

DETECÇÃO DE FALHAS EM MOTORES TRIFÁSICOS UTILIZANDO DEEP LEARNING NA ANÁLISE DE VIBRAÇÕES

FAILURE DETECTION IN THREE-PHASE MOTORS USING DEEP LEARNING IN VIBRATION ANALYSIS

DETECCIÓN DE FALLOS EN MOTORES TRIFÁSICOS MEDIANTE APRENDIZAJE PROFUNDO EN ANÁLISIS DE VIBRACIONES

 <https://doi.org/10.56238/arev7n8-127>

Data de submissão: 13/07/2025

Data de publicação: 13/08/2025

David Alves Luna

Graduando em Engenharia de Software
Instituição: Universidade do Estado do Pará (UEPA)
E-mail: davidlunapocket@gmail.com
Lattes: <https://lattes.cnpq.br/3038576619445043>
Orcid: <https://orcid.org/0009-0008-9357-085X>

Thiago Nicolau Magalhães de Souza Conte

Doutor em Engenharia Elétrica, Computação Aplicada
Instituição: Universidade do Estado do Pará (UEPA)
E-mail: thiagoconte@uepa.br
Lattes: <http://lattes.cnpq.br/0783374325529116>
Orcid: <https://orcid.org/0000-0002-1288-366>

Wilker José Caminha dos Santos

Especialista em Engenharia de Sistemas
Instituição: Universidade do Estado do Pará (UEPA)
E-mail: wilker.caminha@uepa.br
Lattes: <http://lattes.cnpq.br/3314938287386016>
Orcid: <https://orcid.org/0000-0002-5265-583X>

Hugo Nicolau Magalhães de Souza Conte

Engenharia da Computação
Instituição: Universidade do Estado do Pará (UEPA)
E-mail: hugo.conte@uepa.br
Lattes: <http://lattes.cnpq.br/1994818574516226>
Orcid: <https://orcid.org/0009-0009-1790-3891>

Armando José de Sá Santos

Mestre em Ciência e Engenharia de Materiais
Instituição: Universidade do Estado do Pará (UEPA)
E-mail: armando.santos@uepa.br
Lattes: <http://lattes.cnpq.br/6286321140581380>
Orcid: <https://orcid.org/0000-0001-8242-6571>

Wanderson Alexandre da Silva Quinto
Doutor em Psicologia
Instituição: Universidade do Estado do Pará (UEPA)
E-mail: w.quinto@uepa.br
Lattes: <http://lattes.cnpq.br/4429230658129917>
Orcid: <https://orcid.org/0000-0002-1573-1370>

Airton Lima Marinho
Mestrando em Engenharia Elétrica - Computação Aplicada
Instituição: Universidade Federal do Pará
E-mail: airton.marinho@itec.ufpa.br
Lattes: <http://lattes.cnpq.br/5360953655195581>
Orcid: <https://orcid.org/0009-0005-5504-0899>

Rogério Santiago Lopes
Especialista em Engenharia de Controle e Automação Industrial
Instituição: Centro Universitário Católica do Tocantins (UniCatólica)
E-mail: rogeriosantiago08@gmail.com
Lattes: <http://lattes.cnpq.br/3096616845055990>
Orcid: <https://orcid.org/0000-0002-1954-6842>

RESUMO

Os motores de indução desempenham um papel fundamental no setor industrial, sendo necessário que sejam devidamente monitorados a fim de evitar paradas não programadas na produção. O monitoramento por vibração destaca-se no diagnóstico de condição desses motores, por sua eficácia na detecção de falhas, especialmente em rolamentos. Nesse trabalho, propõe-se o uso de técnicas Deep Learning para automatizar a detecção de falhas em rolamentos, por meio de uma análise comparativa entre modelos Long Short Memory (LSTM) e Convolutional Neural Network (CNN). Utilizando o conjunto de dados da Intelligent Maintenance System da universidade de Cincinnati (IMS), o modelo LSTM foi treinado com descritores estatísticos extraídos dos sinais de vibração, enquanto a CNN operou diretamente sobre os dados brutos. Os resultados demonstram a superioridade do modelo LSTM, que obteve 98% de acurácia, em comparação com a CNN, que alcançou 86%.

Palavras-chave: Análise de Vibração. Motor de Indução. Falhas em Rolamento.

ABSTRACT

Induction motors play a fundamental role in the industrial sector and require proper monitoring to avoid unscheduled production downtime. Vibration monitoring stands out in the condition diagnosis of these motors due to its effectiveness in detecting faults, especially in bearings. This work proposes the use of Deep Learning techniques to automate bearing fault detection through a comparative analysis between Long Short Memory (LSTM) and Convolutional Neural Network (CNN) models. Using the University of Cincinnati's Intelligent Maintenance System (IMS) dataset, the LSTM model was trained with statistical descriptors extracted from the vibration signals, while the CNN operated directly on the raw data. The results demonstrate the superiority of the LSTM model, which achieved 98% accuracy, compared to the CNN, which achieved 86%.

Keywords: Vibration Analysis. Induction Motor. Bearing Faults.

RESUMEN

Los motores de inducción desempeñan un papel fundamental en el sector industrial y requieren una monitorización adecuada para evitar paradas de producción no programadas. La monitorización de vibraciones destaca en el diagnóstico del estado de estos motores debido a su eficacia en la detección de fallos, especialmente en rodamientos. Este trabajo propone el uso de técnicas de aprendizaje profundo para automatizar la detección de fallos en rodamientos mediante un análisis comparativo entre los modelos de memoria de larga duración (LSTM) y redes neuronales convolucionales (CNN). Utilizando el conjunto de datos del Sistema de Mantenimiento Inteligente (IMS) de la Universidad de Cincinnati, el modelo LSTM se entrenó con descriptores estadísticos extraídos de las señales de vibración, mientras que la CNN operó directamente con los datos brutos. Los resultados demuestran la superioridad del modelo LSTM, que alcanzó una precisión del 98 %, en comparación con la CNN, que alcanzó el 86 %.

Palabras clave: Análisis de Vibraciones. Motor de Inducción. Fallos en Rodamientos.

