**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS**

**Diretoria de Pesquisa e Pós-Graduação**

**Programa de Pós-Graduação em Engenharia Mecânica**

**PAULO SÉRGIO BRANDÃO JÚNIOR**

# PREVISÃO DE FALHAS EM MANCAIS DE ROLAMENTO UTILIZANDO APRENDIZADO DE MÁQUINA POR MEIO DE REDES NEURAIS ARTIFICIAIS: MÓDULO DE UM GÊMEO DIGITAL

**Orientador:** Prof. Dr. Yukio Shigaki

**Linha de Pesquisa:** Eficiência em Sistemas e Processos Mecânicos

Belo Horizonte, 2024

Paulo Sérgio Brandão Júnior

# Previsão de Falhas em Mancais de Rolamento Utilizando Aprendizado de Máquina por Meio de Redes Neurais Artificiais: módulo de um gêmeo digital

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Mecânica do Centro Federal de Educação Tecnológica de Minas Gerais.

**Orientador:** Prof. Dr. Yukio Shigaki.

**Linha de Pesquisa:** Eficiência em Sistemas e Processos Mecânicos

Belo Horizonte
2024

Brandão Júnior, Paulo Sérgio
B817p Previsão de falhas em mancais de rolamento utilizando aprendizado de máquina por meio de redes neurais artificiais: módulo de um gêmeo digital / Paulo Sérgio Brandão Júnior. – 2024.
84 f. : il., gráfs, tabs, fotos.

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica do Centro Federal de Educação Tecnológica de Minas Gerais.
Orientador: Yukio Shigaki.
Banca examinadora: Yukio Shigaki, Frederico de Castro Magalhães, Alisson Marques da Silva.
Bibliografia: f. 72-84.
Dissertação (mestrado) – Centro Federal de Educação Tecnológica de Minas Gerais.

1. Aprendizado do computador – Teses. 2. Redes neurais (Computação) – Teses. 3. Algoritmos de computador – Teses. 4. Gêmeos digitais (Computação) – Teses. 5. Simulação (Computadores) – Teses. 6. Eficiência industrial – Teses. I. Shigaki, Yukio. II. Centro Federal de Educação Tecnológica de Minas Gerais. IV. Título.

CDD 620.0042

Elaboração da ficha catalográfica pela bibliotecária Jane Marangon Duarte, CRB 6ª 1592 / Cefet/MG

Paulo Sérgio Brandão Júnior

Previsão de Falhas em Mancais de Rolamento Utilizando Aprendizado de Máquina por Meio de Redes Neurais Artificiais: Módulo de um Gêmeo Digital.

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Mecânica do Centro Federal de Educação Tecnológica de Minas Gerais como requisito parcial para a obtenção do título de Mestre em Engenharia Mecânica.

**Linha de Pesquisa:** Eficiência em Sistemas e Processos Mecânicos

Belo Horizonte, 28/11/2024

Resultado: **APROVADO**

Banca Examinadora:

Prof. Dr. Yukio Shigaki, CEFET-MG

Prof. Dr. Frederico de Castro Magalhães, UFMG

Prof. Dr. Alisson Marques da Silva, CEFET-MG

À minha esposa e à minha família.

# AGRADECIMENTOS

Primeiramente à Deus que abriu as portas e me proporcionou essa conquista.

Ao meu professor Yukio Shigaki por todo o incentivo e dedicação que me proporcionou alcançar todos os objetivos traçados.

Ao meu irmão Pedro Vitor Bernardes Brandão por toda a parceria e auxílio no desenvolvimento deste trabalho.

Aos meus pais pelo incentivo, pela criação e por todos os sacrifícios que fizeram.

À minha esposa pelo auxílio, incentivo e compreensão.

# RESUMO

Este trabalho teve como objetivo solucionar o problema da falha prematura dos mancais de rolamento em um redutor de laminador de barras na siderúrgica Gerdau – Usina Barão de Cocais, utilizando técnicas de aprendizado de máquina. O foco foi a construção de um modelo de classificação utilizando redes neurais artificiais (RNA) para predizer falhas no sistema de rolamento, baseado na análise da corrente do motor. O modelo construído apresentou acurácia de 99%, além de níveis de sensibilidade de 0,9871 e especificidade de 0,9942, o que demonstra sua eficácia em identificar anormalidades nas informações. Além disso, o estudo introduziu o conceito de gêmeo digital, propondo sua aplicação futura como ferramenta de monitoramento proativo, permitindo simulação e análise em tempo real. A segunda etapa do estudo utilizou uma nova base de dados que reforçou a hipótese de que falhas nos rolamentos aumentam o torque e, consequentemente, a corrente do motor. O modelo se mostrou eficaz em identificar esse padrão, sendo uma ferramenta eficaz para a manutenção preditiva e a programação de paradas preventivas.

Palavras-Chave: Aprendizado de máquina. RNA. *Kmeans*. Gêmeo digital. Eficiência Operacional.

# ABSTRACT

FAILURE PREDICTION IN ROLLING BEARINGS USING MACHINE LEARNING THROUGH ARTIFICIAL NEURAL NETWORKS: A DIGITAL TWIN MODULE

This work aimed to address the issue of premature bearing failures in a gearbox of a bar mill at Gerdau – Usina Barão de Cocais using machine learning techniques. The focus was on building a classification model with artificial neural networks (ANN) to predict failures in the bearing system, based on motor current analysis. The developed model achieved an accuracy of 99%, with sensitivity levels of 0.9871 and specificity of 0.9942, demonstrating its effectiveness in identifying anomalies. Additionally, the study introduced the concept of a digital twin, proposing its future application as a proactive monitoring tool, enabling real-time simulation and analysis. In the second phase, a new dataset was analyzed, reinforcing the hypothesis that bearing failures increase torque and, consequently, motor current. The model proved effective in identifying this pattern, making it a effective tool for predictive maintenance and scheduled preventive stops.

Keywords: Machine Learning. ANN. Kmeans. Digital Twin. Operational Efficiency.

# LISTA DE FIGURAS

Figura 1 - Representação de um redutor industrial. ..... 17
Figura 2 - Rolamento radial do tipo cilíndrico. ..... 20
Figura 3 - Representação esquemática de um modelo de gêmeo digital. ..... 31
Figura 4 - Estrutura de um neurônio em RNA. ..... 36
Figura 5 - Representação esquemática de uma rede neural artificial. ..... 40
Figura 6 - Fluxograma da metodologia aplicada. ..... 45
Figura 7 - Representação esquemática do redutor do laminador acabador de perfis da Gerdau-Barão de Cocais. ..... 46
Figura 8 - Rolamento TDO HM926747 / 10CD – XA. ..... 47
Figura 9 - Medidas e parâmetros rolamento TDO HM926747 / 10CD – XA. ..... 47
Figura 10 - Dimensões do rolamento e capacidade de carga. ..... 48
Figura 11 - Matriz de correlação dos dados de produção referente ao laminador acabador de barras. ..... 52
Figura 12 - Número ótimo de grupos- Método Gap Statisc. ..... 53
Figura 13 - Representação esquemática da rede neural proposta. ..... 54
Figura 14 - Projeto de aplicação de um gêmeo digital para um laminador. ..... 58
Figura 15 - Agrupamento utilizando Kmeans e o método Hartigan Wong. ..... 59
Figura 16 - Desempenho dos modelos variando a função de ativação. ..... 60
Figura 17 - Desempenho dos modelos por número de neurônios na camada oculta. ..... 61
Figura 18 - Desempenho dos modelos por métrica de erro. ..... 62
Figura 19 - Desempenho dos modelos por parâmetro de otimização – Acurácia. ..... 63
Figura 20 - Curva ROC por classe. ..... 65
Figura 21 - Frequência das classes em relação a primeira base de dados. ..... 67
Figura 22 - Frequência das classes em relação a segunda base de dados. ..... 67

# LISTA DE TABELAS

Tabela 1 - Principais modos de falha dos elementos de um redutor. ..... 18
Tabela 2 - Níveis de falhas em rolamentos devido a lubrificação inadequada. ..... 22
Tabela 3 - interpretação de agrupamentos segundo coeficiente de Silhueta..... 53

# LISTA DE QUADROS

Quadro 1 - Análise descritiva dos atributos selecionados. ..... 50
Quadro 2 - Dados de entrada ao modelo de RNA. ..... 55
Quadro 3 - Relação dados inteiros por dados codificados. ..... 55
Quadro 4 - Parâmetros de avaliação variando a função de ativação. ..... 61
Quadro 5 - Parâmetros de avaliação variando o número de neurônios na camada oculta. .. 62
Quadro 6 - Parâmetro de avaliação variando a perda. ..... 63
Quadro 7 - Parâmetros de avaliação variando o algoritmo de otimização. ..... 64
Quadro 8 - Valores de AUC por classe. ..... 65
Quadro 9 - Matriz de confusão. ..... 66
Quadro 10 - Impacto das variáveis na classificação. ..... 68

# LISTA DE ABREVIATURAS E SIGLAS

A - Altura do Laço

Adam - Adaptive Moment Estimation

CC - Corrente do Motor

DP - Desvio Padrão

GD – Gêmeo digital

IA - Inteligência Artificial

*Kmeans* – Modelo de aprendizado de máquina por agrupamento

Max - Máximo

Min – Mínimo

R - Fator R

ReLU - *Rectified Linear Unit*

RMSprop - Root Mean Square Propagation

RNA - Redes Neurais Artificiais

ROC – Curva de desempenho de sensibilidade e especificidade das classificações

RPM - Rotações Por Minuto

T_M – Tensão do Motor

V_G - Velocidade da Gaiola

V_M - Velocidade do Motor

V_S - Velocidade de Saída do Material

# SUMÁRIO

1. INTRODUÇÃO ..... 12
1.1. Justificativa ..... 14
1.2. Objetivos ..... 14
1.2.1. Objetivos específicos ..... 14
1.3. Estrutura dos próximos capítulos ..... 14
2. REVISÃO TEÓRICA ..... 16
2.1. Falhas em Redutores ..... 16
2.1.1. Aspectos da manutenção em redutores industriais ..... 19
2.1.2. Falhas em rolamentos ..... 19
2.2. Manutenção aplicada ao cenário da indústria 4.0 ..... 24
2.2.1. Gêmeo digital como ferramenta para a manutenção ..... 25
2.2.2. Aplicações de Gêmeo digital na manutenção industrial ..... 27
2.3. Propriedade de modularização do gêmeo digital ..... 29
2.4. Aprendizado de máquina como módulo do gêmeo digital ..... 32
2.4.1. Algoritmo de agrupamento *Kmeans* ..... 33
2.4.2. Redes neurais artificiais ..... 36
2.4.3. Aplicações de aprendizado de máquina como módulo do gêmeo digital nos processos de conformação ..... 42
3. METODOLOGIA ..... 44
3.1. Contextualização e fluxograma da metodologia aplicada ..... 44
3.2. Hipótese e descrição das atividades ..... 48
3.3. Pré-processamento dos dados ..... 49
3.4. Metodologia de agrupamento utilizando *Kmeans* ..... 52
3.5. Metodologia de aprendizado por classificação utilizando RNA ..... 54
3.5.1. Grupos de testes para modelo de classificação RNA ..... 55
3.6. Análise de novos dados ..... 56
4. RESULTADOS ..... 57
4.1. Projeto para futura aplicação do gêmeo digital considerando o aprendizado de máquina desenvolvido ..... 57
4.2. Agrupamento utilizando o método *Kmeans* ..... 59
4.3. Desenvolvimento do modelo de classificação utilizando RNA ..... 60
4.4. Avaliação de desempenho do modelo de classificação utilizando RNA ..... 64
4.5. Classificação da segunda base de dados por meio do modelo RNA desenvolvido ..... 66
4.6. Impacto das variáveis na classificação da base utilizando RNA ..... 68

5. CONCLUSÃO ..... 69
6. TRABALHOS FUTUROS ..... 71
REFERÊNCIAS ..... 72

# 1. INTRODUÇÃO

Produtos laminados possuem forte impacto no mercado internacional, assim como no mercado brasileiro. Em um levantamento referente ao ano de 2022, a China ocupava o primeiro lugar na exportação de aço laminado, seguida do Japão e União Europeia. Já o Brasil ocupava a 10ª posição com um total de 12,1 milhões de toneladas (WORLDSTEEL ASSOCIATION, 2023). Segundo o Instituto Aço Brasil (2023), no ano de 2022 houve uma produção de produtos laminados que gira em torno de 23,4 milhões de toneladas. Dentre essa produção, os laminados longos alcançaram uma marca de 9,8 milhões de toneladas.

A alta capacidade de produção e elevado controle dimensional, torna a laminação como o processo de conformação mecânica mais utilizado (DIETER, 1981). Em relação aos componentes de máquinas pertencentes ao processo de laminação, segundo Errandonea, Beltràn e Arrizabalaga (2020), os rolamentos são elementos importantes para sua eficiência e funcionamento, entretanto, segundo Cerrada et al. (2018), os rolamentos representam a principal fonte de falha de máquinas rotativas, além de possuírem elevada sensibilidade e, portanto, poderem indicar alguma anormalidade existente no sistema por meio de variações. Essas variações podem ser expressas mediante análise desses elementos como análise vibracional ou alguma tecnologia de manutenção preditiva (GOYAL; PABLA, 2015).

Ao longo das revoluções que ocorreram desde o século XVIII a indústria vem aprimorando métodos e processos produtivos. Nesses aprimoramentos, a primeira revolução foi marcada pela mecanização de processos manuais, já a segunda revolução industrial, que se iniciou no século XIX, teve como pilar a substituição, nos processos produtivos, do ferro pelo aço, a implementação da produção seriada e o uso de eletricidade na produção. A terceira revolução por sua vez, que ocorreu em meados do século XX, foi marcada com a implementação de meios tecnológicos, como a robótica, nos setores industriais. Por fim, a indústria vive a chamada quarta revolução industrial, ou indústria 4.0 cujos destaques são conectividade e facilidade em realizar trocas de informações, além do aprimoramento de como as empresas fabricam, melhoram e distribuem seus produtos. A quarta revolução industrial conectou novas tecnologias como: internet das coisas (IoT), computação em nuvem, análise de dados e inteligência artificial (IA) aos processos fabris já consolidados. Essas conexões levam ao aumento de automação, manutenção preditiva, otimização dos processos e, acima de tudo, um novo nível de eficiência e responsividade que auxiliam nas tomadas de decisões (IBM, 2023).

Como um dos principais pilares industriais, a manutenção se beneficia com as tecnologias embarcadas da indústria 4.0. Segundo Sifonte e Reyes-Picknell (2017), a manutenção possui o papel primordial de prolongar a vida útil do parque industrial e dos componentes de máquina. Dentre suas técnicas, as indústrias procuram implementar os modelos preventivos e preditivos no lugar das manutenções corretivas, visto que paradas inesperadas em linha de produção geram grandes impactos financeiros para as organizações. Portanto, a união de conceitos básicos da manutenção com novas tecnologias provenientes da indústria 4.0 determinam um desafio importante para o setor industrial, como a mudança de políticas para adequação e a otimização dos processos com o uso das tecnologias disponíveis (SILVESTRI et al., 2020).

Levando em consideração a importância do sistema de rolamentos para o processo de laminação, um controle efetivo de manutenção pode ser realizado por intermédio da predição de falhas utilizando as tecnologias da indústria 4.0. Entre essas técnicas está o gêmeo digital (GD) que pode proporcionar para o processo redução de custos e maior controle nas manutenções dos equipamentos, assim como um controle da qualidade, utilizando para tal, a virtualização e eventos físicos do processo, como ruído, vibração e análise das forças envolvidas (QIN; WU; LUO, 2021).

Segundo o trabalho desenvolvido por Aivaliotis, Georgoulias e Chryssolouris (2019), o gêmeo digital é um processo que simula o meio físico, utilizando dados processuais reais, retornando parâmetros preditos. Essa técnica possibilita um melhor controle operacional, assim como auxilia na gestão da manutenção dos componentes das máquinas.

Uma das principais vantagens da utilização do GD é o fato do sistema possuir característica modular, ou seja, um sistema complexo pode ser dividido em vários outros sistemas de forma a simplificar sua estruturação e o seu funcionamento. Um desses módulos, que possui papel significativo no sistema se trata da análise de dados e da utilização de aprendizado de máquina para predição e controle processual (ROLLE; MARTUCCI; GODOY, 2021).

O presente trabalho propõe-se a desenvolver um módulo de um gêmeo digital do sistema de rolamentos de um laminador acabador de barras focando na análise de dados e desenvolvimento de um modelo em aprendizado de máquina para predição de falhas do sistema físico.

## 1.1. Justificativa

Falhas inesperadas e manutenções corretivas geram impacto financeiro e produtivo para as corporações. Como o sistema de rolamentos possui difícil acesso para análise de integridade, a manutenção utilizando gêmeo digital, como será visto na revisão bibliográfica, pode se fazer relevante para acompanhar os padrões produtivos e prever falhas e aspectos anormais no seu funcionamento.

## 1.2. Objetivos

O objetivo geral desse trabalho foi o desenvolvimento de um módulo de um gêmeo digital, baseado em dados, do sistema de rolamentos de um redutor pertencente a um laminador acabador de perfis, para predição de falhas.

### 1.2.1. Objetivos específicos

- Formular um modelo em aprendizado de máquina que seja capaz de predizer falhas do sistema de rolamento proposto;
- Identificar na modelagem as variáveis que indicam falhas do sistema de rolamento proposto;
- Estruturar uma proposta de gêmeo digital que contemple o modelo em aprendizado de máquina desenvolvido.

## 1.3. Estrutura dos próximos capítulos

Os capítulos a seguir estão dispostos da seguinte forma:

- Revisão teórica realizada a respeito dos assuntos pertinentes ao tema proposto;
- Metodologia que foi aplicada no desenvolvimento do trabalho;
- Resultados alcançados;

- Conclusões;
- Proposta de trabalhos futuros;
- Referências bibliográficas.

# 2. REVISÃO TEÓRICA

Nesse capítulo são apresentados os princípios de falhas em redutores, assim como seus aspectos de manutenção. Além disso são explorados os princípios de falhas em rolamentos e a utilização de gêmeo digital para controle de falhas utilizando aprendizado de máquina como meio de operação principal.

## 2.1. Falhas em Redutores

Os redutores desempenham um papel crucial em sistemas mecânicos e industriais. Sua principal função é reduzir a velocidade de rotação de um motor para atender às necessidades específicas de máquinas ou equipamentos, enquanto simultaneamente aumenta o torque disponível na saída. Além disso, os redutores podem inverter a direção do movimento, adaptar a potência entre diferentes componentes do sistema e compensar incompatibilidades de velocidade e torque. Essas funções são vitais para otimizar a eficiência e o desempenho em uma variedade de aplicações industriais (QUIN; WU; LYU, 2018).

A Figura 1, disposta a seguir, ilustra um redutor industrial. Este equipamento é composto por elementos como engrenagens, rolamentos e eixos. Além de serem submetidos a lubrificação abundante, para minimização de desgastes e melhor performance. Os redutores de velocidade encontram ampla aplicação em diversos setores industriais, podendo ser empregados, por exemplo, em siderúrgicas, veículos automotivos, aerogeradores, sistemas de elevação como guindastes e elevadores, além de áreas como robótica, processamento de alimentos e maquinário agrícola (BARON et al., 2023).

Figura 1 - Representação de um redutor industrial.
Fonte: (ZANINI HENK, 2024).



Segundo Sheng (2014), as falhas em redutores são difundidas, demandando uma manutenção preventiva e preditiva bem aplicada. Além disso, suas falhas prematuras afetam a maioria dos equipamentos que estão acoplados a eles. Sheng ainda afirma que as falhas em redutores, na sua maioria, não são causadas por práticas específicas de fabricação, o que indica que a não aplicação de manutenções e controles preditivos ou preventivos podem, em sua maioria, proporcionar as condições de falha prematura destes equipamentos e seus componentes.

Os princípios de falhas nos redutores estão intimamente ligados às falhas dos seus componentes individualmente, como é o caso dos rolamentos e das engrenagens. Todavia, a lubrificação quando aplicada de forma inadequada, ou quando não aplicada, pode proporcionar falhas prematuras nestes equipamentos, sem contar com partículas de contaminantes que também contribuem para a diminuição da vida útil (DU et al., 2017).

Os principais modos de falha dos subcomponentes dos redutores, segundo Du et al. (2017) e Sheng (2014) são apresentados na Tabela 1:

Tabela 1 - Principais modos de falha dos elementos de um redutor.
Fonte: (Du et al., 2017; Sheng ,2014)

| Subcomponentes | Modos de Falha | Principais causas |
|---|---|---|
| Engrenagens / Rolamentos | Desgaste por adesão | Contato relativo entre os componentes e vibração entre as superfícies |
| Engrenagens | Fadiga por flexão | Tensão excessiva na raiz do dente da engrenagem |
| Engrenagens / Rolamentos | Rachadura | Resfriamento não homogêneo |
| Engrenagens / Rolamentos | Desgaste por abrasão | Contaminação do óleo lubrificante |
| Engrenagens / Rolamentos | Marcação na superfície | Abrasão / diferença de texturas entre as superfícies |
| Lubrificante | Contaminantes | Desgaste de detritos e pó |
| Lubrificante | Espuma | Ar preso no óleo, tempo insuficiente de acomodação |

No contexto das transmissões mecânicas, as engrenagens desempenham uma função crucial na transferência de força e na definição da relação de saída do eixo (SUMITOMO DRIVE TECHNOLOGIES, 2023). Dentre seus principais modos de falha, relatados na Tabela 1, destacam-se o desgaste por atrito e a abrasão, que podem ocorrer devido à presença de contaminantes no óleo lubrificante, provocando microcorrosão e desgastes internos. Adicionalmente, o desalinhamento das engrenagens, muitas vezes atribuído à manutenção inadequada dos redutores, também se configura como um fator preponderante nas análises de falhas.

O lubrificante, por sua vez, desempenha funções cruciais nos sistemas mecânicos, visando otimizar o desempenho e a vida útil dos componentes. Essas funções incluem a redução do desgaste, resfriamento eficaz das máquinas, minimização do atrito, proteção do mancal e absorção de partículas de desgaste para manter a limpeza do sistema. Para atender a esses objetivos, é essencial que o lubrificante preserve suas propriedades ao longo de sua vida útil, como resistência ao envelhecimento, baixa formação de espuma, eficiente separação do ar, elevada capacidade de carga, neutralidade aos materiais, resistência a temperaturas extremas, bom comportamento viscosidade-temperatura e capacidade de detergência para limpeza e dissolução de sujeira no circuito hidráulico (ÁLAMO; DURAN; MUÑOZ, 2020).

