

UNIVERSIDADE DO ESTADO DO AMAZONAS – UEA

ESCOLA SUPERIOR DE TECNOLOGIA - EST

PEDRO TIAGO SILVA MELO

**INTELIGÊNCIA ARTIFICIAL PARA DIAGNÓSTICO E
PROGNÓSTICO NA ENGENHARIA MECÂNICA:
METODOLOGIA, APLICAÇÕES E ANÁLISE DE
EXPLICABILIDADE EM INJEÇÃO PLÁSTICA E
ROLAMENTOS**

Manaus - AM

2025

PEDRO TIAGO SILVA MELO

**INTELIGÊNCIA ARTIFICIAL PARA DIAGNÓSTICO E
PROGNÓSTICO NA ENGENHARIA MECÂNICA:
METODOLOGIA, APLICAÇÕES E ANÁLISE DE
EXPLICABILIDADE EM INJEÇÃO PLÁSTICA E
ROLAMENTOS**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Mecânica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como requisito parcial para obtenção do título de Engenheiro Mecânico.

Orientador: Prof. Dr. Rubelmar Maia de Azevedo Cruz Neto

Manaus - AM
2025

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).
Sistema Integrado de Bibliotecas da Universidade do Estado do Amazonas.

S586i	Silva Melo, Pedro Tiago Inteligência artificial para diagnóstico e prognóstico na engenharia mecânica : metodologia, aplicações e análise de explicabilidade em injeção plástica e rolamentos / Pedro Tiago Silva Melo. Manaus : [s.n], 2025. 85 f.: color.; 21.0 cm. TCC - Graduação em Engenharia Mecânica- Universidade do Estado do Amazonas, Manaus, 2025. Inclui Bibliografia. Inclui Apêndice. Orientador: Rubelmar Maia de Azevedo Cruz Neto. 1. Inteligência artificial. 2. Prognóstico de vida útil. 3. Inteligência artificial explicável (XAI). 4. Diagnóstico de falhas. 5. Monitoramento de rolamentos. I. Rubelmar Maia de Azevedo Cruz Neto (Orient.) II. Universidade do Estado do Amazonas. III. Título CDU(1997)621
-------	---


PEDRO TIAGO SILVA MELO

**INTELIGÊNCIA ARTIFICIAL PARA DIAGNÓSTICO E
PROGNÓSTICO NA ENGENHARIA MECÂNICA:
METODOLOGIA, APLICAÇÕES E ANÁLISE DE
EXPLICABILIDADE EM INJEÇÃO PLÁSTICA E
ROLAMENTOS**


Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Mecânica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como requisito parcial para obtenção do título de Engenheiro Mecânico.

Aprovado em: **09 de dezembro de 2025**

BANCA EXAMINADORA



Prof. Dr. Rubelmar Maia de Azevedo Cruz Neto
(Orientador)



Prof. Me. Silvio Romero Adjar Marques



Documento assinado digitalmente
MARCOS DANTAS DOS SANTOS
Data: 12/12/2025 14:26:56-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Marcos Dantas dos Santos

Manaus - AM
2025

Dedico este trabalho a todos que contribuíram direta ou indiretamente para a minha formação acadêmica e pessoal.

AGRADECIMENTOS

Agradeço à minha família, que sempre me apoiou, encorajou e acreditou em mim. Vocês foram minha fonte de força e inspiração.

Aos meus amigos de faculdade, que compartilharam comigo as alegrias e desafios dessa jornada. Juntos, vivemos momentos inesquecíveis e construímos laços que durarão para sempre.

Aos meus professores, que dedicaram seu tempo e conhecimento para me guiar, desafiando-me a alcançar meu melhor potencial. Suas lições moldaram meu caminho e minha visão de mundo.

Um agradecimento especial ao meu orientador, Prof. Dr. Rubelmar Maia de Azevedo Cruz Neto, pela orientação paciente, conhecimento compartilhado e incentivo constante ao longo do desenvolvimento deste trabalho e dos projetos que o compõem.

Este trabalho não teria sido possível sem o apoio, incentivo de todos vocês. Muito obrigado por fazerem parte desta conquista.

*“If I have seen further it is by standing on the
shoulders of Giants.”*

Sir Isaac Newton

RESUMO

A crescente integração da Inteligência Artificial (IA) na engenharia mecânica tem gerado modelos preditivos de alta acurácia. No entanto, muitas dessas aplicações ainda operam como "caixas-pretas", carecendo de uma análise metodológica que valide a coerência física do conhecimento aprendido e garanta a confiança em seus resultados. Este trabalho aborda essa lacuna ao propor uma estrutura metodológica orientada a risco para a aplicação e, crucialmente, a explicabilidade – a capacidade de interpretar como os modelos geram suas previsões – de técnicas de Aprendizado de Máquina em dois estudos de caso distintos: a previsão da qualidade das peças produzidas por injeção plástica e o prognóstico da Vida Útil Remanescente (RUL) de rolamentos. O objetivo central é desenvolver modelos preditivos cuja confiabilidade seja avaliada não apenas por métricas de desempenho, mas também pela coerência do seu aprendizado e pelo alinhamento com os requisitos de engenharia. No primeiro estudo de caso, foi desenvolvida e otimizada uma Rede Neural Artificial para prever a ocorrência de defeitos nos produtos manufaturados. O modelo alcançou uma acurácia de 99,39% e demonstrou excelente *recall* para as classes de defeito críticas, uma decisão de projeto guiada pela aplicação da ferramenta de Análise de Modos e Efeitos de Falha (FMEA). A análise com o método SHAP (*SHapley Additive exPlanations*) validou o aprendizado do modelo ao identificar variáveis de processo fisicamente relevantes. O segundo estudo de caso abordou o prognóstico de rolamentos. Embora a análise de sensibilidade tenha confirmado que o modelo aprendeu relações fisicamente coerentes, o desempenho preditivo foi limitado pela escassez de dados. Os resultados evidenciam que a aplicação bem-sucedida da IA na engenharia depende criticamente da qualidade dos dados e de uma metodologia que integre análise de risco, validação técnica e princípios de governança. A explicabilidade demonstrou ser fundamental para construir confiança e promover a transparência necessária para atender a requisitos de sistemas de gestão de IA, como os preconizados pela norma ISO 42001.

Palavras-chave: Inteligência Artificial, Aprendizado de Máquina, Engenharia Mecânica, Engenharia de Risco, Diagnóstico de Falhas, Prognóstico de Vida Útil, Injeção Plástica, Monitoramento de Rolamentos, Inteligência Artificial Explicável (XAI), Governança de IA.

ABSTRACT

The increasing integration of Artificial Intelligence (AI) in mechanical engineering has led to highly accurate predictive models. However, many of these applications still operate as 'black boxes,' lacking a methodological analysis to validate the physical coherence of the learned knowledge and ensure trust in their outcomes. This work addresses this gap by proposing a risk-oriented methodological framework for the application and, crucially, the explainability—the ability to interpret how models generate their predictions—of Machine Learning techniques in two distinct case studies: predicting the quality of parts produced by plastic injection molding and prognosing the Remaining Useful Life (RUL) of bearings. The central aim is to develop predictive models whose reliability is assessed not only by performance metrics but also by the coherence of their learned knowledge and alignment with engineering requirements. In the first case study, an optimized Artificial Neural Network was developed to predict the occurrence of defects in manufactured products. The model achieved 99.39% accuracy and demonstrated excellent recall for critical defect classes, a design choice guided by the application of the Failure Mode and Effects Analysis (FMEA) tool. Analysis with SHAP (*SHapley Additive exPlanations*) validated the model's learning by identifying physically relevant process variables. The second case study addressed bearing prognosis. Although sensitivity analysis confirmed that the model learned physically coherent relationships, predictive performance was limited by data scarcity. The results evidence that the successful application of AI in engineering critically depends on data quality and a methodology that integrates risk analysis, technical validation, and governance principles. Explainability proved to be fundamental for building trust and promoting the necessary transparency to meet the requirements of AI management systems, such as those advocated by the ISO 42001 standard.

Keywords: Artificial Intelligence, Machine Learning, Mechanical Engineering, Risk Engineering, Fault Diagnosis, Remaining Useful Life Prognosis, Plastic Injection Molding, Bearing Monitoring, Explainable Artificial Intelligence (XAI), AI Governance.

Lista de Figuras

1	Exemplos de espectros de frequência representativos para rolamentos. Os espectros (a) e (b) são de um rolamento em condição saudável, enquanto os espectros (c) e (d) correspondem a um rolamento em condição de falha. Esses espectros são usados como "templates" para o cálculo de features de similaridade.	18
2	Exemplo ilustrativo de uma Árvore de Decisão treinada no dataset Iris para classificação das espécies de flores (Setosa, Versicolor, Virginica) com base nas características das pétalas (petal width, petal length). Cada nó mostra o critério de divisão, o índice Gini, o número de amostras e a distribuição das classes.	24
3	Exemplos esquemáticos de arquiteturas de Aprendizado Profundo: (a) MLP, (b) CNN e (c) RNN/LSTM.	25
4	Comparação esquemática entre um modelo de IA do tipo Caixa-Preta e um modelo com capacidade de Explicação (XAI).	30
5	Fluxograma geral ilustrando as etapas de um projeto de Aprendizado de Máquina aplicado ao PHM, dividido em preparação de dados e modelagem/avaliação.	32
6	Representações dos dados de vibração brutos para um rolamento do dataset PRONOSTIA.	43
7	Distribuição das classes de qualidade das peças no conjunto de dados de injeção plástica.	50
8	Heatmap da matriz de correlação entre as variáveis numéricas de entrada do processo de injeção plástica.	50
9	Importância global média das features (SHAP Bar Plot) para o modelo de Rede Neural Otimizada na predição de qualidade em injeção plástica. As cores indicam a contribuição média para cada classe (azul: OK, magenta: NOK Preenchimento, oliva: NOK Rebarba).	54
10	SHAP Dot Plot para a classe OK (Rede Neural Otimizada - Injeção Plástica).	55
11	SHAP Dot Plot para a classe NOK (Rebarba) (Rede Neural Otimizada - Injeção Plástica).	56
12	SHAP Dot Plot para a classe NOK (Preenchimento) (Rede Neural Otimizada - Injeção Plástica).	57
13	Análise visual dos erros de previsão do Indicador de Saúde (HI) para o ensemble LSTM no conjunto de teste de rolamentos.	61
14	Evolução temporal do HI real e previsto (ensemble e individual) para o rolamento Rolamento 3_3 do conjunto de teste.	62

15	Evolução temporal do HI real e previsto (ensemble e individual) para dois rolamentos do conjunto de treinamento, ilustrando o ajuste do modelo aos dados vistos.	63
16	Resultado da predição de RUL para rolamentos representativos do conjunto de teste, incluindo o melhor (1_7) e o pior (3_3, RPN mais alto).	65
17	Resultado da predição de RUL para rolamentos 1.3, 1.4 e 1.5 (Condição Operacional 1).	78
18	Resultado da predição de RUL para rolamentos 1.6 e 1.7 (Condição Operacional 1).	79
19	Resultado da predição de RUL para rolamentos 2.3, 2.4 e 2.5 (Condições Operacionais 2 e 3).	80
20	Resultado da predição de RUL para rolamentos 2.6, 2.7 e 3.3 (Condições Operacionais 2 e 3).	81

Lista de Tabelas

1	Desempenho comparativo dos modelos de classificação para injeção plástica no conjunto de teste.	51
2	Arquitetura da Rede Neural Otimizada para o problema de injeção plástica.	52
3	Matriz de confusão em valores absolutos para o modelo de Rede Neural Otimizada (injeção plástica) no conjunto de teste.	52
4	Métricas detalhadas de desempenho por classe para o modelo de Rede Neural Otimizada.	53
5	Resultados detalhados da previsão de RUL para o conjunto de teste de rolamentos (Ensemble LSTM, Ajuste Exponencial Ponderado, Monotônico). . .	64
6	Sensibilidade das Top 5 features do domínio do tempo na predição de HI de rolamentos.	66
7	Sensibilidade das Top 5 features de similaridade na predição de HI de rolamentos.	66

SUMÁRIO

LISTA DE FIGURAS	10
LISTA DE TABELAS	11
1 Introdução	10
2 Revisão da Literatura	13
2.1 Fundamentos de Manutenção Preditiva e Prognostics and Health Management (PHM)	13
2.1.1 Engenharia de Risco e Análise FMEA em Sistemas Mecânicos	14
2.2 Métodos de Monitoramento de Condição em Sistemas e Processos Mecânicos	14
2.2.1 Inspeção Visual	15
2.2.2 Sensores de Processo (Temperatura, Pressão, Vazão, Corrente, etc.)	16
2.2.3 Análise de Vibração	16
2.2.4 Outros Sensores Relevantes (Termografia, Emissão Acústica)	18
2.2.5 Métodos Não Destrutivos (NDT)	19
2.2.6 Monitoramento por Sinais Elétricos	20
2.2.7 Sensores Ópticos e Visão Computacional	20
2.3 Técnicas de Inteligência Artificial para Diagnóstico e Prognóstico	21
2.3.1 Conceitos de Aprendizado de Máquina	22
2.3.2 Algoritmos Clássicos de Aprendizado de Máquina	23
2.3.3 Conceitos e Arquiteturas de Aprendizado Profundo	25
2.3.4 Aplicações Práticas em Engenharia Mecânica	27
2.3.5 Vantagens e Desafios do Uso de IA em PHM e Engenharia Mecânica	28
2.3.6 Governança e Confiabilidade de IA: A Norma ABNT NBR ISO/IEC 42001	31
3 Metodologia	32
3.1 Abordagem Geral e Ferramentas Computacionais	33
3.2 Estudo de Caso 1: Predição de Falhas no Processo de Injeção Plástica	35
3.2.1 Descrição Detalhada do Processo e Definição do Problema	35
3.2.2 Definição de Requisitos de Risco via FMEA	36
3.2.3 Coleta e Caracterização dos Dados	36
3.2.4 Pré-processamento dos Dados para Injeção Plástica	37
3.2.5 Desenvolvimento e Treinamento dos Modelos Preditivos	38
3.2.6 Otimização de Hiperparâmetros	39
3.2.7 Avaliação de Desempenho e Análise de Explicabilidade (XAI)	40
3.3 Estudo de Caso 2: Predição da Vida Útil Remanescente de Rolamentos	41

3.3.1	Descrição do Problema de Prognóstico e Dataset Utilizado . .	42
3.3.2	Definição de Requisitos de Risco via FMEA	43
3.3.3	Extração e Seleção de Características (Features)	44
3.3.4	Pré-processamento dos Dados para Prognóstico de Rolamentos	45
3.3.5	Desenvolvimento do Modelo Ensemble LSTM	45
3.3.6	Estimativa da RUL a partir do HI Previsto	47
3.3.7	Métricas de Avaliação para Prognóstico	47
3.3.8	Análise de Sensibilidade das Features	48
4	Resultados e Discussão	49
4.1	Resultados do Estudo de Caso 1: Predição da Qualidade em Injeção Plástica	49
4.1.1	Caracterização Inicial dos Dados e Desempenho dos Modelos de Classificação	49
4.1.2	Análise de Explicabilidade (SHAP) para o Modelo de Rede Neural Otimizada	53
4.1.3	Discussão dos Resultados da Injeção Plástica	58
4.2	Resultados do Estudo de Caso 2: Predição da Vida Útil Remanescente de Rolamentos	60
4.2.1	Desempenho na Previsão do Indicador de Saúde (HI)	60
4.2.2	Desempenho na Estimativa da RUL	63
4.2.3	Análise de Sensibilidade das Features e Interpretabilidade do Modelo	66
4.2.4	Discussão dos Resultados do Prognóstico de Rolamentos . . .	67
4.3	Discussão Consolidada e Comparativa	69
5	Conclusão	73
5.1	Trabalhos Futuros	74
APÊNDICES		77
A	Critérios de Pontuação para Análise FMEA	77
B	Gráficos Completos de Predição de RUL	78
B.1	Condição Operacional 1	78
B.2	Condições Operacionais 2 e 3	80
REFERÊNCIAS		82

1 INTRODUÇÃO

A Quarta Revolução Industrial, ou Indústria 4.0, tem impulsionado uma transformação significativa nos processos de manufatura e na engenharia mecânica como um todo. A integração de tecnologias digitais, como a Internet das Coisas (IoT), Big Data, computação em nuvem e, crucialmente, a Inteligência Artificial (IA), está redefinindo a forma como sistemas e processos mecânicos são projetados, operados e mantidos (KAGERMANN; WAHLSTER, 2022). Nesse contexto, a capacidade de analisar grandes volumes de dados gerados por sensores em tempo real abre novas fronteiras para a otimização, o controle de qualidade proativo e a manutenção preditiva.

Sistemas e processos na engenharia mecânica, como a moldagem por injeção de plásticos e o funcionamento de componentes críticos como rolamentos em maquinário rotativo, são complexos e sujeitos a diversas fontes de variabilidade e degradação. Falhas inesperadas nesses sistemas podem levar a paradas de produção custosas, perdas de material, comprometimento da segurança e insatisfação do cliente. Tradicionalmente, a manutenção corretiva (reparar após a falha) e preventiva (baseada em tempo ou uso) têm sido as abordagens predominantes (MOUBRAY, 2001). No entanto, essas estratégias podem ser ineficientes. A avaliação e mitigação dos riscos associados a essas falhas (sejam eles de qualidade, financeiros ou de segurança) é um elemento essencial da prática de engenharia, frequentemente formalizada através de ferramentas como a Análise de Modos e Efeitos de Falha (FMEA) (STAMATIS, 2003).