1 INTRODUÇÃO

Os motores de indução desempenham um papel fundamental em diversos setores, sendo amplamente utilizados na indústria, em ambientes comerciais e até mesmo em residências. Essa popularidade se deve a características como robustez, custo reduzido e longa vida útil (Bahgat, 2024). No entanto, apesar de sua confiabilidade, esses motores não estão imunes a falhas, as quais podem gerar prejuízos significativos, especialmente quando resultam em paradas não planejadas na produção, impactando diretamente na produtividade e no lucro (Garcia-Calva *et al.*, 2022).

Diante deste cenário, medidas de manutenção preditiva têm sido cada vez mais adotadas, com objetivo de evitar falhas catastróficas e permitir a correção de anomalias antes que comprometam o funcionamento do equipamento. O monitoramento contínuo, por exemplo, permite identificar padrões de degradação e antecipar falhas, viabilizando ações corretivas planejadas e reduzindo o impacto das paradas (Junior *et al.*, 2023).

Em geral, as falhas em motores de indução podem ser classificadas em três estágios: falha incipiente, quando há degradação interna ainda sem sintomas perceptíveis; Falha desenvolvida, quando o desempenho do motor é afetado, falha catastrófica, é quando o motor torna-se incapaz de operar (Garcia-Calva *et al.*, 2022).

Entre as técnicas de monitoramento, a análise de vibração destaca-se, por sua eficácia na identificação de falhas em motores elétricos. No entanto, esse tipo de análise frequentemente depende da interpretação humana, o que pode se tornar inviável frente ao grande volume de dados e à sutileza de sinais associados a falhas incipientes, muitas vezes mascarados por ruídos (Ahmed; Nandi, 2020).

Dentre os tipos de falhas, as que ocorrem em rolamentos representam 40% do total em motores elétricos. Tais falhas são geralmente progressivas e podem ser evitadas com técnicas adequadas por vibração (Immovilli, F *et al.* 2012; Frosini, L 2020). Nesse contexto, técnicas de aprendizado de máquina, como redes neurais convolucionais (CNN) e redes neurais recorrentes com memória de longo e curto prazo (LSTM), têm demonstrado resultados promissores na automação do diagnóstico, com elevada precisão e capacidade de identificar anomalias de forma não supervisionada (SUN *et al.*, 2025).

O diagnóstico de falhas em rolamentos é, portanto, um campo amplamente explorado na literatura, com foco em métodos de processamento de sinais e algoritmos de aprendizagem de máquina. A análise adequada dos dados de vibração permite a identificação precoce de falhas, reduzindo significativamente o risco de paradas inesperadas (CERRADA *et al.*, 2018).

Neste contexto, o presente trabalho tem como objetivo comparar o desempenho de dois modelos, baseados *Deep learning* - um utilizando LSTM e o outro CNN aplicados à detecção de

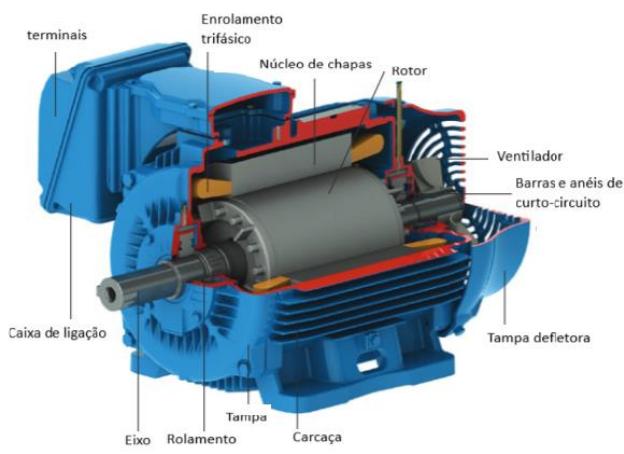
fallas em rolamentos dos motores elétricos. Para isso, são utilizados sinais de vibração provenientes do conjunto de dados do *Intelligent Maintenance Systems* (IMS).

2 FALHAS E PRINCÍPIO DE FUNCIONAMENTO DO MOTOR DE INDUÇÃO

Nos motores de indução, ao energizar o estator com uma corrente trifásica, gera-se no interior das bobinas um campo magnético rotativo de intensidade constante. O rotor, que fica, portanto, imerso num campo rotativo, geram-se correntes induzidas. Estas correntes, por sua vez, produzem um campo magnético que tentará se alinhar com o campo magnético girante do estator, produzindo torque e fazendo o rotor girar (Martignoni, 1978).

O motor de indução tem como constituição básica o estator e o rotor. O estator é a parte estática composta de chapas finas de aço magnético onde ficam alojadas as bobinas. E o rotor é a parte móvel composta também por chapas finas de aço magnético e com enrolamento alojados longitudinalmente (Silva, 2008). A Figura 1 representa as peças que compõem um motor trifásico do tipo gaiola de esquilo.