### 2.1.1. Aspectos da manutenção em redutores industriais

A aplicação de manutenção nos redutores, como na maioria dos equipamentos industriais, utiliza de métodos preditivos e preventivos, evitando o uso de manutenções corretivas, salvo para casos específicos, em que o custo do equipamento é menor do que o custo para aplicar algum processo de controle e, se esse elemento falhar, não atrapalhe o funcionamento do sistema como um todo, evitando paradas inesperadas. Considerando, portanto, as manutenções preditivas e preventivas, alguns processos como: análise de vibração, análise de óleo, análise do filtro de óleo e análise de imagem, por exemplo, podem ser utilizados para controle e efetivo planejamento de manutenção (SHENG, 2014).

Levando em consideração a importância fundamental do óleo lubrificante nos redutores, a manutenção preventiva é comumente utilizada. A inspeção do filtro do óleo lubrificante e sua troca controlada, análise de óleo, análise de contaminantes e tamanho dessas partículas presentes no sistema, entre outros possíveis procedimentos preventivos são essenciais para que o redutor funcione de forma eficiente e que seus componentes obtenham uma vida útil programada (MÁRQUEZ et al., 2012; SHENG, 2014).

Dentre os maiores esforços para aplicação de um sistema de manutenção em redutores, se destacam os controles realizados para contornar as possíveis falhas apresentadas pelos rolamentos, que, nesses equipamentos, apresentam os maiores volumes de falhas (SUMITOMO DRIVE TECHNOLOGIES, 2023). Mais de 50% das falhas nos redutores são provocadas por falhas prematuras nos rolamentos. Em um levantamento realizado por Sheng (2014), abrangendo 270 redutores, a principal causa de falha nesses equipamentos, com um total de 70% dos casos, está relacionada aos rolamentos, seguido de 26% dos casos para falhas nas engrenagens e 4% para os demais casos.

### 2.1.2. Falhas em rolamentos

Rolamentos são equipamentos que permitem, operando com baixo atrito, o movimento rotacional relativo entre elementos conectados. Em relação aos seus tipos, os rolamentos são classificados, principalmente, quanto aos seus elementos rolantes, podendo ser esféricos, de rolos cilíndricos, de rolos cônicos e de agulhas, sendo que, os mancais com elementos rolantes de roletes possuem a capacidade de suportar maior carga, se comparados com os

mancais com elementos esféricos. Isso se dá pelo fato da maior distribuição de tensão entre os elementos, proporcionado por suas geometrias (MARGHITU; DUPAC, 2019).

Os mancais de rolamento também podem ser classificados quanto ao tipo de esforço que será solicitado, podendo ser do tipo radial, quando os esforços estão no sentido radial, axial, quando os esforços estão no sentido axial, ou angular, quando existem os dois tipos de esforços aplicados (JUVINALL; MARSHEK, 2013).

A seguir, na Figura 2, está representada a estrutura de um rolamento de esforço radial com elementos rolantes do tipo roletes cilíndricos.

Figura 2 - Rolamento radial do tipo cilíndrico.
Fonte: (SKF, 2023. Modificado).




Os rolamentos são elementos de máquina amplamente estudados para se obter um meio eficaz de predizer falhas, visto que esses componentes são um dos principais causadores de falhas em máquinas rotacionais (CERRADA et al., 2018). Os tipos de falha mais comuns em rolamentos são desgaste por partículas estranhas, descascamento por fadiga, ranhuras, oxidação, lubrificação inadequada, excesso de pré-carga ou sobrecarga, excesso de folga lateral, dano por impacto, entre outros (TIMKEN, 2023).

Segundo a Timken (2023), em mais de 50% dos seus casos de manutenção, os rolamentos não atingiram a vida nominal planejada, sendo que em 90% dos casos os problemas estão associados a fatores como: partículas estranhas, corrosão, lubrificação

inadequada, manuseio inadequado e condições operacionais impróprias e em cerca de 10% dos casos os problemas estão associados a fadiga por contato.

O desgaste por partículas estranhas se caracteriza como uma das causas mais comuns de problemas em rolamentos. Esse tipo de falha pode surgir de um processo de fragmentação, denominado *spalling*, originado de um lascamento de material, que geralmente é provocado por fadiga, originada de uma nucleação e posterior propagação de uma trinca, denominado *pitting,* e posterior formação das micropartículas (VANEGAS; ÁLVAREZ; DE SOUZA, 2009).

As micropartículas estranhas presentes no óleo também podem surgir de retentores gastos ou defeituosos, o que proporciona a contaminação do óleo lubrificante com agentes externos ao redutor. Os modos de desgaste predominantes causados por essas partículas estranhas são por deslizamento e rolamento dessas partículas nas superfícies dos componentes do redutor. A falta de uma limpeza inicial adequada das caixas e outras peças, juntamente com a utilização de filtragem inadequada ou a manutenção incorreta dos filtros, pode resultar no acúmulo de partículas abrasivas. Esse processo, por sua vez, não apenas compromete a vida útil do rolamento, mas também amplifica os efeitos prejudiciais ao afetar outros componentes (TIMKEN, 2023; ALBERTIN, 2003).

Ainda a respeito das partículas estranhas, estas podem provocar outros dois tipos de falhas que são o descascamento por fadiga mecânica e as ranhuras nos componentes dos rolamentos como pista interna e externa e os elementos rolantes. O descascamento se origina do desgaste abrasivo e a falha por fadiga do material, já as ranhuras, partem de incrustações das partículas estranhas nas folgas dos porta rolos do rolamento que, por obterem dureza superior aos componentes do rolamento, deformam a superfície plasticamente, o que prejudica a geometria de contato dos rolos e das pistas, reduzindo a vida útil do rolamento (ABECON, 2020).

Outro tipo de falha que causa grande impacto na vida útil dos rolamentos é a lubrificação inadequada. Segundo Reichmann (2022), cerca de 80% das falhas em rolamentos estão conectadas com aspectos da lubrificação, como lubrificação imprópria, lubrificante envelhecido, falta de lubrificante e contaminação do lubrificante. A lubrificação em rolamentos, em sua maioria, é realizada com graxas, que são compostas de um óleo base e espessante. Essa lubrificação possui três fases, segundo Lugt (2013), que são a fase da agitação, em que a graxa é realocada entre as partes do rolamento, a fase da deposição do óleo, quando a graxa está se sedimentando e por fim, a fase em que a lubrificação diminui e pode ocorrer contato metal-metal.

É crucial realizar uma análise criteriosa na determinação da quantidade apropriada de lubrificante, seu tipo, grau, sistema de aplicação, viscosidade e aditivos específicos para cada

sistema de rolamentos, considerando fatores como histórico, carga, velocidades, sistemas de vedação, condições de serviço e expectativa de vida útil. O desempenho do rolamento e da aplicação pode ficar aquém das expectativas se esses elementos não forem devidamente ponderados. A falha nos rolamentos devido a uma lubrificação inadequada pode se manifestar de maneiras diversas, variando desde uma alteração leve na coloração devido ao calor até um travamento total com considerável fluxo de metal, dependendo da gravidade da falha (TIMKEN, 2023).

A seguir estão representados, na Tabela 2, os níveis de falhas em rolamentos proporcionados por lubrificação inadequada:

Tabela 2 - Níveis de falhas em rolamentos devido a lubrificação inadequada.
Fonte: (TIMKEN, 2023).

| Nível | Dano | Causa |
|---|---|---|
| 1 | Descoloração | O contato direto entre superfícies metálicas aumenta temperatura que provocam descoloração das pistas e dos rolos |
| 2 | Descascamento | A falta ou insuficiência de lubrificante, seleção inadequada do tipo de lubrificante e variações bruscas de temperatura ou mudanças repentinas nas condições operacionais |
| 3 | Aquecimento excessivo na extremidade dos rolos | Película de lubrificante inadequada provoca altas temperaturas localizadas e deformação nas extremidades maiores dos rolos |
| 4 | Travamento total do rolamento | O calor concentrado pode fundir o metal, enviesando os rolos, destruindo o porta-rolos e, por fim, travando totalmente o rolamento. |

O excesso de pré-carga em rolamentos pode desencadear superaquecimento e resultar em falhas que, à primeira vista, assemelham-se àquelas associadas à lubrificação inadequada. Dada a propensão à confusão entre essas causas, é imperativo realizar uma análise criteriosa para identificar com precisão a origem do problema. Notavelmente, um lubrificante adequado para operações normais pode revelar-se inadequado quando aplicado a um rolamento submetido a alta pré-carga, pois a resistência de sua película pode não ser suficiente para suportar cargas elevadas. A falha do lubrificante induzida pela pré-carga elevada pode manifestar-se de maneira semelhante às falhas decorrentes da inadequada lubrificação, conforme descrito anteriormente. Além disso, mesmo a utilização de um lubrificante de extrema pressão, projetado para suportar cargas significativas, não elimina o

risco de falhas, como o descascamento por fadiga subsuperficial, quando altas pré-cargas estão presentes. O desencadeamento e a vida útil subsequente desse processo dependerão diretamente da magnitude da pré-carga e da capacidade intrínseca do rolamento (ABECON, 2020).

Outro meio de falha pode acontecer devido a manipulação e montagem incorreta de rolamentos, que pode proporcionar danos nos elementos rolantes, pistas e bordas. Impactos que resultam em marcas profundas na superfície da pista e golpes nos elementos rolantes podem gerar levantamento de metal, causando descascamento localizado prematuro e resultando em rugosidade, vibração e ruído no funcionamento do rolamento. Além disso, é importante destacar que o manuseio negligente e a utilização de ferramentas inadequadas durante a montagem podem causar danos significativos aos porta-rolos. Esses componentes, comumente fabricados em aço doce, bronze ou latão, são suscetíveis a danos provocados por manipulação ou montagem incorreta, levando a problemas prematuros de desempenho (TIMKEN, 2023).

Segundo Zhang et al. (2020), após um certo período suportando cargas, os rolamentos podem falhar por fadiga sendo necessário sua troca. Um dos meios para manutenção preventiva dos rolamentos é a aplicação de graxas lubrificantes, com o intuito de diminuir o atrito, entretanto, quanto maior a carga em que o rolamento estiver exposto mais rapidamente a graxa lubrificante se oxidará, devido as altas temperaturas, diminuindo assim sua vida útil. Quatro aspectos são importantes a serem observados para realização de manutenção, que são: variações de temperatura, vibração, ruído e mudanças no lubrificante.

Um meio para predição de falhas em rolamentos, comumente utilizado, é a análise do espetro vibracional, Monavar, Ahmadi e Mohtasebi (2008), realizaram um estudo de aplicação de manutenção preditiva em rolamentos, mediante análise vibracional do sistema. Os estudos mostraram que o rolamento danificado apresenta um forte impacto no espectro vibracional do sistema, indicando uma possível falha do componente.

A análise de frequências dos rolamentos pode não ser completamente precisa na predição da sua condição devido a algumas limitações, como a dificuldade na detecção de ruídos iniciais que indicam falhas, devido à presença de ruídos de fundo provenientes do processo e do equipamento (ZHONG et al., 2018). Por isso, é necessário o uso de técnicas computacionais avançadas, como o aprendizado de máquina, para a detecção e seleção dos dados apropriados para a análise de falhas em rolamentos. Essas técnicas permitem a identificação e interpretação precisa dos sinais de vibração dos rolamentos, contribuindo para a manutenção preditiva mais eficiente e confiável.

## 2.2. Manutenção aplicada ao cenário da indústria 4.0

Segundo Raghavaiah e Hariprasad (2019), a manutenção pode ser definida como todo tipo de atividade realizada que mantém um certo equipamento em funcionamento, com o objetivo de manter a capacidade do sistema como um todo. Quatro tipos de manutenções são comumente empregadas no meio industrial, sendo elas a manutenção corretiva, preventiva, centrada na confiabilidade e a manutenção preditiva.

A manutenção corretiva é realizada, basicamente, quando existe alguma falha no equipamento, provocando paradas de produção não programadas, o que pode gerar um impacto financeiro para a indústria. Já a manutenção preventiva é realizada por intermédio de paradas programadas na produção, e nessas paradas a linha de produção é supervisionada e pequenas manutenções são realizadas, com o objetivo de prolongar a vida útil dos equipamentos e evitar a falha prematura. A manutenção centrada na confiabilidade, por sua vez, tem o objetivo de realizar um estudo prévio de todos os módulos de falhas possíveis para cada equipamento, e desenvolver um roteiro de manutenção individual, aumentando a confiabilidade e disponibilidade do equipamento. Por fim, a manutenção preditiva, tem por objetivo prever falhas antes que elas aconteçam, permitindo, assim, que as devidas correções sejam realizadas no momento certo e de forma programada (RAGHAVAIAH; HARIPRASAD, 2019).

O avanço tecnológico e o crescimento dos conceitos da indústria 4.0 estão aprimorando alguns processos industriais já consolidados, melhorando o controle e a qualidade. Tal avanço tecnológico proporciona um crescimento na geração de dados processuais que podem ser utilizados para observar o histórico de comportamento e predizer o comportamento futuro. Com a facilidade e o crescimento do monitoramento produtivo, as tecnologias da indústria 4.0 contribuem para as manutenções no tempo correto, reduzindo as ocorrências de paradas produtivas inesperadas, devido a predição de falhas proporcionadas pela análise e processamento dos dados coletados.

A indústria 4.0 conta com estruturas que são usadas com combinações específicas entre si, dependendo do problema que será resolvido. Tais estruturas são: interoperabilidade (capacidade dos sistemas ciber-físicos de comunicarem entre si), virtualização (capacidade dos sistemas ciber-físicos de transformar um sistema físico em um sistema virtual), descentralização (autonomia do sistema para tomada de decisão), comunicação em tempo real e modularização (capacidade de se adaptar de forma flexível ao problema proposto) (HERMANN; PENTEK; OTTO, 2015).

Levando em consideração a virtualização presente nas tecnologias da indústria 4.0, esta pode ser entendida como a criação de uma versão virtual de um modelo físico pelo sistema ciber-físico, gerando uma conexão que é utilizada para coleta de dados, impactando o modelo (HERMANN; PENTEK; OTTO, 2015; PIRES et al., 2019). A partir deste conceito nasceu o gêmeo digital, que pode ser definido como uma representação unificada, detalhada e realista do sistema ciber-físico, e conta com aspectos de modularização, autonomia e conectividade, além de envolver processos cognitivos de controle (ROSEN et al., 2015; VIOLA; CHEN, 2023). O GD é eficiente para o controle de processos, análise de desempenho, assim como, colabora para a realização da predição de falhas mediante simulações, utilizando dados processuais reais e retornando parâmetros preditos (AIVALIOTIS; GEORGOULIAS; CHRYSSOLOURIS, 2019). Outro aspecto que integra sua definição é a simulação multiescala, que se baseia na divisão da análise em módulos, o que colabora com a eficiência do fluxo das informações (SHAFTO et al., 2010).

### 2.2.1. Gêmeo digital como ferramenta para a manutenção

Gêmeo digital é uma tecnologia que possui a funcionalidade de executar de forma virtual um processo real, com o objetivo de analisar, controlar e melhorar o desempenho dos processos reais. Seu princípio de funcionamento se baseia na obtenção de dados de uma fonte física, manipulação desses dados utilizando o processo virtual criado, geração de informações e devolução dessas para o meio físico (GRIEVES; VICKERS, 2017).

A primeira definição desta tecnologia surgiu com Grieves (2014), apresentando-o apenas como uma representação virtual de um modelo físico. Este conceito obteve incrementos e novas vertentes ao longo dos anos, como pode ser visto por Tao e Qi (2019) que apresentaram o GD como cópias virtuais precisas de processos ou produtos que são sustentadas por dados coletados por sensores em tempo real. Já IBM (2020), destaca em sua definição, a evolução do sistema em relação ao ciclo de vida do meio físico e apresenta a importância da incorporação de técnicas como aprendizado de máquina, simulações e análise de dados, fornecendo autonomia ao sistema.

Segundo GE Digital (2019), o gêmeo digital é uma representação virtual de um ativo ou processo usado para entender, prever e otimizar suas funcionalidades. Deloitte (2020) também compartilha dessa definição e complementa que, ao aplicar esta tecnologia, é possível, rapidamente, simular condições e compartilhar dados de forma a atuar no meio físico, buscando os melhores cenários de saída.

Glaessgen e Stargel (2012) e Dufour (2018) apresentam o conceito de GD como uma integração multi-física, multiescala e multifacetada com diferentes técnicas e modelos digitais que são capazes de reproduzir, com alta fidelidade, processos, produtos ou sistemas de operação.

Em um ponto de vista produtivo, o GD, com suas virtualizações, pode colaborar com outros sistemas, com o propósito de alcançar uma inteligência abrangente que permite o autocontrole descentralizado (WEBER, et al., 2017). Possui ainda, como uma das principais características, a capacidade de transmissão constante e instantânea de dados e informações entre os meios, visando a otimização e evolução sistêmica (NEGRI et al., 2017; SODERBERG et al., 2017).

O conceito pode ser dividido em duas vertentes, o gêmeo digital que utiliza das informações necessárias do meio físico para descrever o virtual, para isso podem ser usados modelos 3D, porém não estão limitados à modelagem e, por sua vez, o gêmeo digital que possui como foco a troca de informações constante tornando-o dinâmico (GRIEVES; VICKERS, 2017).

O primeiro conceito de gêmeo digital, apresentado por Grieves (2014), foi elaborado considerando três dimensões para o seu funcionamento, sendo a primeira a entidade física no espaço físico, a segunda a entidade virtual no espaço virtual e a terceira a conexão e transmissão de dados bidirecional entre os espaços físico e virtual. Todavia, o avanço tecnológico e o aumento substancial da geração de dados dos equipamentos modernos, tornam a proposta de Grieves obsoleta, dessa forma, Tao et al. (2018) propuseram a complementação de duas dimensões ao modelo de Grieves que são os módulos de dados e serviços.

Nesse novo modelo proposto por Tao et al. (2018), a dimensão de dados assume uma posição central no sistema, realizando o cruzamento das informações, o que gera insights e controle dos dados, já a dimensão de serviços presta suporte ao meio físico e virtual, com o objetivo de promover a otimização do sistema físico e manter a alta fidelidade do meio virtual.

Segundo Tao, Zhang e Nee (2018), a aplicação do GD possui alguns pontos positivos em relação ao controle e produtividade, como: monitoramento de produtos e serviços de forma dinâmica, com alta fidelidade e em tempo real; Auxílio na elaboração de novos produtos, diminuindo e até evitando erros de projetos, além da possibilidade de fornecer aos clientes a experiência virtual antes que o produto físico esteja disponível; Interconexão em tempo real entre a parte física e a virtual, permitindo a otimização no

funcionamento do sistema; Suporte na manutenção por meio da predição de falhas e controle dos ativos; Possibilidade de incorporação de diferentes tecnologias, o que aumenta a capacidade de aplicação em diferentes meios.

Todavia, alguns desafios podem ser encontrados em relação a implementação desta tecnologia, segundo Tao, Zhang e Nee (2018) e Viola e Chen (2023), como: desafios de modelagem e integração entre os diferentes softwares necessários para a elaboração e execução do sistema, provimento da comunicação adequada entre os sensores e receptores, armazenamento e manipulação de grande quantidade de dados (*big datas*), nível técnico dos indivíduos envolvidos na sua implementação, visto que, por se tratar de uma tecnologia emergente, muitos conceitos e técnicas não fazem parte de muitos meios aos quais o gêmeo digital pode ser implementado. Infraestrutura do ambiente de implementação, além da capacidade tecnológica dos itens que irão compor o sistema, podem apresentar obstáculos para sua execução. Por se tratar de uma tecnologia que incorpora, em um único sistema, várias técnicas, o suporte pode ser um desafio, visto que, vários provedores estão envolvidos. O GD se trata de um processo oneroso devido aos gastos com sensoriamento, conectividade, além de hardwares e softwares para o armazenamento dos dados, dessa forma, sua aplicação tende a ser desenvolvida para produtos ou serviços de maior valor agregado, por fim, o desenvolvimento insuficiente do conceito e falta de definição concreta, podem vir a dificultar a implementação do sistema.

### 2.2.2. Aplicações de Gêmeo digital na manutenção industrial

O gêmeo digital envolve diferentes áreas como: trabalho colaborativo entre humanos e robôs (LIU; WANG; WANG, 2022), fábricas inteligentes (XIA et al., 2022; ALI et al., 2021), setor de telecomunicações (MOZO et al., 2022), sistemas de geração de energia (ARRANO-VARGAS; KONSTANTINOU, 2022), processos de manufatura aditiva (DEBROY et al., 2017), sistemas de agricultura inteligente (VERDOUW et al., 2021), entre outros. Além disso, por se tratar de uma metodologia que admite diversas tecnologias para aplicação, é empregada para resolução de diferentes demandas, como aplicação de manufatura inteligente (QI; TAO, 2018), manutenção preditiva (LUO et al., 2020; TAO et al., 2018; XU et al., 2019; REN; WAN; DENG, 2022), análise estrutural (ANGJELIU; CORONELLI; CARDANI, 2019), análise de desempenho (CORADDU et al., 2019), assim como manutenção não tripulada (LV et al., 2023; KHAN et al., 2020), para estas demandas, propostas de resolução estão aplicando diferentes conexões como o funcionamento colaborativo do GD com a utilização de Big Data (QI; TAO,

2018), utilização da análise de dados históricos juntamente com os dados dinâmicos fornecidos por GD (LUO et al., 2020; XU et al., 2019), utilização de modelagem em elementos finitos (ANGJELIU; CORONELLI; CARDANI, 2019) e aprendizado de máquina (REN; WAN; DENG, 2022).

Zhang et al. (2022a), realizaram um trabalho de aplicação de gêmeo digital em um processo de laminação de tiras. O estudo comparou o método tradicional de monitoramento de vibração utilizando sensores com o sistema desenvolvido que foi alimentado com a carga de laminação e a velocidade de laminação do laminador, esses dados foram processados e o modelo virtual informou a vibração na carcaça do equipamento. Essa vibração foi comparada com a que foi coletada no laminador e o GD informou os valores de velocidade e força de laminação que amenizaria a vibração no processo. Este trabalho evidencia a função de um modelo virtual para a geração de economia no processo e aplicação de manutenção preditiva.

Visto que a manutenção preditiva colabora para o alto desempenho produtivo industrial e que a manutenção multinível, por envolver diversos parâmetros para sua construção, possibilita maior assertividade e robustez para o sistema, Feng et al. (2023) desenvolveram um gêmeo digital para elaboração e controle de um cronograma de manutenção preditiva multinível para um parque industrial, com foco em autonomia nas tomadas de decisão. Para isso elaboraram um sistema autônomo capaz de verificar o funcionamento de diversas máquinas mapeadas, mediante dispositivos sensoriais. As informações coletadas foram processadas por um algoritmo desenvolvido capaz de tomar decisões utilizando parâmetros pré-determinados, como: ciclo de produção, número de componentes críticos, custos do equipamento, técnicos de manutenção disponíveis, quantidades de peças de reposição em estoque, entre outros. Após o processamento, um cronograma de manutenção foi construído e retornado ao meio físico fechando o ciclo.