A Inteligência Artificial, particularmente o Aprendizado de Máquina, oferece ferramentas poderosas para superar esses desafios. Modelos de Aprendizado de Máquina podem aprender padrões complexos a partir de dados históricos de processo e de sensores, permitindo o desenvolvimento de sistemas de diagnóstico e prognóstico (ARABACI; LAVING, 2019; HUANG; FARAHAT; GUPTA, 2020). Uma vertente crucial na aplicação dessas técnicas é a Inteligência Artificial Explicável (XAI), que busca fornecer transparência e interpretabilidade aos modelos, permitindo não apenas confiar em suas previsões, mas também validar se o aprendizado está alinhado com o conhecimento físico do domínio. Essa validação é um requisito fundamental para a implementação responsável da IA, conforme preconizado por novos frameworks de governança, como a norma ABNT NBR ISO/IEC 42001 (Associação Brasileira de Normas Técnicas, 2024).

Este trabalho explora a aplicação e a análise metodológica de técnicas de IA em dois estudos de caso distintos, mas representativos dos desafios encontrados na engenharia mecânica moderna, com ênfase na explicabilidade dos modelos. O primeiro estudo de caso foca no desenvolvimento de um sistema de previsão da qualidade em peças plásticas produzidas por moldagem por injeção. O objetivo é criar um modelo que, com base nos parâmetros de máquina configurados antes do início de um ciclo de produção, possa alertar o operador sobre a probabilidade de ocorrência de defeitos específicos, como rebarbas ou

falhas de preenchimento, permitindo a realização de ajustes proativos nos parâmetros do processo. O segundo estudo de caso aborda o prognóstico da vida útil restante de rolamentos, utilizando dados de vibração e uma abordagem baseada em *features* de similaridade e modelos de aprendizado profundo. Aqui, um foco importante é verificar, através da análise de sensibilidade, se o modelo de IA aprende tendências fisicamente coerentes com o processo de degradação, como por exemplo, a relação entre a distância de um *template* de falha e a proximidade do fim da vida útil.

A escolha desses dois problemas justifica-se pela sua relevância industrial e pela oportunidade de investigar diferentes facetas da aplicação de IA. Mais importante, eles permitem demonstrar uma metodologia de engenharia que transcende a simples otimização de métricas preditivas. Embora a obtenção de resultados de alta *performance* seja desejável, uma ênfase significativa deste trabalho reside na integração da análise de risco no planejamento e da análise de explicabilidade na validação, como forma de garantir a robustez e a confiabilidade do conhecimento aprendido, mesmo em cenários com desempenho subótimo.

O objetivo geral deste trabalho é desenvolver, implementar e avaliar modelos de Aprendizado de Máquina para diagnóstico e prognóstico, analisando sua confiabilidade através de uma estrutura metodológica que integra análise de risco, avaliação de desempenho e explicabilidade. Os objetivos específicos incluem:

1. Para o estudo de caso de injeção plástica:

- Coletar e pré-processar dados de parâmetros de máquina do processo de injeção.
- Desenvolver e comparar modelos de aprendizado de máquina (ex: Redes Neurais, Árvores de Decisão, Regressão Logística) para classificar a probabilidade de ocorrência de diferentes tipos de defeitos antes da produção.
- Analisar a importância das variáveis de processo e a explicabilidade do modelo preditivo com melhor desempenho utilizando técnicas como SHAP (*SHapley Additive exPlanations*), visando entender como os parâmetros de entrada influenciam a predição de qualidade.

2. Para o estudo de caso de prognóstico de rolamentos:

- Implementar uma metodologia baseada em *features* de similaridade e *ensemble* de Redes Neurais Long Short-Term Memory (LSTM) para prever um Indicador de Saúde (HI) dos rolamentos, utilizando o *dataset* público PRONOSTIA.
- Estimar a Vida Útil Restante (RUL) dos rolamentos a partir da extrapolação do HI previsto.
- Avaliar o desempenho do modelo na predição do HI e da RUL e realizar uma análise de sensibilidade para investigar a influência das *features* de entrada,

verificando a coerência do aprendizado do modelo com os princípios físicos da degradação.

3. Comparar as abordagens metodológicas, os desafios de dados, as técnicas de explicabilidade aplicadas e os aprendizados obtidos em ambos os estudos de caso, ressaltando a importância da análise metodológica e da interpretabilidade.

Este trabalho está estruturado da seguinte forma: o Capítulo 2 apresenta uma revisão da literatura sobre os fundamentos de manutenção preditiva, métodos de monitoramento de condição, as técnicas de Inteligência Artificial relevantes e a importância da XAI. O Capítulo 3 detalha a metodologia empregada em cada um dos dois estudos de caso, incluindo as técnicas de análise de explicabilidade. O Capítulo 4 apresenta e discute os resultados obtidos, com ênfase na interpretação dos modelos e na discussão do desempenho, incluindo uma análise consolidada. Finalmente, o Capítulo 5 sumariza as conclusões do trabalho, as limitações e sugere direções para pesquisas futuras, reforçando os aprendizados metodológicos.

2 REVISÃO DA LITERATURA

Esta seção aborda os conceitos fundamentais e os avanços recentes relevantes para a aplicação de Inteligência Artificial no diagnóstico e prognóstico em sistemas e processos da engenharia mecânica. Inicialmente, são discutidos os fundamentos da Manutenção Preditiva e do Gerenciamento da Saúde e Prognóstico (PHM). Em seguida, são revisados os principais métodos de monitoramento de condição. Por fim, são detalhadas as técnicas de Inteligência Artificial, com ênfase em Aprendizado de Máquina e Aprendizado Profundo, suas aplicações e desafios.

2.1 Fundamentos de Manutenção Preditiva e Prognostics and Health Management (PHM)

A manutenção é uma atividade crucial para garantir a operacionalidade, segurança e eficiência de sistemas e equipamentos industriais. Conforme definido pela norma **NBR 5462** (ABNT, 1994), a manutenção compreende a combinação de todas as ações técnicas e administrativas destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida. Tradicionalmente, as estratégias podem ser classificadas em:

- **Manutenção Corretiva:** Realizada após a ocorrência de uma falha (ou pane), visando restaurar o equipamento à sua condição operacional. É geralmente a mais custosa devido a paradas não planejadas e possíveis danos secundários (ABNT, 1994).
- **Manutenção Preventiva:** Executada em intervalos pré-determinados (baseada em tempo) ou após um certo número de ciclos de operação, independentemente da condição real do equipamento. Busca reduzir a probabilidade de falha, mas pode levar à substituição de componentes ainda em bom estado ou não evitar falhas que ocorrem antes do previsto (ABNT, 1994).
- **Manutenção Preditiva (PdM):** Baseia-se no monitoramento contínuo ou periódico da condição do equipamento para detectar sinais de degradação incipiente e prever quando a manutenção será necessária (na NBR 5462, este conceito relaciona-se à *manutenção controlada*). Permite otimizar os intervalos de manutenção, evitando paradas desnecessárias e reduzindo o risco de falhas catastróficas (MOBLEY, 2002).
- **Manutenção Prescritiva:** Um avanço da PdM, não apenas prevê falhas, mas também recomenda ações otimizadas de manutenção e operação para mitigar riscos ou maximizar a vida útil.

O Gerenciamento da Saúde e Prognóstico (Prognostics and Health Management - PHM) é uma tecnologia de manutenção focada na avaliação da saúde atual e na predição

da vida útil restante (RUL) de sistemas e componentes. O PHM integra tecnologias de sensoriamento, processamento de sinais, modelagem de degradação e algoritmos de aprendizado de máquina para fornecer informações acionáveis para a tomada de decisão em manutenção (SOUALHI et al., 2022). Os principais componentes de um sistema PHM incluem:

1. **Aquisição de Dados (Sensoriamento):** Coleta de dados relevantes de sensores instalados no equipamento ou processo (ex: vibração, temperatura, pressão, corrente elétrica, imagens).
2. **Processamento de Sinais e Extração de Características (Features):** Transformação dos dados brutos dos sensores em informações significativas (features) que reflitam a condição ou o estado de degradação do sistema.
3. **Diagnóstico:** Identificação e classificação de modos de falha existentes ou incipientes com base nas features extraídas.
4. **Prognóstico:** Estimativa da RUL do componente ou sistema, ou a probabilidade de falha dentro de um horizonte de tempo futuro.
5. **Apoio à Decisão:** Fornecimento de recomendações para ações de manutenção, logística ou operação com base nos resultados do diagnóstico e prognóstico.

A aplicação eficaz de PHM pode resultar em aumento da disponibilidade e confiabilidade dos ativos, redução de custos de manutenção, otimização de estoques de peças sobressalentes e melhoria da segurança operacional.

2.1.1 Engenharia de Risco e Análise FMEA em Sistemas Mecânicos

A engenharia de sistemas mecânicos opera sob o princípio fundamental da mitigação de riscos. Uma das ferramentas mais consolidadas para essa finalidade é a Análise de Modos e Efeitos de Falha (FMEA, do inglês *Failure Mode and Effects Analysis*). O FMEA é um método sistemático e proativo utilizado para identificar falhas potenciais em um projeto, processo ou produto, antes que elas ocorram. O processo consiste em avaliar a severidade das consequências da falha, a probabilidade de sua ocorrência e a capacidade dos controles existentes de detectá-la, resultando em um Número de Prioridade de Risco (RPN) que orienta as ações de melhoria (Number Analytics, 2025). Tradicionalmente aplicada a componentes físicos e processos de manufatura, a lógica do FMEA pode ser estendida para avaliar os riscos associados à implementação de sistemas de software complexos, como os modelos de Inteligência Artificial, que atuam em ambientes de engenharia críticos.

2.2 Métodos de Monitoramento de Condição em Sistemas e Processos Mecânicos

A capacidade de monitorar continuamente ou periodicamente a condição de sistemas e processos mecânicos é a espinha dorsal de qualquer estratégia eficaz de manutenção

preditiva e controle de qualidade. Uma variedade de métodos, desde os mais tradicionais até os tecnologicamente avançados, são empregados para coletar dados que possam indicar desvios de operação, degradação de componentes ou a presença de defeitos. Esta seção revisa os principais métodos de monitoramento, com ênfase naqueles relevantes para os estudos de caso aqui apresentados e para o contexto mais amplo da engenharia mecânica moderna.

2.2.1 Inspeção Visual

A inspeção visual (IV) é, historicamente, o método mais fundamental e frequentemente a primeira linha de defesa na detecção de descontinuidades ou anomalias em componentes e produtos manufaturados (INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, 2016). Consiste no exame direto da superfície de um objeto por um inspetor qualificado, buscando identificar defeitos macroscópicos evidentes como trincas superficiais, corrosão, desgaste excessivo, deformações, ou, em processos de fabricação como a moldagem por injeção, falhas como rebarbas, marcas de fluxo, falhas de preenchimento e problemas de acabamento. Normas técnicas, como a ISO 17637, embora originalmente focada em soldas, estabelecem critérios gerais que podem ser adaptados para a inspeção visual de diversos componentes mecânicos, recomendando sua realização em diferentes etapas do ciclo de vida do produto ou processo.

Apesar de seu baixo custo e simplicidade de aplicação, a inspeção visual tradicional é inerentemente subjetiva, dependendo significativamente da acuidade visual, experiência, treinamento e até mesmo do estado de fadiga do inspetor. Além disso, sua eficácia é limitada a defeitos superficiais e visíveis a olho nu, não sendo capaz de detectar problemas internos ou microestruturais.

Nos últimos anos, avanços tecnológicos têm buscado superar essas limitações. Sistemas de visão computacional, equipados com câmeras digitais de alta resolução, iluminação controlada e algoritmos de processamento de imagem, permitem uma inspeção automatizada e mais objetiva (RODRÍGUEZ-GONZÁLEZ et al., 2017). Estes sistemas podem ser programados para identificar padrões específicos associados a defeitos, realizar medições dimensionais precisas e classificar produtos de forma consistente e em alta velocidade. Por exemplo, algoritmos de processamento de imagens 3D podem reconstruir o perfil de componentes para avaliar a qualidade geométrica (CHU; WANG, 2016). Pesquisas recentes têm explorado o uso de redes neurais convolucionais (CNNs) para segmentação semântica e identificação automática de regiões defeituosas, indicando que a inspeção visual automatizada, reforçada por inteligência artificial, pode superar a subjetividade e as limitações da inspeção humana tradicional, oferecendo maior repetibilidade e confiabilidade (XU et al., 2022; SOARES et al., 2023). Contudo, mesmo com a automação, a IV permanece mais adequada para defeitos superficiais; imperfeições internas ou em estágios incipientes de degradação exigem métodos complementares.

2.2.2 Sensores de Processo (Temperatura, Pressão, Vazão, Corrente, etc.)

Em inúmeros processos industriais e sistemas mecânicos, o monitoramento em tempo real de parâmetros operacionais chave é fundamental tanto para o controle do processo quanto para a detecção de anomalias. Sensores dedicados são empregados para medir grandezas como temperatura (do fluido, do molde, do ambiente), pressão (hidráulica, pneumática, de injeção), vazão (de fluidos, de material), corrente elétrica e tensão de motores, velocidade, força, torque e tempos de ciclo.

Estes parâmetros fornecem uma "assinatura" do estado normal de operação. Desvios significativos desses parâmetros em relação aos seus valores de referência, ou o surgimento de padrões anormais em suas séries temporais, podem ser indicativos de problemas no processo, desgaste de componentes da máquina, ou variações na matéria-prima. No contexto da moldagem por injeção plástica, por exemplo, o controle preciso da temperatura do polímero e do molde, da pressão e velocidade de injeção, do tempo de recalque e da pressão na cavidade são determinantes para a qualidade final da peça moldada. Flutuações ou desvios nesses parâmetros podem levar diretamente a defeitos como falhas de preenchimento, rebarbas, empenamento ou variações dimensionais (LOPES; SOUSA; ALENYà, 2021). Similarmente, no monitoramento de máquinas rotativas, a corrente consumida por um motor elétrico pode indicar variações de carga que, por sua vez, podem estar relacionadas ao estado de degradação de um rolamento ou engrenagem acoplada.

A integração desses dados de sensores de processo em sistemas de monitoramento e aquisição de dados (SCADA ou sistemas dedicados) permite não apenas o controle em malha fechada, mas também a criação de bases de dados históricas que podem ser utilizadas para treinar modelos de aprendizado de máquina para detecção de falhas ou otimização de processo. A análise de tendências e a correlação entre múltiplos parâmetros de processo podem revelar interações complexas e insights sobre a saúde do sistema que não seriam evidentes a partir do monitoramento de um único sensor.

2.2.3 Análise de Vibração

A análise de vibração é, indiscutivelmente, uma das técnicas mais poderosas e difundidas para o monitoramento de condição e diagnóstico de falhas em máquinas rotativas, incluindo motores elétricos, bombas, compressores, turbinas e, de forma proeminente, rolamentos (HUANG; FARAHAT; GUPTA, 2020). Praticamente todas as máquinas em operação geram vibrações como parte de seu funcionamento normal. No entanto, quando um componente começa a se degradar ou uma falha se desenvolve (como um desgaste em uma pista de rolamento, um desbalanceamento em um rotor, ou um dente de engrenagem quebrado), a natureza dessas vibrações se altera, gerando padrões característicos que podem ser detectados e analisados.


Acelerômetros, fixados em pontos estratégicos da carcaça da máquina (geralmente próximos aos mancais de rolamento), convertem as vibrações mecânicas em sinais elétricos.

Estes sinais, tipicamente complexos e ruidosos, são então processados para extrair características (features) que quantificam a severidade da vibração e indicam a presença e o tipo de falha. A extração de features pode ser realizada em diferentes domínios:

- **Domínio do Tempo:** Consiste na análise direta da forma de onda do sinal de vibração. Features estatísticas comumente extraídas incluem o valor RMS (Root Mean Square), que reflete a energia total da vibração; valor de pico e fator de crista (relação pico/RMS), sensíveis a impactos; curtose (kurtosis), que mede o "achatamento" da distribuição do sinal e é particularmente sensível a defeitos incipientes em rolamentos que geram impulsos; e assimetria (skewness), que indica a simetria da distribuição do sinal.
- **Domínio da Frequência:** A análise espectral, obtida através da Transformada Rápida de Fourier (FFT), decompõe o sinal de vibração em suas componentes de frequência. O espectro de frequência revela as amplitudes das vibrações em diferentes frequências, permitindo identificar frequências específicas associadas a determinados tipos de falha. Por exemplo, rolamentos defeituosos geram vibrações em frequências características de falha de pista interna (BPFI), pista externa (BPFO), elementos rolantes (BSF) e gaiola (FTF), que podem ser calculadas com base na geometria do rolamento e na velocidade de rotação.
- **Domínio Tempo-Frequência:** Para sinais não estacionários, onde as características de frequência mudam ao longo do tempo (comum durante o desenvolvimento de uma falha), técnicas como a Transformada de Fourier de Curto Tempo (STFT), a Transformada Wavelet e o espectrograma são utilizadas. Elas fornecem uma representação tridimensional da energia do sinal em função do tempo e da frequência, permitindo rastrear a evolução das componentes de falha.

A Figura 1 ilustra um conceito fundamental na análise de vibrações para prognóstico, conforme proposto por Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020). A imagem exibe os espectros de frequência médios (ou templates) para um rolamento em condição saudável e para um em condição de falha. A distinção visual clara entre os espectros permite o desenvolvimento de features baseadas em similaridade, que quantificam o quão próximo o espectro de um novo sinal de vibração está de cada um desses templates, indicando assim a evolução da degradação.