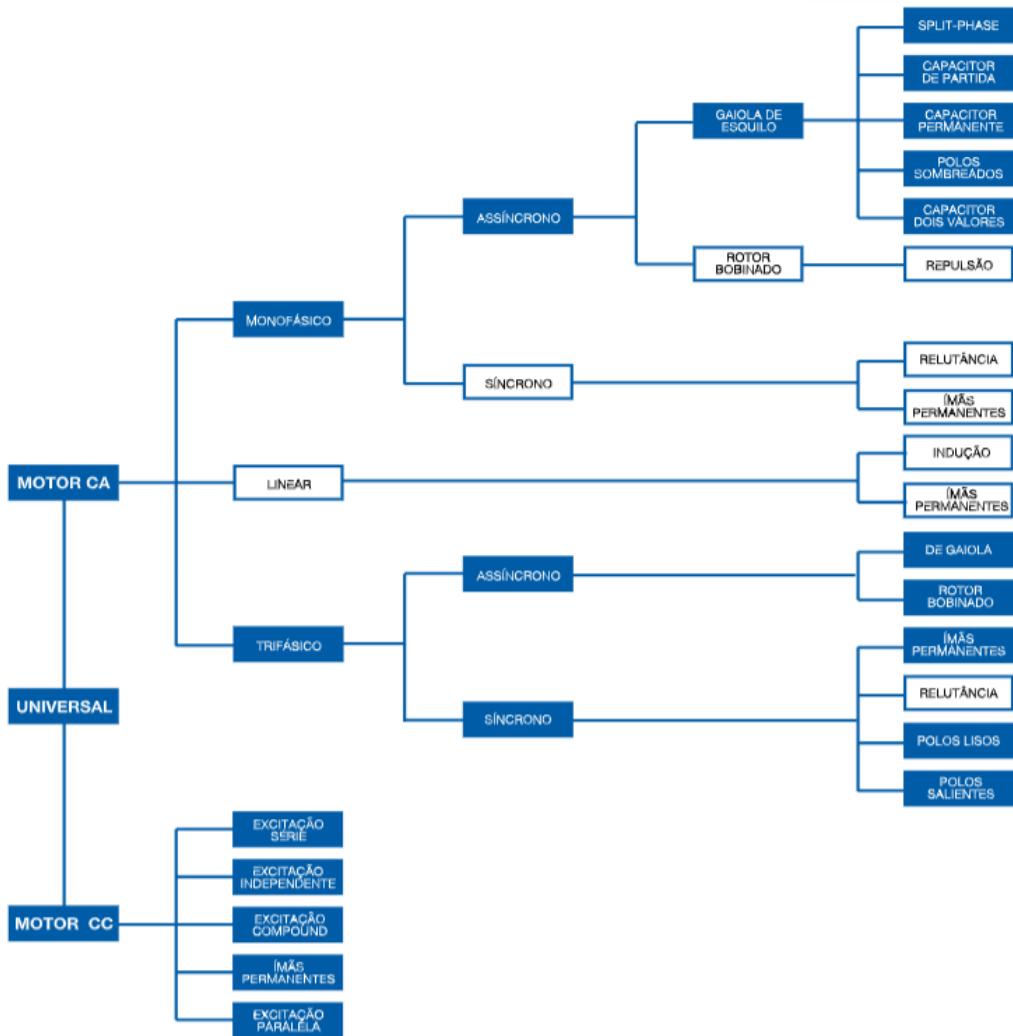
Figura 1. Esquema de uma motor de indução do tipo gaiola de esquilo



Fonte. Adaptado de Weg (2024)

Eles podem ser divididos em dois tipos principais: Monofásico e trifásico. Os motores monofásicos são geralmente utilizados em ambientes comerciais ou residenciais onde são utilizados em situações de menor potência, como pequenos equipamentos industriais e eletrodomésticos. Os motores trifásicos são comuns em ambientes industriais, onde operam em sistemas de alta potência (Cabrera, 2013). Na Figura 2, é ilustrada a classificação dos motores elétricos.

Figura 2. Classificação de motores



Fonte. Weg, 2024

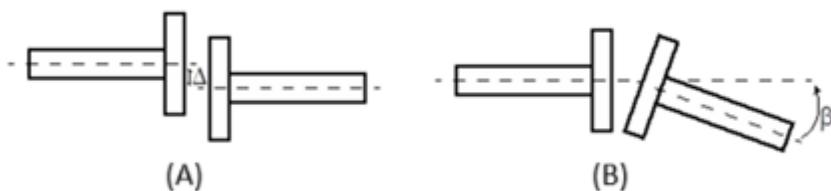
As falhas mais comuns em motores de indução que causam vibração incluem: Desbalanceamento; Desalinhamento; Excentricidade; Ressonância; Folgas mecânicas; Defeitos em rolamentos (Spamer, 2009).

O desbalanceamento ocorre quando há um desequilíbrio de massa em relação ao eixo de rotação, frequentemente causado por assimetrias no rotor ou no conjunto rotor-estator. Esse desequilíbrio gera uma força estacionária em relação ao rotor que induz uma vibração senoidal na frequência de rotação. Essa vibração pode apresentar alta amplitude nas direções radiais (horizontal e vertical) (Baccarini, 2005).

Segundo a mesma linha de raciocínio de Baccarini (2005), o desalinhamento ocorre quando os componentes de duas máquinas acopladas apresentam desgastes. Ocorrendo de duas formas principais: paralelo ou angular. O desalinhamento paralelo pode ser subcategorizado como desalinhamento vertical ou horizontal. Ele acontece quando há deslocamento tanto vertical quanto

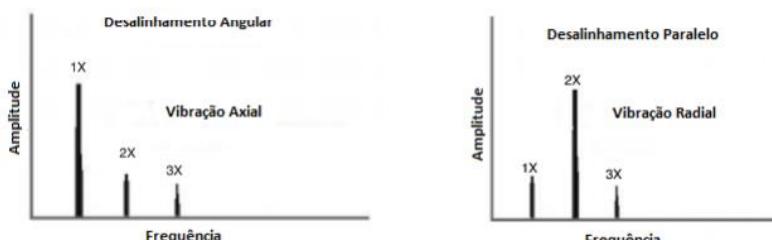
horizontal dos eixos que estão em paralelo. O desalinhamento angular acontece quando forma-se um ângulo na linha de centro de dois eixos, podendo ser também tanto vertical quanto horizontal. A Figura 3 representa de forma simplificada os desalinhamentos paralelo e angular e a Figura 4 representa as vibrações axial e radial associadas aos desalinhamentos em motores de indução.

Figura 3. Representação esquemática dos tipos de desalinhamento: (a) paralelo e (b) angular



Fonte. Silva, 2013

Figura 4. Representação da vibrações axial e radial associadas, respectivamente, aos desalinhamentos angular e paralelo em motores de indução



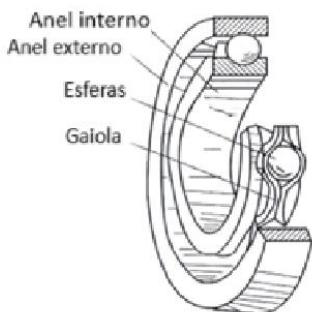
Fonte. Silva, 2013

As folgas mecânicas em motores de indução podem ser classificadas em três tipos distintos:

- Tipo A : associadas problemas estruturais, como falta de rigidez na fundação ou na base da máquina.
- Tipo B: relacionadas a componentes frouxos ou danificados, como folgas em parafusos ou trincas nos pés.
- Tipo C: Associados à fixação inadequada entre as partes da máquina como folga entre a bucha e a capa do mancal, entre o anel interno do rolamento e o eixo, ou entre o anel externo e a capa do mancal (Spamer, 2009).