Com o intuito de elaborar um sistema preditor de falhas em um parque industrial, Hassan, Svadling e Bjorsell (2023) elaboraram um gêmeo digital baseado em dados, que utiliza da comparação de desempenho do meio físico para predizer o status de funcionamento do maquinário, sendo que as discrepâncias encontradas são evidenciadas como pontos de manutenção. Os resultados dos modelos foram classificados em três tipos: configurações de parâmetros, substituição de componentes e degradação. Para avaliação do desempenho do modelo digital, foi utilizada uma técnica de caixa cinza, além da análise comparativa entre as respostas do sistema e as fichas de manutenção cadastradas por especialistas. Por ser desenvolvido um modelo sem autonomia, a troca de informações entre o meio físico e digital não apresentou sincronia, provocando algumas respostas equivocadas por parte do GD.

A autonomia industrial possui um importante papel para a diminuição de erros provenientes da ação humana, além de proporcionar maior flexibilidade quanto a operações devido a possíveis ausências de operadores. Influenciados pela demanda por manutenções não tripuladas de máquinas-ferramenta, Lv et al. (2023) desenvolveram uma arquitetura de gêmeo digital capaz de auxiliar na manutenção não tripulada utilizando suporte cognitivo. O modelo digital desenvolvido se baseia em um método cognitivo denominado LIDA. Esse método utiliza de quatro fases: sensorial, memória, atenção e execução. O processo se inicia com a coleta de dados dos sensores, armazenamento dessas informações, inferências a respeito dos cruzamentos dos dados e execução da melhor decisão levantada. Este trabalho resultou na construção de um sistema autônomo e com potencial de evolução sem perdas de eficiência, que utiliza de aspectos técnicos e neurossensoriais sem a dependência de especialistas ou mão de obra humana.

Ainda a respeito de manutenção preditiva, considerando que em muitos equipamentos, diferentes técnicas de predição devem ser empregadas para se determinar a vida útil dos seus componentes, Mourtzis, Tsoubou e Angelopoulos (2023) desenvolveram um gêmeo digital para otimização de confiabilidade de células robóticas quanto a vida útil dos seus elementos. O sistema foi elaborado utilizando aprendizado de máquina supervisionado, com o objetivo de detectar e classificar o comportamento defeituoso dos componentes críticos, além da elaboração de um modelo 3D, desenvolvido mediante os dados obtidos do modelo físico por meio de dispositivos sensoriais. Todos os módulos construtivos elaborados foram compilados e processados, debatendo-os com os elementos críticos levantados.

Aivaliotis, Georgoulias e Chryssolouris (2019) também desenvolveram um GD com foco na determinação de vida útil de elementos de máquinas. Para isso, inicialmente, os dados foram coletados por controladores e utilizados como parâmetros de ajustes síncronos dos modelos digitais. Os resultados de análise foram processados a ponto de predizerem a vida útil dos equipamentos.

## 2.3. Propriedade de modularização do gêmeo digital

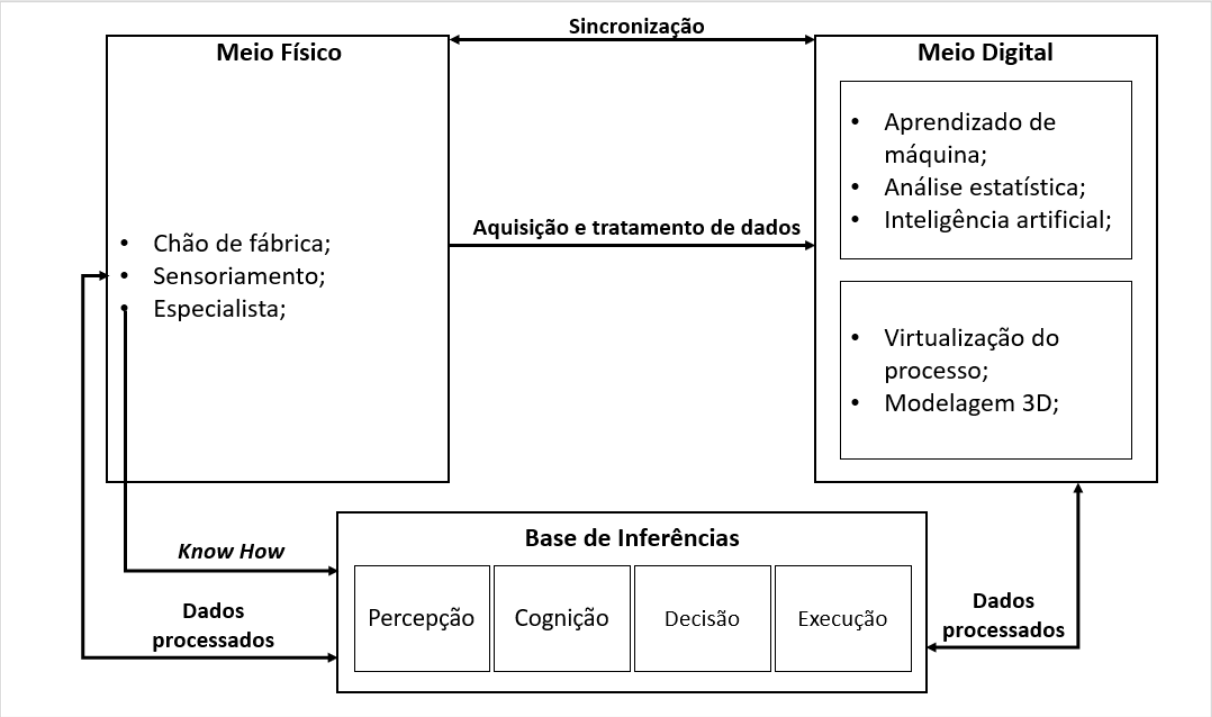
Um aspecto relevante do GD é a modularização do sistema, que permite que uma solução complexa seja subdividida em soluções pontuais que, ao funcionar em conjunto, proporcione resultados robustos e completos.

Rolle, Martucci e Godoy (2021), desenvolveram um GD enfatizando a modularização do sistema. Na ocasião o gêmeo digital foi composto por cinco módulos, sendo o módulo 1 o controle do processo, o módulo 2 o sistema físico, o módulo 3 análise de dados, o módulo 4 virtualização do processo e por fim, o módulo 5 modelagem 3D do meio físico. Os autores destacam que a abordagem modular reduz a interdependência entre os módulos e fornece escalabilidade.

> Os componentes fundamentais para a elaboração de um GD são a captação dos dados no meio físico, transmissão das informações, simulação, análise de dados e atuadores (VIOLA; CHEN, 2023). Os sensores são aparelhos utilizados para captação de dados do meio físico, esses dados são transmitidos por intermédio do módulo de conexão e armazenados em um banco de dados. Os dados armazenados podem ser analisados ou utilizados para validação da simulação matemática. Essa, por sua vez, consiste na representação virtual do meio físico, levando em consideração os aspectos constitutivos e as interações entre os indivíduos e elementos do sistema. A etapa de análise permite visualizar a performance e produzir insights a respeito do GD e a respeito do sistema real. Por fim, os atuadores correspondem à parte mecânica do processo, que recebe os dados analisados e atuam no meio físico com as devidas melhorias e ajustes processuais.

Com base nas arquiteturas desenvolvidas por Lv et al. (2023) e Quin, Wu e Lyu (2018), é proposta uma arquitetura de gêmeo digital na Figura 3, que demonstra a propriedade de modularização do sistema.

Figura 3 - Representação esquemática de um modelo de gêmeo digital.
Fonte: (Elaborada pelo autor).




O módulo central do gêmeo digital apresentado na Figura 3 é a base de inferências, pois ela capta informações dos demais módulos e os processa para tomada de decisão coerente. As decisões e inferências resultantes retornam para o processo físico e digital atualizando-os. Dessa forma, o sistema pode se tornar autônomo. A base de inferências é composta por quatro etapas: (1) Percepção – que consiste na compilação dos dados recebidos e armazenamento; (2) Cognição – reprocessamento dos dados para tomadas de decisão; (3) Decisão – elaboração de decisão frente as informações recebidas da etapa anterior; (4) Execução – atuação nos módulos físicos e digitais com respaldo do processo.

Como foi retratado na revisão, um GD possui uma transmissão de dados sincronizada e bidirecional e o sistema pode contar ainda com *know how* dos seus operadores. Em relação ao módulo “Meio Digital”, presente na Figura 3, pode ser subdividido em dois subgrupos, um voltado para análise de dados e outro para modelagem 3D do processo. Portanto, um GD pode contar com diferentes práticas, métodos ou tecnologias que facilitem a interação e inferência a respeito da conexão entre um meio físico e um meio virtual.

Todavia, o sistema somente é caracterizado como gêmeo digital, se houver a virtualização do processo e o fluxo bidirecional de informações entre o meio físico e o meio digital. Porém, submódulos se destacam por tornar o sistema mais completo, preciso e

confiável, entre eles, apresentado na Figura 3, está o submódulo referente à análise e manipulação de dados.

Uma das principais vantagens do GD é a capacidade de coletar e analisar dados em tempo real, permitindo tomada de decisão de forma mais dinâmica, realização de previsões e otimizações que aprimorem o desempenho e a eficiência do processo representado. Nesse sentido, o aprendizado de máquina desempenha um papel importante, pois é uma técnica computacional que permite que os sistemas analisem grandes conjuntos de dados, identifiquem padrões e aprendam com eles. Assim, essas técnicas podem compor a estrutura de um GD, por meio da análise dos dados coletados pelo sistema, possibilitando a criação de modelos preditivos cada vez mais precisos e sofisticados, capazes de fornecer informações valiosas para a tomada de decisões e aprimoramento contínuo do objeto ou processo representado (RITTO; ROCHINHA, 2021).

## 2.4. Aprendizado de máquina como módulo do gêmeo digital

O aprendizado de máquina é um ramo de evolução dos algoritmos computacionais, projetados para reproduzir as funções de inteligência e tomadas de decisões humanas. Trata-se de técnicas que podem utilizar procedimentos estatísticos para predição de algum evento, além de influências de outras áreas do conhecimento como Inteligência artificial, probabilidade, ciência da computação, psicologia e filosofia (EL NAQA; MURPHY, 2015; BISHOP, 2006; SHRESTHA; KRISHNA; KROGH, 2021). De modo geral, representa a capacidade dos sistemas de aprenderem o comportamento dos dados como um todo, para isso, utilizam dados de treinamento, retornando aos usuários a probabilidade do acontecimento de determinado evento (BISHOP, 2006; JANIESCH; ZSCHECH; HEINRICH, 2021; MAHESH, 2020).

O aprendizado de máquina é composto por duas etapas, o treinamento e o teste. O treinamento se baseia na aprendizagem dos padrões pré-determinados, ao qual, amostras de dados de entrada são fornecidos juntamente com os resultados desejados para que o algoritmo seja capaz de criar um padrão e reproduzi-lo, tanto com os dados de treinamento quanto com novos dados (JANIESCH; ZSCHECH; HEINRICH, 2021). Em relação ao teste, esse se baseia na exposição dos dados ao modelo treinado, para que as predições sejam efetuadas. O algoritmo pode realizar novos ciclos de aprendizagem, aprimorando o modelo e corrigindo possíveis erros (EL NAQA; MURPHY, 2015).

Soluções em dados podem ser implementados com diferentes tipos de algoritmos de aprendizado de máquina, sendo os dois principais grupos os aprendizados do tipo supervisionado e do tipo não supervisionado (MAHESH, 2020).

O aprendizado supervisionado utiliza variáveis independentes para prever uma variável dependente. Os algoritmos precisam de assistência externa e o conjunto de dados de entrada é dividido em conjunto de dados de treinamento e teste (EL NAQA; MURPHY, 2015; JANIESCH; ZSCHECH; HEINRICH, 2021; MAHESH, 2020). Algumas das técnicas pertencentes a esse grupo são *decision tree, naive Bayes*, *Support Vector Machine* e redes neurais artificiais (RNA), por exemplo (MAHESH, 2020).

Já em relação ao aprendizado não supervisionado, ao contrário do aprendizado supervisionado, em que existe um indicador na base de dados que aponta ao modelo os momentos que ocorreram ou não o evento de interesse, o modelo é alimentado com um conjunto de dados sem indicação de desfecho, e a modelagem se dá a partir da análise dos padrões e estruturas encontradas. Esse tipo de aprendizado é especialmente útil em casos em que não há uma compreensão clara do que se procura, ou quando o volume de dados é muito grande para rotular manualmente. (EL NAQA; MURPHY, 2015; JANIESCH; ZSCHECH; HEINRICH, 2021; MAHESH, 2020). Algumas técnicas utilizadas nesse grupo são *kmeans*, Fuzzy C-Means, *Hierarchical Clustering* e *principal component analysis*, por exemplo (MAHESH, 2020).

### 2.4.1. Algoritmo de agrupamento *Kmeans*

Em relação ao aprendizado não supervisionado, métodos que utilizam de técnicas de agrupamento se destacam, como é o caso do algoritmo *Kmeans*. Este algoritmo utiliza de estatística clássica para realizar os agrupamentos dos dados baseando-se na distância euclidiana (Equação 1) para cálculo de similaridade entre os pontos e os centros dos grupos. Inicialmente o algoritmo gera, aleatoriamente, alguns pontos que serão os centros dos grupos. A quantidade desses centros gerados depende do valor determinado nos parâmetros do processo. Após a geração desses centros, o algoritmo realiza a distribuição dos dados que estão sendo agrupados, levando em consideração a distância euclidiana de cada dado ao seu centro. A cada iteração os centros são recalculados por meio da média dos pontos atribuídos a cada grupo e o algoritmo processa até que o número de iterações, que são pré-definidos,

aconteça, ou até que o algoritmo apresente convergência por meio da minimização da soma das suas distâncias quadráticas (KRUSE et al., 2013).

$$d(x_i, c_i) = \sqrt{\sum_{i=1}^{n}(x_i - c_i)^2} \quad (1)$$

Em que:

$d(x_i, c_i)$ – Distância euclidiana;
$x_i$ – Vetor de dados;
$c_i$ – Centroide dos grupos *i*;
*n* – Dimensão dos dados.

Os parâmetros fundamentais para a execução do agrupamento utilizando *Kmeans* são o número de grupos, o número de iterações máximas que o algoritmo irá executar, número de inicializações aleatórias e o algoritmo utilizado. Em relação ao número de grupos existem algoritmos que, por meio de técnicas de pontuação e análise de variabilidade dos dados, determinam seu número ótimo. Para o parâmetro que determina o número máximo de iterações, este é determinado por meio de teste e validação, levando em consideração dois aspectos, convergência do algoritmo e custo computacional. Em relação ao terceiro parâmetro, que é o número de inicializações aleatórias, este possibilita que o agrupamento se inicie de diferentes formas, para que o melhor resultado possa ser utilizado. Pelo fato do *Kmeans* se tratar de um método não determinístico (apresenta inicialização aleatória), a aplicação de diferentes inicializações auxilia para a redução do erro ou para a convergência do algoritmo (WU, 2012).

Por fim, o último parâmetro utilizado é o algoritmo aplicado ao método. Como padrão se utiliza o algoritmo *Hartigan-Wong*, todavia, outros tipos de algoritmos podem ser utilizados como é o caso do *Forgy, Lloyd* e *McQueen*. As principais diferenças entre esses algoritmos estão relacionadas à maneira como os centroides são inicializados e como os dados são processados durante as iterações (GÓMEZ; REICH, 2023)

O método de agrupamento *Kmeans*, utilizando o algoritmo *Hartigan-Wong*, visa dividir M pontos pertencentes a N dimensões em K grupos de forma que a soma dos quadrados dentro desses grupos seja minimizada, sendo que nenhum movimento de um ponto de um

grupo para outro reduza a soma dos quadrados das distâncias ou, até que o número de iterações determinado seja alcançado (HARTIGAN; WONG, 1979).

Como meio de avaliação do agrupamento realizado, a métrica de desempenho denominada silhueta pode ser utilizada. O coeficiente de Silhueta calcula o grau de pertencimento de uma amostra a um determinado grupo, avaliando a coesão interna e a separação dos grupos, sendo que, valores mais próximos de 1 representam grupos robustos e coesos (MACIEL; VINHAS; CÂMARA, 2015).

O resultado fornecido por meio do processamento do algoritmo *Kmeans* são rótulos, ou classificadores, que podem ser utilizados como parâmetros para uma posterior classificação, ou podem ser utilizados como foco de um estudo e serem analisados de forma independente, gerando *insights*. Dessa forma, Rodriguez e colegas (2023), aplicaram o método de agrupamento *Kmeans* em uma base de dados que representavam o funcionamento de turbinas eólicas, com o intuito de acompanhar seus dados gerando *insights* para o setor de manutenção. É interessante ressaltar que as informações geradas, por meio dos agrupamentos, não proporcionaram conclusões claras, como, se houveram falhas, quais tipos de falhas, ou se a turbina precisava de algum tipo específico de manutenção. Ao invés disso, o agrupamento gerou alertas a respeito do funcionamento das turbinas, por meio do comportamento incomum dos dados ao serem agrupados, se comparados com os dados de uma turbina que estava funcionando sem anomalias.

Como mencionado, o *Kmeans* pode ser utilizado com o intuito de geração de rótulos, ou classificadores, para aplicação posterior de aprendizado supervisionado. À vista disso, Yoo, Young-Kook e Han (2022), desenvolveram um estudo para auxiliar na manutenção preditiva de robôs de transporte de discos finos de materiais semicondutores. Para este estudo foram utilizadas três etapas, a primeira consistiu no mapeamento dos dados de erro apresentados pelo equipamento, já a segunda etapa consistiu na aplicação do agrupamento nesses dados utilizando *Kmeans*, para que fosse possível determinar padrões e gerar classificadores que foram incorporados a base. Por fim, na terceira etapa foi aplicado um aprendizado supervisionado, por meio de redes neurais artificiais, com o intuito de classificar os dados de funcionamento do equipamento e gerar medidores de desempenho, para que fosse possível analisar o desempenho e predizer falhas ou anormalidades, necessário para aplicação de manutenção programada.

A integração entre diferentes tipos de aprendizados de máquina torna a solução, que geralmente possui origem complexa, mais robusta e confiável. A seguir, está apresentado a

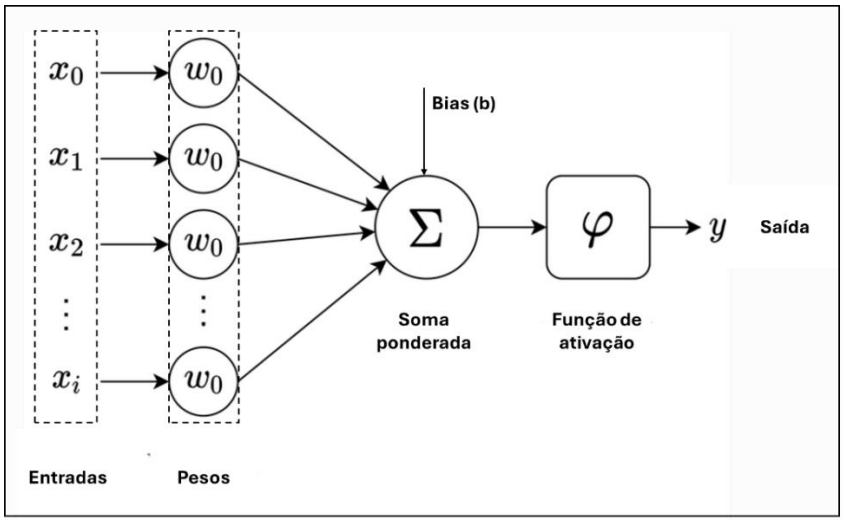
respeito do aprendizado por redes neurais artificiais, assim como suas características, parâmetros internos e princípio de funcionamento.

## 2.4.2. Redes neurais artificiais

Outro aprendizado de máquina que se destaca, principalmente por sua amplitude de aplicação, são as redes neurais artificiais. Compostas por muitas unidades de processamento relativamente simples, denominadas neurônios, as redes neurais artificiais (RNA) operam em paralelo. Esses neurônios trocam informações, sob a forma de potenciais de ação, por meio de conexões direcionadas a outros neurônios, associados a determinado peso. A modelagem e imitação desses sistemas são orientadas pelo conhecimento sobre o funcionamento das redes neurais biológicas, visando, sobretudo, alcançar a capacidade de aprendizado (KRUSE et al., 2013).

Os neurônios são componentes primordiais para o funcionamento da rede. O primeiro modelo de neurônio é o *perceptron*, desenvolvido por Frank Rosenblatt em 1958 (IBM, 2024). Esse modelo de neurônio possui a capacidade de resolução de problemas lineares, o que não representa a maioria dos problemas, que são de origem não linear. Dessa forma foram desenvolvidos outros tipos de neurônios, porém sua estrutura básica e princípio de processamento se mantiveram e estão representados na Figura 4.

Figura 4 - Estrutura de um neurônio em RNA.
Fonte: (NUNES, 2018. Modificado).



O esquema da Figura 4 apresenta valores de entrada x1, x2, ..., xi que são os dados fornecidos ao modelo. Além disso, também apresenta o valor de saída y que representa o resultado fornecido por meio do modelo. Os valores de entrada são ponderados por pesos resultando em uma somatória (Equação 2), que é acrescentado a uma constante b que contribui para o ajuste e refinamento das predições. O resultado da somatória S é aplicada na função de ativação que produz ao valor de saída.

$$S = \sum_{i=0}^{n}(w_i * x_i) + b \quad (2)$$

Em que:

$S$ – Resultado da soma ponderada acrescida do bias;
$x_i$ – Valores de entrada;
$w_i$ – Pesos aplicados;
$b$ – Bias;
$n$ – Número de entradas por neurônio.

As funções de ativação desempenham um papel crucial nesse contexto, conferindo não-linearidade às relações entre os neurônios. Elas possibilitam que a rede modele padrões complexos nos dados, contribuindo para sua capacidade de realizar tarefas diversas, como classificação e regressão. Além disso, as características dos neurônios, como a capacidade de aprender e adaptar-se ao longo do treinamento, são essenciais para o desempenho eficaz da rede. Assim, a interação entre as funções de ativação e as propriedades dos neurônios é fundamental para compreender e aprimorar o funcionamento das redes neurais artificiais em diversas aplicações (KRUSE et al., 2013).

As funções de ativação utilizadas neste trabalho são *ReLU* (*Rectified Linear Unit*), *Softmax* e *Sigmoid* e são funções não lineares, porém amplamente utilizadas e estão associadas ao final da estrutura do neurônio, como pode ser observado na Figura 4.