Figura 1: Exemplos de espectros de frequência representativos para rolamentos. Os espectros (a) e (b) são de um rolamento em condição saudável, enquanto os espectros (c) e (d) correspondem a um rolamento em condição de falha. Esses espectros são usados como "templates" para o cálculo de features de similaridade.



Fonte: Huang, Farahat e Gupta (2020).

No estudo de caso de prognóstico de rolamentos abordado neste trabalho, um conjunto de 16 features estatísticas do domínio do tempo foi extraído dos sinais de vibração dos sensores horizontal e vertical. Adicionalmente, 8 features de similaridade, baseadas na comparação entre o espectro de frequência de novas medições e templates de espectros de condições normais e de falha, foram calculadas, seguindo a abordagem de Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020). A combinação dessas features visa capturar de forma mais robusta a transição da condição saudável para a falha.

2.2.4 Outros Sensores Relevantes (Termografia, Emissão Acústica)

Além da análise de vibração e dos sensores de processo, outras tecnologias de sensoriamento desempenham papéis importantes no monitoramento de condição:

- **Termografia Infravermelha:** Utiliza câmeras infravermelhas para capturar o mapa de temperaturas na superfície de um equipamento. Anomalias térmicas, como pontos quentes, podem indicar atrito excessivo em componentes mecânicos (ex: rolamentos superaquecidos), problemas em conexões elétricas, falhas de isolamento térmico ou obstruções em sistemas de refrigeração (MALDAGUE, 2001). Pode ser aplicada de forma passiva (monitorando a temperatura durante a operação normal) ou ativa (monitorando a resposta térmica após uma excitação controlada).
- **Emissão Acústica (EA):** Sensores de EA detectam ondas de tensão elástica de alta frequência (tipicamente na faixa de kHz a MHz) geradas pela liberação rápida de

energia dentro de um material, como o crescimento de trincas, deformação plástica, atrito ou vazamentos. A EA é particularmente útil para a detecção precoce de defeitos ativos e para o monitoramento de estruturas sob carga.

- **Análise de Óleo Lubrificante:** Em máquinas com sistemas de lubrificação, a análise periódica do óleo pode revelar muito sobre a condição dos componentes internos. A presença de partículas de desgaste (identificadas por espectrometria ou ferrografia), a contaminação por água ou outros fluidos, e a degradação das propriedades do lubrificante (viscosidade, acidez) são indicadores de problemas.

2.2.5 Métodos Não Destrutivos (NDT)

Técnicas de Ensaio Não Destrutivo (END ou NDT, do inglês *Non-Destructive Testing*) são um conjunto de métodos de inspeção utilizados para avaliar a integridade e as propriedades de materiais, componentes ou sistemas sem causar dano à peça inspecionada. São amplamente aplicados tanto no controle de qualidade durante a fabricação quanto na inspeção em serviço para detecção de degradação ou defeitos. Dentre os principais métodos, destacam-se:

- **Ultrassom (UT):** Utiliza ondas sonoras de alta frequência que são introduzidas no material. Reflexões dessas ondas (ecos) ocorrem em interfaces, como a superfície oposta da peça ou descontinuidades internas (trincas, vazios, inclusões). Analisando o tempo de propagação e a amplitude dos ecos, é possível localizar e dimensionar defeitos. Técnicas avançadas como o Phased Array UT (PAUT) permitem escanear volumes complexos com maior precisão e gerar imagens seccionais do interior da peça (LOPEZ et al., 2018).
- **Radiografia Industrial (RT):** Utiliza radiação ionizante (raios X ou raios gama) que atravessa a peça e é registrada em um filme radiográfico ou detector digital. Variações na densidade ou espessura do material, ou a presença de descontinuidades internas, resultam em diferentes graus de atenuação da radiação, criando uma imagem de sombra que revela esses defeitos (LOPEZ et al., 2018; CHIFFRE et al., 2014). A Tomografia Computadorizada (CT) industrial é uma forma avançada de RT que permite a reconstrução de imagens tridimensionais do interior do objeto.
- **Partículas Magnéticas (MT):** Aplicável apenas a materiais ferromagnéticos. A peça é magnetizada e, se houver descontinuidades superficiais ou subsuperficiais, estas causam uma fuga do campo magnético. Partículas ferromagnéticas finas (secas ou em suspensão líquida) são aplicadas à superfície e se acumulam nas regiões de fuga de campo, tornando os defeitos visíveis.
- **Líquidos Penetrantes (PT):** Utilizado para detectar descontinuidades abertas à superfície em materiais não porosos. Um líquido colorido ou fluorescente de baixa

tensão superficial é aplicado à superfície e penetra nas aberturas por capilaridade. Após a remoção do excesso de penetrante da superfície, um revelador é aplicado, que extrai o penetrante retido nas discontinuidades, tornando-as visíveis.

Cada método NDT tem suas próprias vantagens, limitações e campos de aplicação. Frequentemente, uma combinação de técnicas é empregada para uma avaliação completa. A tendência recente é a digitalização da aquisição e interpretação dos dados de NDT, muitas vezes com o auxílio de IA para classificação de indicações e redução da subjetividade (TESSEMA; BISMOR, 2024).

2.2.6 Monitoramento por Sinais Elétricos

Durante a operação de equipamentos acionados eletricamente, como motores, os sinais elétricos (corrente, tensão, potência, fator de potência) carregam informações valiosas sobre a condição não apenas do motor em si, mas também da carga mecânica que ele aciona (ARABACI; LAVING, 2019). A Análise da Assinatura da Corrente do Motor (MCSA - Motor Current Signature Analysis) é uma técnica bem estabelecida que analisa o espectro de frequência da corrente do estator para detectar anomalias. Falhas como barras de rotor quebradas, excentricidade do entreferro, problemas em rolamentos do motor ou mesmo anomalias na carga acoplada (desbalanceamento, desalinhamento, falhas em engrenagens) podem modular a corrente do motor, introduzindo componentes de frequência específicos no espectro.

A vantagem do monitoramento por sinais elétricos é que ele é frequentemente não intrusivo (os sensores de corrente e tensão podem ser instalados no painel de controle do motor) e pode fornecer uma visão integrada da saúde do sistema motor-carga. Além da MCSA, a análise de outras grandezas elétricas, como a potência instantânea ou a tensão do barramento CC em inversores de frequência, também pode fornecer indicadores de diagnóstico e prognóstico. Pesquisas recentes têm aplicado técnicas de aprendizado de máquina aos dados de sinais elétricos para automatizar a detecção e classificação de falhas.

2.2.7 Sensores Ópticos e Visão Computacional

O monitoramento baseado em sensores ópticos e visão computacional tem ganhado proeminência em diversas aplicações industriais, indo além da simples inspeção visual mencionada anteriormente. Esta categoria engloba desde fotodiodos simples para medir a intensidade luminosa ou detectar a presença/ausência de objetos, até sistemas sofisticados de câmeras acopladas a algoritmos de processamento de imagem e inteligência artificial. No contexto do monitoramento de processos e condição, sistemas de visão podem ser empregados para:

- **Inspeção de Qualidade Automatizada:** Como já discutido, para detectar defeitos superficiais, verificar dimensões, cores, e acabamento de produtos em linhas de produção (CHU; WANG, 2016; SOARES et al., 2023).

- **Metrologia sem Contato:** Medição precisa de dimensões, perfis e formas de componentes utilizando técnicas como triangulação a laser, luz estruturada ou fotogrametria.
- **Guiagem de Robôs e Posicionamento:** Câmeras fornecem feedback visual para robôs realizarem tarefas complexas como montagem, soldagem (seguimento de junta) ou manipulação de objetos com precisão.
- **Monitoramento de Processo em Tempo Real:** Câmeras de alta velocidade podem ser usadas para observar fenômenos dinâmicos, como a formação de um cordão de solda, o fluxo de material em um processo de injeção, ou o padrão de spray em um bico injetor. Algoritmos podem analisar essas imagens para detectar anomalias ou controlar o processo. Por exemplo, é possível monitorar o tamanho e forma da poça de fusão em soldagem, onde desvios podem prenunciar defeitos (TESSEMA; BISMOR, 2024).
- **Análise de Textura e Superfície:** Técnicas de análise de textura podem revelar desgaste, corrosão ou outras alterações na superfície de componentes que não seriam facilmente quantificáveis por inspeção visual humana.

Os desafios na aplicação de visão computacional em ambientes industriais incluem iluminação variável, oclusões, reflexos, e a necessidade de algoritmos robustos para interpretar cenas complexas. A integração com aprendizado profundo tem sido fundamental para superar muitos desses desafios, permitindo, por exemplo, a detecção automática de defeitos com acurácia elevada, muitas vezes superando a capacidade humana em termos de velocidade e consistência (PALMA-RAMÍREZ et al., 2024). A fusão de dados ópticos com informações de outros sensores (elétricos, acústicos, de vibração) em abordagens multimodais é uma área de pesquisa ativa, visando fornecer um quadro mais completo e confiável do estado do sistema ou processo.

2.3 Técnicas de Inteligência Artificial para Diagnóstico e Prognóstico

A Inteligência Artificial (IA) emergiu como uma força transformadora em diversas áreas da engenharia, e a engenharia mecânica não é exceção. Particularmente, os subcampos do Aprendizado de Máquina (AM) e do Aprendizado Profundo (AP) têm fornecido um arsenal de técnicas capazes de extrair conhecimento valioso de grandes volumes de dados gerados por sensores e processos industriais. Essas técnicas são fundamentais para o desenvolvimento de sistemas avançados de diagnóstico de falhas e prognóstico da saúde de componentes e sistemas mecânicos, superando muitas das limitações dos métodos tradicionais baseados em modelos físicos ou regras heurísticas. Esta seção explora os conceitos fundamentais do AM e AP, detalha os algoritmos clássicos e as arquiteturas de redes neurais profundas mais relevantes, discute suas aplicações práticas na engenharia mecânica e analisa as vantagens e desafios inerentes à sua utilização.

2.3.1 Conceitos de Aprendizado de Máquina

O Aprendizado de Máquina, conforme definido por (SAMUEL, 1959) e subsequentemente refinado, é um campo de estudo que confere aos computadores a habilidade de aprender sem serem explicitamente programados para uma tarefa específica. Em vez de seguir instruções codificadas passo a passo, os algoritmos de AM são "treinados" usando dados, permitindo que identifiquem padrões, façam previsões ou tomem decisões. As principais paradigmas de aprendizado de máquina incluem:

- **Aprendizado Supervisionado:** Nesta abordagem, o algoritmo é alimentado com um conjunto de dados de treinamento onde cada exemplo de entrada (vetor de características ou *features*) é acompanhado por um rótulo de saída correto. O objetivo do algoritmo é aprender uma função de mapeamento $f : X \rightarrow Y$ que possa generalizar a partir dos dados de treinamento para prever corretamente os rótulos de novos dados de entrada (instâncias não vistas). O aprendizado supervisionado é comumente dividido em duas categorias de tarefas:
 - **Classificação:** A variável de saída (rótulo) é categórica, representando a qual classe uma determinada instância pertence. Exemplos incluem a identificação de tipos de defeitos (como "OK", "NOK Rebarba", "NOK Preenchimento" no estudo de caso de injeção plástica), detecção de spam em e-mails, ou reconhecimento de imagens.
 - **Regressão:** A variável de saída é um valor numérico contínuo. Exemplos incluem a previsão do preço de um imóvel, a estimativa da temperatura futura, ou, como no estudo de caso de rolamentos, a previsão de um Indicador de Saúde (HI) ou da Vida Útil Restante (RUL) de um componente.
- **Aprendizado Não Supervisionado:** Em contraste com o aprendizado supervisionado, os algoritmos de aprendizado não supervisionado operam sobre dados de entrada que não possuem rótulos de saída pré-definidos. O objetivo é descobrir estruturas, padrões ou relações ocultas nos próprios dados. As tarefas mais comuns incluem:
 - **Clusterização (Agrupamento):** Agrupar instâncias de dados semelhantes em clusters, de modo que instâncias no mesmo cluster sejam mais parecidas entre si do que com aquelas em outros clusters.
 - **Redução de Dimensionalidade:** Reduzir o número de variáveis (features) de entrada, preservando a informação mais relevante. Técnicas como a Análise de Componentes Principais (PCA) são amplamente utilizadas.
 - **Detecção de Anomalias (Outliers):** Identificar instâncias que são significativamente diferentes da maioria dos dados, o que pode indicar falhas, fraudes ou eventos raros.

- **Aprendizado por Reforço:** Neste paradigma, um agente de aprendizado interage com um ambiente dinâmico e aprende a tomar uma sequência de ações para maximizar uma noção de recompensa cumulativa. O agente recebe feedback na forma de recompensas ou punições por suas ações, ajustando sua política de decisão ao longo do tempo. É frequentemente aplicado em robótica, jogos e sistemas de controle autônomo.

Os estudos de caso apresentados neste trabalho focam predominantemente em técnicas de aprendizado supervisionado (classificação para injeção plástica e regressão para o prognóstico de rolamentos).

2.3.2 Algoritmos Clássicos de Aprendizado de Máquina

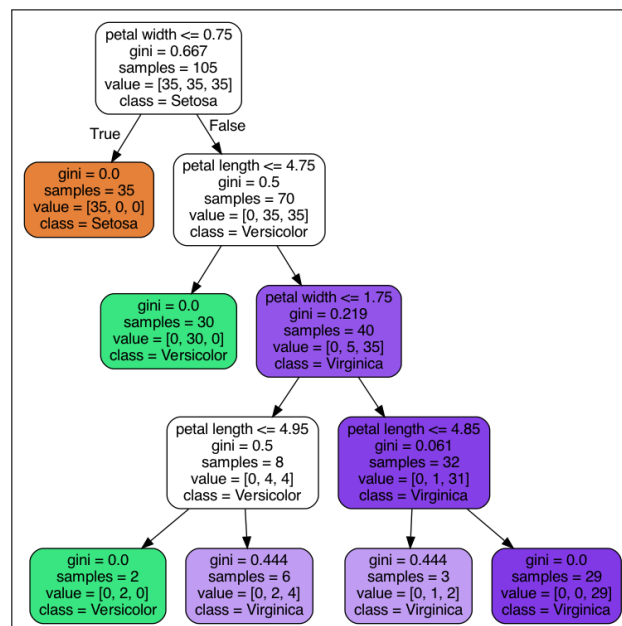
Antes do advento e popularização do aprendizado profundo, uma vasta gama de algoritmos de aprendizado de máquina "clássicos" já demonstrava eficácia em diversas tarefas de diagnóstico e prognóstico. Muitos desses algoritmos continuam sendo altamente relevantes, especialmente quando os conjuntos de dados são de tamanho moderado, a interpretabilidade é crucial, ou os recursos computacionais são limitados. Alguns dos algoritmos mais proeminentes incluem:

- **Regressão Logística:** Apesar do nome, é um algoritmo de classificação linear. Modela a probabilidade de uma instância pertencer a uma determinada classe usando uma função logística (sigmoide para classificação binária) ou uma função softmax (para classificação multiclasse, como no caso da Regressão Logística Multinomial utilizada no estudo de injeção plástica). Seus coeficientes podem oferecer alguma interpretabilidade sobre a influência das features (FÁVERO; BELFIORE, 2017).
- **Árvores de Decisão:** São modelos não paramétricos que aprendem uma série de regras de decisão hierárquicas, representadas na forma de uma árvore. Cada nó interno da árvore corresponde a um teste em uma feature, cada ramo representa o resultado do teste, e cada nó folha representa um rótulo de classe (classificação) ou um valor numérico (regressão). Algoritmos como ID3, C4.5 e CART são usados para construir árvores de decisão. Sua principal vantagem é a alta interpretabilidade, pois as regras de decisão são explícitas (ROKACH; MAIMON, 2014).
- **Random Forest:** É um método de aprendizado de conjunto (*ensemble learning*) que opera construindo uma infinidade de árvores de decisão no momento do treinamento e gerando a classe que é o modo das classes (classificação) ou a predição média (regressão) das árvores individuais. Cada árvore é treinada em uma subamostra aleatória dos dados (bagging) e, em cada divisão, considera apenas um subconjunto aleatório das features. Isso ajuda a reduzir a variância e o overfitting, geralmente levando a um desempenho superior em relação a uma única árvore de decisão (BREIMAN, 2001).

- **Support Vector Machines (SVM):** São classificadores lineares (ou não lineares, através do "truque do kernel") que buscam encontrar o hiperplano que melhor separa as instâncias de diferentes classes no espaço de features, maximizando a margem entre as classes. SVMs são eficazes em espaços de alta dimensionalidade e podem lidar com relações complexas, mas podem ser computacionalmente intensivas para grandes datasets e sua interpretabilidade direta é limitada.
- **Modelos baseados em Gradient Boosting (XGBoost, LightGBM, CatBoost):** São algoritmos de ensemble poderosos que constroem modelos (tipicamente árvores de decisão) de forma aditiva e sequencial. Cada novo modelo é treinado para corrigir os erros residuais dos modelos anteriores, utilizando uma abordagem de otimização baseada em gradiente. Esses algoritmos são conhecidos por seu alto desempenho preditivo em uma ampla variedade de tarefas e são frequentemente vencedores em competições de aprendizado de máquina (CHEN; GUESTRIN, 2016).
- **K-Nearest Neighbors (KNN):** Um algoritmo simples e não paramétrico que classifica uma nova instância com base na classe majoritária de seus 'k' vizinhos mais próximos no espaço de features. A escolha de 'k' e da métrica de distância é crucial.

A seleção do algoritmo apropriado depende da natureza do problema, do tamanho e características do dataset, dos requisitos de interpretabilidade e dos recursos computacionais disponíveis.