Os rolamentos são elementos fundamentais no suporte do eixo rotor em motores de indução, com a função de reduzir o atrito entre as partes móveis. Um rolamento típico é composto por quatro elementos: pista interna, pista externa, esfera e uma gaiola que mantém as esferas equidistantes e posicionadas corretamente (Garcia-Calva *et al.*, 2022). Sendo representada na Figura 5.

Figura 5. Componentes rolamento de esferas



Fonte: Adaptado de SUN et al, 2025

As falhas de rolamentos podem ser classificadas em duas categorias principais:

- Pré-operacionais, que se originam de problema de instalação ou manuseio inadequado.
- Operacionais, que ocorrem durante o funcionamento do rolamento.

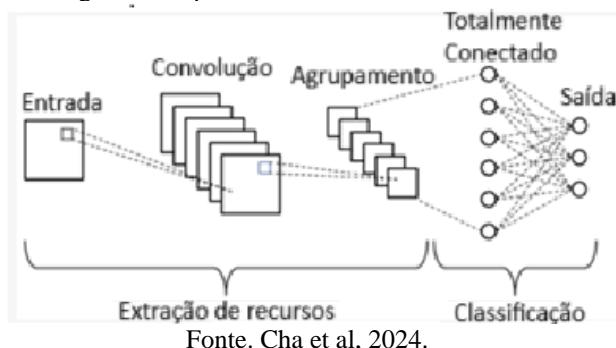
Dentro da categoria operacional, as falhas mais comuns estão relacionadas a fadiga, lubrificação insuficiente, desgaste e outros mecanismos de degradação (Luciano, 2020).

3 REDES NEURAIS

As redes neurais artificiais (RNAs) são sistemas computacionais inspirados no funcionamento do cérebro humano. Segundo Haykin (2007, p28) “uma RNA é um processador massivamente paralelo e distribuído, constituído por unidades de processamento simples, que possui uma propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.”

Dentre os diversos tipos de RNAs, destaca-se a *Convolutional Neural Network* (CNN), que é amplamente utilizada no reconhecimento de padrões em imagens. As CNNs são projetadas para aprender, de forma automática e adaptativa, hierarquias espaciais de características – desde padrões de baixo até alto nível. Sua arquitetura é composta, principalmente, por três tipos de camadas: camadas de convolução, camadas de agrupamento (pooling) e camadas totalmente conectadas (fully connected). As duas primeiras são responsáveis pela extração de características, enquanto a última mapeia as características extraídas para a saída final, como a classificação (Yamashita, 2018), a Figura 6, retrata a arquitetura de uma CNN.

Figura 6. Arquitetura de três camadas da CNN.



Fonte. Cha et al, 2024.

Na arquitetura CNN, o componente mais significativo é a camada de convolução, cuja função principal é a extração de características. Essa camada é composta por um conjunto de filtros (ou kernels) que desliza sobre toda a entrada, realizando, em cada posição, o produto escalar entre seus pesos e os valores da entrada. Esse processo permite que a rede aprenda padrões espaciais e temporais relevantes (Mishra, 2020).

Para introduzir a não linearidade ao modelo, são aplicadas Funções de ativação, sendo a mais comum a unidade Linear Retificada (ReLU), que acelera o treinamento e evita o problema do gradiente descendente. Em seguida, a camada de agrupamento é utilizada para reduzir a dimensionalidade espacial dos mapas de características, que contribui para a diminuição da carga computacional e o número de parâmetros. Além de evitar o *overfitting* (Alzubaidi *et al*, 2021; Mishra, 2020).

Ao final da arquitetura, encontra-se a Camada Totalmente Conectada responsável por receber as características extraídas, que são achatadas em um vetor unidimensional, e realizar a classificação final com base nesses dados processados (Mishra, 2020).

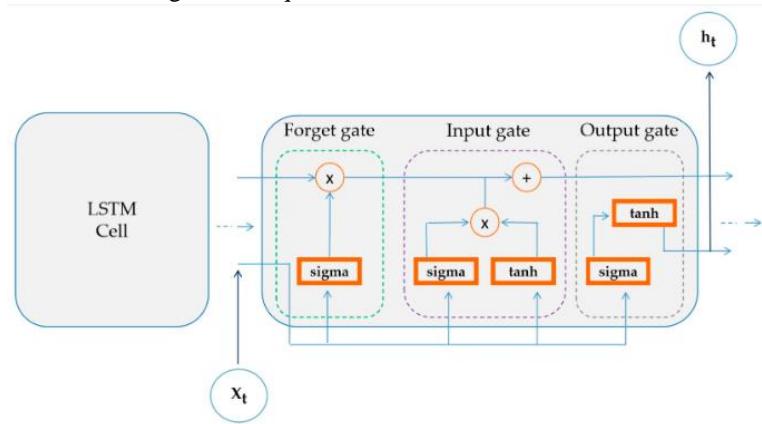
Essas camadas, quando combinadas, permitem que a CNN processe dados brutos, como os sinais de vibração, oriundos de sensores acoplados aos motores, extraia características hierárquicas relevantes e, por fim, realize a classificação com elevada acurácia, tornando-a uma solução promissora para a detecção automática de falhas em motores de indução.

Outra arquitetura de destaque no contexto do diagnóstico de falhas é a LSTM, é um tipo de Rede Neural Recorrente (RNN) projetada para armazenar informações ao longo do tempo, sendo especialmente eficaz para tarefas envolvendo séries temporais, como é o caso da análise de sinais de vibração.

Cada Célula LSTM é composta por três componentes básicos que regulam o fluxo de informações: Porta de entrada que controla os dados que devem ser adicionados à memória, a porta de esquecimento, responsável por decidir quais informações devem ser descartadas; e a porta de saída,

que determina quais informações da memória serão utilizadas como saída naquele instante. Essa estrutura permite que a LSTM aprenda dependências de longo prazo nos dados, superando limitações comuns das RNNs tradicionais (Rafi *et al.*, 2021; Calzone. 2022; Conte, 2024). Conforme ilustrado na Figura 7

Figura 7. Arquitetura de uma unidade LSTM



Fonte. Conte, 2024

4 ANÁLISE NO DOMÍNIO DO TEMPO

Para analisar as vibrações, consiste em avaliar os dados brutos provenientes dos sensores de vibração adquiridos no domínio do tempo. Essa análise temporal permite observar a evolução do comportamento da máquina e serve como base para a extração de métricas estatísticas. Esses indicadores estatísticos podem formar uma assinatura que ajuda a diagnosticar a condição de funcionamento do equipamento (Lobão, 2020).

