sequência Wavelet (WSGRU), para prever o RUL de máquinas rotativas. A abordagem é dividida em duas partes: primeiro, sequências wavelet são construídas usando a transformada wavelet contínua para lidar com sinais não estacionários e destacar as características dinâmicas dos sinais de vibração; segundo, a rede de unidade recorrente fechada (GRU) é empregada para modelar dependências temporais e controlar o fluxo de informação.

Ding et al. (2020) propõem uma abordagem inovadora para avaliar a degradação de rolamentos em máquinas rotativas, utilizando análise de agrupamento de features em vez de modelos matemáticos complexos. O processo inclui coleta de dados de vibração, identificação de padrões de desvio por meio de técnicas de agrupamento e estimativa da vida útil restante (RUL). Enquanto isso, Qiu et al. (2003) apresentam um método que emprega filtro Wavelet para desobstrução de sinal e aprimoramento de features em sinais de defeitos mecânicos. O artigo compara métodos de redução de ruídos e introduz um método baseado em Self Organizing Map (SOM) para construção de espaço de características, detecção de degradação e avaliação de desempenho. Ambos os estudos contribuem para avanços nas técnicas de monitoramento e prognóstico de rolamentos em máquinas industriais.

3.2 CNN PARA O DIAGNÓSTICO DE FALHAS EM MÁQUINAS ROTATIVAS

Na busca por uma abordagem mais detalhada sobre CNN em máquinas rotativas, realizou-se uma pesquisa aprofundada utilizando algumas bases de dados, inclusive WoS e as três palavras-chaves utilizadas anteriormente, mas agregando uma quarta palavra-chave (CNN). Foram selecionados 5 trabalhos relevantes (Tabela 3), que oferecem uma visão ampla das contribuições mais significativas nesse método específico.

Tabela 3. Relações entre autores e publicações

REFERÊNCIA	TÍTULO DA PUBLICAÇÃO	MÉTODO PROPOSTO	CONJUNTO DE BASE DE DADOS	TIPO DE PROBLEMA	DESCRIÇÃO
Krizhevsky et al. (2012)	ImageNet Classification with Deep Convolutional Neural Networks	Redes Neurais Convolucionais Profundas (AlexNet)	ImageNet Large Scale Visual Recognition Challenge (ILSVRC)	Classificação	Utiliza CNNs na classificação de imagens em larga escala, superando significativamente taxas de erro comparadas a métodos convencionais, graças a método AlexNet.
Li et al. (2019)	A deep learning driven method for fault classification and degradation assessment in mechanical equipment	Rede neural de retropropagação (BPNN)	Case Western Reserve University (CWRU)	Classificação	O artigo apresenta um método inovador de aprendizado profundo para a classificação de falhas e avaliação de degradação em equipamentos mecânicos.
Janssens et al. (2016)	Convolutional Neural Network Based Fault Detection for Rotating Machinery	Redes Neurais Convolucionais (CNN)	Case Western Reserve University (CWRU)	Classificação	Propõe um método de detecção de falhas em máquinas rotativas com base em redes CNNs, visando abordar desafios na detecção precisa e precoce de falhas.
Jeong et al. (2016)	Rotating Machinery Diagnostics using Deep Learning on Orbit Plot Images	Redes Neurais Convolucionais (CNN)	Case Western Reserve University (CWRU)	Classificação	O artigo tem uma abordagem baseada em aprendizado profundo para o diagnóstico de máquinas rotativas.
Guo et al. (2016)	Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis	Adaptative Convolutional Neural Network (ADCNN)	Case Western Reserve University (CWRU)	Classificação	Apresenta um método avançado para o diagnóstico de falhas em rolamentos, buscando aprimorar a precisão e eficácia do diagnóstico. Introduzindo o modelo Adaptative Convolutional Neural Network (ADCNN).

Fonte: O Autor, 2023

O trabalho pioneiro de Krizhevsky et al. (2012) destacou-se ao demonstrar o poder das CNNs na classificação de imagens em grande escala. Esses autores conseguiram obter um desempenho superior ao alcançar uma redução significativa na taxa de erro em comparação com abordagens convencionais de classificação de imagens. Esse avanço foi possível graças ao uso da arquitetura de rede neural convolucional conhecida como AlexNet. Desta forma, parece ser adequada a aplicação de técnicas avançadas, como o processamento de sinal e as CNN, na detecção de falhas em máquinas rotativas e na classificação precisa em escala industrial. Essas abordagens têm o potencial de melhorar a eficiência, a confiabilidade e a segurança das operações em diversas indústrias.

Neste contexto, Li et al. (2019) apresenta um método baseado em aprendizado profundo para a classificação de falhas e avaliação de degradação em equipamentos mecânicos. O estudo visa abordar os desafios relacionados à detecção e diagnóstico de falhas em equipamentos mecânicos, considerando as complexidades do ambiente operacional e a crescente demanda por sistemas de autoavaliação na indústria inteligente. A abordagem proposta utiliza redes CNNs como parte essencial do método. As CNNs são arquiteturas de aprendizado profundo que demonstraram sucesso em tarefas de classificação de imagens. Elas têm a capacidade de aprender automaticamente características distintivas dos dados, o que é especialmente benéfico para a análise de sinais e imagens em problemas de diagnóstico de falhas. Os resultados resultam em um desempenho superior em comparação com abordagens convencionais baseadas em dados. A capacidade das CNNs em aprender transformações não lineares complexas através de camadas ocultas possibilita a captura de informações discriminativas e variações significativas nos dados industriais. Esse artigo contribui para o avanço do campo de manutenção e diagnóstico de equipamentos mecânicos, oferecendo um método inovador e eficiente baseado em aprendizado profundo, com foco no uso de CNNs para aprimorar a precisão na classificação de falhas e avaliação de degradação em equipamentos mecânicos.

O trabalho de Janssens et al. (2016) apresenta um método de detecção de falhas em máquinas rotativas baseado em redes de CNNs. O objetivo do estudo é abordar os desafios relacionados à detecção precoce e precisa de falhas em equipamentos mecânicos, visando melhorar a confiabilidade e o desempenho das máquinas. Os autores propõem a utilização de uma arquitetura de CNN para analisar os sinais de resposta das máquinas rotativas e identificar padrões característicos de diferentes tipos de falhas. O método utiliza dados de treinamento para treinar a CNN e desenvolver um modelo de detecção de falhas. Os resultados demonstram que a abordagem baseada em feature-learning e CNNs supera um

sistema concorrente que utiliza feature-learning e o classificador Random Forest. O sistema desenvolvido pelos pesquisadores alcançou uma precisão de 93,61%, enquanto o outro sistema obteve 87,25%. Esses resultados evidenciam a efetividade do uso de CNNs e feature-learning na detecção de falhas em máquinas rotativas, oferecendo uma solução robusta e precisa para o diagnóstico de problemas em equipamentos industriais.