Figura 2: Exemplo ilustrativo de uma Árvore de Decisão treinada no dataset Iris para classificação das espécies de flores (Setosa, Versicolor, Virginica) com base nas características das pétalas (petal width, petal length). Cada nó mostra o critério de divisão, o índice Gini, o número de amostras e a distribuição das classes.




Fonte: Amit (2024).

2.3.3 Conceitos e Arquiteturas de Aprendizado Profundo

O Aprendizado Profundo (AP) representa uma evolução significativa no campo do Aprendizado de Máquina, caracterizado pelo uso de Redes Neurais Artificiais (RNAs) com múltiplas camadas ocultas (daí o termo "profundo"). Essas arquiteturas profundas permitem que o modelo aprenda representações hierárquicas dos dados, onde camadas iniciais aprendem features de baixo nível (ex: bordas em uma imagem, tendências em um sinal) e camadas subsequentes combinam essas features para formar conceitos mais abstratos e complexos, relevantes para a tarefa em questão (LECUN; BENGIO; HINTON, 2015). Uma vantagem chave do AP é sua capacidade de realizar a extração de features de forma automática e implícita a partir de dados brutos, reduzindo a necessidade de engenharia manual de features, que é muitas vezes demorada e requer conhecimento especializado do domínio.

A Figura 3 ilustra esquematicamente três das principais arquiteturas de aprendizado profundo discutidas nesta seção: o **Perceptron Multicamadas** (*Multi-Layer Perceptron* - MLP), a **Rede Neural Convolucional** (*Convolutional Neural Network* - CNN) e a **Rede Neural Recorrente** (*Recurrent Neural Network* - RNN), com destaque para a célula de **Memória de Longo e Curto Prazo** (*Long Short-Term Memory* - LSTM).

Figura 3: Exemplos esquemáticos de arquiteturas de Aprendizado Profundo: (a) MLP, (b) CNN e (c) RNN/LSTM.



Fonte: Adaptado de Sobreiro et al. (2008) (a), Feltran (2020) (b) e Carvalho et al. (2012) (c).

As principais arquiteturas de aprendizado profundo relevantes para diagnóstico e prognóstico em engenharia mecânica incluem:

- **Redes Neurais Artificiais (RNA) / Multi-Layer Perceptron (MLP):** Conforme ilustrado na Figura 3a, são a forma mais fundamental de rede neural profunda. Consistem em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, com neurônios em camadas adjacentes totalmente conectados. Cada conexão possui um peso, e cada neurônio aplica uma função de ativação não linear (ex:

Sigmoid, Tanh, ReLU) à sua entrada ponderada. O treinamento ocorre tipicamente através do algoritmo de retropropagação (*backpropagation*), que ajusta os pesos para minimizar uma função de perda. MLPs são modelos universais de aproximação de funções e podem ser usados para tarefas de classificação e regressão, como no estudo de caso de injeção plástica (DIAO et al., 2021).

- **Redes Neurais Convolucionais (CNNs):** A Figura 3b apresenta um esquema típico de uma CNN. Originalmente desenvolvidas para processamento de imagens, as CNNs são extremamente eficazes na extração de features espaciais hierárquicas. Sua arquitetura é inspirada no córtex visual humano e utiliza camadas especializadas, como camadas convolucionais (que aplicam filtros para detectar padrões locais), camadas de pooling (que reduzem a dimensionalidade espacial) e camadas totalmente conectadas (geralmente no final da rede para classificação ou regressão). As CNNs demonstraram grande sucesso na detecção de defeitos em imagens radiográficas de soldas ou em imagens de superfícies de peças (PALMA-RAMÍREZ et al., 2024). Além disso, CNNs unidimensionais (1D-CNNs) podem ser aplicadas diretamente a sinais de séries temporais (como vibração ou sinais elétricos) para aprender features relevantes para diagnóstico ou prognóstico, capturando padrões temporais locais.
- **Redes Neurais Recorrentes (RNNs):** São arquiteturas projetadas especificamente para lidar com dados sequenciais, onde a ordem das informações é importante, como séries temporais, linguagem natural ou sequências de eventos, conforme esquematizado na Figura 3c. As RNNs possuem conexões de realimentação (*recurrent connections*) que permitem que a saída de um passo de tempo seja usada como entrada para o próximo passo, conferindo à rede uma forma de "memória" do estado passado. No entanto, RNNs simples sofrem com o problema do desaparecimento ou explosão do gradiente durante o treinamento com sequências longas.
 - **Long Short-Term Memory (LSTM) e Gated Recurrent Unit (GRU):** São variantes sofisticadas de RNNs desenvolvidas para superar as limitações das RNNs simples. As LSTMs e GRUs utilizam unidades de memória complexas com mecanismos de "portões" (gates) – como portão de entrada, portão de esquecimento e portão de saída nas LSTMs – que controlam seletivamente o fluxo de informação, permitindo que a rede aprenda e retenha dependências de longo prazo nos dados sequenciais. Essas arquiteturas são amplamente empregadas em tarefas de prognóstico de RUL, como no estudo de caso de rolamentos deste trabalho, devido à sua capacidade de modelar a evolução temporal da degradação de componentes (HUANG; FARAHAT; GUPTA, 2020; HOCHREITER; SCHMIDHUBER, 1997).

- **Autoencoders (AE):** São um tipo de RNA não supervisionada (ou auto-supervisionada) treinada para reconstruir sua própria entrada. Um autoencoder consiste em duas partes: um codificador (*encoder*), que mapeia a entrada para uma representação latente de menor dimensionalidade, e um decodificador (*decoder*), que tenta reconstruir a entrada original a partir dessa representação latente. São utilizados para redução de dimensionalidade, extração de features, remoção de ruído e detecção de anomalias (instâncias que são mal reconstruídas são consideradas anômalas).
- **Transformers:** Originalmente propostas para tradução automática, as arquiteturas Transformer baseadas em mecanismos de auto-atenção (*self-attention*), revolucionaram o processamento de linguagem natural e estão começando a ser exploradas para séries temporais. Elas permitem modelar dependências entre todos os pontos de uma sequência simultaneamente, superando algumas limitações das RNNs em capturar relações de muito longo alcance.

A escolha da arquitetura de aprendizado profundo depende intrinsecamente da natureza dos dados (imagens, séries temporais, dados tabulares) e da tarefa específica (classificação, regressão, prognóstico).

2.3.4 Aplicações Práticas em Engenharia Mecânica

As técnicas de Aprendizado de Máquina e Aprendizado Profundo têm sido aplicadas com sucesso a uma gama crescente de problemas na engenharia mecânica, impulsionando avanços no diagnóstico, prognóstico, controle de qualidade e otimização de processos.

- **Detecção e Diagnóstico de Falhas em Processos e Componentes:**
 - **Moldagem por Injeção Plástica:** Como demonstrado no primeiro estudo de caso deste trabalho, modelos de AM podem ser treinados para prever a qualidade das peças injetadas com base nos parâmetros de processo da máquina (ex: tempo de ciclo, pressão de injeção, temperatura do molde). Isso permite a identificação proativa de ciclos que podem resultar em defeitos como rebarbas, falhas de preenchimento ou empenamento, auxiliando na otimização do processo e na redução de refugo (LOPES; SOUSA; ALENYà, 2021; OGORODNYK et al., 2019).
 - **Soldagem:** CNNs são usadas para analisar imagens radiográficas de soldas ou frames de vídeo do processo para identificar automaticamente descontinuidades como trincas, poros ou falta de fusão (PALMA-RAMÍREZ et al., 2024). Sinais elétricos do arco também são analisados para detectar instabilidades (ARABACI; LAVING, 2019).
 - **Usinagem:** Modelos preditivos são desenvolvidos para monitorar o desgaste de ferramentas de corte com base em sinais de força, vibração ou emissão acústica,

permitindo a substituição otimizada da ferramenta.

- **Prognóstico de Vida Útil Remanescente (RUL) de Componentes:**

- **Rolamentos:** Este é um dos campos mais ativos de pesquisa em PHM. Modelos, especialmente baseados em LSTMs e CNNs, são treinados com dados de vibração, temperatura ou outros sensores de rolamentos operando até a falha para prever um Indicador de Saúde (HI) e, subsequentemente, estimar a RUL (HUANG; FARAHAT; GUPTA, 2020; JIN et al., 2020; NECTOUX et al., 2012). Abordagens inovadoras, como o uso de features de similaridade explorado no segundo estudo de caso deste trabalho, buscam melhorar a representação da degradação.
- **Outros Componentes Críticos:** Engrenagens, turbinas a gás, baterias de íon-lítio, bombas e motores também são alvos de desenvolvimento de modelos de prognóstico de RUL, visando otimizar a manutenção e evitar falhas catastróficas.

- **Otimização de Parâmetros de Processo e Controle Adaptativo:** Modelos preditivos que mapeiam parâmetros de entrada para indicadores de qualidade ou desempenho podem ser integrados a algoritmos de otimização (ex: algoritmos genéticos, otimização bayesiana) para encontrar os setpoints ótimos de operação. Além disso, modelos de IA podem ser usados em sistemas de controle adaptativo em tempo real, ajustando dinamicamente os parâmetros do processo para manter a qualidade ou compensar distúrbios (TESSEMA; BISMOR, 2024; YAMANE; MATSUO, 2019).
- **Manufatura Aditiva (Impressão 3D):** Modelos de AM são usados para monitorar a qualidade da deposição de material em tempo real, detectar defeitos durante a impressão e otimizar os parâmetros de impressão para diferentes materiais e geometrias.

A crescente disponibilidade de dados de sensores e o avanço contínuo dos algoritmos de IA prometem expandir ainda mais o escopo dessas aplicações, levando a sistemas de engenharia mais inteligentes, eficientes e confiáveis.

2.3.5 Vantagens e Desafios do Uso de IA em PHM e Engenharia Mecânica

A incorporação de técnicas de Inteligência Artificial no diagnóstico, prognóstico e controle de processos na engenharia mecânica oferece vantagens significativas, mas também apresenta desafios consideráveis que precisam ser abordados para uma implementação bem-sucedida.

Vantagens


- **Capacidade de Lidar com Complexidade e Não-Linearidade:** Processos e sistemas mecânicos são frequentemente caracterizados por interações complexas e dinâmicas não-lineares. Modelos de IA, especialmente redes neurais profundas, são capazes de aprender essas relações complexas a partir dos dados, muitas vezes superando as capacidades dos modelos analíticos tradicionais (LECUN; BENGIO; HINTON, 2015; ZHAO et al., 2019).
- **Automação da Extração de Features (com AP):** Arquiteturas de aprendizado profundo podem aprender representações úteis diretamente de dados brutos ou minimamente processados, reduzindo a necessidade de engenharia manual de features, que pode ser demorada e exigir profundo conhecimento do domínio (JIA et al., 2016).
- **Adaptação e Generalização (Potencial):** Modelos bem treinados têm o potencial de se adaptar a diferentes tipos de dados, processos ou condições operacionais, e generalizar seu aprendizado para novas situações não vistas durante o treinamento (WEN et al., 2019).
- **Deteção Precoce de Falhas e Prognóstico Preciso:** A capacidade de identificar padrões sutis associados a estágios incipientes de degradação permite a detecção de falhas mais cedo do que seria possível com métodos tradicionais, viabilizando a manutenção preditiva e a redução de paradas não planejadas (LEI et al., 2020).
- **Melhoria Contínua:** Modelos de IA podem ser continuamente retreinados e aprimorados à medida que novos dados se tornam disponíveis, levando a um ciclo de melhoria do desempenho ao longo do tempo (SIAHPOUR; KIANFAR; MOMENI, 2021).

Desafios


- **Disponibilidade, Qualidade e Quantidade de Dados:** O desempenho dos modelos de IA é fortemente dependente dos dados utilizados para o treinamento. Em muitos cenários industriais, obter grandes volumes de dados de alta qualidade, representativos de todas as condições operacionais e, crucialmente, rotulados com informações de falha (especialmente dados de "run-to-failure" para prognóstico) é um desafio significativo. Dados ruidosos, incompletos ou desbalanceados podem comprometer seriamente o desempenho do modelo (ZHAO et al., 2019). Este foi um fator limitante chave no estudo de caso de rolamentos.
- **Interpretabilidade e Explicabilidade:** Muitos modelos avançados de IA, como redes neurais profundas, são frequentemente percebidos como "caixas-pretas", pois suas decisões não são facilmente interpretáveis por humanos. Em aplicações críticas

de engenharia, onde a segurança e a confiabilidade são primordiais, essa falta de transparência pode ser uma barreira para a adoção (ARRIETA et al., 2020). A Figura 4 ilustra o contraste entre um modelo caixa-preta, onde o processo interno de decisão não é revelado, e um modelo caixa-transparente (ou caixa-cinza), que incorpora mecanismos de explicação para justificar suas saídas. O campo da **Inteligência Artificial Explicável** (XAI, do inglês *Explainable Artificial Intelligence*) emergiu para superar essa barreira, desenvolvendo técnicas post-hoc como LIME (RIBEIRO; SINGH; GUESTRIN, 2016) e SHAP (LUNDBERG; LEE, 2017). LIME fornece explicações locais treinando um modelo interpretável simples no entorno de uma predição específica, enquanto SHAP, baseado na teoria dos jogos, atribui a contribuição de cada feature para a predição. Na engenharia, a aplicação de Inteligência Artificial Explicável é fundamental para validar o conhecimento e descobrir novos insights. Por exemplo, Grezma et al. (2021) aplicaram SHAP para interpretar um modelo de previsão de defeitos em manufatura aditiva, identificando os parâmetros de processo mais críticos (GREZMAK; EVERSON; JOHNSON, 2021). Este esforço crescente busca transformar modelos de IA de "oráculos" opacos em parceiros colaborativos e transparentes no processo de tomada de decisão em engenharia (HASSIJA et al., 2023).

Figura 4: Comparação esquemática entre um modelo de IA do tipo Caixa-Preta e um modelo com capacidade de Explicação (XAI).



(a) Modelo Caixa-Preta (Black-Box), onde o processo interno de decisão não é diretamente observável.



(b) Modelo Caixa-Transparente ou Caixa-Cinza, com mecanismos de XAI que fornecem uma justificativa para a predição.

Fonte: Elaboração própria.

- **Generalização para Condições Não Vistas:** Garantir que um modelo treinado em um conjunto específico de dados e condições operacionais generalize bem para novas máquinas, diferentes regimes de operação ou tipos de falha não encontrados no treinamento é um desafio constante. O overfitting, onde o modelo aprende muito bem os dados de treinamento mas falha em generalizar, é uma preocupação comum (WEN et al., 2019).
- **Custo Computacional e de Implementação:** O treinamento de modelos complexos de aprendizado profundo pode exigir recursos computacionais significativos (GPUs, TPUs) e tempo considerável. A implementação desses modelos em sistemas embarcados ou em tempo real no chão de fábrica também pode apresentar desafios de infraestrutura e integração (VOEGELE; PALM; WEBER, 2022).
- **Expertise e Conhecimento do Domínio:** Embora a IA possa automatizar partes do processo, a colaboração entre especialistas em ciência de dados e engenheiros com profundo conhecimento do domínio é essencial para definir o problema corretamente, selecionar features relevantes, interpretar os resultados e validar os modelos (WILLARD et al., 2022).
- **Robustez e Segurança:** Em aplicações de segurança crítica, é fundamental garantir que os modelos de IA sejam robustos a entradas adversariais ou inesperadas e que suas falhas não levem a consequências catastróficas (ZHANG; LI; WANG, 2020).

Superar esses desafios requer uma abordagem multidisciplinar, combinando avanços em algoritmos de IA com boas práticas de engenharia de software, conhecimento do domínio e um entendimento claro das limitações e potenciais de cada técnica.


2.3.6 Governança e Confiabilidade de IA: A Norma ABNT NBR ISO/IEC 42001

À medida que a Inteligência Artificial se torna mais prevalente em aplicações críticas, a necessidade de uma governança robusta emerge como um desafio central. Em resposta a essa demanda, a Organização Internacional de Normalização (ISO) desenvolveu a norma ISO/IEC 42001:2023, recentemente adotada no Brasil como ABNT NBR ISO/IEC 42001:2024. Este é o primeiro padrão internacional para um Sistema de Gestão de Inteligência Artificial (SGIA). Seu objetivo é fornecer às organizações um framework para desenvolver, implementar e governar sistemas de IA de forma ética e responsável. A norma estabelece processos para a gestão de riscos, avaliação de impacto, transparência, responsabilidade e melhoria contínua, garantindo que as aplicações de IA, como as abordadas neste trabalho, possam ser integradas aos processos industriais com um nível adequado de controle e confiança (Associação Brasileira de Normas Técnicas, 2024). A ISO 42001, portanto, representa a ponte entre a validação técnica de um modelo de IA e sua implementação segura e governada no ambiente organizacional.

3 METODOLOGIA

Este capítulo apresenta de forma pormenorizada as abordagens metodológicas empregadas para conduzir os dois estudos de caso centrais deste trabalho: a predição de falhas no processo de injeção plástica e o prognóstico da vida útil remanescente de rolamentos. Embora cada estudo possua suas particularidades intrínsecas em termos de dados, modelos e objetivos específicos, ambos foram desenvolvidos seguindo um fluxo de trabalho sistemático, **conforme ilustrado na Figura 5**, comum em projetos de aplicação de Aprendizado de Máquina e Inteligência Artificial. Este fluxo engloba desde a definição clara do problema e a obtenção e preparação dos dados, passando pela seleção, desenvolvimento e otimização de modelos preditivos, até a avaliação rigorosa de seu desempenho e, crucialmente, a análise de sua interpretabilidade ou sensibilidade para validar o conhecimento adquirido. A seguir, será detalhada a abordagem geral e as ferramentas computacionais comuns a ambos os estudos, precedendo a descrição específica das metodologias aplicadas a cada caso.