Parâmetros estatísticos como o valor médio (X_m), a amplitude da raiz(X_{root}), a raiz quadrada média (X_{rms}), o valor de pico (X_{peak}), o desvio padrão (X_{std}), skewness (assimetria - $X_{skewness}$), curtose ($X_{kurtosis}$), fator de crista (X_{crest}), fator de folga ($X_{clearance}$), fator de forma (X_{shape}) e fator de impulso ($X_{impulse}$), podem representar o comportamento das falhas, que são mostradas pelos sinais de vibração (Lobão, 2020). A Figura 8 demonstra os descritores extraídos do sinal no domínio do tempo.

Figura 8. Descritores estatísticos extraídos do sinal no domínio do tempo

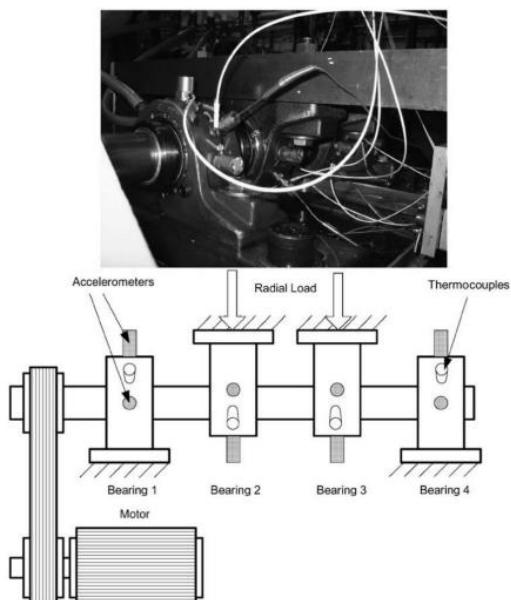
Parâmetro	Descrição Matemática
Valor médio	$X_m = \frac{\sum_{n=1}^N x(n)}{N}$
Valor de pico	$X_{peak} = \max x(n) $
Fator de folga	$X_{clearance} = \frac{X_{peak}}{X_{root}}$
Amplitude da raiz	$X_{root} = \left(\frac{\sum_{n=1}^N \sqrt{ x(n) }}{N} \right)^2$
Curtose	$X_{kurtosis} = \frac{\sum_{n=1}^N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

Fonte: Lobão, 2020

5 COLETA DE DADOS DE VIBRAÇÃO

Os dados de vibração utilizados neste estudo foram da *Intelligent maintenance system of the University of Cincinnati* (IMS). Segundo o documento presente no arquivo em que consiste os dados de vibração, o experimento foi realizado através de quatro rolamentos Rexnord ZA-2115 que foram instalados em um eixo que ficava a uma velocidade de 2000 rpm, este rolamentos eram lubrificados à força. Um mecanismo de mola aplica uma carga radial de 2700 kg ao eixo e ao rolamento. A Figura 9, representa a bancada utilizada para a coleta dos sinais. Para coletar os sinais de vibração do conjunto 1 de dados foram colocados na carcaça dos rolamentos dois acelerômetros de alta sensibilidade ICP de quartzo para cada rolamento e um acelerômetro para os conjuntos 2 e 3. Todos os rolamentos apresentaram falhas após excederem o seu tempo de vida útil.

Figura 9. Bancada experimental do centro de pesquisa da IMS.



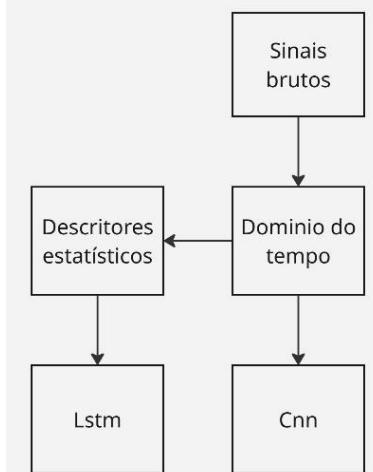
Fonte: IMS

Ao todo, tem três conjuntos de testes do IMS. E todos os testes foram finalizados quando os rolamentos apresentaram falhas e cada arquivo do conjunto de dados apresenta a um instantâneo do sinais de vibração de 1 segundo e cada arquivo consiste em 20.480 pontos com a taxa de amostragem definida em 20 khz.

No presente estudo, será usado o conjunto 1, que teve 35 dias de duração, e que no final do teste, apresentou falhas na pista interna do rolamento 3 e um defeito no rolo no rolamento 4 e foram produzidos 2156 sinais de vibração. No conjunto 2, o experimento teve 7 dias de duração, apresentou falha na pista do rolamento 1 e foi produzido 984 sinais de vibração e no conjunto 3 do experimento da IMS, teve 30 dias de duração, foi produzido 4448 sinais de vibração e o experimento apresentou falha na pista externa do rolamento 3.

A classificações do modelo foi realizando por uma CNN e uma LSTM. O modelo apresenta um domínio de sinal de vibração (domínio do tempo) e um extrator de características (descritores estatísticos) conforme a Figura 10. abaixo apresenta.

Figura. 10 Fluxograma da modelagem comparativa entre LSTM e CNN



Fonte. Autores 2025

6 PRÉ-PROCESSAMENTO E ORGANIZAÇÃO DOS DADOS.

Os sinais utilizados neste estudo foram obtidos a partir do conjunto de dados do IMS o qual já havia passado por um processo prévio de normalização realizado pelos responsáveis pela coleta. Dessa forma, não foi necessário aplicar técnicas adicionais de normalização para a modelagem proposta nesta pesquisa.

O conjunto analisado, conhecido como *IMS Bearing Dataset – Set 1*, é composto por sinais com 20.480 amostras por arquivo. Cada um desses sinais foi segmentado em janelas de 1.024 amostras, com sobreposição de 50% entre segmentos consecutivos (512 amostras). Para cada segmento, foi extraído um vetor contendo 10 descritores estatísticos no domínio do tempo, representando características relevantes do comportamento vibracional.