Jeong et al. (2016) propõe uma abordagem baseada em aprendizado profundo para o diagnóstico de máquinas rotativas utilizando imagens de gráficos de órbita. O objetivo do estudo é melhorar a precisão e eficiência do diagnóstico de falhas em máquinas rotativas por meio da aplicação de técnicas de aprendizado profundo. A metodologia proposta consiste em extrair recursos das imagens de gráficos de órbita e alimentá-las em uma rede CNN para realizar a classificação das falhas. Os resultados experimentais mostram que o modelo de aprendizado profundo alcançou uma alta taxa de precisão na detecção de diferentes tipos de falhas em máquinas rotativas, demonstrando o potencial do uso de técnicas de aprendizado profundo para diagnóstico de falhas em equipamentos industriais.

O trabalho Guo et al. (2016) apresenta um método avançado para o diagnóstico de falhas em rolamentos. O objetivo do estudo é melhorar a precisão e eficácia do diagnóstico de falhas por meio do uso de uma rede neural convolucional profunda adaptativa e hierárquica. Os pesquisadores concluíram que existem poucos estudos que utilizam CNN para o diagnóstico de falhas. Diante disso, eles propuseram um modelo chamado Adaptive Convolutional Neural Network (ADCNN) para classificar falhas em rolamentos e determinar sua gravidade. O ADCNN tem a capacidade de extrair automaticamente as principais características dos dados, sem a necessidade de intervenção manual. Durante o desenvolvimento do modelo, foi aplicada uma taxa de aprendizado adaptativa para extrair as características mais significativas e obter os melhores resultados de reconhecimento.

Com base nesse recorte da literatura, referente a aprendizado de máquina profundo utilizando CNN, é possível observar os notáveis avanços alcançados no desenvolvimento de modelos substitutos nos últimos anos. Ao mesmo tempo, destaca-se o progresso crescente na aplicação de técnicas de aprendizado de máquina para o diagnóstico de falhas em sistemas rotativos.

4. METODOLOGIA

Este estudo concentra-se na aplicação de um modelo de aprendizagem profunda CNN, para diagnosticar falhas em máquinas rotativas, onde os dados podem apresentar lacunas ou ruídos decorrentes de falhas nos sensores. Utilizando a base de dados CWRU, a pesquisa envolverá a transformação dos dados temporais em vetores de características para a comparação entre os modelos SVM, Regressão Logística, MLP, Random Forest e de sinais de vibração para modelo CNN. O treinamento e avaliação dos modelos, seguidos por uma análise dos resultados, resultarão em conclusões que orientarão futuras pesquisas na busca por aprimoramentos e novas abordagens para a aplicação bem-sucedida de aprendizagem profunda no diagnóstico de falhas em máquinas rotativas.

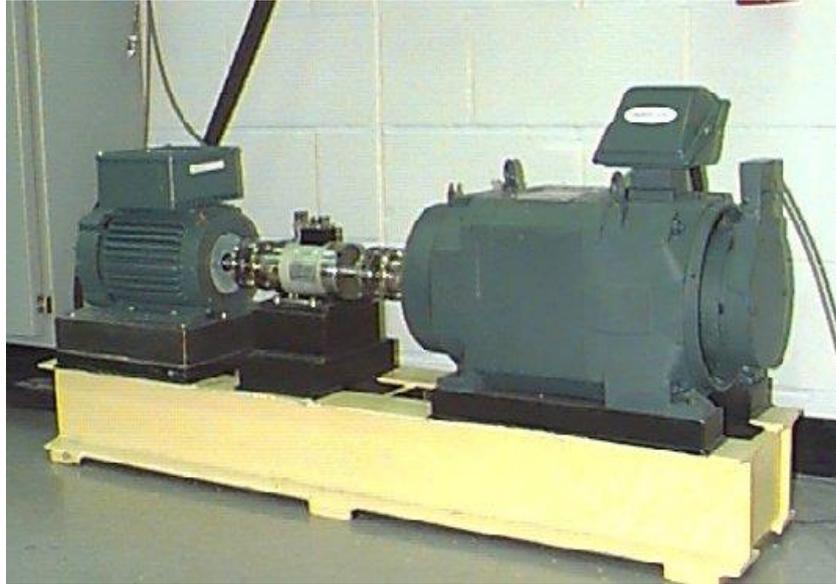
4.1 CASE WESTERN RESERVE UNIVERSITY BEARINGS DATA CENTER

O conjunto de dados de falhas em rolamentos que será utilizado representa uma compilação de informações sobre problemas em rolamentos, elaborada pela Case Western Reserve University, (2020) para fins de pesquisa. Este repositório é amplamente adotado nos estudos direcionados à detecção de falhas em rolamentos, estabelecendo-se como uma referência para o desenvolvimento e aprimoramento das técnicas de análise de anomalias em sistemas de rolamentos.

O banco de dados engloba registros de vibrações de rolamentos aprovados em diferentes estados de falha. Essas falhas foram deliberadamente geradas por meio do processo de usinagem eletroerosiva, afetando os componentes essenciais dos rolamentos, como os elementos rolantes e os trilhos internos e externos.

Conforme ilustrado na Figura 8 a bancada de testes é composta por um motor de 2 hp à esquerda, um transdutor/codificador de torque no centro, um dinamômetro à direita e um controle eletrônico (não visível). Os rolamentos de teste suportam o eixo do motor. Para simular falhas, foram fornecidas falhas pontuais nos rolamentos por meio de um processo chamado usinagem de descarga elétrica. Essas falhas têm diâmetros diferentes, variando de 7 mils a 40 mils (sendo 1 mil = 0,001 polegadas). Mais detalhes sobre a profundidade das falhas podem ser encontrados nas especificações de falha.

Figura 8. Bancada de teste de rolamento



Fonte: (CWRU, 2008)

Falhas com diâmetros de 7, 14 e 21 mils foram induzidas utilizando rolamentos SKF, enquanto falhas com diâmetros de 28 e 40 mils foram simuladas utilizando rolamentos equivalentes da NTN. As informações específicas sobre os rolamentos nas extremidades do acionador e do ventilador, como geometria e frequências de defeitos, estão minuciosamente documentadas nas especificações do rolamento.

A bancada de teste também inclui rolamentos na extremidade do acionamento (DE) e na extremidade do ventilador (FE) do motor. Os rolamentos utilizados possuem diâmetro interno de 25 mm, diâmetro externo de 52 mm e largura de 15 mm. Para representar os dados do sinal de vibração em condição de funcionamento faltoso, falhas de ponto único foram artificialmente induzidas através de eletro-descarga (EDM) com diâmetros de falha de 0,18 a 0,71 mm. As cargas aplicadas ao motor durante o teste variaram de 0 a 3 HP, com velocidade aproximadas de 1720 a 1797 rpm.