Figura 5: Fluxograma geral ilustrando as etapas de um projeto de Aprendizado de Máquina aplicado ao PHM, dividido em preparação de dados e modelagem/avaliação.



Fonte: Elaboração própria.

3.1 Abordagem Geral e Ferramentas Computacionais

A aplicação de técnicas de Inteligência Artificial, especialmente o Aprendizado de Máquina (AM) e o Aprendizado Profundo (AP), para resolver problemas complexos na engenharia mecânica, como os abordados neste TCC, requer uma abordagem metodológica estruturada. O desenvolvimento dos modelos preditivos para os dois estudos de caso seguiu um conjunto de etapas iterativas e interconectadas, conforme ilustrado no fluxograma genérico da Figura 5.

As principais fases deste fluxo de trabalho, adaptadas para os contextos de diagnóstico e prognóstico, incluem:

1. **Definição do Problema e Objetivos:** Compreensão clara do problema de engenharia a ser resolvido (diagnóstico de qualidade na injeção plástica, prognóstico de RUL em rolamentos) e estabelecimento de objetivos mensuráveis para os modelos de IA.
2. **Aquisição e Compreensão dos Dados:** Coleta ou obtenção de conjuntos de dados relevantes, seguida de uma análise exploratória para entender suas características, distribuições, limitações e a relação física das variáveis com o fenômeno em estudo.
3. **Pré-processamento dos Dados:** Etapa crucial que envolve a limpeza dos dados (tratamento de valores ausentes, ruídos ou outliers), transformação de variáveis (ex: codificação de variáveis categóricas) e normalização ou escalonamento das features para garantir que os algoritmos de AM funcionem de maneira ótima.
4. **Engenharia e Extração/Seleção de Características (Features):** Identificação, criação ou seleção das variáveis de entrada (features) mais informativas para o modelo. Isso pode envolver conhecimento do domínio para criar features significativas (como as features de similaridade no estudo de rolamentos) ou técnicas automáticas de seleção.
5. **Divisão dos Dados:** Particionamento do conjunto de dados em subconjuntos de treinamento, validação e teste. O conjunto de treinamento é usado para ajustar os parâmetros do modelo; o de validação, para otimizar hiperparâmetros e evitar overfitting; e o de teste, para avaliar o desempenho final do modelo em dados não vistos.
6. **Seleção, Treinamento e Otimização de Modelos:** Escolha dos algoritmos de AM/AP mais adequados para a tarefa (classificação ou regressão), treinamento dos modelos com os dados de treinamento e ajuste fino de seus hiperparâmetros para maximizar o desempenho no conjunto de validação.

7. **Avaliação do Desempenho do Modelo:** Utilização de métricas apropriadas para quantificar a capacidade preditiva do modelo no conjunto de teste (ex: acurácia, F1-score para classificação; RMSE, MAE, score PHM para prognóstico).
8. **Análise de Explicabilidade e Interpretabilidade (XAI):** Aplicação de técnicas (ex: SHAP, análise de sensibilidade) para entender como o modelo toma suas decisões, quais features são mais importantes e se o conhecimento aprendido é fisicamente coerente. Esta etapa é fundamental para construir confiança e validar os modelos em aplicações de engenharia.

A escolha da Inteligência Artificial e do Aprendizado de Máquina como ferramentas centrais neste trabalho justifica-se pela sua capacidade comprovada de lidar com a alta dimensionalidade e a complexidade inerente aos dados de processos industriais e sistemas mecânicos. Muitos desses sistemas exibem comportamentos não-lineares e interações sutis entre variáveis que são difíceis de modelar com abordagens puramente analíticas ou baseadas em física de primeira ordem. Modelos de AM/AP, ao aprenderem diretamente dos dados, podem capturar esses padrões complexos e fornecer previsões robustas, desde que sejam alimentados com dados representativos e de qualidade.

Para a implementação computacional dos modelos e análises apresentadas, foi utilizada a linguagem de programação **Python (versão 3.x)**. O ecossistema Python oferece uma vasta gama de bibliotecas consolidadas e de código aberto para ciência de dados e aprendizado de máquina, que foram extensivamente empregadas:

- Para manipulação e análise de dados: **Pandas** (estruturas de dados e ferramentas de análise), **NumPy** (operações numéricas eficientes).
- Para aprendizado de máquina clássico e pré-processamento: **Scikit-learn** (implementação de diversos algoritmos de classificação, regressão, clusterização, ferramentas de divisão de dados, escalonamento, métricas de avaliação).
- Para aprendizado profundo (Redes Neurais): **TensorFlow** com a API de alto nível **Keras** (para construção e treinamento de RNAs, MLPs e LSTMs).
- Para visualização de dados e resultados: **Matplotlib** e **Seaborn** (geração de gráficos estáticos, interativos e informativos).
- Para análise de explicabilidade (XAI): A biblioteca **SHAP** (SHapley Additive exPlanations) foi utilizada para interpretar as previsões dos modelos de rede neural no estudo de caso de injeção plástica.
- Para otimização e ajuste de curvas: **SciPy** (especificamente a função ‘curve-fit’ para o ajuste exponencial no estudo de caso de rolamentos).

O desenvolvimento e a experimentação foram realizados predominantemente em ambientes interativos como Jupyter Notebooks e/ou Google Colaboratory, que facilitam a exploração de dados, o desenvolvimento iterativo de modelos e a visualização de resultados.

3.2 Estudo de Caso 1: Predição de Falhas no Processo de Injeção Plástica

Este primeiro estudo de caso concentra-se no desenvolvimento e análise de um modelo de Inteligência Artificial para a predição da qualidade de peças produzidas pelo processo de moldagem por injeção plástica. O objetivo principal é criar um sistema capaz de, com base nos parâmetros de máquina configurados antes do início de um ciclo de produção, antecipar a probabilidade de ocorrência de defeitos específicos, nomeadamente rebarbas (NOK Rebarba) ou falhas de preenchimento (NOK Preenchimento), em contraposição a uma peça conforme (OK). Tal predição proativa visa permitir intervenções e ajustes nos parâmetros do processo antes que peças defeituosas sejam produzidas, contribuindo para a redução de desperdícios e o aumento da eficiência produtiva. A interpretabilidade do modelo final também é um foco central, buscando entender quais parâmetros de processo são mais determinantes para a qualidade da peça.

3.2.1 Descrição Detalhada do Processo e Definição do Problema

O processo de moldagem por injeção é um método de fabricação de alto volume amplamente utilizado na indústria de transformação de termoplásticos. De forma sucinta, consiste na fusão do material polimérico, que é então injetado sob alta pressão em uma cavidade de molde fechada, onde se solidifica, adquirindo a forma da peça desejada. As principais fases do ciclo incluem plastificação, injeção, recalque, resfriamento e extração da peça (BRYCE, 1996). A qualidade da peça final é sensível a uma miríade de parâmetros de processo, como temperaturas, pressões, velocidades e tempos associados a cada fase.

Neste estudo, o problema é formulado como uma tarefa de classificação multiclasse, onde o modelo deve predizer uma das três seguintes categorias para cada ciclo de injeção:

- **OK:** Peça produzida em conformidade com os padrões de qualidade.
- **NOK (Rebarba):** Peça apresentando excesso de material nas linhas de partição do molde, geralmente resultante de força de fechamento inadequada, pressão de injeção excessiva ou desgaste no molde.
- **NOK - Falha de Preenchimento:** Peça incompleta devido ao material polimérico não ter preenchido totalmente a cavidade do molde, podendo ser causado por volume de injeção insuficiente, baixa temperatura do material ou do molde, ou obstruções nos canais de alimentação.

3.2.2 Definição de Requisitos de Risco via FMEA

Para além da tarefa de classificação, uma abordagem de engenharia exige, primeiramente, uma **avaliação de impacto** para compreender as consequências da implementação do sistema de IA. O impacto positivo principal da solução proposta é o aumento da eficiência produtiva e a redução de refugo. No entanto, os impactos negativos de predições incorretas precisam ser gerenciados proativamente.

Essa avaliação de impacto informa a **Análise de Modos e Efeitos de Falha (FMEA)** do sistema de IA, que foca nos riscos técnicos. Nesta análise, identificam-se dois modos de falha principais: um "Falso Negativo", onde o modelo prevê "OK" para uma peça que possui um defeito, e um "Falso Positivo", onde o modelo prevê um defeito para uma peça conforme.

A análise das consequências (detalhada na Seção 4.1.3) revela que o impacto de um Falso Negativo — especialmente para defeitos críticos como a Falha de Preenchimento ('NOK Preenchimento') — é significativamente mais severo, podendo levar à falha do produto final e custos de recall. Em contrapartida, o impacto de um Falso Positivo resulta em custos operacionais menores, como uma inspeção adicional ou o descarte de uma peça boa.

Portanto, um requisito fundamental para o desenvolvimento do modelo é a **minimização do risco associado aos Falsos Negativos**. Este requisito de engenharia, derivado da análise de risco, orienta diretamente a estratégia de otimização e a escolha das métricas de avaliação, que devem priorizar a maximização da Revocção (Recall) para as classes de defeito.

3.2.3 Coleta e Caracterização dos Dados

Os dados utilizados neste estudo foram provenientes do trabalho publicado por Silva, Sousa e Alenya (2021) (LOPES; SOUSA; ALENYÀ, 2021). O conjunto de dados foi coletado de um processo de moldagem por injeção estável, utilizando uma máquina injetora de 220 toneladas e material Polietileno Linear de Baixa Densidade (LLDPE). O dataset original é composto por 31.537 ciclos de injeção, dos quais 692 ciclos resultaram em peças não conformes, distribuídas em 300 ocorrências de "NOK Preenchimento" e 392 de "NOK Preenchimento".

As variáveis de entrada (features) selecionadas do processo, que representam os parâmetros da máquina injetora, foram:

- **TI:** Tempo de Injeção (s).
- **TP:** Tempo de Plastificação (s).
- **TC:** Tempo de Ciclo (s).
- **A:** Amortecimento/Almofada (mm).

- **PIM:** Pressão no Interior do Molde (bar).

Adicionalmente, foram realizadas etapas de engenharia de features para explorar potenciais interações e relações não-lineares, resultando nas seguintes features derivadas:

- Razão entre o Tempo de Injeção e o Tempo de Plastificação (denotada como `TI_TP` na implementação).
- Produto entre a Almofada e o Tempo de Ciclo (denotada como `A_TC` na implementação).
- Pressão no Interior do Molde elevada ao quadrado (denotada como `PIM_squared` na implementação).

A variável alvo para a classificação foi a condição de qualidade da peça, representando as três categorias mencionadas.

3.2.4 Pré-processamento dos Dados para Injeção Plástica

Antes do treinamento dos modelos, os dados passaram por uma série de etapas de pré-processamento para garantir sua adequação e otimizar o desempenho dos algoritmos de aprendizado:

1. **Codificação da Variável Alvo:** A variável categórica de qualidade da peça foi convertida em rótulos numéricos inteiros (0, 1, 2), com os nomes originais das classes preservados para interpretação posterior.
2. **Tratamento de Valores Anômalos na Engenharia de Features:** Após a criação das features derivadas, foi realizada uma verificação de valores inconsistentes (como infinitos ou não numéricos) que poderiam surgir de operações matemáticas. Tais valores foram substituídos por zero, como forma de imputação simples.
3. **Divisão dos Dados:** O conjunto de dados completo foi dividido em conjuntos de treinamento e teste, utilizando uma proporção de 70% para treinamento e 30% para teste. A divisão foi realizada de forma estratificada em relação à variável alvo, garantindo que a proporção das classes de qualidade fosse mantida em ambos os subconjuntos. Uma semente pseudoaleatória foi fixada em 42 para assegurar a reprodutibilidade dos resultados da divisão.
4. **Escalonamento das Features:** As features numéricas de entrada foram padronizadas. Este processo, realizado através da técnica de ‘StandardScaler’, transforma os dados para que apresentem média zero e desvio padrão unitário. O escalonador foi ajustado utilizando apenas os dados de treinamento e, subsequentemente, a transformação foi aplicada tanto aos dados de treinamento quanto aos de teste, prevenindo assim o vazamento de informações do conjunto de teste para o processo de ajuste do escalonador.

5. **Tratamento de Desbalanceamento de Classes:** Foi identificada uma distribuição desigual das classes de qualidade no conjunto de treinamento. Para mitigar o potencial viés do modelo em favor da classe majoritária (peças "OK"), foram calculados pesos de classe. Estes pesos, obtidos através de uma estratégia de balanceamento que atribui maior importância às classes minoritárias, foram aplicados durante o treinamento do modelo de Rede Neural, especificamente na função de perda, para compensar o desequilíbrio.

3.2.5 Desenvolvimento e Treinamento dos Modelos Preditivos

Para a tarefa de classificação da qualidade das peças, o foco principal foi o desenvolvimento de um modelo de Rede Neural Artificial (RNA), dada sua reconhecida capacidade de modelar relações complexas e não-lineares presentes em dados de processos industriais. Embora modelos clássicos como Regressão Logística Multinomial e Árvore de Decisão tenham sido explorados em fases preliminares para fins comparativos, a otimização sistemática de hiperparâmetros e a análise de explicabilidade detalhada concentraram-se no modelo de RNA.

A arquitetura da Rede Neural foi concebida para ser flexível, permitindo a otimização de diversos de seus componentes estruturais e de treinamento. A estrutura base investigada consistiu em:

- Uma camada de entrada correspondente ao número de features.
- Um número variável de camadas ocultas (explorando-se de 1 a 3 camadas).
- Um número variável de unidades (neurônios) em cada camada oculta (com valores testados entre 16 e 96).
- Utilização de regularização L2 nos pesos das camadas densas para mitigar o overfitting.
- Aplicação de normalização em lote ('Batch Normalization') após cada camada densa e antes da função de ativação, para estabilizar e acelerar o treinamento.
- Funções de ativação como 'ReLU' ou 'ELU' para as camadas ocultas.
- Camadas de 'Dropout' após cada camada oculta, com taxas variáveis, como outra forma de regularização.
- Uma camada de saída com três neurônios (correspondentes às três classes de qualidade) e função de ativação 'softmax', adequada para problemas de classificação multiclasse onde as saídas representam probabilidades de pertencimento a cada classe.

A função de perda selecionada para o treinamento foi a entropia cruzada categórica esparsa (`'sparse_categorical_crossentropy'`), apropriada para problemas de classificação com rótulos de classe inteiros. O otimizador Adam foi utilizado, com sua taxa de aprendizado também sendo um hiperparâmetro a ser otimizado.

3.2.6 Otimização de Hiperparâmetros

A otimização dos hiperparâmetros da Rede Neural foi conduzida de forma sistemática utilizando o algoritmo `'Hyperband'`, uma técnica eficiente de busca que combina alocação adaptativa de recursos e parada antecipada de configurações menos promissoras. Esta abordagem foi implementada através da biblioteca KerasTuner. Os principais aspectos da estratégia de otimização foram:

- **Métrica Objetivo:** O processo de busca visou minimizar a perda (`'loss'`) no conjunto de validação interno ao KerasTuner. Adicionalmente, uma métrica customizada focada no `'recall'` da classe minoritária "NOK Preenchimento" foi monitorada e utilizada como critério principal para a interrupção antecipada (`'EarlyStopping'`) durante o treinamento final do modelo selecionado.
- **Configuração do Hyperband:** Foram definidas 50 épocas como o máximo por configuração testada dentro do ciclo do Hyperband, com um fator de redução de 3. Uma semente de aleatoriedade (42) foi utilizada para garantir a reprodutibilidade da busca.

Durante a busca, uma fração de 20% dos dados de treinamento foi reservada para validação interna de cada configuração de hiperparâmetros. Um mecanismo de interrupção antecipada foi empregado para finalizar o treinamento de configurações que não apresentavam melhoria na métrica objetivo após 10 épocas, otimizando o tempo de busca. Os pesos de classe, previamente calculados para tratar o desbalanceamento, foram aplicados durante este processo.

Após a conclusão da busca, a configuração de hiperparâmetros que resultou no melhor desempenho na métrica objetivo foi selecionada. O modelo final foi então construído com essa configuração otimizada e treinado no conjunto completo de dados de treinamento. Este treinamento final também empregou mecanismos de `EarlyStopping` e `ReduceLROnPlateau`. Dada a criticidade de identificar corretamente as peças não conformes, especialmente aquelas com falhas de preenchimento que podem comprometer a funcionalidade do produto, o `EarlyStopping` foi configurado para monitorar o *recall* da classe "NOK Preenchimento" (denominada `val_recall_classe_2` na implementação) no conjunto de validação (neste caso, o conjunto de teste foi usado para esta finalidade no treino final). A maximização do recall para esta classe de defeito visa minimizar a ocorrência de falsos negativos, ou seja, peças defeituosas erroneamente classificadas como conformes, o que representa um custo significativamente maior para o processo produtivo

do que um falso positivo (peça boa classificada como defeituosa). A paciência para o `EarlyStopping` foi definida em 100 épocas. O mecanismo de `ReduceLROnPlateau` também foi vinculado a esta métrica de recall para ajustar dinamicamente a taxa de aprendizado. O número máximo de épocas para o treino final foi de 300.