Como os sinais foram captados por dois acelerômetros distintos, o processo de extração foi realizado separadamente para cada canal, resultando em vetores de 20 características por segmento (10 por canal).

Para fins de classificação supervisionada, os dados foram rotulados em três classes distintas, baseadas no ciclo de vida do rolamento monitorado:

- *Healthy* (Saudável)
- *Developing Fault* (Falha em desenvolvimento)
- *Imminent Failure* (Falha iminente)

Os vetores de características extraídos foram organizados em sequências de 20 segmentos consecutivos, de modo a preservar a evolução temporal dos descritores estatísticos ao longo do tempo. Essa abordagem permite que os modelos considerem a dinâmica do comportamento vibracional em vez de apenas snapshots isolados.

No caso da modelagem utilizando redes neurais convolucionais (CNNs), não foi necessário realizar um pré-processamento adicional, uma vez que esse tipo de arquitetura é capaz de extrair automaticamente as características relevantes diretamente dos sinais brutos.

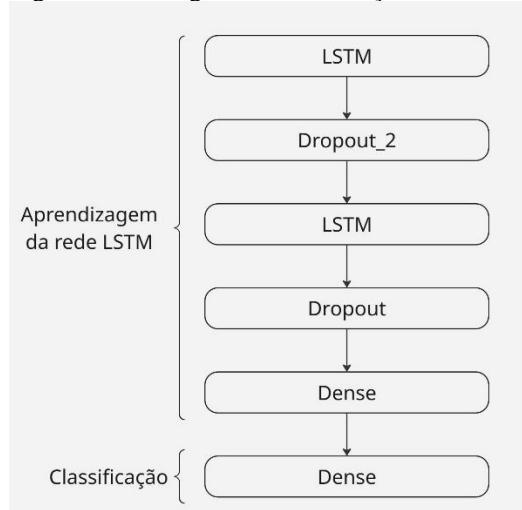
Considerando que os sinais do conjunto 1 foram capturados por dois acelerômetros posicionados em pontos distintos do rolamento, os dados foram organizados de forma a permitir que a CNN os processasse como uma imagem bidimensional (2D). Para isso, os dois sinais temporais unidimensionais (1D) foram combinados em uma matriz 2D, onde cada linha representa o sinal de um acelerômetro e cada coluna corresponde a uma amostra no tempo. Essa representação matricial viabiliza a aplicação de filtros convolucionais que exploram correlações espaciais e temporais entre os canais, simulando a estrutura de uma imagem.

7 ARQUITETURA DA REDE UTILIZADA PARA CLASSIFICAÇÃO

A arquitetura da rede proposta é composta por seis camadas empilhadas. As duas primeiras são camadas LSTM, contendo, respectivamente, 64 e 32 neurônios. A primeira camada LSTM foi configurada com o parâmetro *return_sequences=True*, permitindo o repasse da sequência completa para a próxima camada, o que é necessário para redes com múltiplas camadas LSTM.

Em seguida, são inseridas duas camadas de *Dropout*: a primeira visa reduzir o *overfitting*, enquanto a segunda atua na regularização da saída da segunda camada LSTM. Por fim, a rede conta com duas camadas densas (*fully connected*). A primeira possui 32 neurônios e utiliza a função de ativação ReLU, e a segunda contém 3 neurônios com função de ativação *Softmax*, adequada para a tarefa de classificação multiclasse. A Figura 11, mostra o fluxograma da arquitetura utilizada.

Figura 11. Fluxograma da construção do modelo



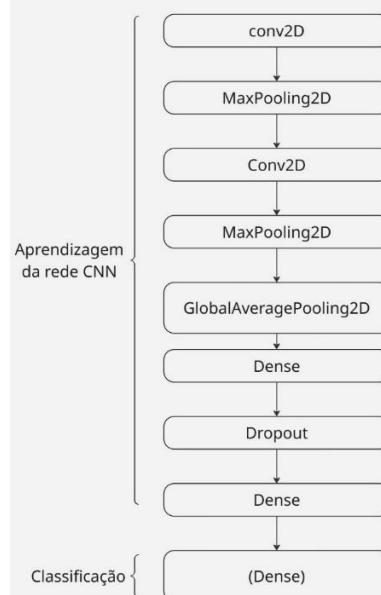
Fonte. Autores 2025

A arquitetura da CNN utilizada neste estudo é composta por 8 camadas. As duas primeiras são camadas convolucionais com ativação ReLU. A primeira camada convolucional possui 32 filtros com tamanho do *Kernel* de (2, 8), enquanto a segunda contém 64 filtros com tamanho (1,8). Em seguida, foram aplicadas duas camadas de *pooling*, ambas com janela de tamanho (1, 2). A primeira camada de *pooling* tem como objetivo reduzir a dimensionalidade dos dados, preservando as características mais relevantes.

Posteriormente, uma camada de *global average pooling* é utilizada para transformar as representações bidimensionais extraídas pelas camadas convolucionais em um vetor unidimensional, preparando os dados para a etapa de classificação.

A rede se encerra com três camadas densas. A primeira contém 128 neurônios com ativação ReLU, a segunda possui 64 neurônios, também com ReLU, e a última camada apresenta 3 neurônios com função de ativação *Softmax*, adequada para classificação em três classes. A Figura 12, mostra o fluxograma da arquitetura utilizada.

Figura 12. Arquitetura da Rede CNN.



Fonte: Autores 2025

8 CONFIGURAÇÃO DE TREINAMENTO E VALIDAÇÃO

Para o treinamento dos modelos, os dados foram divididos em 70% para treinamento e 30% para teste. Do total destinado ao treinamento, 20% foram utilizados para validação durante cada época.

Todos os modelos foram treinados por até 30 épocas. Para evitar *overfitting*, foi empregada a técnica de *early stopping*, configurada para interromper o treinamento caso a perda de validação

(validation loss) não apresentasse melhora após 10 épocas consecutivas.

Os experimentos foram conduzidos na plataforma Google Colab.

9 RESULTADOS

Os resultados obtidos demonstram um desempenho satisfatório do modelo LSTM na tarefa de detecção de falhas. Conforme apresentado na Figura 13, após 30 épocas de treinamento, o modelo alcançou uma perda (loss) de aproximadamente 0.03% e uma acurácia de 98%.