Os dados de vibração foram coletados através de acelerômetros com bases magnéticas fixados ao invólucro dos rolamentos DE e FE. Os dados foram coletados por 10 segundos com duas frequências de amostragem, 1000 amostras por segundo e 48000 amostras por segundo, e foram processados no MATLAB. No conjunto de dados completo estão disponíveis os dados de vibração dos rolamentos DE e FE para as condições normal (N), falha na pista interna (IF), falha na pista externa (OF) e falha do elemento rolante (BF), nas diversas condições de funcionamento.

Neste estudo foram escolhidos os dados de vibração do rolamento na extremidade do acionamento (DE) amostrados a 48000 amostras por segundo, a uma carga aplicada de 0 HP, com velocidade de rotação de 1797 RPM, em condição de funcionamento normal (N); Inner Race (IF) com diâmetro de 0,007, 0,014 e 0,021; Ball (B) com diâmetro de 0,007, 0,014 e 0,021 e Outer Race (OR) de 0,007, 0,014 e 0,021, como pode ser visto na Tabela 4 .

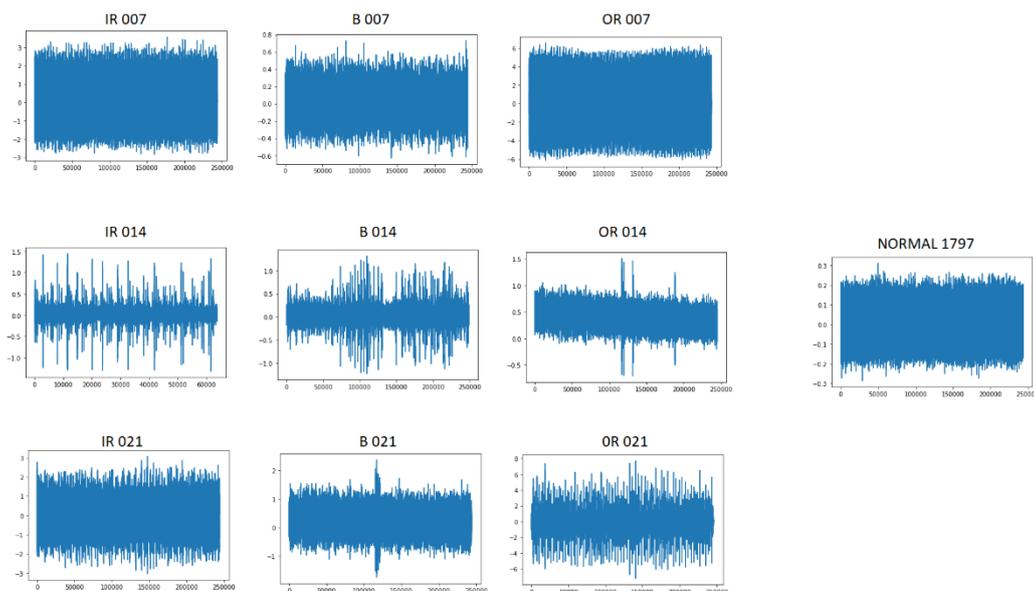
Tabela 4. Simulação de falhas na Bancada de teste CWRU

Modo de Falha	Diâmetro de Falha Inserida
Dados saudáveis	0
Falha de pista interna do rolamento	0.007; 0,014; 0,021
Falha de pista externa do rolamento	0.007; 0,014; 0,021
Falha no elemento rolante	0.007; 0,014; 0,021

Fonte: (CWRU, 2008)

A Figura 9 é composta por 10 gráficos, cada um representando a evolução temporal da variável DE para cada modo de falha. Isso pode fornecer uma análise visual rápida e comparativa do comportamento dessa variável em diferentes situações identificadas pelos rótulos.

Figura 9. Amostra dos sinais das classes



Fonte: Autor, 2023

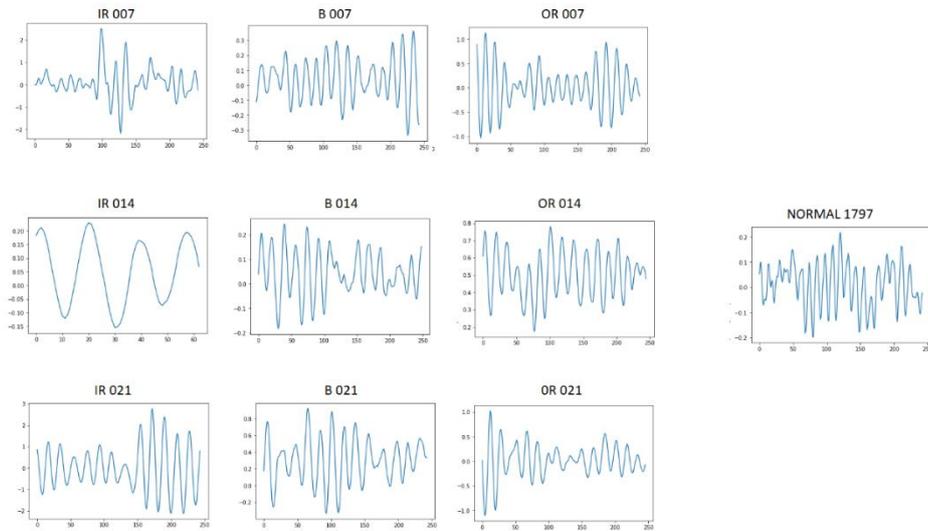
O processo de preparação dos dados para aplicação no modelo envolveu o manuseio de arquivos. mat., cada um contendo informações específicas sobre diferentes modos de falha em máquinas rotativas, como 'B007', 'B014', 'B021', 'Normal', 'IR007', 'IR014', 'IR021', 'OR007', 'OR014', 'OR021'. Cada categoria representava uma condição operacional ou um tipo de falha na máquina. Utilizando a biblioteca SciPy em Python, o código carregou os dados dos arquivos Matlab correspondentes a cada categoria e extraiu a variável associada ao sinal vibratório em um ponto específico da máquina. Posteriormente, esses dados foram convertidos para o formato CSV para facilitar a manipulação e aplicação em algoritmos de aprendizado de máquina. Em seguida, os dados são trabalhados de forma distintas a depender se a aplicação for em ML (Seção 4.2) ou CNN (Seção 4.3).

4.2 PREPARAÇÃO PARA OS MODELOS DE ML

Com intuito de facilitar a compreensão dos dados do CWRU, uma comparação entre os modelos é realizada considerando métricas como precisão, recall e f1-score. A precisão mede a proporção de exemplos positivos corretamente classificados, o recall mede a proporção de exemplos positivos corretamente identificados e o F1-score combina essas métricas em uma única medida, fornecendo um equilíbrio entre precisão e recall, as mesmas auxiliam na escolha do modelo mais adequado para o diagnóstico de falhas. A realização desses testes é mais interpretável e são menos computacionalmente intensivos que os modelos de CNN.