Considerando a Função *ReLU*, é uma função de ativação que considera apenas a parte positiva dos dados de entrada, ou seja, ela atribui o valor zero se o dado de entrada for negativo, não ativando o neurônio e atribui o valor do dado de entrada se este for maior ou igual a zero, como pode ser observado na Equação 3. Assim, apenas alguns neurônios são ativados, resultando em uma rede esparsa (OBERDIEK; ROTTMANN; GOTTSCHALK, 2018).

$$f(x) = \max(0, x) \qquad se\ x \geq 0 \rightarrow f(x) \qquad se\ x < 0 \rightarrow 0 \tag{3}$$

Em que:

$f(x)$ – Função *ReLU*;
$x$ – Valores de entrada associado ao peso e ao bias;

A função *Softmax* é usada principalmente para problemas de classificação e se difere da função *ReLU* pois ela produz como resposta uma probabilidade normalizada, que varia entre zero e um, sendo que cada saída pode ser interpretada como a probabilidade de pertencimento a uma classe específica. Sua formulação está desenvolvida na Equação 4 (FÁVERO; BELFIORE; SOUZA, 2023).

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^{n} e^{z_j}} \quad para\ i = 1, \ldots, n \tag{4}$$

Em que:

$\sigma(z)_i$ – Representa o valor de saída da função softmax para a i-ésima classe. É a probabilidade estimada de que a entrada pertença à classe i;
$z_i$ – Valores de entrada associado ao peso e ao bias;
$\sum_{j=1}^{n} e^{z_j}$ – É a soma de todos os exponenciais das entradas para todas as n classes;
n – Número total de classes.

Por fim, a função *Sigmoid* possui saída sempre entre 0 e 1, o que se assemelha a função *Softmax*, todavia, devido ao seu formato em “S”, esta função tende a deslocar as saídas para os extremos, o que é vantajoso para problemas de classificação. Sua formulação está apresentada na Equação 5 (FÁVERO; BELFIORE; SOUZA, 2023).

$$f(x) = \frac{1}{1+e^{-x}} \tag{5}$$

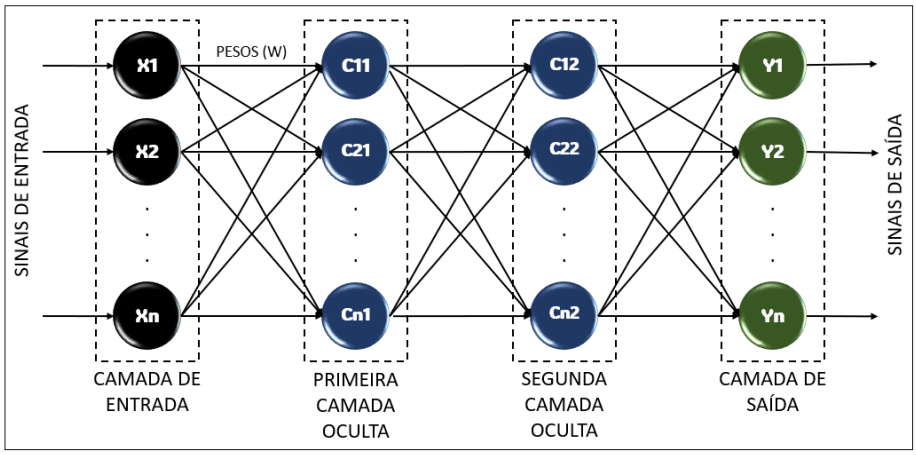
Em que:

$f(x)$ – Função *Sigmoid*;
$x$ – Valores de entrada associado ao peso e ao bias;

As RNA apresentam pontos favoráveis e desfavoráveis que moldam sua eficácia em diversas aplicações. Um ponto forte notável reside na capacidade desses sistemas de aprendizado. A capacidade de adaptar-se e melhorar seu desempenho com base em dados fornecidos é um diferencial significativo. No entanto, um obstáculo crucial é a falta de transparência e interpretabilidade em suas decisões. A complexidade das redes neurais profundas pode tornar difícil a compreensão do raciocínio por trás de suas conclusões, o que levanta desafios éticos e práticos em áreas sensíveis, como a medicina e a tomada de decisões críticas. Portanto, embora as redes neurais artificiais demonstrem notável poder de aprendizado, a opacidade em suas operações é um aspecto que requer atenção cuidadosa em sua implementação (EL NAQA; MURPHY, 2015; JANIESCH; ZSCHECH; HEINRICH, 2021; MAHESH, 2020).

A Figura 5 apresenta um esquema de funcionamento das redes neurais e as devidas conexões dos neurônios por camada. Nesse esquema foi representada uma estrutura com duas camadas ocultas. As camadas ocultas são essenciais para extrair características da camada de entrada. No entanto, a quantidade de camadas ocultas e neurônios devem ser ajustadas conforme o problema. Uma rede com muitos neurônios em uma camada oculta pode se ajustar excessivamente, memorizando os padrões de entrada e prejudicando a generalização. Por outro lado, poucas unidades ocultas podem fazer com que a rede não consiga representar bem os dados. Em geral, redes menores, com menos neurônios e pesos, tendem a ter um desempenho melhor (JONES, 2017).

Figura 5 - Representação esquemática de uma rede neural artificial.
Fonte: (Elaborada pelo autor).




As redes neurais multicamadas contam com um algoritmo fundamental de retropropagação, que consiste na atribuição dos erros de predição da camada de saída nos neurônios das camadas anteriores, ajustando os pesos para que novas iterações possuam o erro de predição minimizado (RUMELHART; MCCLELLAND, 1987). O erro da camada de saída consiste na diferença entre o valor predito e o valor real e, neste trabalho, duas métricas de erro foram comparadas que são a *Categorical-crossentropy* (Equação 6) e a *Sparse-categorical-crossentropy* (Equação 7) (FÁVERO; BELFIORE; SOUZA, 2023).

Para problemas de classificação multiclasse, a *Categorical-crossentropy* é uma métrica comum para calcular a diferença entre distribuições de probabilidade preditas e verdadeiras.

$$categorical\ crossentropy = -\frac{1}{N}\sum_{i=1}^{N}\sum_{j=1}^{C} y_{ij} * \log\left(\hat{y}_{ij}\right) \quad (6)$$

Em que:

$N$ – Número de entradas do conjunto de dados;

$C$ – Número de classes;

$y_{ij}$ – Classe real j para o dado i;

$\hat{y}_{ij}$ – Probabilidade predita da classe j para o dado i;

A métrica de perda *Sparse-categorical-crossentropy* é utilizada para problemas de classificação multiclasse, Em que os rótulos das classes são representados como inteiros.

$$sparse\ categorical\ crossentropy = -\frac{1}{N}\sum_{i=1}^{N} log\ (P_{i,y_i}) \quad (7)$$

Em que:

$N$ – Número de entradas do conjunto de dados;

$P_{i,y_i}$ – é a probabilidade prevista pelo modelo para a classe correta $y_i$ do exemplo $i$;

Levando em consideração os ajustes dos pesos, para minimização dos erros de predição, estes são realizados por meio dos algoritmos de otimização do sistema. Exemplos populares incluem *Gradient Descent*, *Adam*, *RMSprop*, entre outros. Cada algoritmo tem suas próprias características e hiperparâmetros que podem influenciar a velocidade e a eficácia do treinamento (ZOU; HAN; SO, 2008).

A principal função dos algoritmos de otimização está em ajustar os pesos a cada época de treinamento, para que o erro de predição seja minimizado e o modelo consiga convergir. Os otimizadores garantem a eficiência do modelo de aprendizagem construído. O *RMSprop*, abreviação para *Root Mean Square Propagation*, é um método que adapta a taxa de aprendizado para cada parâmetro individualmente. Ele mantém uma média móvel ponderada dos gradientes ao quadrado e utiliza essa média para normalizar a taxa de aprendizado para cada atualização de peso. Isso ajuda a ajustar a taxa de aprendizado de forma mais eficaz, especialmente em problemas com diferentes escalas de gradientes. Por outro lado, o *Adam* (*Adaptive Moment Estimation*) combina os conceitos do *RMSprop* com a ideia de momento, que ajuda a acelerar o processo de aprendizado em direções relevantes e desacelera em direções irrelevantes. Além de armazenar uma média dos gradientes ao quadrado como o *RMSprop*, o *Adam* também mantém uma média móvel dos gradientes (momento). Isso permite que o *Adam* lide de forma eficiente com problemas de otimização complexos, adaptando a taxa de aprendizado de forma dinâmica e geralmente resultando em convergência mais rápida e estável (KINGMA; BA, 2017) (ZAHEER; SHAZIYA, 2019).

### 2.4.3. Aplicações de aprendizado de máquina como módulo do gêmeo digital nos processos de conformação

A geração de dados e informações está em ascendência com o passar dos anos e com o aumento da conectividade tecnológica. Em relação à indústria manufatureira esse volume alcançou níveis na faixa de *exabytes* ($10^{18}$) no ano de 2018 e possui a perspectiva de crescimento de 30% ao ano até 2025 (CUI; KARA; CHAN, 2020). Levando em consideração esse grande volume de dados e a velocidade de geração destes, o aprendizado de máquina se destaca como ferramenta propícia para análise de predições devido à eficiência na execução dos algoritmos. Dessa forma o aprendizado de máquina pode ser aplicado em diversas áreas como: médica e saúde (LIU et al., 2022), telecomunicações (MOZO et al., 2022), automotiva, civil, ferroviário (MARQUEZ et al., 2020), aviação, nuclear, marítima, segurança cibernética (HEGDE; ROKSETH, 2020), indústria 4.0 (DALZOCHIO et al., 2020), indústria de manufatura (SCHWENDEMANN; AMJAD; SIKORA, 2021), entre outras.

Ralph et al. (2022), desenvolveram um gêmeo digital, baseando-se em aprendizado de máquina, que utiliza de um algoritmo de recomendações a respeito do processo de laminação, ao qual fornece um cronograma otimizado com a quantidade de passes de processamento adequados. São fornecidos dados de entrada como largura inicial, espessura final e inicial, carga de laminação e o tipo de material. Como saída o algoritmo recomenda a quantidade de passes adequados para a realização do processo, baseando-se na otimização e redução do atrito. O algoritmo, além de prever e adaptar o cronograma de laminação resultante de uma chapa metálica definida, também é capaz de aprender com os cronogramas adicionais de laminação realizados.

Junquera et al. (2020) desenvolveram um gêmeo digital com o objetivo de realizar a seleção dos cilindros de laminação para cada programação produtiva. Para isso, criaram um algoritmo em *python* que verifica a conformidade dos parâmetros do cilindro, como diâmetro e disponibilidade e indica o par para determinada cadeira de laminação. Além disso, por meio de um modelo em aprendizado de máquina, o sistema possui capacidade de predizer o desgaste nos cilindros e as suas vidas úteis.

Zhang et al. (2022b) desenvolveram um método de previsão de vida útil de rolamentos baseado em gêmeo digital. Para o desenvolvimento do GD foi utilizada uma abordagem de aprendizado de máquina não supervisionado com um algoritmo de árvore de decisão. Os dados utilizados foram os sinais de vibração dos rolamentos. Como resultado, o GD foi capaz

de prever a vida útil do rolamento contando com dados limitados para a realização do processamento.

Qin, Wu e Luo (2022) propuseram um gêmeo digital para o monitoramento de rolamentos ao longo de seu ciclo de vida, utilizando aprendizado de máquina para prever a evolução de falhas. A partir de dados medidos de vibração e do modelo dinâmico de falhas, o sistema estima o tamanho das falhas e aplica uma rede neural de retropropagação (BP) para prever a variação do defeito ao longo do tempo. Além disso, utilizam um método de mapeamento entre o ambiente virtual e o físico, que ajusta os dados simulados para que correspondam aos dados reais coletados, garantindo consistência entre o modelo simulado e os dados reais.

Link et al. (2025), desenvolveram um gêmeo digital para prever a qualidade e realizar ajustes em tempo real nas condições de lubrificação durante o processo de conformação de chapas metálicas. O sistema incorpora um modelo de aprendizado de máquina (ML) avançado, baseado em redes neurais convolucionais, para correlacionar as condições locais de atrito em toda a chapa com a qualidade da peça conformada. O modelo foi treinado com dados de um modelo de elementos finitos (FE) calibrado, permitindo prever em tempo real a geometria e o afinamento da peça. Um algoritmo de otimização calcula ajustes nas condições locais de atrito quando detectadas variações na qualidade, sugerindo a quantidade mínima de lubrificante adicional para corrigir as falhas. Essa abordagem permite que o gêmeo digital faça recomendações em tempo real, com alta precisão, reduzindo o tempo de resposta para ajustes no processo.

Ademujimi e Prabhu (2022), desenvolveram um gêmeo digital para sistemas de manufatura, combinando sensores avançados e controle inteligente com aprendizado de máquina. O modelo utiliza redes neurais convolucionais para prever falhas e ajustar parâmetros críticos, como condições de atrito local em processos de conformação, em tempo real. Com base nos dados dos sensores, o sistema ajusta dinamicamente as condições do processo para minimizar erros de produção, otimizando a qualidade final da peça. Essa abordagem foi validada em sistemas de controle industrial, demonstrando sua eficácia em prever e ajustar falhas com alta precisão e rapidez.

# 3. METODOLOGIA

## 3.1. Contextualização e fluxograma da metodologia aplicada

Este trabalho foi desenvolvido junto à siderúrgica Gerdau – Usina Barão de Cocais com o objetivo de sanar um problema referente à falha prematura dos mancais de rolamento de um redutor que compõe um laminador acabador de barras, de um processo de laminação a quente, por intermédio do uso de aprendizado de máquina. Para o desenvolvimento do modelo de aprendizagem foi utilizado o *software* R, versão 4.4.1 e bibliotecas padrões, assim como as bibliotecas *cluster*, fpc, *factorextra*, *keras* e *tensorflow*.

O fluxograma da metodologia aplicada está apresentado na Figura 6. Inicialmente os dados de produção foram coletados por meio do software de controle utilizado pela Gerdau-BC, denominado *Iba Analyzer*. Um documento que continha os dados de toda a cadeia produtiva foi disponibilizado pela Gerdau, e foi necessário a seleção das informações que correspondiam apenas ao laminador acabador de barras estudado. Os dados foram extraídos no formato txt e devidamente estruturados, como um banco de dados, por meio da utilização do software Excel 2016.

Em seguida a base de dados estruturada foi submetida ao processo de pré-processamento, ao qual valores vazios foram substituídos com a média dos valores dos atributos correspondentes e dados discrepantes foram desprezados para que a análise não apresentasse inconsistência. Esses dados discrepantes foram identificados por meio de variações abruptas nos atributos, correspondendo a informações que possuíam desvio padrão elevado, em relação aos demais dados. Isso ocorreu porque o laminador em alguns momentos estava laminando algum material e em outros momentos não. Devido ao fato, do processo de laminação ser complexo e envolver muitas variáveis, os dados utilizados para construção desse trabalho se referem apenas aos momentos em que o laminador estava funcionando sem carga, ou seja, estava “girando em vazio”.

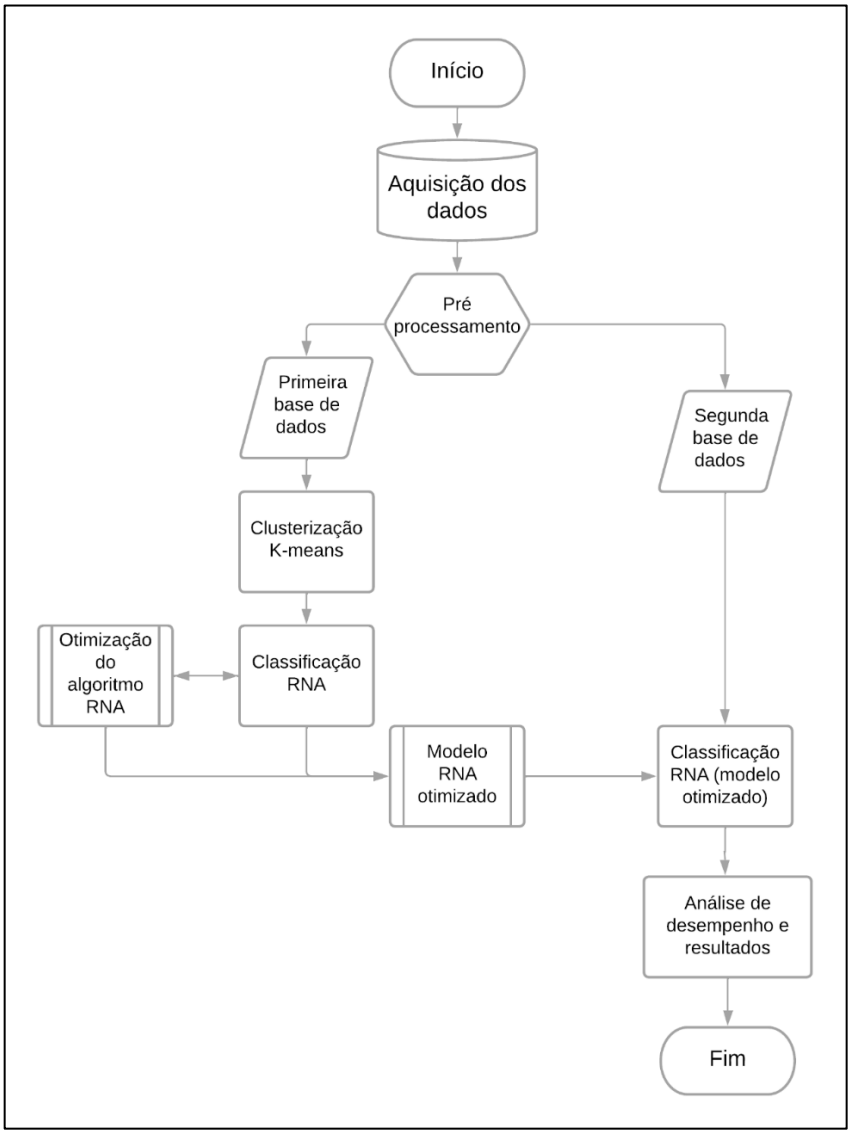
Após o pré-processamento, a primeira base de dados foi agrupada, utilizando o algoritmo *Kmeans*, com o propósito de entender os padrões dos dados e estipular preditores que foram utilizados como classificadores na etapa posterior, em que foi construído um modelo de classificação por meio de RNA. Esse modelo de classificação foi submetido a grupos de testes, em que alguns de seus parâmetros foram alterados, com o propósito de se obter um modelo com elevado nível de acurácia.

Após essa etapa, foi coletado uma segunda base de dados, seguindo o mesmo processo de coleta e pré-processamento da primeira base. Esta segunda base de dados, diferente da primeira, correspondia a um período de produção que antecedeu a falha prematura dos rolamentos.

A segunda base de dados foi classificada utilizando o modelo treinado e testado na primeira base. É importante ressaltar que o modelo RNA não foi treinado novamente na segunda base de dados, esse processo se restringiu apenas a primeira base.

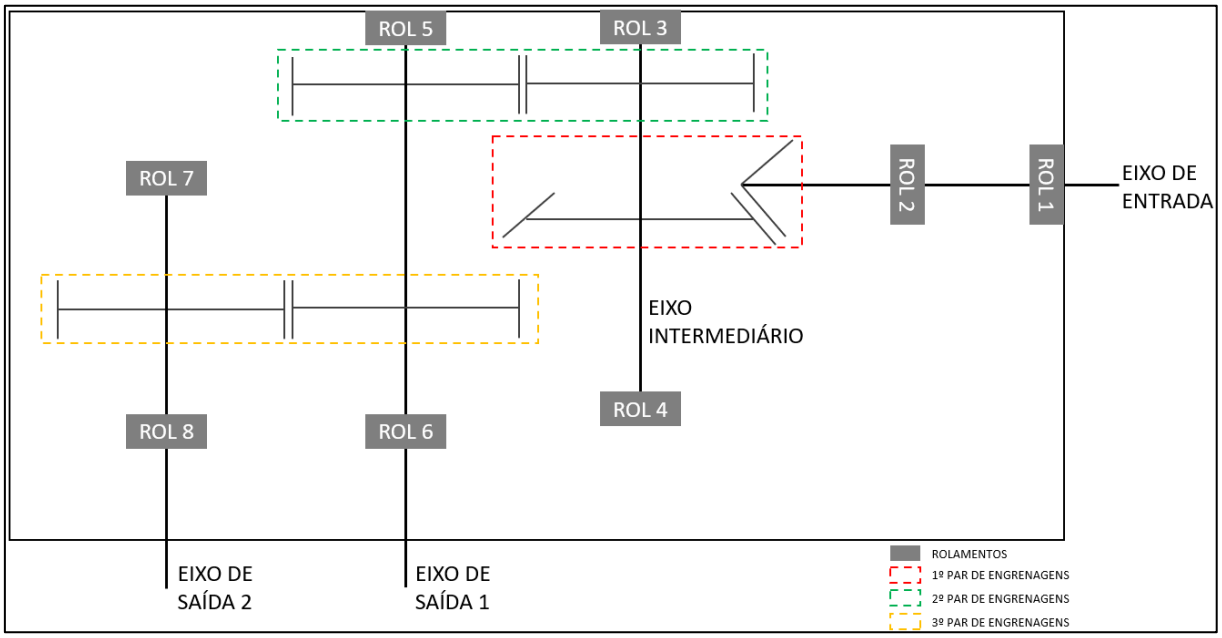
Por fim, as informações da classificação foram discutidas e analisadas, com o propósito de identificar se a corrente do motor, que é o atributo de enfoque, pode ser um preditor de falhas para o sistema de rolamento que compunha o redutor do laminador acabador de barras.

Figura 6 - Fluxograma da metodologia aplicada.
Fonte: (Elaborada pelo autor).



Na Figura 7 está apresentado um esquema do redutor que foi estudado, visto que a representação 2D do redutor é de propriedade intelectual da Gerdau e não pode ser publicado. O rolamento estudado está identificado como “ROL 1”, que, segundo a Gerdau, apresentava recorrência em falhas prematuras, o que o tornou o elemento crítico entre os demais rolamentos. O eixo de entrada representa o eixo que é acoplado ao motor. Em seguida existem as demais relações de transmissão das engrenagens, os rolamentos que sustentam os eixos e os eixos de saída 1 e 2, aos quais são acoplados os cilindros de laminação.

Figura 7 - Representação esquemática do redutor do laminador acabador de perfis da Gerdau-Barão de Cocais.
Fonte: (Elaborada pelo autor).




O rolamento ROL 1 é fornecido pela empresa TIMKEN e está representado na Figura 8. Esse rolamento é do tipo cônico, ou seja, possui pistas e elementos rolantes cônicos. Além disso suporta cargas combinadas, sendo elas radiais e axiais. O ângulo dos cones é de 45º e este rolamento é atribuído a aplicações de cargas média a pesadas.