3.2.7 Avaliação de Desempenho e Análise de Explicabilidade (XAI)

O desempenho do modelo de Rede Neural final, treinado com os hiperparâmetros otimizados, foi rigorosamente avaliado no conjunto de teste (`'X_test_scaled'`, `'y_test'`), que não foi utilizado em nenhuma etapa de treinamento ou otimização de hiperparâmetros. As métricas de avaliação empregadas para quantificar a capacidade preditiva do modelo incluíram:

- Acurácia geral, representando a proporção total de predições corretas.
- A Matriz de Confusão, para uma análise visual e quantitativa dos acertos e erros para cada classe.
- Um Relatório de Classificação detalhado, fornecendo os valores de Precisão, Revocação (Recall) e F1-Score para cada uma das três classes de qualidade (OK, NOK Rebarba, NOK Preenchimento). Particular atenção foi dada à métrica de **Revocação (Recall)** para as classes de não conformidade ("NOK Rebarba" e "NOK Preenchimento"). No contexto industrial da moldagem por injeção, a falha em identificar uma peça defeituosa (falso negativo) geralmente acarreta custos e consequências mais severas – como problemas em etapas subsequentes de montagem ou falha do produto em campo – do que a identificação incorreta de uma peça boa como defeituosa (falso positivo), que levaria a uma inspeção adicional ou descarte desnecessário, mas com menor impacto sistêmico. Portanto, um alto recall para as classes de defeito é um indicador chave da utilidade prática do modelo.
- Os valores agregados de F1-Score Macro (média aritmética simples dos F1-Scores por classe) e F1-Score Ponderado (média dos F1-Scores ponderada pelo suporte de cada classe), para resumir o desempenho multiclasse.

Para aprofundar o entendimento sobre o comportamento do modelo de Rede Neural e identificar a influência das features de entrada em suas predições, foi aplicada a técnica de Inteligência Artificial Explicável (XAI) denominada SHAP (SHapley Additive exPlanations) (LUNDBERG; LEE, 2017). Dada a natureza do modelo (baseado em TensorFlow/Keras), foi utilizada a implementação `'DeepExplainer'` da biblioteca SHAP. O processo de análise SHAP compreendeu:

1. A seleção de um conjunto de dados de referência (ou "fundo"), composto por uma amostra de 150 instâncias dos dados de treinamento escalados. Este conjunto é

necessário para o ‘DeepExplainer’ estimar a expectativa condicional dos valores SHAP.

2. A seleção de um conjunto de instâncias para explicação, formado por uma amostra de 100 instâncias dos dados de teste escalados, sobre as quais os valores SHAP seriam efetivamente calculados.
3. O cálculo dos valores SHAP, que atribuem a cada feature uma medida de sua contribuição para “empurrar” a predição de uma instância específica para longe da predição base (média). Para problemas multiclasse, os valores SHAP são calculados em relação a cada classe de saída.
4. A visualização e interpretação dos valores SHAP por meio de:
 - **Gráficos de Barras SHAP (Importância Global):** Apresentam a magnitude média da contribuição de cada feature para cada classe, indicando as variáveis de processo com maior impacto geral nas predições.
 - **Gráficos de Dispersão SHAP (ou “Dot Plots”/“Summary Plots”):** Para cada classe, exibem a distribuição dos valores SHAP para cada feature em todas as instâncias explicadas. Estes gráficos são particularmente informativos, pois mostram não apenas a magnitude, mas também a direção (positiva ou negativa) da contribuição de uma feature, e como essa contribuição se correlaciona com os próprios valores da feature (indicados por cor, representando valores altos ou baixos da feature).

O propósito fundamental desta análise XAI foi validar se o modelo de Rede Neural aprendeu relações intuitivas e fisicamente coerentes entre os parâmetros de processo da máquina de injeção e a qualidade resultante das peças, além de identificar os principais fatores que direcionam o modelo a classificar uma peça como OK, NOK Rebarba ou NOK Preenchimento.

3.3 Estudo de Caso 2: Predição da Vida Útil Remanescente de Rolamentos

Este segundo estudo de caso investiga a aplicação de uma abordagem de Aprendizado Profundo para o prognóstico da Vida Útil Remanescente (RUL) de rolamentos. O trabalho teve como objetivo principal replicar e analisar a metodologia proposta por Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020), que utiliza features baseadas em similaridade de espectros de vibração e um ensemble de Redes Neurais Long Short-Term Memory (LSTM) para estimar um Indicador de Saúde (HI) do componente. A partir do HI previsto, a RUL é então extrapolada. Um foco adicional significativo foi colocado na análise de sensibilidade do modelo treinado, buscando verificar se o modelo aprende relações fisicamente coerentes entre as features de entrada e a degradação do rolamento, contribuindo para a interpretabilidade da solução.

3.3.1 Descrição do Problema de Prognóstico e Dataset Utilizado

O prognóstico da RUL de rolamentos é uma tarefa crítica na manutenção preditiva de máquinas rotativas. A falha inesperada de um rolamento pode levar a paradas de produção dispendiosas, danos secundários a outros componentes da máquina e até falhas catastróficas dependendo da aplicação. Estimar com precisão quanto tempo de vida útil resta a um rolamento permite o planejamento otimizado de intervenções de manutenção, evitando falhas e maximizando a utilização do componente. A degradação de rolamentos geralmente se manifesta por um aumento progressivo nos níveis de vibração, causado pelo surgimento e propagação de defeitos nas pistas, elementos rolantes ou gaiola.


Para este estudo, foi utilizado o conhecido dataset público PRONOSTIA, fornecido pelo FEMTO-ST Institute como parte do desafio IEEE PHM 2012 Conference Data Challenge (NECTOUX et al., 2012). Este conjunto de dados contém sinais de vibração, medidos por acelerômetros nos eixos horizontal e vertical, de rolamentos operados sob diferentes condições de carga e velocidade de rotação até a ocorrência da falha. Conforme especificado no desafio e seguido neste trabalho:

- **Dados de Treinamento:** Foram utilizados seis rolamentos, sendo dois para cada uma das três condições operacionais distintas propostas no desafio.
- **Dados de Teste:** Foram utilizados onze rolamentos para avaliação final do modelo, para os quais os valores reais de RUL no final da coleta de dados são conhecidos.


A variável intermediária a ser prevista pelo modelo LSTM é o Indicador de Saúde (HI), uma métrica normalizada (tipicamente entre 0 e 1) que representa o grau de degradação do rolamento, onde 0 indicaria um rolamento perfeitamente saudável e 1 o fim da vida útil.

Para ilustrar a natureza dos dados brutos contidos no dataset PRONOSTIA, a Figura 6 apresenta um exemplo de um dos rolamentos utilizados. É possível observar a evolução completa do sinal de vibração ao longo do tempo (Figura 6a), desde uma condição inicial estável até a fase de falha avançada, caracterizada por um aumento significativo na amplitude. Adicionalmente, o espectro de frequência de um segmento inicial do sinal (Figura 6b) revela a distribuição de energia nas diferentes frequências, que serve de base para a extração de características.

Figura 6: Representações dos dados de vibração brutos para um rolamento do dataset PRONOSTIA.



(a) Evolução temporal completa do sinal de aceleração para o rolamento Rolamento 3_3.



(b) Espectro de frequência (FFT) de um segmento inicial do sinal para o rolamento Rolamento 3_3.

Fonte: Elaboração própria.

3.3.2 Definição de Requisitos de Risco via FMEA

No contexto do prognóstico de componentes críticos como rolamentos, a análise de risco é primordial. Uma análise FMEA aplicada ao sistema de predição de RUL (detalhada na Seção 4.2.4) identifica dois modos de falha principais: uma "Previsão Tardia", onde a RUL prevista é maior que a real, e uma "Previsão Precoce", onde a RUL prevista é menor que a real.

Os efeitos de uma Previsão Tardia são potencialmente catastróficos, incluindo a parada não planejada da máquina, danos secundários a outros componentes e, mais criticamente, riscos à segurança dos operadores. Por outro lado, os efeitos de uma Previsão Precoce são primariamente financeiros, associados ao custo de uma manutenção prematura

e ao desperdício da vida útil remanescente do componente.

Dada a severidade inaceitável do primeiro modo de falha, um requisito essencial para o sistema de prognóstico é que ele seja, por natureza, **conservador**, minimizando a qualquer custo a probabilidade de uma previsão tardia. Este requisito de segurança e confiabilidade justifica a utilização de métricas de avaliação assimétricas, como o score do desafio PHM 2012, que penalizam mais severamente os erros que subestimam a degradação do componente.

3.3.3 Extração e Seleção de Características (Features)

As features de entrada para os modelos de LSTM foram extraídas seguindo a metodologia descrita por Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020). Este processo, realizado em uma etapa de pré-processamento dos sinais brutos de vibração, resultou em um conjunto de 24 características (features) para cada janela temporal de dados:

- **16 Features Estatísticas do Domínio do Tempo:** Calculadas a partir dos sinais de vibração dos sensores horizontal e vertical. Para cada sensor, foram extraídas oito features: Média Absoluta, Mínimo-Máximo Absoluto (diferença entre o máximo e o mínimo dos valores absolutos do sinal), Desvio Padrão, Assimetria (Skewness), Curtose (Kurtosis), Energia (soma dos quadrados das amplitudes), Entropia de Shannon (medida da incerteza ou aleatoriedade do sinal) e a Razão Energia/Entropia. Estas features visam capturar mudanças na amplitude e na distribuição estatística do sinal de vibração à medida que o rolamento se degrada.
- **8 Features de Similaridade:** Estas features inovadoras foram calculadas com base na similaridade entre o espectro de frequência (obtido via Transformada Rápida de Fourier - FFT) de uma nova janela de dados de vibração e dois tipos de templates de espectros representativos, previamente aprendidos a partir dos dados de treinamento:
 - **Template Normal (Fn):** Representa o espectro de frequência característico de um rolamento em condição saudável.
 - **Template de Falha (Ff):** Representa o espectro de frequência característico de um rolamento próximo ao fim de sua vida útil.

Os templates Fn e Ff foram aprendidos separadamente para cada condição operacional, utilizando os primeiros e os últimos segmentos de dados dos rolamentos de treinamento daquela condição. Antes do cálculo da similaridade, tanto os espectros das novas medições quanto os templates foram normalizados (norma L2). As métricas de similaridade calculadas foram a Correlação de Pearson e a Distância Euclidiana entre o espectro da janela atual e cada um dos templates (Fn e Ff), para cada um dos dois sensores de vibração (horizontal e vertical), totalizando oito features de

similaridade. A hipótese é que, à medida que o rolamento se degrada, a similaridade com o template Fn diminui, enquanto a similaridade com o template Ff aumenta.

Este conjunto de 24 features constituiu a entrada para os modelos de estimação do Indicador de Saúde (HI).

3.3.4 Pré-processamento dos Dados para Prognóstico de Rolamentos

Após a extração das 24 features, um pré-processamento adicional foi aplicado antes de alimentar os dados aos modelos LSTM:

1. **Escalonamento Seletivo das Features:** Seguindo a abordagem implícita no artigo de referência (HUANG; FARAHAT; GUPTA, 2020), apenas as 16 features estatísticas do domínio do tempo foram padronizadas (escalonadas para ter média zero e desvio padrão unitário) utilizando a técnica ‘StandardScaler’. O escalonador foi ajustado utilizando os dados de todas as features de tempo dos seis rolamentos de treinamento. As 8 features de similaridade não foram escalonadas, mantendo seus valores originais. O escalonador ajustado foi então aplicado às features de tempo dos dados de teste.
2. **Cálculo do HI Real (Ground Truth) para o Conjunto de Teste:** Embora o HI não seja diretamente fornecido para os rolamentos de teste no dataset PRONOSTIA, seus valores reais de RUL são conhecidos. Utilizando esses valores de RUL e o último timestamp registrado para cada rolamento de teste, o HI real para cada ponto de dados do teste foi calculado como a razão entre o tempo operacional atual e o tempo total de vida estimado (tempo operacional atual + RUL real). O valor do HI real foi limitado a um máximo de 1.0. Este HI real do conjunto de teste foi utilizado exclusivamente para a avaliação final do desempenho do modelo.
3. **Preparação de Sequências para LSTM:** Os modelos LSTM são projetados para processar sequências de dados. Portanto, os dados de features (24 features) foram transformados em sequências temporais sobrepostas. Foi definido um comprimento de sequência de 64 passos de tempo. Cada amostra de entrada para a LSTM consistiu em uma matriz de dimensão (64, 24), representando os valores das 24 features nos 64 passos de tempo anteriores. O valor alvo (HI) correspondente a cada sequência de entrada foi o valor do HI no último passo de tempo daquela sequência.

3.3.5 Desenvolvimento do Modelo Ensemble LSTM

A abordagem de modelagem seguiu as especificações da arquitetura e estratégia de ensemble propostas por Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020):

- **Arquitetura LSTM Individual Base:** Cada modelo LSTM individual no ensemble possuía a seguinte arquitetura:

- Duas camadas LSTM empilhadas, cada uma com 128 unidades. A primeira camada LSTM foi configurada para retornar sequências completas para a camada LSTM seguinte, enquanto a segunda não. Ambas as camadas LSTM utilizaram ‘dropout’ (taxa de 0.1) e ‘recurrent_dropout’ (taxa de 0.1) para regularização e prevenção de overfitting.
 - Duas camadas Densas (totalmente conectadas) subsequentes com função de ativação ReLU. A primeira camada densa com 128 neurônios e a segunda com 16 neurônios. Ambas foram seguidas por uma camada de ‘Dropout’ com taxa de 0.1.
 - Uma camada Densa final com 1 neurônio e função de ativação Sigmoid, para produzir a saída do HI, que é um valor normalizado entre 0 e 1.
- **Otimizador e Função de Perda:** O otimizador Adam foi utilizado com uma taxa de aprendizado de 0.001. A função de perda para o treinamento foi o Erro Quadrático Médio (MSE). As métricas monitoradas durante o treinamento e validação incluíram o Erro Absoluto Médio (MAE) e a Raiz do Erro Quadrático Médio (RMSE).
 - **Estratégia de Ensemble (Leave-One-Out):** Dado o número limitado de rolamentos de treinamento (seis no total), foi implementada uma estratégia de ensemble utilizando validação cruzada Leave-One-Out. Seis modelos LSTM individuais, com a arquitetura descrita acima, foram treinados. Para treinar o i -ésimo modelo (onde i varia de 1 a 6), o i -ésimo rolamento do conjunto de treinamento foi reservado como conjunto de validação. Os outros cinco rolamentos de treinamento foram utilizados como dados de treinamento para esse modelo específico. Este processo foi repetido seis vezes, garantindo que cada um dos seis rolamentos de treinamento fosse usado como conjunto de validação exatamente uma vez.
 - **Treinamento de Cada Modelo Individual:** O treinamento de cada modelo LSTM individual utilizou um mecanismo de ‘EarlyStopping’, monitorando o MAE no respectivo conjunto de validação (o rolamento “deixado de fora”), com uma paciência de 20 épocas sem melhoria para interromper o treinamento. Um callback de ‘ModelCheckpoint’ foi usado para salvar o modelo que apresentou o melhor desempenho no conjunto de validação. O número máximo de épocas para o treinamento de cada modelo foi definido como 200.
 - **Previsão do Ensemble:** Para fazer previsões no conjunto de teste, cada um dos seis modelos LSTM treinados individualmente gerou uma previsão de HI para cada sequência de teste. A previsão final do ensemble para o HI foi calculada como a média aritmética simples das previsões dos seis modelos individuais.

3.3.6 Estimativa da RUL a partir do HI Previsto

A RUL não foi prevista diretamente pelo modelo LSTM. Em vez disso, seguiu-se uma abordagem de extrapolação da série temporal do HI previsto pelo ensemble:

1. Para cada rolamento de teste, obteve-se a série temporal do HI previsto pelo ensemble.
2. Considerando que a degradação mecânica de um rolamento é um processo irreversível (o componente não se "regenera"), a série temporal do HI deve ser sempre crescente ou estável. Para garantir essa coerência física e suavizar ruídos nas previsões, aplicou-se uma correção onde qualquer valor previsto inferior ao acumulado máximo anterior foi substituído por este último (ou seja, $HI_t = \max(HI_t, HI_{t-1})$).
3. Uma curva exponencial da forma $y = a \cdot \exp(b \cdot t)$ foi ajustada a esta série temporal monotônica do HI previsto (y) em função do tempo operacional (t). Os parâmetros a e b da curva exponencial foram determinados utilizando a função 'curve_fit' da biblioteca SciPy. Para guiar o ajuste da curva, especialmente considerando a maior importância do início da degradação e da fase próxima da falha, foi utilizada uma ponderação nos dados, atribuindo um peso maior aos primeiros e aos últimos 64 pontos da série temporal do HI.
4. O tempo de falha previsto para o rolamento foi determinado como o tempo (t) em que a curva exponencial ajustada atinge o valor de $HI = 1.0$.
5. A RUL prevista foi então calculada como a diferença entre o tempo de falha previsto e o tempo do último ponto de dados disponível para aquele rolamento de teste.

3.3.7 Métricas de Avaliação para Prognóstico

O desempenho do modelo foi avaliado em duas frentes:

- **Para a Previsão do Indicador de Saúde (HI):** As métricas utilizadas incluíram o Erro Quadrático Médio (MSE), Erro Absoluto Médio (MAE), Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Determinação (R^2), comparando o HI previsto pelo ensemble com o HI real no conjunto de teste.
- **Para a Estimativa da RUL:** O desempenho foi avaliado utilizando a métrica de score definida no desafio IEEE PHM 2012. Esta métrica calcula um score individual para cada rolamento de teste, que penaliza erros percentuais na RUL de forma assimétrica: erros que resultam em uma previsão tardia (RUL prevista maior que a RUL real, levando a uma falha não prevista) são penalizados mais severamente do que erros de previsão antecipada. O score final para o conjunto de teste é a média dos scores individuais.