Aqui, foi desenvolvido um DataFrame que sintetiza características derivadas dos dados originais do banco CWRU. Esse DataFrame resume informações por rótulo de falha, considerando intervalos de 1000 amostras (Figura 10), e inclui resultados da extração de 10 características estatísticas: máximo, mínimo, média, desvio padrão, *root mean square* (RMS), assimetria, curtose, *crest factor*, *form* e *fault*. Dentre estes, pode-se definir o *crest fator* como uma métrica que enfoca a relação entre valor de pico e valor RMS, o *form* como uma métrica de forma relacionada com a divisão do RMS pela média da intensidade do sinal analisado, e o *fault*, que avalia a resiliência de sistemas em face de falhas ou perturbações. Em seguida, esse conjunto de dados foi utilizado para avaliar os modelos, permitindo a comparação de métricas.

Figura 10. Amostra dos sinais das classes (amostra com recorte de 1000)



Fonte: Autor, 2023

No código utilizado, os conjuntos de treinamento e teste são criados usando a função `train_test_split` da biblioteca `scikit-learn`. Aqui estão os valores específicos utilizados para treinamento e teste na Figura 11 abaixo.

Figura 11. Recorte do Código para Treinamento e Teste

```
# Carregar e processar dados
data_time = pd.read_csv('C:/Users/Eggleston/Desktop/CWRU.48/feature_48k.csv')

# Divisão dos dados em treino e teste
train_data, test_data = train_test_split(data_time, test_size=690, stratify=data_time['fault'], random_state=1234)

# Dimensionamento
scaler = StandardScaler()
train_data_scaled = scaler.fit_transform(train_data.iloc[:, :-1])
test_data_scaled = (test_data.iloc[:, :-1].values - scaler.mean_) / np.sqrt(scaler.var_)
```

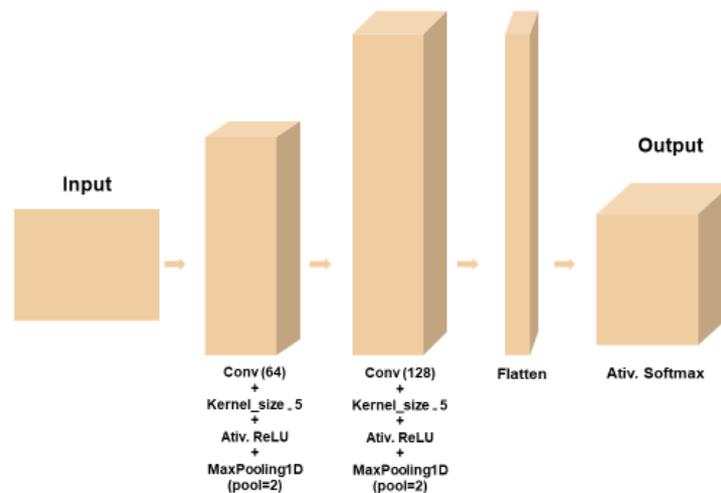
Fonte: Autor, 2023

Aqui, 690 amostras serão utilizadas como conjunto de teste (30%), e o restante (70%) será usado como conjunto de treinamento. A opção `stratify = data_time ['fault']` garante que a divisão seja estratificada com base na categoria de falha ('fault'). O `random_state = 1234` é uma semente para a reprodução dos resultados, garantindo consistência nos resultados quando o código é executado várias vezes. Portanto, o conjunto de treinamento consistirá na maioria das amostras, enquanto o conjunto de teste terá 690 amostras.

4.3 PREPARACAO PARA O MÉTODO CNN

Devido ao fato do CNN já possuírem uma extração de características intrínseca, aqui os dados brutos podem ser considerados diretamente. Os dados foram estratificados em conjuntos de treinamento e teste, reservando 70% para treinar o modelo e 30% para avaliar sua performance em dados não vistos. Abaixo, na Figura 12, segue a arquitetura do modelo.

Figura 12. Arquitetura do modelo CNN



Fonte: Autor, 2023

Especificamente, a arquitetura da CNN desenvolvida possui duas camadas convolucionais. A primeira camada possui 64 filtros e um kernel de tamanho 5, enquanto a segunda camada possui 128 filtros e também um kernel de tamanho 5. Ambas as camadas utilizam a função de ativação ReLU. A escolha dessa função de ativação, conforme sugerido por Albawi et al. (2017), visa otimizar o treinamento, garantindo uma velocidade substancialmente maior sem sacrificar a precisão. Entre essas camadas convolucionais, foram inseridas camadas de normalização em lote para regularizar os Outputs. Uma camada de Dropout com uma taxa de 0.5 foi adicionada para prevenir Overfitting, seguida por uma camada de Max Pooling (tamanho de pool 2) para redução de dimensionalidade.

Os dados são então achatados por uma camada Flatten, preparando o caminho para duas camadas densas. A primeira camada densa possui 128 neurônios e ativação ReLU, enquanto a camada de saída é densa, com neurônios equivalentes às classes e ativação Softmax para a tarefa de classificação multiclasse. A rede é compilada com a função de perda "categorical_crossentropy" e otimizador "adam", e é Treinada por 40 épocas com Batch Size 16. Este processo configura uma CNN eficaz para a análise de falhas em máquinas rotativas.

5. RESULTADOS

Este capítulo é dedicado a descrever a implementação da metodologia proposta e avaliar os resultados e eficácia dos modelos. Aqui, as performances dos modelos de ML são comparadas e, em seguida, são apresentados os resultados do modelo de CNN.

5.1 COMPARAÇÃO ENTRE OS MODELOS DE ML

Os resultados das métricas de avaliação dos modelos SVM, Regressão Logística, MLP, Random Forest na Tabela 5 refletem o desempenho de quatro modelos de ML (SVM, Regressão Logística, MLP e Random Forest) em relação a métricas cruciais: Precision, Recall, F1-score e acurácia dos modelos.