Figura 8 - Rolamento TDO HM926747 / 10CD – XA.
Fonte: (TIMKEN, 2019).



A Figura 9 e a Figura 10 apresentam os dados técnicos do rolamento como dimensões e capacidade de carga. A capacidade de carga C90 é a capacidade radial de carga dinâmica equivalente para 90 milhões de rotações (ou uma vida útil equivalente), geralmente usada como uma referência para rolamentos cônicos. Essa medida reflete a carga que o rolamento pode suportar durante o seu ciclo de vida previsto. Já a capacidade de carga Ca90 é a capacidade axial do rolamento, ou seja, a carga que ele pode suportar ao longo do eixo, também considerando 90 milhões de rotações.

Por fim, a capacidade de carga C90(2) refere-se à capacidade de carga para um período de duas vezes 90 milhões de rotações. Isso dá uma ideia de como a carga suportada pode mudar quando o tempo de operação é duplicado. Já o coeficiente K normalmente é um fator de carga ou coeficiente, que pode estar relacionado à resistência à sobrecarga ou a ajustes de desempenho para condições especiais.

Figura 9 - Medidas e parâmetros rolamento TDO HM926747 / 10CD – XA.
Fonte: (TIMKEN, 2019).

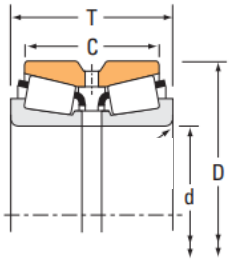


Figura 10 - Dimensões do rolamento e capacidade de carga.
Fonte: (TIMKEN, 2019).

| Dimensões do Rolamento | | | | Capacidade de carga | | | |
|---|---|---|---|---|---|---|---|
| Furo d | D.E. D | Largura T | Largura da capa dupla C | C90 | Ca90 | C90(2) | K |
| **mm** | **mm** | **mm** | **mm** | **N** | **N** | **N** | |
| 127 | 228,6 | 115,888 | 84,138 | 152000 | 192000 | 265000 | 0,79 |

## 3.2. Hipótese e descrição das atividades

A hipótese estudada foi que o aumento de resistência à rotação devido a falha dos rolamentos reflete em um aumento do torque por parte do motor, consumindo maior corrente do sistema. Portanto, a corrente do motor poderia ser um indicador de falha nos rolamentos dos mancais.

A análise de corrente elétrica do motor para determinação de falhas em sistemas mecânicos é um tema amplamente estudado por alguns autores e apresenta como principais vantagens a sua alta confiabilidade, baixo custo e instalação não intrusiva. Ayerbe et al. (2023), desenvolveram uma metodologia para determinação da vida útil de rolamentos esféricos por meio da análise de corrente do motor que estava acoplado ao sistema. Houve validação da metodologia proposta por meio de técnicas que são utilizadas para análise de vida útil, como é o caso da análise dos sinais de vibração.

A Gerdau-BC utiliza das medições de corrente elétrica para determinação da carga de laminação, devido ao fato do laminador em estudo não possuir células de carga. Por se tratar de um equipamento obsoleto, não havia sensores acoplados que facilitassem a análise de vida útil dos rolamentos, dessa forma, uma análise baseando-se na corrente de alimentação do motor foi utilizada.

Para isso existem algumas relações que serão expostas a seguir nas Equações 8, 9 e 10:

$$P = T * \omega \tag{8}$$

$$P = V * I \tag{9}$$

Portanto,

$$I = \frac{T*\omega}{V} \quad (10)$$

Em que:

P – Potência (W);
T – Torque (N*m);
V – Tensão (V);
I – Corrente (A);
ω – Velocidade angular (rad/s).

Inicialmente foi aplicado um aprendizado do tipo não supervisionado, utilizando o algoritmo de agrupamento *Kmeans*. Esse tipo de aprendizado foi utilizado inicialmente porque a base de dados não possuía preditores para aplicação de um aprendizado supervisionado, além disso, por meio desse tipo de aprendizado, é possível identificar os padrões aos quais os dados estão submetidos. Com os grupos definidos, um novo modelo foi aplicado, utilizando RNA com aprendizado por classificação. Por fim, com o modelo de classificação treinado e testado com a primeira base de dados, foi aplicado a uma nova base de dados que corresponde ao período que antecede a falha do rolamento. Foi analisado a variação da frequência das classificações da primeira base de dados para a segunda, com o propósito de construir um modelo preditor que fosse capaz de indicar anormalidade no sistema.

## 3.3. Pré-processamento dos dados

O primeiro passo realizado foi a extração dos dados. Os dados foram coletados em formato txt de um banco de controle da instituição proprietária dos direitos, manipulados para que os atributos fossem identificados e enviados ao software R para processamento.

O primeiro banco de dados recebido corresponde à produção referente aos dias 11 e 12 de agosto de 2022, período posterior a manutenção do redutor e substituição dos rolamentos que falharam anteriormente. O banco de dados fornecido continha 7 atributos e 14400 registros. Os atributos são velocidade do motor (V_M), corrente do motor (CC), tensão do motor (T_M), fator R (R), altura do laço (A), velocidade de saída do material (V_S), velocidade da gaiola (V_G).

As variáveis velocidade do motor e corrente são representados como valores percentuais de suas medidas nominais. A variável fator R, se trata da razão entre as velocidades do material considerando a saída e entrada no laminador. A variável altura do laço, por sua vez, se trata do acúmulo de material entre laminadores. A variável velocidade da gaiola representa as rotações por minuto dos cilindros de laminação.

No Quadro 1 são apresentadas medidas de tendência central e valores máximos e mínimos dos dados listados acima.

Quadro 1 - Análise descritiva dos atributos selecionados.

| **Atributos** | **Média** | **Mediana** | **Desvio Padrão** | **Máximo** | **Mínimo** |
|---|---|---|---|---|---|
| V_M (% velocidade nominal do motor) | 64,56 | 64,66 | 0,57 | 67,60 | 58,95 |
| CC (% corrente nominal do motor) | 3,72 | 3,78 | 2,53 | 8,08 | 0,02 |
| T_M (V) | 512,68 | 515 | 7,82 | 525 | 479 |
| R | 1,47 | 1,47 | 0,01 | 1,48 | 1,46 |
| A (mm) | -46,40 | -93 | 97,33 | 187 | -93 |
| V_S (m/s) | 2,68 | 2,68 | 0,02 | 2,79 | 2,43 |
| V_G (RPM) | 1160 | 1160 | 10,99 | 1220 | 1050 |

Foi aplicado uma análise de regressão linear a base de dados, com o propósito de verificar a correlação entre a variável dependente CC e as demais variáveis independentes, avaliando se há uma relação linear significativa entre elas. O modelo ajustado apresentou um $R^2$ de 0,7572, indicando que aproximadamente 75,7% da variação em CC pode ser explicada pelas variáveis incluídas no modelo. As variáveis V_M, R, V_S e V_G mostraram coeficientes estatisticamente significativos, com p-valores extremamente baixos ($p < 2e\text{-}16$), reforçando a ideia de uma forte correlação linear com a variável dependente. Essas variáveis, portanto, desempenham um papel importante na predição de CC dentro do contexto analisado.

Por outro lado, a variável T_M não apresentou significância estatística (p = 0,804), sugerindo que não tem uma correlação linear considerável com CC. Além disso, a presença de singularidade do atributo A, sugere a possível redundância ou forte colinearidade com outras variáveis do modelo.

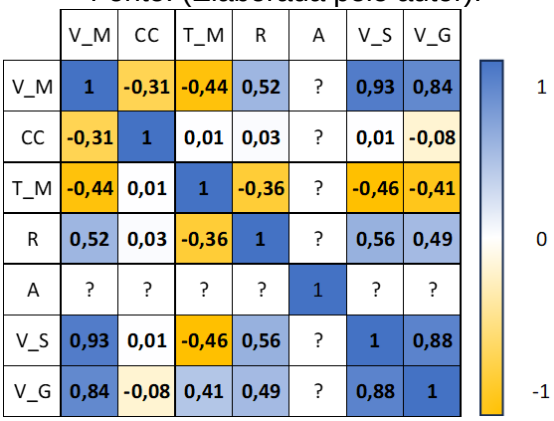
Em termos de ajuste geral, o modelo de regressão mostrou-se robusto, com um erro padrão residual de 1,248 e um *F-statistic* de 7066, ambos sugerindo que a variabilidade explicada pelo modelo é bem superior à variabilidade residual. Assim, a análise demonstra que há uma correlação linear substancial entre algumas variáveis independentes e a variável dependente.

O segundo passo consistiu na seleção dos atributos relevantes e limpeza nos dados por meio de análise de correlação e níveis de significância das variáveis para predição da corrente. Correlação refere-se à relação estatística entre duas variáveis. Ela descreve como as variáveis se movem juntas e até que ponto estão associadas. Quando duas variáveis têm uma correlação positiva, significa que elas tendem a aumentar ou diminuir juntas. Por outro lado, uma correlação negativa indica que uma variável aumenta enquanto a outra diminui.

O coeficiente de correlação mais comum é o coeficiente de Pearson, representado por r, que varia de -1 a +1. Um valor de r = 1 indica uma correlação perfeita positiva, ao qual as variáveis aumentam juntas. Um valor de r = −1 indica uma correlação perfeita negativa, em que uma variável aumenta enquanto a outra diminui. Quando r = 0, não há correlação linear entre as variáveis.

A seguir, na Figura 11, está apresentada a matriz de correlação dos dados. Em relação à corrente do motor (CC), a maior correlação observada foi com a variável velocidade do motor (V_M) no valor de -0,31. Isso significa que as duas variáveis são inversamente proporcionais, respeitando um coeficiente de -0,31. As demais variáveis possuem correlação próximas a zero com a variável CC, dessa forma, foi considerada apenas a relação corrente e velocidade do motor para a realização do agrupamento por meio da execução do *Kmeans*.

Figura 11 - Matriz de correlação dos dados de produção referente ao laminador acabador de barras.
Fonte: (Elaborada pelo autor).




Após o pré-processamento, a base de dados ficou estabelecida com cinco atributos, sendo desconsiderados os atributos T_M, que não apresentou correlação considerável com a variável CC, como foi apresentado no teste de regressão realizado e o atributo A que apresentou singularidade, por não ser possível a determinação do nível de correlação com a variável CC. Os atributos que foram utilizados para o desenvolvimento do estudo foram a velocidade do motor, corrente, Fator R, velocidade de saída e velocidade da gaiola. Além disso, a base ficou estabelecida com 11307 observações por atributo.

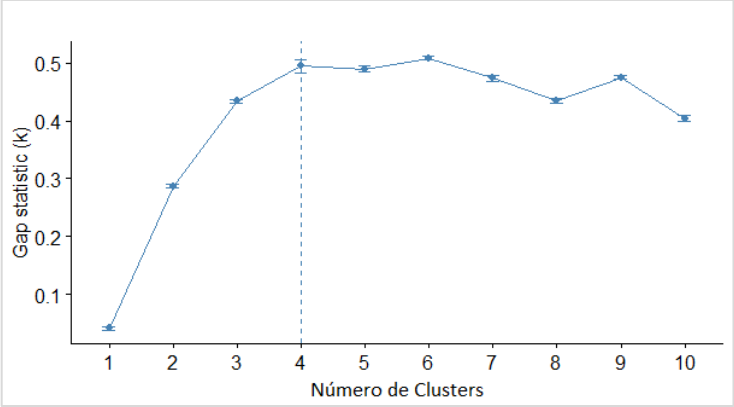
## 3.4. Metodologia de agrupamento utilizando *Kmeans*

A etapa posterior ao pré-processamento foi o agrupamento dos dados por meio do algoritmo *Kmeans*. O método de aplicação do *Kmeans* foi o *Hartigan-Wong* que se trata de um algoritmo iterativo que tenta melhorar a alocação inicial dos centros. Ele seleciona os centros iniciais de forma aleatória e, em seguida, realiza um refinamento iterativo, movendo os centros para posições que minimizam a soma dos quadrados das distâncias dos pontos para seus centros atribuídos.

Um dos parâmetros do método *Kmeans* é o número de grupos que será formado. Para isso foi executada a função *fviz-nbclust* utilizando o método *gap-stat* que está representada na Figura 12. Essa função possui o objetivo de calcular o número ótimo de grupos com base em uma análise de pontuação. Como resultado à aplicação dessa função, o número de grupos imputados no algoritmo foi igual a quatro. O número de inicializações aleatórias foi igual ao

número de grupos definidos. O número de iterações máximo foi igual a dez para que todos os centros convergissem.

Figura 12 - Número ótimo de grupos- Método *Gap Statisc.*
Fonte: (Elaborada pelo autor).




Como meio de avaliação da qualidade do agrupamento realizado, foi utilizado o coeficiente de silhueta. Maciel, Vinhas e Câmara (2015), sugeriram a utilização dos patamares de avaliação apresentados na Tabela 3.

Tabela 3 - interpretação de agrupamentos segundo coeficiente de Silhueta.
Fonte: (MACIEL; VINHAS; CÂMARA, 2015).

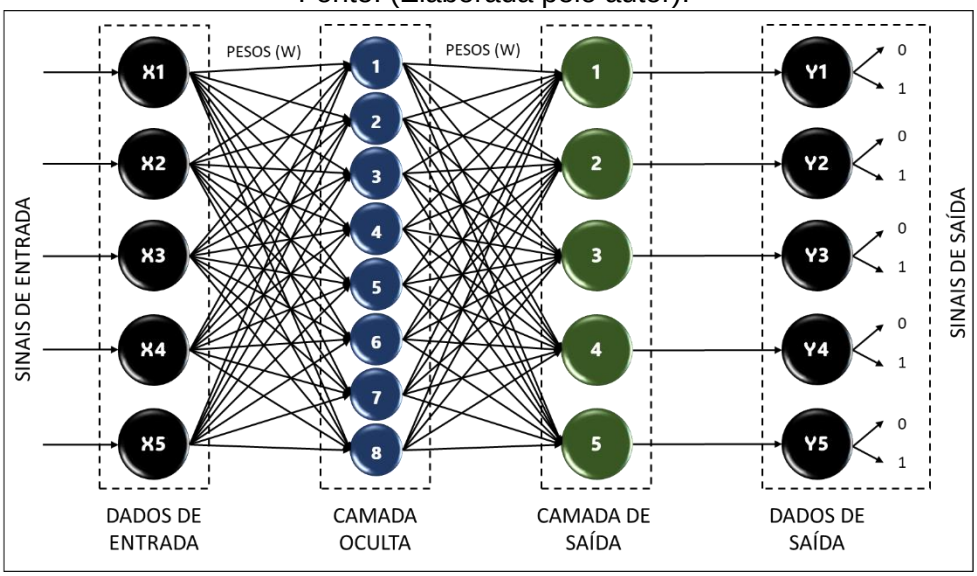
| **Coeficiente** | **Interpretação sugerida** |
|---|---|
| 0,71 - 1,00 | Estrutura robusta |
| 0,51- 0,70 | Estrutura razoável |
| 0,26- 0,50 | Estrutura fraca |
| ≤ 0,25 | Não foi encontrado estrutura |

Os rótulos gerados por meio do algoritmo de agrupamento foram incorporados à base e, em seguida, foi realizada uma divisão desta em uma base de treino e uma base de teste, respeitando a proporção de 80% e 20%, respectivamente, sendo que os dados de treino ainda foram subdivididos em treino e validação, mantendo a proporção indicada acima, respectivamente. A biblioteca *keras* não possui suporte para realização de predição com dados numéricos, portanto foi utilizado o método *one hot encoding* para categorizar os dados das classes.

## 3.5. Metodologia de aprendizado por classificação utilizando RNA

Para aplicação de classificação por RNA, inicialmente foram testados alguns parâmetros de construção do algoritmo. Todos os testes de RNA realizados contaram com um *layout* de duas camadas de neurônios, como pode ser observado na Figura 13. Foram utilizados todos os atributos da base para a construção dos modelos de classificação, exceto a altura do laço, pois esse atributo não apresentou correlação com o atributo em estudo.

Figura 13 - Representação esquemática da rede neural proposta.
Fonte: (Elaborada pelo autor).




Os dados de entrada, como pode ser observado na Figura 13, correspondem a todos os atributos selecionados após o pré-processamento dos dados e estão representados no Quadro 2. Já os dados de saída, apresentados no Quadro 3, são de origem binária, resultantes da aplicação do método de categorização, *one hot encoding*. Ou seja, cada valor de Y pode representar 0 ou 1. Dessa forma, a combinação de tais valores binários representam o rótulo do classificador no modo inteiro.

Quadro 2 - Dados de entrada ao modelo de RNA.

| Dados de entrada | Atributos |
|---|---|
| X1 | Velocidade do motor |
| X2 | Corrente |
| X3 | Fator R |
| X4 | Velocidade de saída |
| X5 | Velocidade da gaiola |

Quadro 3 - Relação dados inteiros por dados codificados.

| Saída formato inteiro | Saída codificada |
|---|---|
| 1 | 01000 |
| 2 | 00100 |
| 3 | 00010 |
| 4 | 00001 |

### 3.5.1. Grupos de testes para modelo de classificação RNA

O modelo de classificação em RNA construído foi submetido a quatro grupos de testes, com o propósito de selecionar os atributos que proporcionassem as maiores acurácias às predições realizadas.

O primeiro grupo testou as funções de ativação *softmax* e *sigmoid* na camada de saída. Já o segundo grupo testou a quantidade de neurônios na camada oculta, variando de dois até oito e utilizando a função de ativação na camada de saída que apresentou melhor desempenho no teste anterior. O terceiro grupo, por sua vez, testou os parâmetros de erro *categorical-crossentropy* e *sparse-categorical-crossentrop*y para ajuste dos pesos.

Por fim, o quarto grupo testou os parâmetros de otimização *Adam* e *RMSProp*. Para todos os grupos de testes foram utilizados como parâmetros de desempenho a acurácia, o erro empregado nos testes e as curvas de aprendizado em relação à acurácia e ao erro pelas épocas de treinamento.

As métricas de erro apresentadas não são complementares à acurácia, visto que o erro reflete o quão bem o modelo está prevendo em termos de probabilidade, e a fórmula envolve logaritmos, o que não se traduz diretamente em um simples erro percentual.

Para todos os testes foram utilizadas 250 épocas de treinamento e atualização dos pesos de duas em duas épocas. As funções padrões, quando não estavam em análise, foram *categorical-crossentropy* para o erro e *Adam* para o otimizador, o ponto de partida contou com dois neurônios na camada oculta, já a camada de saída se manteve com cinco neurônios em todos os testes.

O modelo final, após os testes, foi executado 30 vezes, com o princípio de avaliar a média da acurácia e do erro empregado. Logo depois, foram elaboradas suas medidas de desempenho. Para isso foi utilizada a acurácia, erro empregado no teste, matriz de confusão, curva ROC por classe e curva AUC.

## 3.6. Análise de novos dados

Em relação ao segundo banco de dados, este correspondia ao período produtivo do dia 23 de abril de 2023, período este que antecede a falha dos mancais de rolamento. A segunda base de dados, após ser coletada, foi submetida as mesmas etapas de pré-processamento utilizadas na primeira base. Logo após, foi classificada por meio do modelo RNA previamente desenvolvido.

É importante ressaltar que, as bases testadas representam diferentes épocas de funcionamento do laminador, porém apresentam uma sequência temporal lógica, o que fortalece os resultados que foram obtidos evitando a presença de erros não planejados.

Por fim, com o propósito de ranquear as variáveis por nível de impacto na classificação, foram realizados cinco testes por meio da permutação das variáveis da base de dados na classificação. O primeiro teste se baseou na classificação da base de dados omitindo a primeira variável, que no caso se tratava da velocidade do motor. Os demais testes seguiram a mesma lógica, sendo que no segundo teste foi omitido a corrente, no terceiro o fator R, no quarto a velocidade de saída e, por fim, no quinto teste, a velocidade da gaiola. Cada teste foi executado 30 vezes, considerando 250 épocas de treinamento. Para a determinação do *ranking*, foram avaliadas as médias da acurácia e as médias do erro empregado no modelo. Para a realização dessa etapa foi necessário a reestruturação dos parâmetros do modelo, visto que os dados de entrada foram de cinco atributos para quatro.

# 4. RESULTADOS

Neste tópico estão apresentados os resultados obtidos neste trabalho. No primeiro tópico foi desenvolvido uma proposta de futura aplicação do gêmeo digital com um de seus módulos sendo aprendizado de máquina. No segundo tópico foram apresentados os resultados do agrupamento utilizando o algoritmo *Kmeans*. Já no terceiro tópico foi apresentado o desenvolvimento do modelo de classificação RNA, assim como os quatro grupos de testes para seleção dos parâmetros. No quarto tópico, por sua vez, foi discutida a comparação entre as classificações da primeira e da segunda base de dados. Por fim, no último tópico, foi elaborado um *ranking* de relevância das variáveis utilizadas na classificação por RNA.

## 4.1. Projeto para futura aplicação do gêmeo digital considerando o aprendizado de máquina desenvolvido

O esquema apresentado na Figura 14 possui como base o modelo físico, que é composto pelo equipamento, assim como o sistema de sensoriamento, responsável por captar os dados de funcionamento do laminador. O uso de sensores permite o monitoramento contínuo de operação, possibilitando a detecção imediata de anomalias ou desvios de desempenho. As informações coletadas serão armazenadas em um banco de dados.

O modelo 3D espelha o modelo físico, porém em uma representação virtual. Com o modelo virtual da máquina, é possível realizar simulações para testar diferentes cenários e estratégias sem a necessidade de interferir no equipamento físico. Isso ajuda na tomada de decisões baseadas em dados.