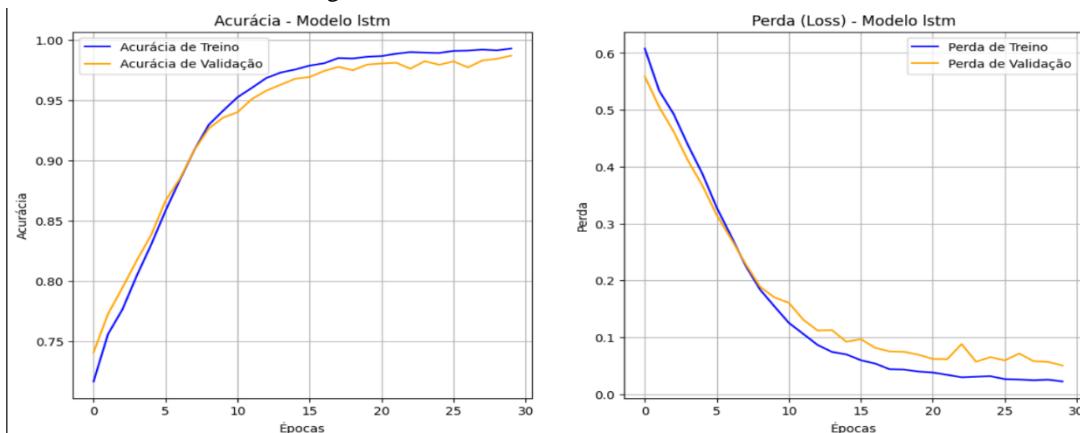
A análise da Tabela 1, revela uma sensibilidade de 99%, indicando que o modelo é altamente eficaz na identificação da condição de normalidade dos rolamentos. Esses resultados evidenciam a robustez do modelo proposto para aplicações de diagnóstico preditivo em sistemas rotativos.

Tabela 1. Resultados da LSTM como classificadora.

	Precisão	Sensibilidade	F1-score
Developing_fault	0.98	0.98	0.98
Healthy	0.99	0.99	0.99
Imminent_Failure	0.98	0.99	0.98
Accuracy			0.98
Macro avg	0.98	0.99	0.98
Weighted avg	0.98	0.98	0.98

Fonte. Autores 2025

Figura 13 Gráfico do treinamento da LSTM.



Fonte. Autores 2025

O teste do modelo baseado em CNN foi conduzido com o mesmo número de época (30) utilizado no modelo da LSTM. No entanto, apresentou desempenho significativamente inferior, com acurácia de 86% e uma perda (loss) mais elevada 0.35%.

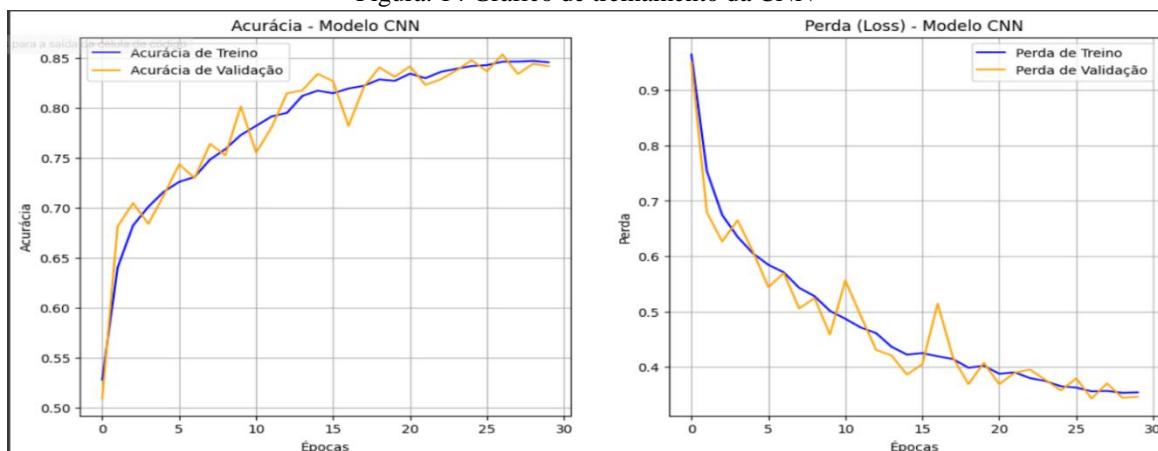
Além disso, o valor da sensibilidade foi de 86%, o que indica uma maior probabilidade de ocorrência de falso positivos durante a detecção de falhas. Conforme a Figura 14 e a Tabela 2.

Tabela 2. Resultado da CNN como classificadora

	Precisão	Sensibilidade	F1-score
Developing_fault	0.75	0.80	0.77
Healthy	0.90	0.88	0.89
Imminent_Failure	0.92	0.89	0.90
Accuracy			0.86
Macro avg	0.86	0.86	0.86
Weighted avg	0.86	0.86	0.86

Fonte. Autores 2025.

Figura. 14 Gráfico de treinamento da CNN



Fonte. Autores 2025

10 CONCLUSÃO

O presente trabalho partiu da constatação de que paradas não planejadas dos motores na produção industrial podem gerar impactos financeiros significativos. Além disso, observou-se que as análises tradicionais de vibração requerem atuação de especialistas capacitados para interpretar os dados. Nesse contexto, com objetivo de automatizar diagnóstico de falhas, investigaram-se aplicações de modelos de *Deep Learning*.

O objetivo de realizar uma análise comparativa entre os modelos LSTM e CNN foi alcançado com sucesso. Para isso, foi realizado um estudo sobre os principais defeitos ocorridos nos motores elétricos e aplicação de métricas para comparar o desempenho dos modelos.

O modelo LSTM apresentou desempenho superior ao CNN. A LSTM foi treinado com descritores estatísticos extraídos dos sinais de vibração e apresentou uma acurácia de 98% e 99% de sensibilidade. O que indica uma alta precisão na detecção de anomalias nos rolamentos. Enquanto o modelo CNN, embora funcional, apresentou uma acurácia de 86% e os valores da sensibilidade e do F1 score (86% , respectivamente) isso indica que a utilização dessa arquitetura para implementar sistemas de diagnóstico de falhas pode ser problemática para o uso industrial. Esse resultado, resolvendo o problema desta pesquisa, apontando a LSTM como a mais eficaz na classificação de anomalias de vibração de rolamentos.