Tabela 5. Métricas dos modelos SVM, Regressão Logística, MLP, Random Forest

	Precision	Recall	F1-score	Precision	Recall	F1-score	Precision	Recall	F1-score	Precision	Recall	F1-score
	SVM			REGRESSÃO LOGÍSTICA			MLP			RANDOM FOREST		
Ball_007	0.94	0.99	0.96	0.91	0.99	0.94	0.93	1.00	0.97	0.97	0.96	0.96
Ball_014	0.94	0.88	0.91	0.87	0.77	0.82	0.92	0.83	0.87	0.93	0.91	0.92
Ball_021	0.98	0.91	0.95	0.91	0.86	0.88	0.95	0.91	0.93	0.93	0.9	0.91
IR_007	0.99	1.00	0.99	0.99	1.00	0.99	0.99	1.00	0.99	1.00	1.00	1.00
IR_014	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
IR_021	1.00	1.00	1.00	0.99	1.00	0.99	1.00	1.00	1.00	1.00	0.99	0.99
Normal_1797	0.97	1.00	0.99	0.92	0.97	0.94	0.94	0.97	0.96	1.00	1.00	1.00
OR_007	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	0.99	1.00	0.99
OR_014	0.85	0.88	0.87	0.86	0.86	0.86	0.86	0.9	0.88	0.85	0.9	0.87
OR_021	0.99	0.99	0.99	0.99	0.99	0.99	1.00	0.99	0.99	0.99	0.99	0.99
Accuracy			0.97			0.94			0.96			0.96
Macro avg	0.97	0.97	0.97	0.94	0.94	0.94	0.96	0.96	0.96	0.96	0.96	0.96
Weighted avg	0.97	0.97	0.97	0.94	0.94	0.94	0.96	0.96	0.96	0.96	0.96	0.96

Fonte: Autor, 2023

Inicialmente, ao avaliar a classe "Ball_007", é possível notar que o SVM e a MLP alcançaram bons resultados, com valores altos precisão, recall e F1-score, indicando uma capacidade consistente de identificar corretamente instâncias positivas. Em contrapartida, a classe "Ball_014" revela que o SVM e a Random Forest superam os demais modelos, destacando uma capacidade mais robusta de equilibrar precisão e recall. Notavelmente, a classe "IR_021" evidencia uma diferença significativa entre os modelos, com a Random Forest superando a MLP em recall, enquanto a MLP supera em precisão, ilustrando trade-offs entre esses indicadores cruciais.

Ao analisar as classes relacionadas a objetos "IR" e "OR", verifica-se um desempenho elevado em todas as métricas, como é o caso do "IR_O14" e o "OR_007", indicando uma forte capacidade dos modelos em lidar com essas categorias específicas. A classe "Normal_1797" também destaca resultados consistentes em todos os modelos, indicando uma alta capacidade de generalização para casos normais. A análise global, por meio das métricas de Accuracy, Macro avg e Weighted avg, reforça a consistência do desempenho dos modelos. Todos os modelos apresentam pontuações altas, com a Random Forest e o SVM liderando em termos de precisão média e recall médio, sugerindo uma abordagem balanceada na classificação de todas as classes.

A análise das matrizes de confusão revela resultados detalhados sobre o desempenho de quatro modelos SVM, regressão logística, MLP e RandomForest na classificação de falhas em máquinas rotativas (Tabela 6). No caso do SVM, tanto nos conjuntos de treinamento quanto de teste, a alta concordância entre previsões e classes verdadeiras destaca sua consistência e capacidade de generalização, apoiadas por sólidos resultados de precisão, recall e F1-score. A regressão logística, focando em previsões corretas, exibe um bom desempenho geral, com algumas confusões entre classes.

O MLP, com altas pontuações de precisão e recall, mostra habilidade notável em prever diferentes classes, mantendo baixos falsos positivos e falsos negativos, indicando consistência e generalização eficaz no conjunto de teste. Por fim, o modelo RandomForest, ao atingir precisão perfeita no treinamento e manter altas pontuações no teste, destaca-se pelo ajuste completo aos dados e robusta capacidade de classificação. Em síntese, cada modelo apresenta características distintas, proporcionando abordagens variadas, mas todos evidenciam promissor potencial no diagnóstico de falhas em máquinas rotativas.

Tabela 6. Matriz de confusão dos modelos SVM, Regressão Logística, MPL e Random Forest

Matrix de confusão SVM											Matrix de confusão Regressão Log.										
Ball_007	67	0	0	0	0	0	0	0	2	0	Ball_007	68	0	0	0	0	0	0	0	1	0
Ball_014	1	50	2	0	0	0	6	0	9	1	Ball_014	1	53	2	0	0	0	6	0	6	1
Ball_021	3	2	56	0	0	1	0	0	7	0	Ball_021	3	3	59	0	0	1	0	0	3	0
IR_007	0	0	0	69	0	0	0	0	0	0	IR_007	0	0	0	69	0	0	0	0	0	0
IR_014	0	0	0	0	69	0	0	0	0	0	IR_014	0	0	0	0	69	0	0	0	0	0
IR_021	0	0	0	0	0	69	0	0	0	0	IR_021	0	0	0	0	0	69	0	0	0	0
OR_007	0	2	0	0	0	0	67	0	0	0	OR_007	0	2	0	0	0	0	67	0	0	0
OR_014	0	0	0	0	0	0	0	69	0	0	OR_014	0	0	0	0	0	0	0	69	0	0
OR_021	2	3	1	0	0	0	0	0	63	0	OR_021	3	3	4	0	0	0	0	0	59	0
Normal	0	0	0	1	0	0	0	0	0	68	Normal	0	0	0	1	0	0	0	0	0	68
Matrix de confusão MPL											Matrix de confusão Random Forest										
Ball_007	69	0	0	0	0	0	0	0	0	0	Ball_007	66	0	0	0	0	0	0	0	3	0
Ball_014	1	57	2	0	0	0	4	0	5	0	Ball_014	1	63	1	0	0	0	4	0	4	1
Ball_021	1	0	63	0	0	0	0	0	5	0	Ball_021	1	3	62	0	0	0	0	0	4	0
IR_007	0	0	0	69	0	4	0	0	0	0	IR_007	0	0	0	69	0	4	0	0	0	0
IR_014	0	0	0	0	69	0	0	0	0	0	IR_014	0	0	0	0	69	0	0	0	0	0
IR_021	0	0	0	0	0	69	0	0	0	0	IR_021	0	0	1	0	0	68	0	0	0	0
OR_007	0	2	0	0	0	0	67	0	0	0	OR_007	0	0	0	0	0	0	69	0	0	0
OR_014	0	0	0	0	0	0	0	69	0	0	OR_014	0	0	0	0	0	0	0	69	0	0
OR_021	3	3	1	0	0	0	0	0	62	0	OR_021	2	2	3	0	0	0	0	0	62	0
Normal	0	0	0	1	0	0	0	0	0	68	Normal	0	0	0	0	0	0	0	1	0	68

Fonte: Autor, 2023

5.2 APLICANDO O MODELO CNN

Finalmente, a entrada para a CNN foi moldada em tensores incorporando as dimensões temporal e permitindo que a rede neural explorasse padrões no sinal, contribuindo para um diagnóstico preciso das máquinas rotativas.