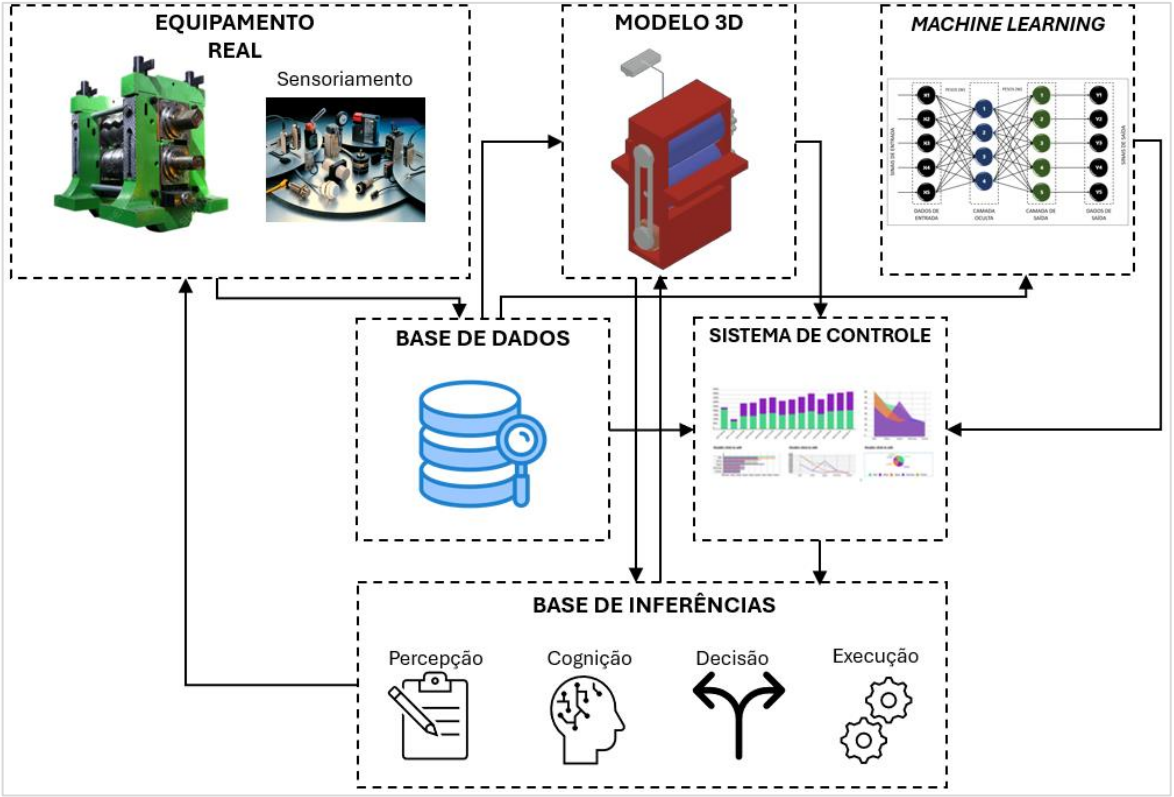
Já o aprendizado de máquina possui função de predição de falhas, para controle de manutenções preditivas. Com os dados coletados e analisados através de redes neurais, é possível acompanhar o funcionamento dos elementos do laminador identificando anomalias, que podem ser caracterizadas como falhas nos componentes, permitindo a realização de manutenções preventivas. Isso reduz o tempo de inatividade e os custos de reparo.

Para acompanhamento do processo como um todo e facilitação nas tomadas de decisões, foi proposto um sistema de controle composto por análise dos dados por meio da elaboração de *dashboards*.

Por fim, o módulo que permite a automatização do processo é a base de inferências. Ela é composta por quatro fases: percepção, que consiste na compilação dos dados recebidos; cognição, consiste no reprocessamento dos dados para tomadas de decisão; decisão, que consiste na formulação dos ajustes necessários para correção dos pontos levantados na etapa anterior; execução, que consiste na efetivação dos ajustes estipulados.

Dessa forma, o ciclo recomeça por meio da coleta dos dados por parte dos sensores e envio ao banco de dados. Esse por sua vez distribui os dados enviando-os ao modelo 3D, ao aprendizado de máquina e ao sistema de controle. Esses dados processados são encaminhados ao módulo base de inferências que toma as decisões para ajuste no processo físico e espelhamento no modelo digital.

Figura 14 - Projeto de aplicação de um gêmeo digital para um laminador.
Fonte: (Elaborada pelo autor).

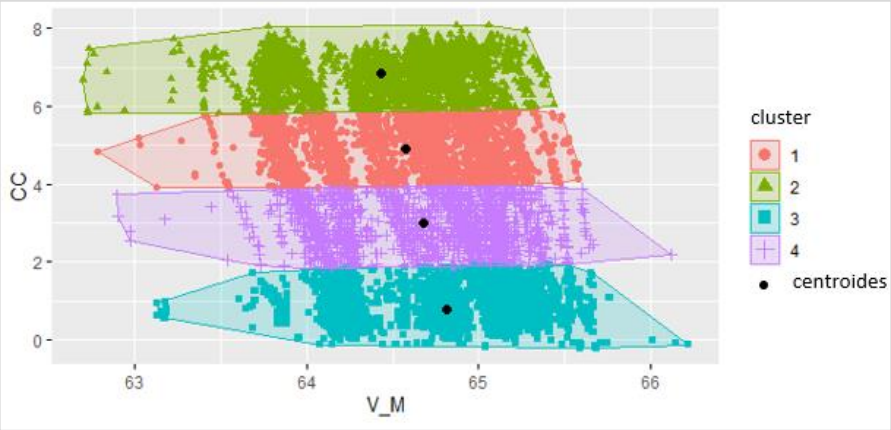


## 4.2. Agrupamento utilizando o método *Kmeans*

Em relação ao agrupamento dos dados utilizando *Kmeans* e o método *Hartigan Wong*, que está representado na Figura 15*,* é interessante observar que os patamares, em que os grupos se mantiveram em relação a variável corrente, ficaram bem definidos.

O agrupamento do atributo corrente do motor foi realizado levando em consideração a velocidade do motor, devido ao fato desses dois atributos apresentarem a maior correlação, se comparado com os demais atributos, como pode ser observado na matriz de correlação desenvolvida, Figura 11. O grupo dois foi o patamar considerado relevante para a posterior análise de classificação realizada por RNA, devido ao fato desse patamar concentrar os maiores valores de corrente coletados, ou seja, de acordo com a relação apresentada na Equação 9, um aumento da corrente pode ser indicado por um aumento do torque do sistema, o que pode representar a falha dos rolamentos.

Figura 15 - Agrupamento utilizando *Kmeans* e o método *Hartigan Wong.*
Fonte: (Elaborada pelo autor).



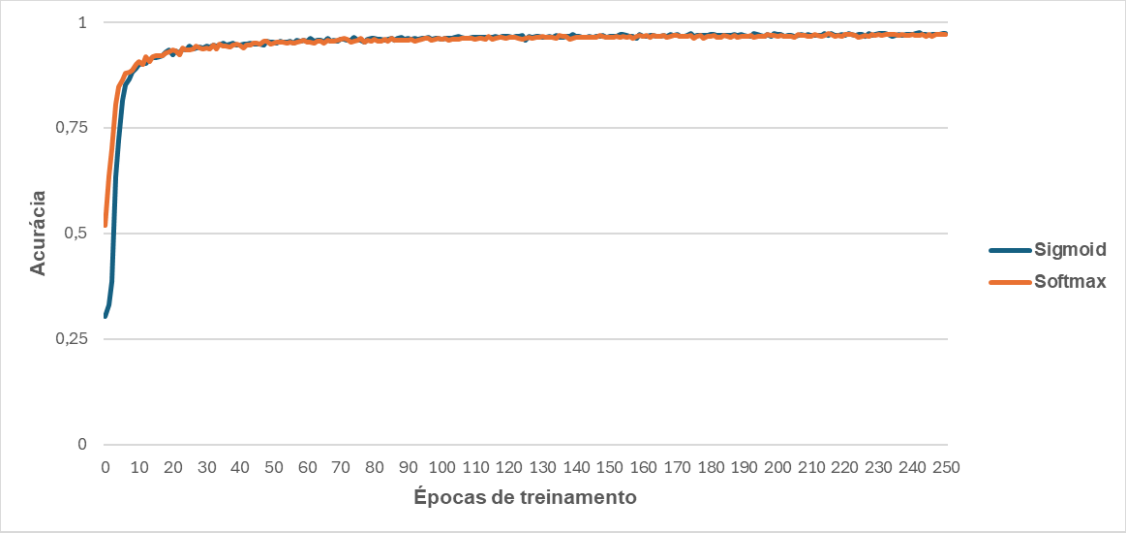

Como meio de avaliação da qualidade do agrupamento o coeficiente de silhueta foi aplicado e foi gerado um valor de 0,53 que, segundo a Tabela 3, corresponde a uma estrutura razoável, o que pode ser comprovado observando os patamares bem definidos do agrupamento realizado.

## 4.3. Desenvolvimento do modelo de classificação utilizando RNA

A seguir estão apresentados os resultados dos grupos de testes desenvolvidos no processo de construção do modelo de classificação por RNA.

O primeiro grupo variou as funções de ativação *softmax* e *sigmoid* na camada de saída. Ao analisar os níveis de acurácia durante o treinamento, Figura 16, pode ser observado que a função softmax apresentou um melhor desempenho nas primeiras épocas de treinamento, todavia a função sigmoide equiparou os níveis de acurácia a partir da décima época de treinamento, aproximadamente. É interessante observar que, a partir da época de treinamento 150, as duas funções de ativação se estabilizaram.

Figura 16 - Desempenho dos modelos variando a função de ativação.
Fonte: (Elaborada pelo autor).




O Quadro 4 retrata os valores de acurácia e erro de classificação nos testes. Pode ser observado que a função *sigmoid* obteve melhor desempenho ao considerar a acurácia. Os níveis de erro foram similares para ambas as funções de ativação. Portanto, a função *sigmoid* foi selecionada como função de ativação da camada de saída e, por consequência, foi utilizada nos próximos três grupos de testes.

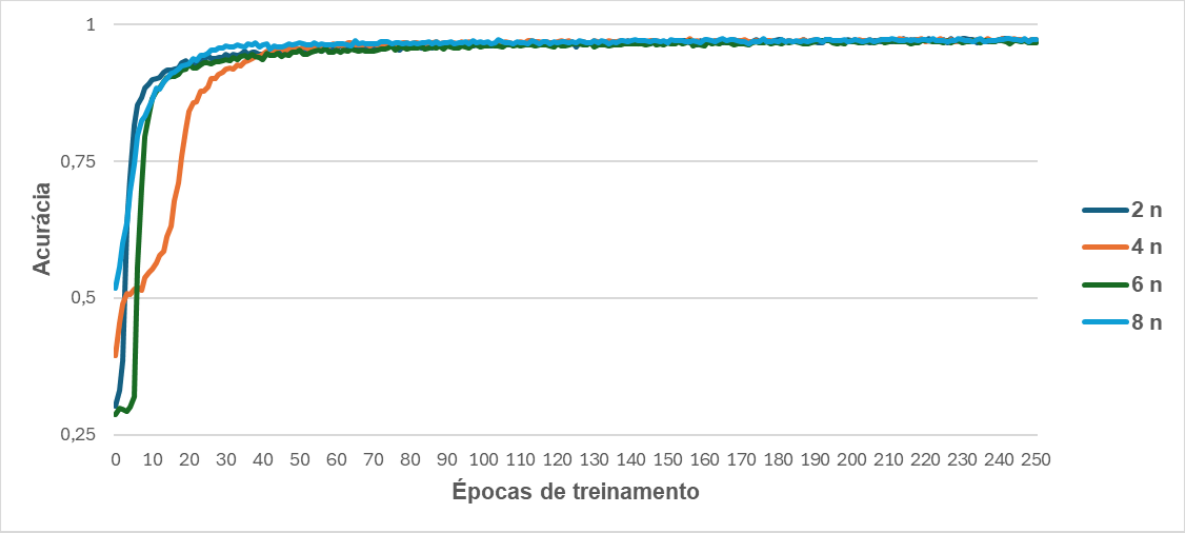
Quadro 4 - Parâmetros de avaliação variando a função de ativação.

| Função | Acurácia | Erro |
|---|---|---|
| Softmax | 0,97 | 0,06 |
| Sigmoid | 0,98 | 0,06 |

O segundo grupo de testes variou o número de neurônios na camada oculta de dois até oito, como pode ser observado na Figura 17 que retrata os níveis de acurácia durantes os treinamentos dos testes. Os modelos que utilizaram dois e seis neurônios na camada oculta apresentaram curvas de aprendizado similares em formato, porém com valores de acurácia diferentes em relação às épocas de treinamento. O modelo com quatro neurônios obteve uma curva de aprendizado levemente deslocada, nas primeiras épocas de treinamento, em relação aos demais modelos, porém foi capaz de equiparar aos níveis de acurácia dos demais testes após a época 40 de treinamento, aproximadamente.

Em relação ao modelo que utilizou oito neurônios na camada oculta houve melhor desempenho durante as épocas 20 e 60 de treinamento, aproximadamente, sendo que, após esse período, houve um equilíbrio entre as variações de desempenho de todos os modelos e a estabilização das curvas de aprendizagem.

Figura 17 - Desempenho dos modelos por número de neurônios na camada oculta.
Fonte: (Elaborada pelo autor).



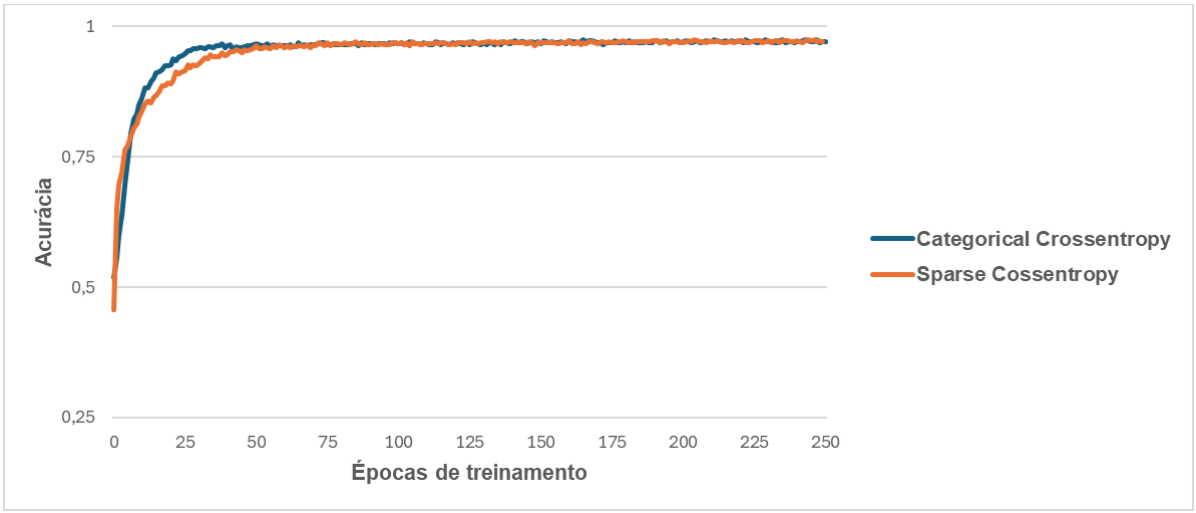
No quadro 7 é possível observar os níveis de acurácia e erros atribuídos aos testes realizados. O modelo desenvolvido que utilizou oito neurônios na camada oculta, apresentou o maior nível de acurácia e o menor erro de predição, portanto, para os demais testes foram utilizados oito neurônios na camada oculta.

Quadro 5 - Parâmetros de avaliação variando o número de neurônios na camada oculta.

| **Nº de neurônios** | **Acurácia** | **Erro** |
|---|---|---|
| 2 | 0,94 | 0,06 |
| 4 | 0,97 | 0,05 |
| 6 | 0,97 | 0,06 |
| 8 | 0,98 | 0,04 |

No terceiro grupo de testes foi avaliado o impacto de duas métricas de perda denominadas *categorical-crossentropy* e *sparse-categorical-crossentropy*. Na Figura 18 estão apresentadas as curvas de aprendizado dos dois modelos desenvolvidos e pode ser observado que, durante as épocas 15 e 35, aproximadamente, houve uma superioridade, em níveis de acurácia, da métrica *Categorical-crossentropy*, sendo que, após essa época, os níveis de acurácia se aproximaram e as curvas de aprendizado atingiram a estabilidade.

Figura 18 - Desempenho dos modelos por métrica de erro.
Fonte: (Elaborada pelo autor).



O Quadro 6 retrata os níveis de acurácia e erro durante os testes dos modelos e pode ser observado que os dois modelos atingiram valores de acurácia e erro similares, portanto, a escolha da métrica de perda se baseou no comportamento gráfico durante os treinamentos, Figura 17, sendo que a métrica *Categorical-crossentropy* foi escolhida para prosseguimento do último teste, devido ao fato dessa métrica apresentar superioridade em nível de acurácia durante as épocas de treinamento mencionadas anteriormente.

Quadro 6 - Parâmetro de avaliação variando a perda.

| **Perda** | **Acurácia** | **Erro** |
|---|---|---|
| *Categorical-crossentropy* | 0,98 | 0,04 |
| *Sparse-categorical-crossentropy* | 0,98 | 0,04 |

Por fim, para o quarto grupo de testes foi realizado a comparação entre dois tipos de funções de otimização, sendo elas as funções *Adam* e *RMSprop*. Ao observar as curvas de aprendizado na Figura 19, se destaca a superioridade dos níveis de acurácia do modelo que utilizou a função *Adam*, durante as épocas de treinamento 10 a 70, aproximadamente. Todavia, após esse período, houve uma equiparação das curvas, além de se estabilizarem.

Figura 19 - Desempenho dos modelos por parâmetro de otimização – Acurácia.
Fonte: (Elaborada pelo autor).



Ao analisar o Quadro 7, a função *Adam* obteve nível de acurácia e erro, vinculado ao teste, melhores do que a função *RMSprop*. Dessa forma, para o modelo final, foi utilizado o otimizador *Adam.*

Quadro 7 - Parâmetros de avaliação variando o algoritmo de otimização.

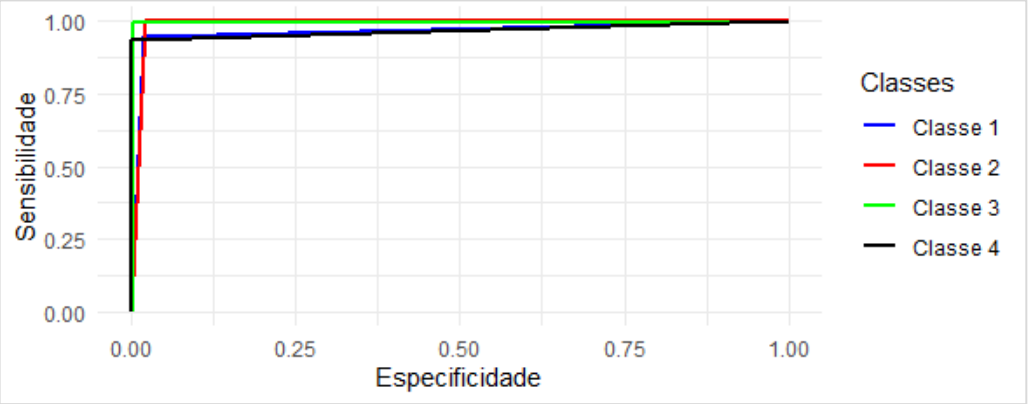
| **Otimizador** | **Acurácia** | **Erro** |
|---|---|---|
| *Adam* | 0,99 | 0,04 |
| *RMSprop* | 0,98 | 0,10 |

## 4.4. Avaliação de desempenho do modelo de classificação utilizando RNA

A estrutura do modelo de classificação por RNA, após os testes realizados para seleção dos parâmetros, ficou estabelecida com duas camadas de neurônios, sendo uma camada oculta e uma camada de saída, com funções de ativação *relu* e *sigmoid*, respectivamente. Já em relação ao número de neurônios por camada, na camada oculta foram utilizados oito neurônios, já na camada de saída foram utilizados cinco neurônios. A função de custo utilizada foi a *categorical-crossentropy* e o otimizador foi o algoritmo *Adam*. A métrica para cálculo de desempenho foi a acurácia, ao qual o modelo alcançou, durante o teste, um nível de 0,99.

A Figura 20 apresenta as curvas ROC por classe. Observa-se que todas as curvas seguem um comportamento muito semelhante, com alta sensibilidade e especificidade, indicadas pela rápida elevação no eixo vertical próximo ao valor 1 de sensibilidade, enquanto a especificidade ainda se mantém alta, próxima de 1. Esse padrão indica um bom desempenho do classificador para todas as classes, com uma alta capacidade de discriminar corretamente entre as diferentes classes, minimizando os falsos positivos. A superposição das curvas também sugere que o modelo tem uma performance similar entre as classes, sem que uma classe se sobressaia ou apresente resultados significativamente piores em relação às outras.

Figura 20 - Curva ROC por classe.
Fonte: (Elaborada pelo autor).




Uma métrica complementar à curva ROC é a AUC que representa a área sob a curva, ou seja, quanto mais próximo a 1 melhor o desempenho do modelo de classificação executado. Quando o valor da AUC for maior do que 0,5 representa que o modelo é mais eficaz do que uma classificação aleatória. O Quadro 8 apresenta os valores de AUC para as curvas ROC plotadas na Figura 20.

Pode ser observado no Quadro 8 que todos os valores de AUC foram próximos a 1, o que representa que o modelo, de modo geral, apresentou elevada sensibilidade para predição, além de alta especificidade na classificação. A média de sensibilidade e especificidade do modelo foram de 0,9871 e 0,9942, respectivamente.

Quadro 8 - Valores de AUC por classe.
Fonte: (Elaborada pelo autor).

| **Classe** | **AUC** |
|---|---|
| Classe 1 | 0,9663 |
| Classe 2 | 0,9894 |
| Classe 3 | 0,9973 |
| Classe 4 | 0,9668 |

Outra métrica de desempenho avaliada foi a matriz de confusão, Quadro 9, que apresenta os níveis de acertos nas classificações, assim como a quantidade de classificações equivocadas. Pode ser observado que houve, aproximadamente, 99% de acertos subdivididos em 24,33% para as classificações dos verdadeiros positivos, quando a classe real foi classificada corretamente e 74,33% para as classificações dos falsos positivos, quando as

classes que não deveriam ser classificadas não foram classificadas. Os erros de classificação, de modo geral, foram de 1,34%.

Quadro 9 - Matriz de confusão.
Fonte: (Elaborada pelo autor).

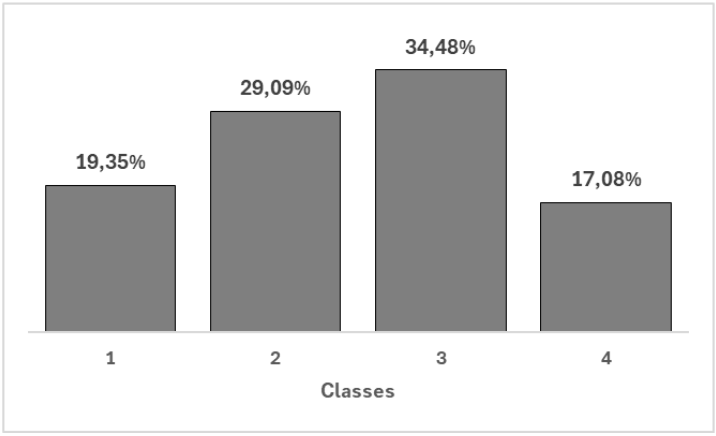
| | **Referências** | |
|---|---|---|
| **Predição** | 0 | 1 |
| 0 | 74,33% | 0,67% |
| 1 | 0,67% | 24,33% |

## 4.5. Classificação da segunda base de dados por meio do modelo RNA desenvolvido

A última etapa deste trabalho se baseou na classificação da segunda base de dados, por meio do modelo que foi desenvolvido nas etapas anteriores. Esta segunda base corresponde ao período que antecedeu a falha nos rolamentos. É importante destacar que o modelo foi treinado apenas com a primeira base de dados. Já com a segunda base, o modelo de classificação foi totalmente testado.