3.3.8 Análise de Sensibilidade das Features

Para investigar a influência das 24 features de entrada na predição do HI e validar a coerência do aprendizado do modelo, foi realizada uma análise de sensibilidade simplificada. Esta análise utilizou o primeiro modelo treinado do ensemble e uma amostra de sequência específica selecionada do conjunto de teste. O procedimento consistiu em perturbar individualmente cada feature de entrada e observar a mudança resultante na predição do HI:

- **Para as 16 Features Escaladas (Domínio do Tempo):** O valor de cada feature, em todos os passos de tempo da sequência de amostra, foi perturbado adicionando-se e subtraindo-se 1.0 (equivalente a ± 1 desvio padrão no espaço transformado, dado que as features foram padronizadas).
- **Para as 8 Features de Similaridade (Não Escaladas):** O valor de cada feature de similaridade, em todos os passos de tempo da sequência, foi perturbado adicionando-se e subtraindo-se um valor absoluto fixo de 0.1. Para as features de correlação, os valores perturbados foram limitados (clipped) ao intervalo $[-1, 1]$ para manter sua validade física.

A influência de cada feature foi quantificada pela máxima diferença absoluta observada na predição do HI devido às perturbações (positiva e negativa) em seu valor. O objetivo principal desta análise foi verificar se a direcionalidade do impacto das features (especialmente as de similaridade) na predição do HI era consistente com o entendimento físico do processo de degradação.

4 RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados obtidos a partir da aplicação das metodologias descritas anteriormente para os dois estudos de caso propostos: a **predição da qualidade das peças** no processo de injeção plástica e a predição da vida útil remanescente de rolamentos. Para cada estudo, serão detalhados os desempenhos quantitativos dos modelos desenvolvidos, seguidos por uma análise qualitativa e discussão dos achados, com ênfase na interpretabilidade dos modelos e na relevância prática dos resultados. Finalmente, uma discussão consolidada buscará comparar as abordagens, os desafios e os aprendizados gerais obtidos em ambos os contextos da engenharia mecânica.


4.1 Resultados do Estudo de Caso 1: Predição da Qualidade em Injeção Plástica

Neste primeiro estudo de caso, o objetivo foi desenvolver e avaliar modelos de Inteligência Artificial capazes de prever a **qualidade** de peças produzidas por moldagem por injeção, classificando-as como conformes (OK) ou indicando a probabilidade de ocorrência de defeitos específicos: rebarba (NOK Rebarba) ou falha de preenchimento (NOK Preenchimento). A análise focou no desempenho preditivo e na explicabilidade do modelo de Rede Neural Artificial (RNA) otimizado.

4.1.1 Caracterização Inicial dos Dados e Desempenho dos Modelos de Classificação

O conjunto de dados utilizado compreende 31.537 ciclos de injeção e é proveniente do trabalho de Silva, Sousa e Alenya (2021) (LOPES; SOUSA; ALENYÀ, 2021). Uma análise exploratória inicial revelou um significativo desbalanceamento entre as classes de qualidade, conforme ilustrado na Figura 7. A classe "OK" representa aproximadamente 97,8% do total (30.845 amostras), enquanto as classes de defeito "NOK (Preenchimento)" e "NOK (Rebarba)" constituem apenas cerca de 1,24% (392 amostras) e 0,95% (300 amostras), respectivamente. Este desbalanceamento é um fator crítico a ser considerado na avaliação do desempenho dos modelos.


Figura 7: Distribuição das classes de qualidade das peças no conjunto de dados de injeção plástica.



Fonte: Elaboração própria.

A análise de correlação entre as features de entrada originais (TI, TP, TC, A, PIM), apresentada na Figura 8, indicou a presença de correlações lineares moderadas, tanto positivas (ex: TI com A, PIM) quanto negativas (ex: TI com TP, TP com A e PIM). Tais correlações sugerem interdependências entre os parâmetros do processo, justificando a exploração de features de engenharia e o uso de modelos capazes de capturar relações complexas.

Figura 8: Heatmap da matriz de correlação entre as variáveis numéricas de entrada do processo de injeção plástica.



Fonte: Elaboração própria.

Diversos modelos de classificação foram treinados e avaliados, incluindo Regressão Logística Multinomial, Árvore de Decisão, Random Forest (RF), XGBoost, LightGBM e uma Rede Neural Artificial (RNA) com arquitetura e hiperparâmetros otimizados via KerasTuner. A Tabela 1 apresenta um comparativo do desempenho dos principais modelos no conjunto de teste, utilizando o F1-Score Macro como principal métrica de comparação devido ao desbalanceamento das classes.

Tabela 1: Desempenho comparativo dos modelos de classificação para injeção plástica no conjunto de teste.

Modelo	Acurácia	F1-Score Macro	F1-Score Ponderado
Regressão Logística Multinomial	0.9937	0.8944	0.9936
Árvore de Decisão (prof. 10)	0.9959	0.9403	0.9959
Random Forest (Otimizado)	0.9968	0.9576	0.9968
XGBoost (Otimizado)	0.9962	0.9483	0.9963
LightGBM (Otimizado)	0.9935	0.9176	0.9936
RNA (Básica, não otimizada)	0.9955	0.9307	0.9955
RNA (Otimizada com KerasTuner)	0.9939	0.9230	0.9942

Nota: O Random Forest otimizado apresentou o maior F1-Score Macro.

Fonte: Elaboração própria.

Embora todos os modelos tenham alcançado alta acurácia, esta métrica é inflacionada pela predominância da classe "OK". O F1-Score Macro revela que modelos baseados em árvores, como Random Forest e XGBoost, apresentaram um desempenho agregado superior. O Random Forest otimizado, com parâmetros `{max_depth: 10, min_samples_split: 5, n_estimators: 50}`, obteve o maior F1-Score Macro (0.9576). A Rede Neural Otimizada, apesar de um F1-Score Macro ligeiramente inferior (0.9230), foi objeto de uma análise de explicabilidade mais aprofundada devido ao interesse em compreender o comportamento de modelos de aprendizado profundo e ao seu bom desempenho no recall de classes minoritárias, conforme detalhado a seguir. A arquitetura final da RNA otimizada, resultante do processo com KerasTuner, está detalhada na Tabela 2.

Tabela 2: Arquitetura da Rede Neural Otimizada para o problema de injeção plástica.

Camada (Tipo)	Formato da Saída	Nº de Parâmetros
Input Layer	(None, 8)	0
Dense	(None, 16)	144
BatchNormalization	(None, 16)	64
Activation (elu)	(None, 16)	0
Dropout (0.1)	(None, 16)	0
Dense	(None, 64)	1,088
BatchNormalization	(None, 64)	256
Activation (relu)	(None, 64)	0
Dropout (0.1)	(None, 64)	0
Dense	(None, 48)	3,120
BatchNormalization	(None, 48)	192
Activation (elu)	(None, 48)	0
Dropout (0.1)	(None, 48)	0
Output Layer (Dense)	(None, 3)	147
Parâmetros Treináveis:		4,899
Parâmetros Não Treináveis:		256
Total de Parâmetros:		5,011

Fonte: Elaboração própria.

O desempenho detalhado da Rede Neural Otimizada no conjunto de teste é elucidado pela matriz de confusão apresentada na Tabela 3 e pelo relatório de classificação subsequente na Tabela 4.

Tabela 3: Matriz de confusão em valores absolutos para o modelo de Rede Neural Otimizada (injeção plástica) no conjunto de teste.

Classe Real	Classe Predita			Total Real
	OK	NOK (Rebarba)	NOK (Preenchimento)	
OK	9207	6	41	9254
NOK (Rebarba)	0	90	0	90
NOK (Preenchimento)	11	0	107	118
Total Predito	9218	96	148	9462

Fonte: Elaboração própria.

Tabela 4: Métricas detalhadas de desempenho por classe para o modelo de Rede Neural Otimizada.

Classe	Precisão	Revocação	F1-Score	Suporte
OK	1,00	0,99	1,00	9254
NOK (Rebarba)	0,94	1,00	0,97	90
NOK (Preenchimento)	0,72	0,91	0,80	118
Acurácia Global		-	0,99	9462
Média Macro	0,89	0,97	0,92	9462
Média Ponderada	0,99	0,99	0,99	9462

Fonte: Elaboração própria.


A Rede Neural Otimizada demonstrou excelente desempenho na identificação de peças "OK" (F1-Score 1.00) e "NOK (Rebarba)" (F1-Score 0.97). Notavelmente, para a classe "NOK (Rebarba)", o modelo alcançou um recall perfeito de 1.00, classificando corretamente todas as 90 instâncias reais deste defeito, sem classificá-las erroneamente como "OK" ou "NOK (Preenchimento)", conforme visível na Tabela 4.

Para a classe "NOK (Preenchimento)", identificada como a mais desafiadora devido ao seu menor suporte e potencial maior complexidade de distinção, o modelo alcançou um recall de 0.91. Isso significa que foi capaz de identificar corretamente 107 das 118 reais falhas de preenchimento. Este alto recall para as classes de defeito foi um dos principais objetivos da estratégia de otimização do modelo, visando minimizar a ocorrência de falsas conformidades, que representam um custo elevado no processo produtivo. A precisão para "NOK (Preenchimento)" foi de 0.72, indicando que, das 148 peças que o modelo classificou como "NOK (Preenchimento)", 107 eram de fato falhas de preenchimento, enquanto as 41 restantes ($148 - 107 = 41$) foram classificadas erroneamente (eram peças "OK" preditas como "NOK (Preenchimento)"), conforme se observa na coluna "Predito NOK (Preenchimento)" da matriz de confusão. Este número de falsos positivos para "NOK (Preenchimento)" vindo da classe "OK" é um reflexo direto do forte desbalanceamento dos dados. O tratamento do desbalanceamento com pesos de classe durante o treinamento provavelmente foi um fator crucial para alcançar o bom desempenho de recall nas classes minoritárias.

4.1.2 Análise de Explicabilidade (SHAP) para o Modelo de Rede Neural Otimizada

Para obter insights sobre como a Rede Neural Otimizada toma suas decisões e quais features de entrada são mais influentes, foi realizada uma análise utilizando SHAP (SHapley Additive exPlanations). A Figura 9 apresenta a importância global média das features para cada classe.

Figura 9: Importância global média das features (SHAP Bar Plot) para o modelo de Rede Neural Otimizada na predição de qualidade em injeção plástica. As cores indicam a contribuição média para cada classe (azul: OK, magenta: NOK Preenchimento, oliva: NOK Rebarba).



Fonte: Elaboração própria.


Observa-se que a feature **A** (Almofada) e a feature de engenharia **TI_TP** (razão entre Tempo de Injeção e Tempo de Plastificação) foram, em média, as mais impactantes nas predições do modelo. Seguem-se **PIM** (Pressão no Interior do Molde), **PIM_squared**, **TP** (Tempo de Plastificação) e **TI** (Tempo de Injeção). Este resultado refina a análise inicial de (LOPES; SOUSA; ALENYà, 2021), que introduziu o dataset utilizado. Enquanto os autores originais selecionaram o conjunto de variáveis com base na literatura, a presente análise quantitativa via SHAP oferece uma hierarquização de sua influência para um modelo de rede neural, validando a relevância do conjunto e, ao mesmo tempo, diferenciando o impacto de cada parâmetro.

A análise torna-se mais rica ao contrastar esta hierarquia com a de outros modelos. No trabalho de (SOUZA, 2023), que aplicou diferentes algoritmos ao mesmo dataset, a importância das variáveis demonstrou ser dependente da arquitetura: uma Árvore de Decisão priorizou a Almofada (**A**) de forma dominante, enquanto uma Regressão Logística focou no Tempo de Injeção (**TI**). Este contraste revela uma conclusão metodológica crucial: a "importância da feature" não é uma propriedade absoluta do processo, mas sim da interação entre os dados e a arquitetura do modelo. Ferramentas de XAI, portanto, são essenciais não apenas para interpretar um único modelo, mas para realizar uma análise comparativa de como diferentes abordagens aprendem a resolver o mesmo problema. As features **A_TC** (produto Almofada e Tempo de Ciclo) e **TC** (Tempo de Ciclo) apresentaram

menor impacto global.

Para uma análise mais detalhada da direção e magnitude da influência de cada feature, os SHAP Dot Plots (Summary Plots) por classe são apresentados nas Figuras 10, 11, e 12. É importante notar, de antemão, que a magnitude dos valores SHAP observados para a maioria das features é relativamente baixa (predominantemente na faixa de $\pm 0.0x$, com alguns pontos isolados atingindo valores maiores), e os pontos nos gráficos de dispersão frequentemente se concentram próximos ao valor SHAP zero, sem formar agrupamentos de cores (representando valores altos ou baixos da feature) claramente distintos em regiões de alto impacto positivo ou negativo. Esta característica geral sugere que, embora o modelo de Rede Neural alcance um bom desempenho preditivo, sua explicabilidade em termos de atribuição de importância clara e direcional para features individuais pode ser limitada, ou que as relações aprendidas são mais complexas e interdependentes do que podem ser capturadas por uma análise marginal de cada feature.

Figura 10: SHAP Dot Plot para a classe OK (Rede Neural Otimizada - Injeção Plástica).




Fonte: Elaboração própria.

Analisando a Figura 10 para a classe "OK", observa-se uma grande concentração de pontos em torno do valor SHAP zero para todas as features. Embora haja alguns pontos isolados com valores SHAP mais altos, como para TI_TP (onde alguns valores altos da feature, em vermelho, têm SHAP positivo), ou para A (onde alguns valores baixos da feature, em azul, têm SHAP positivo), não há uma tendência forte e generalizada. Isso pode indicar que a condição "OK" é o resultado de um equilíbrio complexo entre múltiplos parâmetros, em vez de ser fortemente impulsionada por uma ou duas features específicas em uma direção clara para a maioria das instâncias. A feature TI_TP parece ser a que apresenta a maior dispersão de valores SHAP, sugerindo uma sensibilidade maior

do modelo a esta variável para a classe "OK", embora sem um padrão de cor fortemente definido.


Figura 11: SHAP Dot Plot para a classe NOK (Rebarba) (Rede Neural Otimizada - Injeção Plástica).



Fonte: Elaboração própria.

Para a classe "NOK (Rebarba)" (Figura 11), a feature A (Almofada) exibe alguns pontos com valores SHAP positivos relativamente mais altos quando o valor da feature é alto (vermelho), o que é fisicamente coerente com a ideia de que uma almofada excessiva pode contribuir para a formação de rebarbas. Similarmente, a feature TI_TP mostra alguns pontos com valores SHAP positivos quando o valor da feature é baixo (azul), e PIM apresenta alguns pontos de alto valor (vermelho) com impacto positivo. No entanto, a maioria dos pontos para todas as features ainda se aglomera perto de zero, e a separação por cores não é conclusiva em muitos casos, indicando que, para a maioria das instâncias, a predição de "NOK (Rebarba)" não é dominada por uma única feature de forma inequívoca.

Figura 12: SHAP Dot Plot para a classe NOK (Preenchimento) (Rede Neural Otimizada - Injeção Plástica).



Fonte: Elaboração própria.

Finalmente, para a classe "NOK (Preenchimento)" (Figura 12), a feature TI_TP apresenta a maior dispersão de valores SHAP, com alguns pontos de baixo valor da feature (azul) resultando em valores SHAP positivos significativos (até aproximadamente 0.7 em um caso isolado). Isso sugere que uma baixa razão entre o tempo de injeção e o tempo de plastificação é um forte indicador de falha de preenchimento para algumas instâncias, o que é intuitivo. As features A (Almofada) e PIM também mostram alguma influência, mas com menor clareza na separação por cores e com a maioria dos impactos concentrados próximos a zero.

Em uma perspectiva geral da análise SHAP para este modelo de Rede Neural, algumas features como A (Almofada) e TI_TP (razão Tempo de Injeção/Plastificação) aparecem consistentemente com maior variabilidade e alguns impactos mais significativos nas predições para as diferentes classes, como também sugerido pelo gráfico de barras de importância global (Figura 9). No entanto, a baixa magnitude geral dos valores SHAP e a ausência de agrupamentos de cores claros e distintos para a maioria das features indicam que o modelo de Rede Neural, embora preditivamente competente, opera de uma maneira que torna a atribuição de causalidade direta e simples a features individuais desafiadora. As decisões do modelo parecem ser resultado de interações complexas e não-lineares entre múltiplas features, onde o impacto de uma feature pode ser altamente dependente dos valores das outras, característica comum em redes neurais profundas. Isso ressalta uma limitação na interpretabilidade "humana" direta do modelo, mesmo com o auxílio de técnicas XAI como SHAP. O resultado, portanto, é que, embora possamos identificar quais features o modelo considera mais informativas em média, entender precisamente como ele as utiliza para cada predição individual permanece uma tarefa complexa.

4.1.3 Discussão dos Resultados da Injeção Plástica

Os resultados obtidos no estudo de caso da injeção plástica demonstram o potencial da Inteligência Artificial, e especificamente das Redes Neurais, para a predição da qualidade de peças. A alta acurácia geral observada em todos os modelos é, em grande parte, um reflexo do desbalanceamento do conjunto de dados, onde a classe "OK" é predominante. Por isso, métricas como F1-Score Macro e o recall por classe são mais indicadas para uma avaliação realista do desempenho.

O modelo de Random Forest otimizado apresentou o melhor F1-Score Macro, indicando um bom equilíbrio entre precisão e recall em todas as classes de forma agregada. No entanto, a Rede Neural Otimizada, mesmo com um F1-Score Macro ligeiramente inferior, alcançou um recall notável de 0.91 para a classe "NOK (Preenchimento)", a qual foi identificada como a mais crítica em termos de minimização de falsos negativos (falsas conformidades). Esta capacidade de identificar 91% das peças com falha de preenchimento, mesmo que à custa de uma precisão menor para esta classe (0.72), alinha-se com o objetivo prático de alertar o operador sobre potenciais problemas antes da produção em massa.