Ao longo de 40 épocas de treinamento, o modelo atingiu uma acurácia de 90% nos dados de teste como pode ser vista na Tabela 6. As métricas de precisão, recall e f1-score variaram consideravelmente por classe, destacando a capacidade da CNN em distinguir entre diferentes tipos de falhas.

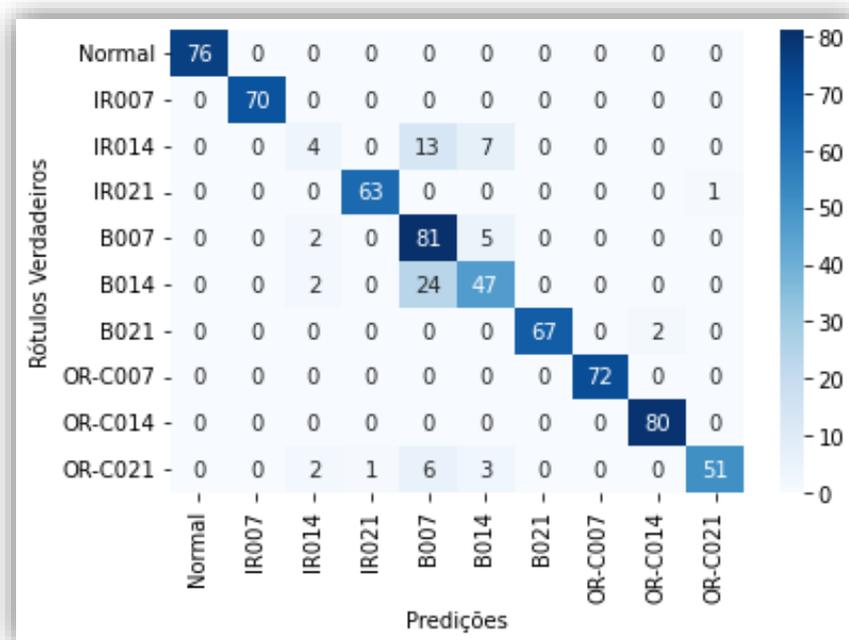
Tabela 7. Métricas do modelo CNN

	Precision	Recall	F1-score
Normal_1797	1.00	1.00	1.00
IR_007	1.00	1.00	1.00
IR_014	0.4	0.17	0.24
IR_021	0.98	0.98	0.98
Ball_007	0.65	0.92	0.76
Ball_014	0.76	0.64	0.7
Ball_021	1.00	0.97	0.99
OR_007	1.00	1.00	1.00
OR_014	0.98	1.00	0.99
OR_021	0.98	0.81	0.89
Accuracy			0.9
Macro avg	0.88	0.85	0.85
Weighted avg	0.9	0.9	0.89

Fonte: Autor, 2023

Algumas classes, como 'Normal_1797', 'IR_007' e 'OR_C007' tiveram resultados perfeitos, com precisão, recall e F1-score de 1.00, alcançaram pontuações notáveis, enquanto outras apresentaram desafios, evidenciando possíveis áreas de melhoria. A análise do relatório de classificação revela a capacidade variada do modelo em lidar com diferentes classes. Classes majoritárias, como 'IR_021' e 'Ball_021', demonstraram precisão e recall mais elevados, sugerindo uma capacidade robusta de identificação. No entanto, classes minoritárias, como 'Ball_007' e 'Ball_014', apresentaram pontuações mais modestas, indicando desafios na detecção dessas falhas específicas.

O método CNN se destaca pela capacidade de aprender padrões espaciais em dados multidimensionais, como séries temporais. No entanto, sua complexidade e sensibilidade aos hiperparâmetros podem exigir ajustes finos para otimizar o desempenho. Na Tabela 7, e apresentada a matriz de confusão do modelo em questão.

Tabela 8. Matriz de confusão do modelo CNN

Fonte: Autor, 2023

As classes "NORMAL" e "IR007" tiveram um desempenho especialmente bom, com todas as instâncias sendo corretamente classificadas. No entanto, algumas classes, como "IR014" e "OR-C021", tiveram um número maior de falsos positivos e falsos negativos, resultando em uma precisão e recall mais baixos. Isso sugere que o modelo pode ter dificuldade em distinguir essas classes de outras, e pode se beneficiar de ajustes adicionais para melhorar o desempenho nessas áreas específicas.

Ao analisar a diagonal principal da matriz de confusão, que representa os verdadeiros positivos para cada classe, podemos concluir que o modelo teve um desempenho bastante satisfatório na classificação das classes "NORMAL", "IR007", "IR021", "B007", "B021", "OR-C007" e "OR-C014". No entanto, outras classes, como "IR014", "B014" e "OR-C021" apresentaram alguns falsos positivos e falsos negativos, indicando que o modelo pode ter dificuldade em distinguir essas classes de outras. Essas observações destacam áreas específicas que podem ser aprimoradas para fortalecer a capacidade do modelo de distinguir entre diferentes tipos de falhas em máquinas rotativas.

Uma análise mais aprofundada das métricas individuais, como precisão, recall e F1-score para cada classe, pode fornecer insights adicionais sobre os pontos fortes e fracos do modelo. Ao comparar os resultados das métricas dos modelos SVM, regressão logística, MLP

e RandomForest com o método CNN, observa-se que o CNN apresentou uma acurácia inferior em relação aos outros modelos. Enquanto SVM, regressão logística, MLP e RandomForest atingiram acurácias consistentes em torno de 94% a 97%, o CNN registrou uma acurácia de 90%. A acurácia menor do CNN em comparação com outros modelos pode indicar a necessidade de ajustes e otimizações. O desempenho do CNN pode ser sensível a vários hiperparâmetros, como arquitetura da rede, taxa de aprendizado e número de épocas de treinamento. Além disso, técnicas como aumento de dados durante o treinamento e ajustes na complexidade da rede podem ser exploradas para aprimorar a capacidade do CNN na detecção de falhas em máquinas rotativas.

6. CONCLUSÃO

Este trabalho realizou um estudo dos principais conceitos que envolvem a manutenção preditiva, destacando-se o uso de técnicas de inteligência artificial para aplicação no diagnóstico de defeitos em máquinas rotativas. Dessa maneira, este estudo pode fornecer uma base para a comunidade de pesquisa e profissionais envolvidos em manutenção preditiva. Foi analisado a detecção de falhas rotativas dos rolamentos, através de cinco métodos diferentes - SVM, Regressão Logística, MLP, Random Forest, e a aplicação do método CNN. Para isso, foram processados e analisados os dados da base CWRU. Os modelos foram avaliados utilizando métricas como Precision, Recall e F1-score para cada classe, bem como métricas globais como Accuracy, Macro avg e Weighted avg. A análise das matrizes de confusão proporcionou insights detalhados sobre o desempenho na classificação de cada classe, destacando a consistência e eficácia dos modelos.