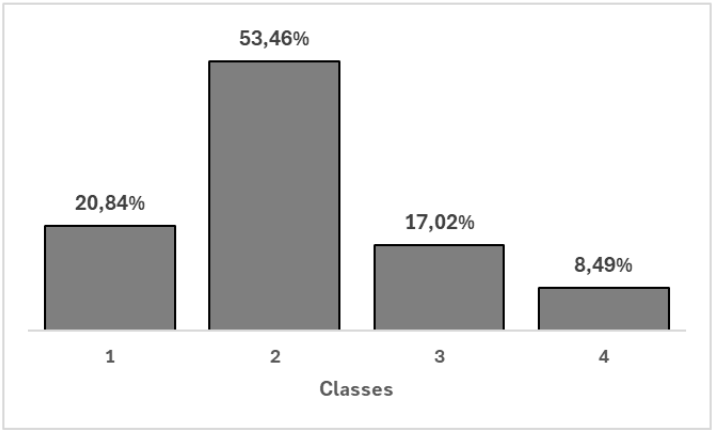
A Figura 21 apresenta as frequências da classificação realizada utilizando a primeira base de dados. É interessante observar que a classe 3 apresentou um maior volume de dados da corrente do motor, que corresponde, em relação a Figura 15, a classe da corrente do motor com o menor módulo. Todavia, existe um certo nivelamento entre as frequências das classes, com maior destaque para as frequências das classes 2 e 3.

Figura 21 - Frequência das classes em relação a primeira base de dados.
Fonte: (Elaborada pelo autor).




A Figura 22, por sua vez, apresenta as frequências das classificações da segunda base de dados. É notória a superioridade da classe 2, que corresponde ao grupo com maior módulo de corrente, conforme apresentado na Figura 15. A alteração das frequências das classes entre as Figuras 21 e 22 representa que o modelo está favorável à hipótese levantada, que aponta que, o aumento da resistência à rotação do motor, devido a falha nos rolamentos, provocaria um maior consumo de corrente elétrica, por parte do motor.

Figura 22 - Frequência das classes em relação a segunda base de dados.
Fonte: (Elaborada pelo autor).




Portanto, o modelo foi capaz de predizer a falha no sistema do redutor ao analisar a variação das frequências das classificações, todavia, o modelo não é capaz de destacar o tipo

de falha ou o componente que sofreu a falha, apenas a existência de uma anormalidade e sua evolução.

## 4.6. Impacto das variáveis na classificação da base utilizando RNA

Com o intuito de analisar o impacto das variáveis na classificação, foram realizados cinco testes por meio da permutação dos atributos da base e a classificação dessa base com o determinado atributo omitido, Quadro 10.

No modelo 1, a velocidade do motor foi omitida da base e esta foi classificada, respeitando os parâmetros estipulados no modelo RNA previamente construído. A predição desse modelo, por meio dos dados de teste, alcançou acurácia de 0, 9409 e erro de 0,1341.

Já no modelo 2, a corrente do motor foi omitida e a predição deste modelo alcançou acurácia igual a 0,2876 e erro igual a 1,4590. Para o terceiro e o quarto modelo, as variáveis fator R e velocidade de saída foram omitidas, respectivamente. Os níveis de acurácia alcançados foram 0,9737, para o modelo que omitiu o fator R, e 0,9642, para o modelo que omitiu a velocidade de saída. Já os erros foram 0,0701 e 0,1141 respectivamente.

Por fim, no modelo 5 foi omitido o atributo velocidade da gaiola. A acurácia alcançada na predição desse modelo foi de 0,9864 e o erro foi igual a 0,0287.

Quadro 10 - Impacto das variáveis na classificação.

| | **Modelo 1** | **Modelo 2** | **Modelo 3** | **Modelo 4** | **Modelo 5** |
|---|---|---|---|---|---|
| **Acurácia** | 0,9409 | 0,2876 | 0,9737 | 0,9642 | 0,9864 |
| **Erro** | 0,1341 | 1,4590 | 0,0701 | 0,1141 | 0,0287 |

Pode ser observado que o modelo 2 apresentou a menor acurácia e o maior erro, isso significa que, a corrente do motor é o atributo que possui maior impacto no modelo de classificação desenvolvido. Seguindo o *ranking*, a velocidade do motor é o segundo atributo com maior impacto no modelo RNA, seguida da velocidade de saída, do fator R e da velocidade da gaiola.

# 5. CONCLUSÃO

O presente trabalho apresentou alguns conceitos preliminares a respeito da laminação e suas tecnologias, assim como a tecnologia de gêmeo digital proveniente da Indústria 4.0. Pôde ser constatado a possibilidade de se aplicar tal tecnologia na manutenção de equipamentos, facilitando a integralização e o fluxo de comunicação, colaborando para uma indústria mais eficiente.

Os objetivos estipulados neste trabalho se basearam na formulação de um modelo em aprendizado de máquina que fosse capaz de predizer falhas do sistema de rolamento de um redutor acoplado em um laminador de perfis. Além disso, foi proposto identificar na modelagem as variáveis que indicam falhas do sistema de rolamento e estruturar uma proposta de gêmeo digital que contemplasse o modelo em aprendizado de máquina desenvolvido.

Foi desenvolvido um dos módulos do gêmeo digital, que consistiu na análise e processamento de dados utilizando aprendizado de máquina e análise estatística. Por meio do uso do aprendizado de máquina foi possível construir um modelo de classificação, utilizando redes neurais artificiais (RNA), que foi capaz de predizer anormalidade no funcionamento do redutor de um laminador acabador de perfis, por meio da análise da corrente do motor. O modelo desenvolvido apresentou acurácia aproximada de 99% e níveis de sensibilidade e especificidade de 0,9871 e 0,9942, respectivamente.

A última etapa deste trabalho focou na classificação de uma segunda base de dados utilizando o modelo de RNA desenvolvido que foi treinado com a primeira base de dados. Esta segunda base de dados representava o período que antecede a falha nos rolamentos, permitindo a verificação da hipótese de que falhas nos rolamentos provocariam um aumento no torque do sistema e, consequentemente, na corrente do motor. Os resultados confirmaram esta hipótese, mostrando que a maior frequência das classificações se deu na classe 2, que representa os maiores módulos de corrente. Essa confirmação fortaleceu a validade do modelo, demonstrando que ele consegue identificar padrões associados a falhas iminentes.

A comparação entre a frequência das classes na primeira e na segunda base de dados revelou um comportamento consistente, particularmente na classe 2, que apresentou a maior frequência de dados na segunda base, correspondendo aos maiores módulos de corrente. A análise também mostrou que a classe 3, que representa os menores módulos de corrente,

apresentou um volume significativo de dados, embora o destaque principal tenha sido a classe 2.

O modelo em RNA desenvolvido, não possui a capacidade de identificação do tipo de falha, mas ele aponta a existência de anormalidades no funcionamento do redutor, por meio das frequências das classificações da corrente do motor. Ou seja, por meio de um volume de dados constante é possível se obter um sistema supervisório do status do funcionamento do redutor, funcionando como um indicador de falha para uma parada programada e a realização de manutenções preventivas.

A utilização de aprendizado de máquina para identificação da falha, por meio da análise da corrente do motor apresenta maior confiabilidade e capacidade de identificação de anormalidade, se comparado com o simples acompanhamento dos valores da corrente. Isso acontece devido ao fato dos valores da corrente não respeitarem um padrão bem definido, além de não representarem uma análise linear, sendo necessário, portanto, a utilização de ferramentas, como o aprendizado de máquina, para identificação de padrões complexos.

Por fim, pôde ser observado que a corrente do motor possui correlação com a falha do redutor, sendo um preditor eficaz por meio da análise do volume dos grupos pré-definidos, principalmente por meio do aumento do volume de classificações no grupo 2, que corresponde ao grupo com maior módulo no valor da corrente. Esses resultados indicam que, embora haja variações entre os métodos de classificação, o modelo de RNA é eficaz na predição de anomalias relacionadas a falhas nos rolamentos. Futuras pesquisas podem explorar técnicas adicionais de aprendizado de máquina, otimização de hiperparâmetros e a inclusão de variáveis adicionais para melhorar a precisão e a robustez do sistema de predição de falhas.

# 6. TRABALHOS FUTUROS

A seguir estão algumas sugestões para trabalhos futuros:

- Realizar uma busca e testes mais extensos de hiperparâmetros para o modelo de RNA, para avaliar se é possível melhorar a acurácia e desempenho do modelo.
- Realizar um estudo a respeito da análise de falha dos rolamentos e comparar com os resultados do modelo RNA desenvolvido para que seja possível apontar a falha e os tipos por meio do modelo de aprendizado de máquina.
- Realizar estudos de caso em diferentes laminadores e indústrias para validar a generalização do modelo, bem como comparar os resultados obtidos em diferentes contextos.
- Usar simulações para modelar diferentes cenários de falha e verificar a robustez do modelo sob diferentes condições de operação.
- Desenvolver os demais módulos do gêmeo digital do laminador.

# REFERÊNCIAS

ABECON. Quais os tipos de falhas de um rolamento?. *[S.I.],* 2020. Disponível em: https://www.abecom.com.br/falhas-de-um-rolamento/. Acesso em: 18 nov. 2023.

ADEMUJIMI, T.; PRABHU, V. Digital Twin for Training Bayesian Networks for Fault Diagnostics of Manufacturing Systems. Sensors. V. 22., p 1-24, 2022. Disponível em: https://doi.org/10.3390/s22041430. Acesso em: 15 out. 2024.

AIVALIOTIS, P.; GEORGOULIAS, K.; CHRYSSOLOURIS, G. The use of Digital Twin for predictive maintenance in manufacturing. International Journal of Computer Integrated Manufacturing. [S.I.], v. 32, p. 1067-1080, 2019. Disponível em: https://doi.org/10.1080/0951192X.2019.1686173. Acesso em: 30 jun. 2022.

ÁLAMO, J. R.; DURAN, M. J.; MUÑOZ, F. J. Analysis of the Gearbox Oil Maintenance Procedures in Wind Energy. MDPI – Energies. V. 13, p. 1-18, 2020. Disponível em: https://doi.org/10.3390/en13133414. Acesso em: 15 nov. 2023.

ALBERTIN, E. Desgaste Abrasivo. 58 Congresso anual ABM - Instituto de Pesquisas Tecnológicas – SP - Divisão de Metalurgia. Rio de Janeiro, 2003. Disponível em: http://ftp.demec.ufpr.br/disciplinas/TM314/Material%20Guia%20da%20discilina%20de%20Aspers%C3%A3o%20T%C3%A9rmica/Desgaste%20abrasivo.pdf. Acesso em: 18 nov. 2023.

ALI, M. I.; PATEL, P.; BRESLIN, J. G.; HARIK, R.; SHETH, A. Cognitive Digital Twins for Smart Manufacturing. IEEE Intelligent Systems. V. 36, ed. 2, p. 96-100, 2021. Disponível em: https://ieeexplore.ieee.org/document/9434454. Acesso em: 09 dez. 2022.

ANGJELIU, G., CORONELLI, D., CARDANI, G. Development of the simulation model for Digital Twin applications in historical masonry buildings: The integration between numerical and experimental reality. Computers & Structures. V. 238, p. 1-20, 2020. Disponível em: https://doi.org/10.1016/j.compstruc.2020.106282. Acesso em: 09 dez. 2022.

ARRANO-VARGAS, F.; KONSTANTINOU, G. Modular Design and Real-Time Simulators Toward Power System Digital Twins Implementation. IEEE Transactions on Industrial Informatics. p. 1-10, 2022. Disponível em: https://ieeexplore.ieee.org/abstract/document/9784425. Acesso em: 09 dez. 2022.

AYERBE, M. A. B.; COCQUEMPOT, V.; MARTINEZ, C. O.; ROZO, J. D. Remaining useful life estimation of ball-bearings based on motor current signature analysis. Reliability Engineering & System Safety. V. 235, 2023. Disponível em: https://doi.org/10.1016/j.ress.2023.109209. Acesso em: 20 jul. 2024.

AYLEN, J. Open versus closed innovation: development of the wide strip mill for steel in the United States during the 1920s. R & D Management. [S.I.], v. 40, ed. 1, p. 67-80, 2010. Disponível em: https://doi.org/10.1111/j.1467-9310.2009.00576.x. Acesso em: 27 jun. 2022.

BARON, P.; KOCISKO, M.; BLASKO, L.; SZENTIVANYI, P. Verification of the operating condition of stationary industrial gearbox through analysis of dynamic signal, measured on the pinion bearing housing. Measurement. V. 96, p. 24-33, 2017. Disponível em: https://doi.org/10.1016/j.measurement.2016.10.048. Acesso em: 15 nov. 2023.

BATAILLE, C.; LUC, E.; BIGERELLE, M.; DELTOMBE, R.; DUBAR, M. Rolls wear characterization in hot rolling process. Tribology International. [S.I.], v. 100, p. 328-337, 2016. Disponível em: https://doi.org/10.1016/j.triboint.2016.03.012. Acesso em: 27 jun. 2022.

BHADESHIA, H. K. D. H. Steels for bearings. Progress in Materials Science. [S.I.], v. 57, ed. 2, p. 268-435, 2012. Disponível em: https://doi.org/10.1016/j.pmatsci.2011.06.002. Acesso em: 27 jun. 2022.

BISHOP, C. M. Pattern recognition and machine learning. New York: Springer, 2006. Disponível em: encurtador.com.br/hovO3. Acesso em: 23 fev. 2023.

BOLJANOVIC, V. Metal-shaping Processes. 1. ed. Nova York: Industrial Press, 2009.

BRESCIANI FILHO, E.; BENTO DA SILVA, I.; BATALHA, G. F.; BUTTON, S. T. Conformação plástica dos. 1. ed. São Paulo: EPUSP, 2011. Disponível em http://www.fem.unicamp.br/~sergio1/CONFORMACAOPLASTICADOSMETAIS.pdf. Acesso em: 25 jun. 2022.

BYON, S. M.; KIM, S. I.; LEE, Y. A semi-analytical model for predicting the wear contour in rod rolling process. Journal of Materials Processing Technology. [S.I.], v. 191, p. 306-309, 2007. Disponível em: https://doi.org/10.1016/j.jmatprotec.2007.03.053. Acesso em: 07 jul. 2022.

CERRADA, M.; SÁNCHEZ, R. V.; LI, C.; PACHECO, F.; CABRERA, D.; VALENTE DE OLIVEIRA, J.; VÁSQUEZ, R. E. A review on data-driven fault severity assessment in rolling

bearings. Mechanical Systems and Signal Processing. [S.I.], v. 99, p. 169-196, 2018. Disponível em: https://doi.org/10.1016/j.ymssp.2017.06.012. Acesso em: 30 jun. 2022.

CHIAVERINI, V. Tecnologia Mecânica: Processos de Fabricação e Tratamento. 2. ed. São Paulo: McGraw-Hill, 1986.

CORADDU, A.; ONETO, L.; BALDI, F.; CIPOLLINI, F.; ATLAR, M.; SAVIO, S. Data-driven ship digital twin for estimating the speed loss caused by the marine fouling. Ocean Engineering. V. 186, p. 1-14, 2019. Disponível em: https://doi.org/10.1016/j.oceaneng.2019.05.045. Acesso em: 09 dez. 2022.

CUI, Y.; KARA, S.; CHAN, K. C. Manufacturing big data ecosystem: A systematic literature review. Robotics and Computer-Integrated Manufacturing. V. 62, p. 1-20, 2020. Disponível em: https://doi.org/10.1016/j.rcim.2019.101861. Acesso em: 23 fev. 2023.

DALZOCHIO, J.; KUNST, R.; PIGNATON, E.; BINOTTO, A.; SANYAL, S.; FAVILLA, J.; BARBOSA, J. Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. Computers in Industry. V. 123, p. 15, 2020. Disponível em: https://doi.org/10.1016/j.compind.2020.103298. Acesso em: 23 fev. 2023.

DELOITTE CONSULTING. Digital Twins (2020). Disponível em: https://www2.deloitte.com/be/en/pages/technology-media-and-telecommunications/articles/digital-twins.html. Acesso em: 20 ago. 2023.

DEBROY, T.; ZHANG, W.; TURNER, J.; BABU, S. S. Building digital twins of 3D printing machines. Scripta Materialia. V. 135, p. 119-124, 2017. Disponível em: https://doi.org/10.1016/j.scriptamat.2016.12.005. Acesso em: 09 dez. 2022.

DIETER, G. E. Metalurgia Mecânica. 2. ed. Rio de Janeiro: Guanabara Dois, 1981.

DU, M.; YI, J.; GUO, J.; CHENG, L.; MA, S.; HE, Q. An Improved FMECA Method for Wind Turbines Health Management. Energy and Power Engineering. V. 9, p. 36-45, 2017. Disponível em: http://www.scirp.org/journal/epe. Acesso em: 14 nov. 2023.

DUFOUR, C.; SOGHOMONIAN, Z.; LI, W. Hardware-in-the-Loop Testing of Modern On-BoardPower Systems Using Digital Twins. SPEEDAM 2018 - Proceedings: International Symposiumon Power Electronics, Electrical Drives, Automation and Motion. pp. 118–123, 2018. Disponível em: https://doi.org/10.1109/SPEEDAM.2018.8445302. Acesso em: 15 jul. 2023.

EL NAQA, I.; MURPHY, M. J. What Is Machine Learning?. Machine Learning in Radiation Oncology. P. 3-11, 2015. Disponível em: https://doi.org/10.1007/978-3-319-18305-3_1. Acesso em: 23 fev. 2023.

ERRANDONEA, I.; BELTRÁN, S.; ARRIZABALAGA, S. Digital Twin for maintenance: A literature review. Computers in Industry. [S.I.], v. 123, p. 1-14, 2020. Disponível em: https://doi.org/10.1016/j.compind.2020.103316. Acesso em: 30 jun. 2022.

FÁVERO, L. P.; BELFIORE, P.; SOUZA, R. F. Data Science, Analytics and Machine Learning with R. Academic Press, 2023. Disponível em: https://doi.org/10.1016/C2020-0-01649-X. Acesso em: 30 jun. 2024.

FENG, Q.; ZHANG, Y.; SUN, B.; GUO, X.; FAN, D.; REN, Y.; SONG, Y.; WANG, Z. Multi-level predictive maintenance of smart manufacturing systems driven by digital twin: A matheuristics approach. Journal of Manufacturing Systems. V. 68, pp. 443 - 454, 2023. Disponível em: https://doi.org/10.1016/j.jmsy.2023.05.004. Acesso em: 16 jun. 2023.

GE DIGITAL. What is a digital twin? (2019). Disponível em: https://www.ge.com/digital/applications/digital-twin. Acesso em: 10 set. 2023.

GLAESSGEN, E. H.; STARGEL, D. S. The Digital Twin Paradigm for Future NASA and U.S. AirForce Vehicles. 53rd Structures, Structural Dynamics, and Materials Conference: SpecialSession on the Digital Twin. Pp. 1–14, 2012. Disponível em: https://ntrs.nasa.gov/api/citations/20120008178/downloads/20120008178.pdf. Acesso em: 24 ago. 2023.

GÓMEZ, H. J. H.; REICH, J. C. A Partitional Clustering Approach for the Identification and Analysis of Coexisting Bacteria in Groups of Bacterial Vaginosis Patients. Computación y Sistemas. V. 27, p. 415-424, 2023. Disponível em: doi: 10.13053/CyS-27-2-4621. Acesso em: 25, jun. 2024.)

GOYAL, D.; PABLA, B. S. Condition based maintenance of machine tools—A review. CIRP Journal of Manufacturing Science and Technology. [S.I.], v. 10, p. 24-35, 2015. Disponível em: https://doi.org/10.1016/j.cirpj.2015.05.004. Acesso em: 07 jul. 2022.

GRIEVES, M. Digital twin: manufacturing excellence through virtual factory replication. Whitepaper, 2014.

GRIEVES, M.; VICKERS, J. Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems. In: KAHLEN, J.; FLUMERFELT, S.; ALVES, A. (eds)

Transdisciplinary Perspectives on Complex Systems. p. 85-113. Cham: Springer, 2017. Disponível em: https://doi.org/10.1007/978-3-319-38756-7_4. Acesso em: 29 jun. 2022.

HARTIGAN, J. A.; WONG, M. A. Algorithm AS 136: A K-Means Clustering Algorithm. Journal of the Royal Statistical Society. V. 28, P. 100-108, 1979. Disponível em: https://doi.org/10.2307/2346830. Acesso em: 25 jun. 2024.

HASSAN, M.; SWADLING, M.; BJORSELL, N. Experience from implementing digital twins for maintenance in industrial processes. Journal of Intelligent Manufacturing. (2023). Disponível em: https://doi.org/10.1007/s10845-023-02078-4. Acesso em: 13 jul. 2023.

HEGDE, J.; ROKSETH, B. Applications of machine learning methods for engineering risk assessment – A review. Safety Science. V. 122, p. 16, 2020. Disponível em: https://doi.org/10.1016/j.ssci.2019.09.015. Acesso em: 23 fev. 2023.

HERMANN, M., PENTEK, T., OTTO, B. Design Principles for Industrie 4.0 Scenarios: A Literature Review. Technische Universität Dortmund. pp. 1-16, 2015. Disponível em: doi: 10.13140/RG.2.2.29269.22248. Acesso em: 10 ago. 2023.

IBM. Digital twin: Helping machines tell their story (2020). Disponível em: https://www.ibm.com/internet-of-things/trending/digital-twin. Acesso em: 10 set. 2023.

IBM. O que é uma rede neural? (2024). Disponível em: https://www.ibm.com/br-pt/topics/neural-networks. Acesso em: 29 jun. 2024.

INSTITUTO AÇO BRASIL - IAB. Anuário Estatístico. Rio de Janeiro: Instituto Aço Brasil, 2023. Disponível em: https://acobrasil.org.br/site/wp-content/uploads/2023/07/AcoBrasil_Anuario_2023.pdf. Acesso em: 10 jun. 2024.

INTERNATIONAL BUSINESS MACHINES – IBM. O que é a Indústria 4.0?. [*S.l.*], IBM, 2023. Disponível em: https://www.ibm.com/br-pt/topics/industry-4-0. Acesso em: 28 fev. 2023.