Os dados foram obtidos a partir de um conjunto de dados (IMS), coletado em um ambiente de bancada experimental. Como limitação, o desempenho dos modelos pode variar em ambientes industriais reais, que apresentam maior complexidade e fontes de ruído distintas. Além disso, é fundamental considerar que, a CNN realizou um processo de aprendizagem de ponta a ponta, responsável pela tanto pela extração de características a partir de dados brutos quanto pela classificação, enquanto a LSTM operou sobre descritores estatísticos já consolidados na literatura. Essa diferença representa que o trabalho da CNN foi muito maior e mais difícil, o que ajuda a explicar o seu desempenho inferior comparado a abordagem realizada com a LSTM.

Como proposta para trabalhos futuros, sugere-se o desenvolvimento de um modelo híbrido CNN-LSTM, combinando o potencial da CNN na extração de características espaciais com a capacidade da LSTM de interpretar as dependências temporais. Adicionalmente, recomenda-se a utilização de Transformada Rápida de Fourier (FFT) para abordagens no domínio tempo-frequência.

REFERÊNCIAS

AHMED, Hosameldin; NANDI, Asoke K. Condition monitoring with vibration signals: compressive sampling and learning algorithms for rotating machines. Hoboken, NJ: Wiley-IEEE Press, 2020.

ALZUBAIDI, L. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, v. 8, n. 53, 2021.

BACCARINI, Lane Maria Rabelo. Detecção e diagnóstico de falhas em motores de indução. 2005. Tese (Doutorado em Engenharia Elétrica) - Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2005.

BAHGAT et al. Advanced fault detection technique of three phase induction motor: comprehensive review. *Discover Electronics*, v. 1, n. 9, 24 jun. 2024.

CABRERA, Miguelises Colla. Análise da eficiência energética de motores monofásicos para aplicações residenciais. 2013. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica com ênfase em Sistemas de Energia e Automação) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2013.

CALZONE, Ottavio. An Intuitive Explanation of LSTM. Medium, 21 de fev. de 2022.

CERRADA, M. et al. A review on data-driven fault severity assessment in rolling bearings. *Mechanical Systems and Signal Processing*, v. 99, p. 169-196, 2018.

CHA, Y.-J et al. A Deep Learning-Based Approach for Effective and Reliable Concrete Crack-Type Classification. *Applied Sciences*, Basel, v. 14, n. 21, p. 9754, 2024. DOI: 10.3390/app14219754.

CONTE, Thiago; OLIVEIRA, Roberto L. Comparative Analysis between Intelligent Machine Committees and Hybrid Deep Learning with Genetic Algorithms in Energy Sector Forecasting: A Case Study on Electricity Price and Wind Speed in the Brazilian Market. *Energies*, v. 17, n. 4, p. 829, 9 fev. 2024. DOI: 10.3390/en17040829

FROGINI, Lucia. Novel diagnostic techniques for rotating electrical machines—A review. *Energies*, v. 13, n. 19, p. 5066, 2020.

GARCIA-CALVA, T, et al. Early Detection of Faults in Induction Motors—A Review. *Energies*, v. 15, n. 21, p. 7855, 2022.

HAYKIN, Simon. Redes Neurais: Princípios e Prática . 2. ed. Porto Alegre: Bookman, 2007. E-book. pág.802. ISBN 9788577800865. Disponível em:
<https://integrada.minhabiblioteca.com.br/reader/books/9788577800865/>.

IMMOVILLI, Fabio et al. Bearing fault model for induction motor with externally induced vibration. *IEEE Transactions on Industrial Electronics*, v. 60, n. 8, p. 3408-3418, 2012.

LOBÃO, D. A. Técnicas de Aprendizado de Máquinas aplicadas ao Diagnóstico de Falhas em Equipamentos Industriais. 87 p. Dissertação (Mestrado Profissional em Engenharia de Controle e

Automação) — Universidade Federal do Espírito Santo, Serra, 2020.

LUCIANO, Bruno. Falhas de um rolamento: conheça as principais causas. Abecom, 28 fev. 2020. Disponível em: <https://www.abecom.com.br/falhas-de-um-rolamento/>. Acesso em: 24 jul. 2025.

MARTIGNONI, Alfonso. Máquinas De Corrente Alternada. 3. ed. Porto Alegre: Globo, 1978.

MISHRA, M. Convolutional Neural Networks, Explained. 2020. Disponível em: <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939>. Acesso em 23 de julho de 2025.

PEREIRA JUNIOR, Milton Carlos Soares et al. Estudo da aplicação de algoritmos de machine learning na manutenção preditiva de motores elétricos. Revista de Gestão e Secretariado, São Paulo, v. 14, n. 10, p. 16542-16561, 2023.

RAFI, S. H. et al. A Short-Term Load Forecasting Method Using Integrated CNN and LSTM Network. *IEEE Access*, New York, v. 9, p. 32436-32448, 2021.

SILVA, Derick Henrique de Jesus. Processamento de Sinais para Monitoramento de Vibrações em Unidades Geradoras Hidrelétricas. 2013. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

SILVA, Jonas Guedes Borges da. Aplicação da Análise de Componentes Principais (PCA) no Diagnóstico de Defeitos em Rolamentos através da Assinatura Elétrica de Motores de Indução. 2008. Dissertação (Mestrado em Ciências em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Itajubá, Itajubá, 2008.

SPAMER, Fernanda Rosa. TECNICAS PREDITIVAS DE MANUTENÇÃO DE MÁQUINAS ROTATIVAS. 2009. 238 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Escola Politécnica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.

SUN, B. et al. State-of-the-Art Detection and Diagnosis Methods for Rolling Bearing Defects: A Comprehensive Review. *Applied Sciences*, Basel, v. 15, n. 2, art. 1001, jan. 2025.

WEG. Guia de especificação: motores elétricos. Jaraguá do Sul: WEG, 2024. Disponível em: <https://static.weg.net/medias/downloadcenter/h32/hc5/WEG-motores-eletricos-guia-de-especificacao-50032749-brochure-portuguese-web.pdf>. Acesso em: 16 jul. 2025.

YAMASHITA, R. et al. Convolutional neural networks: an overview and application in radiology. *Insights into Imaging*, v. 9, p. 611-629, 2018.