O SVM demonstrou uma performance sólida, com boa performance em todas as métricas e uma matriz de confusão revelando previsões precisas para diversas classes. A regressão logística não teve um bom desempenho quando comparada com as demais ML, o que pode ser justificável devido à sua natureza linear, que pode não capturar adequadamente padrões complexos e não lineares nos dados de detecção de falhas em máquinas rotativas. Os resultados obtidos para o MLP e o Random Forest revelam desempenhos bons em termos de acurácia e métricas agregadas, sugerindo uma consistente capacidade de lidar com as diversas classes do conjunto de dados. Já o modelo de CNN testado aqui não apresentou resultados tão favoráveis comparado aos modelos de ML. A performance menor do modelo CNN, pode ser atribuída à escassez de camadas em sua arquitetura, que, apesar de aumentar o custo computacional, pode reconhecer padrões mais complexos no final, ou ponto é que provavelmente o aumento de dados melhoraria o desempenho da CNN.

Como desdobramentos desta pesquisa, considera-se comparação das performances de modelos mais profundos (adição de mais camadas), e consideração de outros modelos de DL, com as redes neurais recorrentes. Outras alternativas incluem a diversificação das bases de dados, indo além da CWRU, e a aplicação de técnicas avançadas de pré-processamento, como wavelets e EMD, para melhorar as capacidades diagnósticas do modelo. Essas estratégias representam direções promissoras para fortalecer a eficácia da CNN no diagnóstico de falhas em máquinas rotativas.

REFERÊNCIAS

- ACHOUCH, M., DIMITROVA, M., DHOUB, R., IBRAHIM, H., ADDA, M., SATTARPANAH KARGANROUDI, S., ZIANE, K., & AMINZADEH, A. (2023a). Predictive Maintenance and Fault Monitoring Enabled by Machine Learning: Experimental Analysis of a TA-48 Multistage Centrifugal Plant Compressor. *Applied Sciences* (Switzerland), 13(3). <https://doi.org/10.3390/app13031790>
- ALBAWI, SAAD & ABED MOHAMMED, TAREQ & ALZAWI, SAAD. (2017). Understanding of a Convolutional Neural Network. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>.
- ALTHUBAITI, A., ELASHA, F., & TEIXEIRA, J. A. (2022). Fault diagnosis and health management of bearings in rotating equipment based on vibration analysis – a review. *Journal of Vibroengineering*, 24(1), 46–74. <https://doi.org/10.21595/jve.2021.22100>
- BARAN, L. R., & TROJAN, F. (N.D.). Manutenção centrada em confiabilidade (mcc) aplicada na redução das falhas funcionais em um sistema de tensionamento. <http://repositorio.utfpr.edu.br/jspui/handle/1/23471>
- BEN ALI, J., CHEBEL-MORELLO, B., SAIDI, L., MALINOWSKI, S., & FNAIECH, F. (2015). Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network. *Mechanical Systems and Signal Processing*, 56, 150–172. <https://doi.org/10.1016/j.ymssp.2014.10.014>
- BENTLY, D. E.; HATCH, C. T. Fundamentals of rotating machinery diagnostics. Bently Pressurized Bearing Company, Minden, NV, USA, 2002.
- BEZERRA, R. A. “Detecção de falhas em rolamentos por análise de vibração”. D.Sc. Thesis, FEM, Universidade Estadual de Campinas, Campinas, Brasil, 2004.
- CASE WESTERN RESERVE UNIVERSITY. Apparatus & Procedures | Case School of Engineering Case Western Reserve University. 2020. Disponível em: <<https://engineering.case.edu/bearingdatacenter/apparatus-and-procedures>>. Acesso em: 30 jan.2024.
- CELIBERTO, L. A., MARTINS, M. F., BIANCHI, R. A. C., & MATSUURA, J. P. (N.D.). Utilizando Transferência De Conhecimento Para Acelerar O Aprendizado Por Reforço. *Reforço*.
- DING, X., WANG, L., HUANG, W., HE, Q., & SHAO, Y. (2020). Feature Clustering Analysis Using Reference Model towards Rolling Bearing Performance Degradation Assessment. *Shock and Vibration*, 2020. <https://doi.org/10.1155/2020/6306087>
- DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern classification. [S.l.]: John Wiley & Sons, 2012.
- GOODFELLOW, I. J., POUGET-ABADIE, J., MIRZA, M., XU, B., WARDE-FARLEY, D., OZAIR, S., COURVILLE, A., & BENGIO, Y. (2014). *Generative Adversarial Networks*. <http://arxiv.org/abs/1406.2661>

GUO, X., CHEN, L., & SHEN, C. (2016). Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis. *Measurement: Journal of the International Measurement Confederation*, 93, 490–502. <https://doi.org/10.1016/j.measurement.2016.07.054>

HAN, J., KAMBER, M., & PEI, J. (2011). *Data Mining. Concepts and Techniques*, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems).

JANSSENS, O., SLAVKOVIKJ, V., VERVISCH, B., STOCKMAN, K., LOCCUFIER, M., VERSTOCKT, S., VAN DE WALLE, R., & VAN HOECKE, S. (2016). Convolutional Neural Network Based Fault Detection for Rotating Machinery. *Journal of Sound and Vibration*, 377, 331–345. <https://doi.org/10.1016/j.jsv.2016.05.027>

JARDINE, ANDREW KS, DAMING LIN, AND DRAGAN BANJEVIC. "A review on machinery diagnostics and prognostics implementing condition-based maintenance." *Mechanical systems and signal processing* 20.7 (2006): 1483-1510. <https://doi.org/10.1016/j.ymsp.2005.09.012>

JEONG, H., PARK, S., WOO, S., & LEE, S. (2016). Rotating Machinery Diagnostics Using Deep Learning on Orbit Plot Images. *Procedia Manufacturing*, 5, 1107–1118. <https://doi.org/10.1016/j.promfg.2016.08.083>

JOHNSON, K. B., FERGUSON, D. H., TEMPKE, R. S., & NIX, A. C. (2021). Application of a Convolutional Neural Network for Wave Mode Identification in a Rotating Detonation Combustor Using High-Speed Imaging. *Journal of Thermal Science and Engineering Applications*, 13(6). <https://doi.org/10.1115/1.4049868>

KATTI FACELI, A. C. L. J. G. A. C. P. L. F. DE C. (2011). *Inteligência Artificial Uma Abordagem de Aprendizado de Máquina* (LTC).

KRIZHEVSKY, A., SUTSKEVER, I., & HINTON, G. E. (N.D.). *ImageNet Classification with Deep Convolutional Neural Networks*. <http://code.google.com/p/cuda-convnet/>
LAURO XAVIER NEPOMUCENO. (2018). *Técnica da manutenção preditiva* (Editora Edgard Ltda, Vol. 1).