JAKUBEK, B.; GROCHALSKI, K; RUKAT, W.; SOKOL, H. Thermovision measurements of rolling bearings. Measurement. V. 189, 2022. Disponível em: https://doi.org/10.1016/j.measurement.2021.110512. Acesso em: 01 março 2023.

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. Machine learning and deep learning. Electronic Markets. V. 31, p. 685-695, 2021. Disponível em: https://doi.org/10.1007/s12525-021-00475-2. Acesso em: 23 fev. 2023.

JONES, M. T. A neural networks deep dive. IBM, 2017. Disponível em: https://developer.ibm.com/articles/cc-cognitive-neural-networks-deep-dive/. Acesso em: 30 jun. 2024.

JUNQUERA, A. M. V.; GONZÁLEZ, J. G.; BALSERA, J. M. V.; MONTEQUÍN, V. R. A Wire Rod Rolling Mill Digital Twin for the Simulation of the Rolls Replacement Process. Proceedings – MDPI. [S.I.], v. 63, p. 1-9, 2020. Disponível em: https://doi.org/10.3390/proceedings2020063013. Acesso em: 07 jul. 2022.

JUVINALL, R. C.; MARSHEK, K. M. Fundamentais of machine component design. 4 ed. Traduzido por RIBEIRO DA SILVA, F. Rio de Janeiro: LTC, 2013.

KHAN, S.; FARNSWORTH, M.; MCWILLIAM, R.; ERKOYUNCU, J. On the requirements of digital twin-driven autonomous maintenance. Annual Reviews in Control. V. 50, p. 13-28, 2020. Disponível em: https://doi.org/10.1016/j.arcontrol.2020.08.003. Acesso em: 09 dez. 2022.

KINGMA; D. P; BA, J. Adam: A Method for Stochastic Optimization. 3rd International Conference for Learning Representations, San Diego, 2015. V. 9. Disponível em: https://doi.org/10.48550/arXiv.1412.6980. Acesso em: 30 jun. 2024.

KRUSE, R.; MOEWES, C.; BORGELT, C.; STEINBRECHER, M.; KLAWONN, F.; HELD, P. Computational Intelligence: A Methodological Introduction. 1 ed. Londres: Springer, 2013.

LEE, Y. Rod and Bar Rolling: Theory and Applications. 1. ed. Boca Raton: CRC Press, 2018.

LESSMEIER, C.; KIMOTHO, J. K.; ZIMMER, D.; SEXTRO, W. Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification. EUROPEAN CONFERENCE OF THE PROGNOSTICS AND HEALTH MANAGEMENT SOCIETY. 2016. Disponível em: https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=79c07f2be8dd894deb572070f674e514d3dd1caa. Acesso em: 04 nov. 2023.

LINK, P.; PENTER, L.; RÜCKERT, U.; KLINGEL, L.; VERL, A.; IHLENFELDT, S. Real-time quality prediction and local adjustment of friction with digital twin in sheet metal forming. Robotics and Computer-Integrated Manufacturing. V. 91, p. 1-11, 2025. Disponível em: https://doi.org/10.1016/j.rcim.2024.102848. Acesso em: 15 out. 2024.

LIU, R.; PAN, D.; XU, Y.; ZENG, H.; HE, Z.; LIN, J.; ZENG, W.; WU, Z.; LUO, Z.; QIN, G.; CHEN, W. A deep learning–machine learning fusion approach for the classification of benign, malignant, and intermediate bone tumors. European Radiology. V. 32, p. 1371-1383, 2022. Disponível em: https://doi-org.ez107.periodicos.capes.gov.br/10.1007/s00330-021-08195-z. Acesso em: 23 fev. 2023.

LIU, S.; WANG, X. V.; WANG, L. Digital twin-enabled advance execution for human-robot collaborative assembly. CIRP Annals. V. 71, ed. 1, p. 25-28, 2022. Disponível em: Doi: https://doi.org/10.1016/j.cirp.2022.03.024. Acesso em: 09 dez. 2022.

LUGT, P. M. Grease Lubrication in Rolling Bearings. John Wiley & Sons, 2013.

LUO, W.; HU, T.; YE, Y.; ZHANG, C.; WEI, Y. A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. Robotics and Computer-Integrated Manufacturing. V. 65, p. 1-16, 2020. Disponível em: https://doi.org/10.1016/j.rcim.2020.101974. Acesso em: 09 dez. 2022.

LV, J.; LI, X.; SUN, Y.; ZHENG, Y.; BAO, J. A bio-inspired LIDA cognitive-based Digital Twin architecture for unmanned maintenance of machine tools. Robotics and Computer-Integrated Manufacturing. V. 80, 2023. Disponível em: https://doi.org/10.1016/j.rcim.2022.102489. Acesso em: 09 dez. 2022.

MACIEL, A. M.; VINHAS, L.; CÂMARA, G. Algoritmos de clustering para separação de culturas agrícolas e tipos de uso e cobertura da Terra utilizando dados de sensoriamento remoto. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto- SBSR. P. 4620-4627. Disponível em: http://www.dsr.inpe.br/sbsr2015/files/p0903.pdf. Acesso em: 27 Maio 2023.

MAHESH, B. Machine Learning Algorithms - A Review. International Journal of Science and Research. V. 9, p. 381-386, 2020. Disponível em: https://www.ijsr.net/get_abstract.php?paper_id=ART20203995. Acesso em: 23 fev. 2023.

MARGHITU, D. B.; DUPAC, M. Chapter Four - Rolling bearings. Machine Component Analysis with MATLAB. Oxônia: Butterworth-Heinemann, p. 141-166, 2019. Disponível em: https://doi.org/10.1016/B978-0-12-804229-8.00009-8. Acesso em 27 jun. 2022.

MARQUEZ, A. C.; CARMONA, A. F.; MARCOS, J. A.; NAVARRO, J. Designing CBM Plans, Based on Predictive Analytics and Big Data Tools, for Train Wheel Bearings. Computers in Industry. V. 122, p. 1-13, 2020. Disponível em: https://doi.org/10.1016/j.compind.2020.103292. Acesso em: 23 fev. 2023.

MÁRQUEZ, F. P. G.; TOBIAS, A. M.; PÉREZ, J. M. P.; PAPAELIAS, M. Condition monitoring of wind turbines: Techniques and methods. Renewable Energy. V. 46, p. 169-178, 2012. Disponível em: https://doi.org/10.1016/j.renene.2012.03.003. Acesso em: 15 nov. 2023.

MONAVAR, H. M.; AHMADI, H.; MOHTASEBI, S. S. Prediction of Defects in Roller Bearings Using Vibration Signal Analysis. World Applied Sciences Journal. [S.I.], v. 4, ed. 1, p. 150-154, 2008. Disponível em: encurtador.com.br/DIJNR. Acesso em: 30 jun. 2022.

MOURTZIS, D.; TSOUBOU, S.; ANGELOPOULOS, J. Robotic Cell Reliability Optimization Based on Digital Twin and Predictive Maintenance. Eletronics. V. 12, 2023. Disponível em: https://doi.org/10.3390/electronics12091999. Acesso em: 12 jul. 2023.

MOZO, A.; KARAMCHANDANI, A.; GÓMEZ-CANAVAL, S.; SANZ, M.; MORENO, J. I.; PASTOR, A. B5GEMINI: AI-Driven Network Digital Twin. Sensors – MDPI. V. 22, n. 11, p. 1-30, 2022. Disponível em: https://doi.org/10.3390/s22114106. Acesso em: 09 dez. 2022.

NAQVI, S. M. R. GHUFRAN, M.; MERAGHNI, S.; VARNIER, C.; NICOD, J. M.; ZERHOUNI, N. Human knowledge centered maintenance decision support in digital twin environment. Journal of Manufacturing Systems. V. 65, p. 528-537, 2022. Disponível em: https://doi.org/10.1016/j.jmsy.2022.10.003. Acesso em: 15 fev. 2023.

NEGRI, E.; Fumagalli, L.; Macchi, M. A Review of the Roles of Digital Twin in CPS-based Production Systems. Vol. 11, pp. 939-948, 2017. Disponível em: https://doi.org/10.1016/j.promfg.2017.07.198. Acesso em: 16 jul. 2023.

NUNES, I.; SPATTI, D. H.; FLAUZINO, R. A.; LIBONI, L. H. B.; ALVES, S. F. R. Artificial Neural Networks. Ed. 1, pp. 307, Springer Cham, 2018. Disponível em: https://doi.org/10.1007/978-3-319-43162-8. Acesso em: 29 jun. 2024.

NWACHUKWU, P. U.; OLUWOLE, O. O. Effects of rolling process parameters on the mechanical properties of hot-rolled St60Mn steel. Case Studies in Construction Materials. Ibadan, v. 6, p. 134-146, 2017. Disponível em: https://doi.org/10.1016/j.cscm.2017.01.006. Acesso em: 26 jun. 2022.

OBERDIEK, P.; ROTTMANN, M.; GOTTSCHALK, H. Classification Uncertainty of Deep Neural Networks Based on Gradient Information. 8th IAPR TC3 Workshop, ANNPR 2018 Siena, Italy, September 19–21. 2018. Disponível em: https://doi.org/10.1007/978-3-319-99978-4. Acesso em: 30 jun. 2024.

PIRES, F.; CACHADA, A.; BARBOSA, J.; MOREIRA, A. P.; LEITÃO, P. Digital Twin in Industry 4.0: Technologies, Applications and Challenges. 2019 IEEE 17th International Conference on Industrial Informatics (INDIN). pp. 721-726, 2019. Disponível em: doi: 10.1109/INDIN41052.2019.8972134.

QI, Q.; TAO, F. Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 Degree Comparison. IEEE Access. V. 6, p. 3585-3593, 2018. Disponível em: https://ieeexplore.ieee.org/document/8258937. Acesso em: 09 dez. 2022.

QIN, Y.; WU, X.; LUO, J. Data-Model Combined Driven Digital Twin of Life-Cycle Rolling Bearing. IEEE Transactions on Industrial Informatics. *[S.I.]*, v. 18, ed. 3, p. 1530-1540, 2021. Disponível em: doi: 10.1109/TII.2021.3089340. Acesso em: 30 jun. 2022.

QUIN, Z.; WU, Y.; LYU, S. A Review of Recent Advances in Design Optimization of Gearbox. International Journal of Precision Engineering and Manufacturing. *[S.I.]*, v. 19, p. 1753-1762, 2018. Disponível em: doi: 10.1007/s12541-018-0203-z. Acesso em: 13 nov. 2023.

RAGHAVAIAH, N. V.; HARIPRASAD, I. Maintenance and reliability strategy of mechanical equipment in industry. International Research Journal of Engineering and Technology (IRJET). *[S.I]*, v. 6, ed. 6, p. 3430-3432, 2019. Disponível em: https://www.irjet.net/archives/V6/i6/IRJET-V6I6688.pdf. Acesso em: 27 jun. 2022.

RALPH, B. J.; SORGER, M.; HARTL, K.; SCHWARZ-GSAXNER, A.; MESSNER, F.; STOCKINGER, M. Transformation of a rolling mill aggregate to a cyber physical production system: from sensor retrofitting to machine learning. Journal of Intelligent Manufacturing. V. 33, p. 493-518, 2022. Disponível em: https://doi-org.ez107.periodicos.capes.gov.br/10.1007/s10845-021-01856-2. Acesso em: 22 fev. 2023.

REICHMANN, F. Lubrication of Rolling Bearings. BHM Berg- und Hüttenmännische Monatshefte. V. 167, p. 207-214, 2022. Disponível em: https://doi-org.ez107.periodicos.capes.gov.br/10.1007/s00501-022-01229-z. Acesso em: 18 nov. 2023.

REN, Z., WAN, J., DENG, P. Machine-Learning-Driven Digital Twin for Lifecycle Management of Complex Equipment. IEEE Transactions on Emerging Topics in Computing. V. 10, n. 1, p. 9-22, 2022. Disponível em: https://ieeexplore.ieee.org/document/9690056. Acesso em: 09 dez. 2022.

RITTO, T. G.; ROCHINHA, F. A. Digital twin, physics-based model, and machine learning applied to damage detection in structures. Mechanical Systems and Signal

Processing. V. 155, p. 1-16, 2021. Disponível em: https://doi.org/10.1016/j.ymssp.2021.107614. Acesso em: 28 fev. 2023.

RODRIGUEZ, P. C.; MARTI-PUIG, P.; CAIAFA, C. F.; SERRA-SERRA, M.; CUSIDÓ, J.; SOLÉ-CASALS, J. Exploratory Analysis of SCADA Data from Wind Turbines Using the K-Means Clustering Algorithm for Predictive Maintenance Purposes. Machines. V. 11, n. 2, 2023. Disponível em: https://doi.org/10.3390/machines11020270. Acesso em: 21 jul. 2024.

ROLLE, R. P.; MARTUCCI, V. O.; GODOY, E. P. Modular Framework for Digital Twins: Development and Performance Analysis. V. 32, p. 1485-1497, 2021. Disponível em: https://doi-org.ez107.periodicos.capes.gov.br/10.1007/s40313-021-00830-w. Acesso em: 24 jun. 2024

ROSEN, R. WICHERT, G. V.; LO, G.; BETTENHAUSEN, K. D. About The Importance of Autonomy and Digital Twins for the Future of Manufacturing. IFAC-PapersOnLine. [S.I.], v. 48, p. 567-572, 2015. Disponível em: https://doi.org/10.1016/j.ifacol.2015.06.141. Acesso em: 07 jul. 2022.

RUMELHART, D. E.; MCCLELLAND, J. L. Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations. Cambridge: MIT Press, 1987. Disponível em: https://ieeexplore.ieee.org/book/6276825. Acesso em: 30 jun. 2024.

SCHWENDEMANN, S.; AMJAD, Z.; SIKORA, A. A survey of machine-learning techniques for condition monitoring and predictive maintenance of bearings in grinding machines. Computers in Industry. V. 125, p.17, 2021. Disponível em: https://doi.org/10.1016/j.compind.2020.103380. Acesso em: 23 fev. 2023.

SHAFTO, M. G.; CONROY, M.; DOYLE, R.; GLAESSGEN, E.; KEMP, C.; LEMOIGNE, J.; WANG, L. DRAFT Modeling, Simulation, Information Technology & Processing Roadmap Technology Area 11. National Aeronautics and Space Administration. (2010). Disponível em: file:///C:/Users/USER/Downloads/TA11-MSITP-DRAFT-Nov2010-A1.pdf. Acesso em 12 jul. 2023.

SHENG, S. Gearbox Typical Failure Modes, Detection and Mitigation Methods. National Renewable Energy Laboratory/National Wind Technology Center. 2014. Disponível em: https://www.nrel.gov/docs/fy14osti/60982.pdf. Acesso em: 14 nov. 2023.

SHRESTHA, Y. R.; KRISHNA, V.; KROGH, G. V. Augmenting organizational decision-making with deep learning algorithms: Principles, promises, and challenges. Journal of

Business Research. V. 123, p. 588-603, 2021. Disponível em: https://doi.org/10.1016/j.jbusres.2020.09.068. Acesso em: 23 fev. 2023.

SIFONTE, J. R.; REYES-PICKNELL, J. V. Reliability Centered Maintenance Reengineered: Practical Optimization of the RCM Process with RCM-R. 1. ed. Boca Raton: CRC Press, 2017.

SILVESTRI, L.; FORCINA, A.; INTRONA, V.; SANTOLAMAZZA, A.; CESAROTTI, V. Maintenance transformation through Industry 4.0 technologies: A systematic literature review. Computers in Industry. *[S.l.]*, v. 123, p. 1-16, 2020. Disponível em: https://doi.org/10.1016/j.compind.2020.103335. Acesso em: 05 jul. 2022.

SKF. Rolamento de roletes cilindricos - SKF - nu 2328 Ecml/C3 – Unitário. Catálogo técnico. Disponível em: https://www.compreskf.com.br/p/6552095/rolamento-de-roletes-cilindricos-skf-nu-2328-ecmlc3-unitario. Acesso em: 06 nov. 2023.

SÖDERBERG, R.; WÄRMEFJORD, K.; CARLSON, J. S.; LINDKVIST, L. Toward a Digital Twin for real-time geometry assurance in individualized production. CIRP Annals. Vol. 66, pp. 137-140, 2017. Disponível em: https://doi.org/10.1016/j.cirp.2017.04.038. Acesso em: 13 jun. 2023.

SUMITOMO DRIVE TECHNOLOGIES. 3 Most Common Gearbox Failures. 2023. Disponível em: https://us.sumitomodrive.com/en-us/news/3-most-common-gearbox-failures. Acesso em: 14 nov. 2023.

VIOLA, J.; CHEN, Y. Digital-Twin-Enabled Smart Control Engineering. A Framework and Case Studies. Springer Cham (2023). Disponível em: https://doi.org/10.1007/978-3-031-22140-8. Acesso em: 22 jun. 2023.

TAO, F.; QI, Q. Make more digital twins. Nature. V. 573, pp. 490-491, 2019. Disponível em: https://doi.org/10.1038/d41586-019-02849-1. Acesso em: 15 ago. 2023.

TAO, F.; ZHANG, M.; LIU, Y.; NEE, A. Y. C. Digital twin driven prognostics and health management for complex equipment. CIRP Annals. V. 67, ed. 1, p. 169-172, 2018. Disponível em: https://doi.org/10.1016/j.cirp.2018.04.055. Acesso em: 09 dez. 2022.

TAO, F.; ZHANG, M.; NEE, A. Y. C. Digital Twin Driven Smart Manufacturing. Matthew Deans, 2018.

TIMKEN. BEARING DAMAGE ANALYSIS REFERENCE GUIDE. *[S.l.]*, 2023. Disponível em: https://www.timken.com/resources/5892-bearing-damage-analysis-with-lubrication-reference-guide/. Acesso em: 18 nov. 2023.

TIMKEN. CATÁLOGO DE ROLAMENTOS DE ROLOS CÔNICOS TIMKEN. *[S.l.]*, 2019. Disponível em: https://www.timken.com/wp-content/uploads/2019/08/E10481-PT.pdf. Acesso em: 10 nov. 2023.

VANEGAS, M. N.; ÁLVAREZ, R. J.; DE SOUZA, G. F. M. THEORY OF RELIABILITY APPLIED IN THE EVALUATION OF THE LIFE IN CONTACT FATIGUE. Ingeniare. Rev. chil. ing. V. 17, n. 3, p. 423-431, 2009. Disponível em: http://dx.doi.org/10.4067/S0718-33052009000300016. Acesso em: 18 nov. 2023.

VERDOUW, C.; TEKINERDOGAN, B.; BEULENS, A.; WOLFERT, S. Digital twins in smart farming. Agricultural Systems. V. 189, p. 1-19, 2021. Disponível em: https://doi.org/10.1016/j.agsy.2020.103046. Acesso em: 09 dez. 2022.

WALLIN, E. Preventive Maintenance of Rolling Bearings. Industrial Lubrication and Tribology. V. 19, p.110-116, 1967. Disponível em: https://doi.org/10.1108/eb052823. Acesso em: 01 março 2023.

WEBER, C.; KÖNIGSBERGER, J.; KASSNER, L.; MITSCHANG, B. M2DDM – A Maturity Model for Data-Driven Manufacturing. Procedia Manufacturing. Vol. 63, pp. 173-178, 2017. Disponível em: https://doi.org/10.1016/j.procir.2017.03.309. Acesso em: 22 jul. 2023.

WORLDSTEEL ASSOCIATION. World Steel in Figures 2023. *[S.l.]*, 2023. Disponível em: https://worldsteel.org/data/world-steel-in-figures-2023/. Acesso em: 10 jun. 2024.

WU, J. Advances in K-means Clustering. A Data Mining Thinking. Heidelberg: Springer Berlin, 2012. Disponível em: https://doi.org/10.1007/978-3-642-29807-3. Acesso em: 25 jun. 2024.

XIA, L.; LU, J.; ZHANG, H.; XU, M.; LI, Z. Construction and application of smart factory digital twin system based on DTME. The International Journal of Advanced Manufacturing Technology. V. 120, p. 4159-4178, 2022. Disponível em: https://doi.org/10.1007/s00170-022-08971-1. Acesso em: 09 dez. 2022.

XU, Y.; SUN, Y.; LIU, X.; ZHENG, Y. A Digital-Twin-Assisted Fault Diagnosis Using Deep Transfer Learning. IEEE Access. V. 7, p. 19990-19999, 2019. Disponível em: https://ieeexplore.ieee.org/document/8598879. Acesso em: 09 dez. 2022.

YOO, J.-H.; PARK, Y.-K.; HAN, S.-S. Predictive Maintenance System for Wafer Transport Robot Using K-Means Algorithm and Neural Network Model. Electronics. V. 11, 2022. Disponível em: https://doi.org/10.3390/electronics11091324. Acesso em: 21 jul. 2024.

ZAHEER, R.; SHAZIYA, H. A Study of the Optimization Algorithms in Deep Learning. hird International Conference on Inventive Systems and Control (ICISC). Pp. 536-539, 2019. Disponível em: doi: 10.1109/ICISC44355.2019.9036442. Acesso em: 30 jun. 2024.

ZHANG, R.; ZENG, Z.; LI, Y.; LIU, J.; WANG, Z. Research on Remaining Useful Life Prediction Method of Rolling Bearing Based on Digital Twin. MSPI. V. 24, n. 11, 2022b. Disponível em: https://doi.org/10.3390/e24111578. Acesso em: 23 fev. 2023.

ZHANG, Y.; WANG, W.; ZHANG, H.; LI, H.; LIU, C.; DU, X. Vibration monitoring and analysis of strip rolling mill based on the digital twin model. Research Square. *[S.l.]*, v. 1, p. 1-15, 2022a. Disponível em: https://doi.org/10.21203/rs.3.rs-1441429/v1. Acesso em: 30 jun. 2022.

ZHANG, Y.; ZHANG, M.; WANG, Y.; XIE, L. Fatigue Life Analysis of Ball Bearings and a Shaft System Considering the Combined Bearing Preload and Angular Misalignment. Appl. Sci. V. 10, 2020. Disponível em: https://doi.org/10.3390/app10082750. Acesso em: 10 jun. 2024.

ZHONG, D.; Yi, C.; XIAO, H.; ZHANG, H.; WU, A. A Novel Fault Diagnosis Method for Rolling Bearing Based on Improved Sparse Regularization via Convex Optimization. Complexity. V. 2018, p. 1-10, 2018. Disponível em: https://doi.org/10.1155/2018/2169364. Acesso em: 08 Março 2023.

ZOU, J.; HAN, Y.; SO, SS. Overview of Artificial Neural Networks. In: Livingstone, D.J. (eds) Artificial Neural Networks. Methods in Molecular Biology. V. 458. Humana Press, 2008. Disponível em: https://doi.org/10.1007/978-1-60327-101-1_2. Acesso em: 30 jun. 2024.