LECUN, Y., BENGIO, Y., & HINTON, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>.

LEE, YONG & KIM, BOK-KYUNG & BAE, JUN-HEE & KIM, KYUNG. (2021). Misalignment Detection of a Rotating Machine Shaft Using a Support Vector Machine Learning Algorithm. *International Journal of Precision Engineering and Manufacturing*. 22. 10.1007/s12541-020-00462-1.

LEI, Y., LI, N., GONTARZ, S., LIN, J., RADKOWSKI, S., & DYBALA, J. (2016). A Model-Based Method for Remaining Useful Life Prediction of Machinery. *IEEE Transactions on Reliability*, 65(3), 1314–1326. <https://doi.org/10.1109/TR.2016.2570568>

LEMLEY, J., BAZRAFKAN, S., & CORCORAN, P. (2017). Deep Learning for Consumer Devices and Services: Pushing the limits for machine learning, artificial intelligence, and

computer vision. *IEEE Consumer Electronics Magazine*, 6(2), 48–56. <https://doi.org/10.1109/MCE.2016.2640698>

LI, N., LEI, Y., LIN, J., & DING, S. X. (2015). An Improved Exponential Model for Predicting Remaining Useful Life of Rolling Element Bearings. *IEEE Transactions on Industrial Electronics*, 62(12), 7762–7773. <https://doi.org/10.1109/TIE.2015.2455055>

LI, X., ZHANG, W., & DING, Q. (2019). Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering and System Safety*, 182, 208–218. <https://doi.org/10.1016/j.res.2018.11.011>

LI, Z., WANG, Y., & WANG, K. (2019). A deep learning driven method for fault classification and degradation assessment in mechanical equipment. *Computers in Industry*, 104, 1–10. <https://doi.org/10.1016/j.compind.2018.07.002>

LIPTON, Z. C., KALE, D. C., ELKAN, C., & WETZEL, R. (2015). Learning to Diagnose with LSTM Recurrent Neural Networks. <http://arxiv.org/abs/1511.03677>

LUCCA, G., PEREIRA, I. A., PRISCO, A., & BORGES, E. N. (N.D.). Uma implementação do algoritmo Naïve Bayes para classificação de texto. <http://mallet.cs.umass.edu>,

MA, M., & MAO, Z. (2021). Deep wavelet sequence-based gated recurrent units for the prognosis of rotating machinery. *Structural Health Monitoring*, 20(4), 1794–1804. <https://doi.org/10.1177/1475921720933155>

MAASOUM, S. M. H., MOSTAFAVI, A., & SADIGHI, A. (2020, December 23). An Autoencoder-Based Algorithm for Fault Detection of Rotating Machines, Suitable for Online Learning and Standalone Applications. 6th Iranian Conference on Signal Processing and Intelligent Systems, ICSPIS 2020. <https://doi.org/10.1109/ICSPIS51611.2020.9349574>

MACHINE TRANSLATED BY GOOGLE. (2002). www.bpb-co.com

MAO, W., HE, J., FENG, W., & TIAN, S. (2019). Bearing Fault Diagnosis Based on Multi-task Learning. *Proceedings - 2018 Prognostics and System Health Management Conference, PHM-Chongqing 2018*, 358–363. <https://doi.org/10.1109/PHM-Chongqing.2018.00067>

MOHSIN ABDULAZEEZ, A., ZEEBAREE, D., ABDULQADER, D. M., & ZEEBAREE, D. Q. (2020). Machine Learning Supervised Algorithms of Gene Selection: A Review Gait recognition with wavelet transform View project Deep Learning View project Machine Learning Supervised Algorithms of Gene Selection: A Review (Vol. 62). <https://www.researchgate.net/publication/341119469>

NACCHIA, M., FRUGGIERO, F., LAMBIASE, A., & BRUTON, K. (2021). A systematic mapping of the advancing use of machine learning techniques for predictive maintenance in the manufacturing sector. In *Applied Sciences (Switzerland)* (Vol. 11, Issue 6). MDPI AG. <https://doi.org/10.3390/app11062546>

QIAN, W., LI, S., WANG, J., XIN, Y., & MA, H. (2019). A New Deep Transfer Learning Network for Fault Diagnosis of Rotating Machine under Variable Working Conditions.

Proceedings - 2018 Prognostics and System Health Management Conference, PHM-Chongqing 2018, 1010–1016. <https://doi.org/10.1109/PHM-Chongqing.2018.00180>

QIU, H., LEE, J., LIN, J., & YU, G. (2003). Robust performance degradation assessment methods for enhanced rolling element bearing prognostics. *Advanced Engineering Informatics*, 17(3–4), 127–140. <https://doi.org/10.1016/j.aei.2004.08.001>

RUSSELL, STUART; NORVIG, PETER. *Artificial intelligence: a modern approach*. 2002.

SALES DA CUNHA, BEATRIZ, ET AL. "A comparison between computer vision-and deep learning-based models for automated concrete crack detection." *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability* 237.5 (2023): 994-1010. <https://doi.org/10.1177/1748006X221140966>

TREVISAN E MECÂNICO. (2011) *Utilização De Medições Ultrassônicas De Vibração E Da Emissão Acústica Para Implantação De Lubrificação Base-Condição Visando A Prevenção De Falhas Em Mancais De Rolamentos*. 2022.

VAN TUNG TRAN, BO-SUK YANG, *An intelligent condition-based maintenance platform for rotating machinery*, *Expert Systems with Applications*, Volume 39, Issue 3, 2012, Pages 2977-2988, ISSN 0957-4174. <https://doi.org/10.1016/j.eswa.2011.08.159>.

X. LI, M. LI, J. ZHENG E Y. HU, "Problemas e dicas: um conjunto de experimentos integrados de aplicação de codificador automático e rede neural convolucional na extração de recursos e diagnóstico de falhas", *Conferência de prognósticos e gerenciamento de integridade do sistema de 2018 (PHM-Chongqing)*, Chongqing, China, 2018, pp. <https://doi.org/10.1109/PHM-Chongqing.2018.00228>

XIN, Y., KONG, L., LIU, Z., CHEN, Y., LI, Y., ZHU, H., GAO, M., HOU, H., & WANG, C. (2018). *Machine Learning and Deep Learning Methods for Cybersecurity*. *IEEE Access*, 6, 35365–35381. <https://doi.org/10.1109/ACCESS.2018.2836950>

ZHANG, Y., LEI, Z., YU, H., & ZHUANG, L. (2022). *Imbalanced High-Resolution SAR Ship Recognition Method Based on a Lightweight CNN*. *IEEE Geoscience and Remote Sensing Letters*, 19. <https://doi.org/10.1109/LGRS.2021.3083262>