A análise de explicabilidade com SHAP para a Rede Neural Otimizada forneceu insights valiosos e, em grande medida, fisicamente coerentes. A importância da Almofada (A) e da Pressão no Molde (PIM) para a formação de Rebarbas, e da razão TI_TP para Falhas de Preenchimento, são exemplos de relações que o modelo aprendeu e que encontram respaldo no conhecimento técnico do processo de moldagem por injeção. A criação de features de engenharia como TI_TP e PIM_squared mostrou-se útil, pois estas figuraram entre as mais importantes na análise SHAP.

Análise de Risco (FMEA) e a Priorização do Recall.

Conforme antecipado na Seção 3.2.2, a priorização do recall foi uma decisão de engenharia guiada pela análise de risco. O Quadro 1 apresenta uma Análise de Modos e Efeitos de Falha (FMEA) simplificada para os principais erros de predição do sistema de IA. A análise quantifica o risco associado a cada modo de falha através do Número de Prioridade de Risco (RPN), calculado como o produto da Severidade (S), Ocorrência (O) e Detecção (D). As pontuações foram atribuídas com base nos critérios de engenharia detalhados no **Apêndice A**.

A análise FMEA demonstra que o risco de um Falso Negativo (RPN=72) é substancialmente maior que o de um Falso Positivo (RPN=12). Esta constatação justifica a estratégia de otimização adotada, que, ao obter um recall de 0.91 para a classe "NOK (Preenchimento)", trata eficazmente o modo de falha de maior risco.

Quadro 1: Análise FMEA detalhada para o sistema de IA de diagnóstico, com distinção entre tipos de defeito.

Processo	Modo de Falha Potencial	S	Efeito Potencial da Falha	O	Causa Potencial	D	RPN	Ações Recomendadas
Sistema de Diagnóstico de Qualidade	Falso Negativo (Falha de Preenchimento) Prevê "OK", é peça incompleta.	10	Falha estrutural do produto final em campo; Risco de segurança para o usuário; Recall de lote completo; Perda de contrato.	2	Modelo não generaliza para essa condição específica; Mudança drástica de processo/material.	5	100	1. Prioridade Máxima: Otimizar o modelo para o Recall da classe "NOK (Preenchimento)" , como foi o foco deste trabalho. 2. Implementar regra de negócio: Se o modelo prevê "OK" mas os parâmetros estão em uma zona limítrofe, sinalizar para inspeção.
	Falso Negativo (Rebarba) Prevê "OK", é peça com rebarba.	6	Problemas na linha de montagem; Aumento do tempo de ciclo (se rebarba for removida manualmente); Rejeição por inspeção de qualidade final; Reclamação do cliente por problema estético.	3	Modelo menos sensível a variações de pressão/fechamento; Drift gradual do molde.	4	72	1. Incluir o Recall da classe "NOK (Rebarba)" como uma métrica secundária de otimização. 2. Correlacionar alertas do modelo com o cronograma de manutenção do molde.
	Falso Positivo Prevê um Defeito (qualquer tipo), é "OK".	3	Parada desnecessária da produção; Tempo de ajuste do operador; Perda de eficiência (OEE).	4	Efeito colateral da otimização para alto recall; Variações normais do processo.	1	12	1. Usar XAI (SHAP) para fornecer ao operador a causa provável do alerta, permitindo uma verificação rápida e direcionada. 2. Implementar um POP de "inspeção da primeira peça" após alerta, antes de alterar os parâmetros da máquina.

Fonte: Elaboração própria.

Implicações para Governança (ISO 42001) e Operação Prática.

A implementação bem-sucedida de um modelo preditivo como o desenvolvido transcende o desempenho técnico, exigindo um enquadramento robusto em um sistema de gestão de IA, como o preconizado pela ABNT NBR ISO/IEC 42001. A performance do modelo, especialmente o alto recall (0.91) obtido para a classe crítica "NOK (Preenchimento)", exemplifica uma decisão de **gestão de riscos (Seção 8.3)**. Ao adotar este modelo, a organização estaria priorizando a mitigação do risco de maior impacto — a produção

de peças defeituosas — em detrimento do risco de menor impacto, como uma inspeção desnecessária de uma peça conforme.

Neste contexto, A Explicabilidade da IA (XAI) deixa de ser apenas teoria e se torna um fator essencial para a conformidade e a confiança. A norma eleva a **transparência a um objetivo organizacional (Anexo C.2.11)**, e a análise SHAP é a ferramenta técnica que materializa esse objetivo. Ela fornece as evidências necessárias para cumprir os controles práticos de **Informações para as partes interessadas (Anexo A.8)**, permitindo transformar a saída complexa da rede neural em um insight operacionalmente valioso. Um alerta do sistema pode ser traduzido em uma recomendação acionável e justificável: **"ALERTA: Alta probabilidade de Falha de Preenchimento. Causa provável: Baixa razão entre Tempo de Injeção e Plastificação (TI_TP)."** Esta abordagem capacita o operador com conhecimento, alinhando a solução tecnológica ao processo humano de tomada de decisão.

O desafio de refinar a precisão da classe "NOK (Preenchimento)" sem comprometer o recall insere-se diretamente no ciclo de **Melhoria Contínua (Seção 10)** da norma. A necessidade de coletar mais dados, explorar técnicas de balanceamento mais avançadas ou refinar a engenharia de features torna-se uma ação corretiva e de melhoria documentada dentro do sistema de gestão, garantindo a evolução e a eficácia contínua do sistema de IA.

Portanto, a capacidade do modelo de não apenas prever, mas também de explicar suas predições, é o que viabiliza sua integração responsável e eficaz no chão de fábrica, transformando um "oráculo" estatístico em um parceiro de processo confiável ou algo próximo a isso.

4.2 Resultados do Estudo de Caso 2: Predição da Vida Útil Remanescente de Rolamentos

Este segundo estudo de caso investigou a aplicação de uma abordagem de Aprendizado Profundo, baseada na metodologia de Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020), para o prognóstico da Vida Útil Remanescente (RUL) de rolamentos. O foco foi na replicação da técnica, que utiliza features de similaridade e um ensemble de LSTMs para prever um Indicador de Saúde (HI), e na análise da sensibilidade do modelo às features de entrada como forma de avaliar a explicabilidade e a coerência do aprendizado.

4.2.1 Desempenho na Previsão do Indicador de Saúde (HI)


A capacidade do modelo ensemble LSTM em estimar o Indicador de Saúde (HI) dos rolamentos no conjunto de teste foi avaliada quantitativamente. As métricas globais obtidas foram:

- Erro Quadrático Médio (MSE): 0.0930
- Erro Absoluto Médio (MAE): 0.2375
- Raiz do Erro Quadrático Médio (RMSE): 0.3049
- Coeficiente de Determinação (R^2): -0.6123

O valor negativo do Coeficiente de Determinação (R^2) indica que o desempenho do modelo ensemble, em termos de explicação da variância do HI real, foi inferior ao de um modelo trivial que previsse constantemente a média do HI real do conjunto de teste. O Erro Absoluto Médio (MAE) de 0.2375 sugere que, em média, a predição do HI desviou-se aproximadamente 23.75% do valor real, considerando a escala normalizada do HI de 0 a 1.

A Figura 13 apresenta uma análise visual dos erros de previsão do HI para o ensemble no conjunto de teste. O gráfico de dispersão "Real vs. Previsto" (Figura 13a) exibe uma tendência geral de aumento do HI previsto com o HI real, mas com uma dispersão considerável dos pontos. Observa-se uma propensão do modelo a subestimar o HI, especialmente em estágios mais avançados de degradação (HI real mais alto), onde muitas previsões situam-se abaixo da linha ideal ($y=x$). Esta subestimação é reforçada pelo gráfico de "Resíduos vs. Previsto" (Figura 13b), que mostra uma maior dispersão na região de erros positivos ($HI_{Real} - HI_{Previsto} > 0$). A distribuição dos resíduos (Figura 13c) confirma essa tendência, com uma média ligeiramente positiva, indicando que as previsões do HI foram, em geral, inferiores aos valores reais.

Figura 13: Análise visual dos erros de previsão do Indicador de Saúde (HI) para o ensemble LSTM no conjunto de teste de rolamentos.




Fonte: Elaboração própria.

A Figura 14 ilustra a evolução temporal do HI real e previsto para um rolamento específico do conjunto de teste (Rolamento 3_3). A previsão média do ensemble (linha tracejada vermelha) consegue capturar a tendência geral de crescimento do HI real (linha preta sólida), mas o faz de forma excessivamente suavizada e com uma subestimação significativa, particularmente na fase final da operação do rolamento. As previsões dos seis modelos individuais que compõem o ensemble (linhas pontilhadas mais claras) demonstram

uma considerável variabilidade entre si, sugerindo que cada modelo pode ter convergido para soluções ligeiramente diferentes durante o treinamento Leave-One-Out, possivelmente devido à pequena quantidade de dados disponíveis em cada fold de validação.


Figura 14: Evolução temporal do HI real e previsto (ensemble e individual) para o rolamento Rolamento 3_3 do conjunto de teste.




Fonte: Elaboração própria.

Para investigar a capacidade do modelo de se ajustar aos dados vistos durante o treinamento e avaliar a ocorrência de overfitting, a Figura 15 apresenta a evolução do HI para dois rolamentos representativos do conjunto de treinamento (Rolamento 1_1 e Rolamento 2_1). Observa-se um ajuste visivelmente melhor entre o HI previsto pelo ensemble e o HI real nestes casos. As previsões acompanham as flutuações dos dados de forma muito mais próxima do que o observado nos rolamentos de teste. Este contraste acentuado entre o bom ajuste nos dados de treino/validação e o desempenho inferior em dados não vistos reforça a hipótese de que o modelo, embora capaz de aprender os padrões presentes nos limitados dados de treinamento, não conseguiu construir uma representação suficientemente robusta para generalizar eficazmente para novos rolamentos com diferentes trajetórias de degradação. Isso sugere um cenário de overfitting ou, mais fundamentalmente, que a informação contida nos seis rolamentos de treino do dataset PRONOSTIA não é suficiente para cobrir toda a variabilidade dos processos de falha encontrados no conjunto de teste.

Figura 15: Evolução temporal do HI real e previsto (ensemble e individual) para dois rolamentos do conjunto de treinamento, ilustrando o ajuste do modelo aos dados vistos.



(a) Rolamento 1.1 (Treino)



(b) Rolamento 2.1 (Treino)

Fonte: Elaboração própria.

4.2.2 Desempenho na Estimativa da RUL

A estimativa da RUL foi realizada ajustando-se uma curva exponencial aos dados de HI previstos pelo ensemble (monotonicamente corrigidos) para cada rolamento de teste e extrapolando-se essa curva até $HI=1.0$. A configuração do ajuste exponencial (ponderado,

com fator de ponderação $F = 50.0$ nos $N = 64$ pontos iniciais e finais, e utilizando o HI previsto monotonicamente corrigido) foi definida manualmente após exploração preliminar, visando robustez.

O Score Médio Final obtido no conjunto de teste, calculado conforme a métrica do desafio IEEE PHM 2012, foi de **0.1875**. Este valor é significativamente inferior ao reportado por Huang et al. (2020) (0.56) para a mesma metodologia base. A Tabela 5 apresenta os resultados detalhados da previsão de RUL para cada um dos 11 rolamentos do conjunto de teste.


Tabela 5: Resultados detalhados da previsão de RUL para o conjunto de teste de rolamentos (Ensemble LSTM, Ajuste Exponencial Ponderado, Monotônico).

Rolamento	Ajuste	RUL Real (s)	RUL Predito (s)	PE (%)	Score (Ai)
Rolamento 1_3	Exponential	5730	5243	8.50%	0.7449
Rolamento 1_4	Exponential	339	0	100.00%	0.0312
Rolamento 1_5	Exponential	1610	44159	-2642.81%	0.0000
Rolamento 1_6	Exponential	1460	882	39.59%	0.2536
Rolamento 1_7	Exponential	7570	7227	4.53%	0.8546
Rolamento 2_3	Exponential	7530	2276	69.77%	0.0891
Rolamento 2_4	Exponential	1390	0	100.00%	0.0312
Rolamento 2_5	Exponential	3090	544	82.40%	0.0575
Rolamento 2_6	Exponential	1290	5580	-332.56%	0.0000
Rolamento 2_7	Exponential	580	1976	-240.67%	0.0000
Rolamento 3_3	Exponential	820	1938	-136.39%	0.0000
Score Médio Final (PHM 2012):					0.1875


Fonte: Elaboração própria.

Os scores individuais variaram consideravelmente, desde 0.0000 (indicando erro de previsão muito grande ou previsão muito tardia) para quatro rolamentos, até 0.8546 para o **Rolamento 1_7** (o melhor resultado). Dois rolamentos (Rolamento 1_4 e Rolamento 2_4) tiveram a RUL prevista como zero, resultando em 100% de erro percentual e scores muito baixos. As demais previsões foram antecipadas, com diferentes graus de acerto. Nenhuma falha no cálculo da RUL (resultado NaN) foi registrada com o ajuste exponencial. A Figura 16 ilustra o processo de ajuste da curva exponencial e extrapolação da RUL para os **rolamentos representativos** do conjunto de teste (Rolamentos 1_3, 1_7 e 3_3). O conjunto completo de resultados é apresentado no Apêndice B.


Figura 16: Resultado da predição de RUL para rolamentos representativos do conjunto de teste, incluindo o melhor (1.7) e o pior (3.3, RPN mais alto).



(a) Rolamento 1.3 (Score: 0.74)



(b) Rolamento 1.7 (Score: 0.85)



(c) Rolamento 3.3 (Score: 0.00)

Fonte: Elaboração própria.

4.2.3 Análise de Sensibilidade das Features e Interpretabilidade do Modelo

A análise de sensibilidade, realizada no primeiro modelo do ensemble para uma amostra de teste específica (índice 1130, predição original HI = 0.1643), buscou entender como perturbações nas features de entrada influenciavam a predição do HI. Esta etapa é crucial para avaliar a explicabilidade do modelo e verificar se ele aprendeu relações fisicamente coerentes.

Features do Domínio do Tempo (Escaladas): A Tabela 6 apresenta as cinco features do domínio do tempo que causaram a maior mudança absoluta na predição do HI quando seus valores (na escala transformada) foram perturbados em ± 1.0 desvio padrão.

Tabela 6: Sensibilidade das Top 5 features do domínio do tempo na predição de HI de rolamentos.

Feature	MaxAbsDiff	Diff_+1std	Diff_-1std
h_skewness	0.7581	-0.0276	0.7581
h_kurtosis	0.5083	0.5083	-0.0423
v_entropy	0.3514	0.3514	-0.0295
v_skewness	0.2750	0.2750	-0.0445
h_entropy	0.2206	-0.0264	0.2206

Fonte: Elaboração própria.

As features estatísticas de ordem superior (assimetria e curtose) e as de entropia, tanto do sensor horizontal (h) quanto do vertical (v), demonstraram a maior sensibilidade a perturbações. Isso sugere que o modelo LSTM utiliza essas informações, que capturam mudanças na forma da distribuição do sinal de vibração, para refinar suas previsões do estado de degradação.

Features de Similaridade (Não Escaladas): A Tabela 7 mostra as cinco features de similaridade com maior impacto quando perturbadas em ± 0.1 (valor absoluto).

Tabela 7: Sensibilidade das Top 5 features de similaridade na predição de HI de rolamentos.

Feature	MaxAbsDiff	Diff_+Perturb (+0.1)	Diff_-Perturb (-0.1)
v_sim_corr_Fn	0.0242	-0.0144	0.0242
h_sim_corr_Fn	0.0073	-0.0073	0.0072
v_sim_dist_Fn	0.0033	0.0033	-0.0030
v_sim_corr_Ff	0.0033	0.0033	-0.0028
h_sim_dist_Fn	0.0028	0.0028	-0.0023

Fonte: Elaboração própria.

As features de correlação com o template normal (Fn), tanto horizontal quanto vertical, mostraram a maior sensibilidade entre as features de similaridade. Notavelmente, a magnitude do impacto (MaxAbsDiff) das features de similaridade foi consideravelmente menor do que a das features de tempo para as perturbações aplicadas. No entanto, o aspecto mais importante desta análise reside na *direcionalidade* das relações aprendidas. Observou-se que:

- Um aumento na correlação com o template normal (`h_sim_corr_Fn`, `v_sim_corr_Fn`) resultou em uma diminuição do HI previsto (Diff_+Perturb negativo). Isso indica que o modelo associou corretamente uma maior similaridade com o estado saudável a um menor nível de degradação.
- Um aumento na correlação com o template de falha (`v_sim_corr_Ff`, `h_sim_corr_Ff`) resultou em um aumento do HI previsto. Isso sugere que o modelo aprendeu a associar uma maior similaridade com o estado de falha a um maior nível de degradação.

Essa confirmação da coerência física das relações aprendidas, especialmente para as *features* de similaridade que foram o foco deste estudo, é um resultado positivo e significativo. Demonstra que, apesar das métricas gerais de desempenho não serem ideais, o modelo conseguiu capturar aspectos relevantes da física da degradação, o que é um passo importante na construção de confiança em modelos de IA aplicados à engenharia mecânica.

4.2.4 Discussão dos Resultados do Prognóstico de Rolamentos

O desempenho do modelo ensemble LSTM na previsão do HI e, subsequentemente, na estimativa da RUL dos rolamentos do dataset PRONOSTIA, apresentou desafios significativos, resultando em um score PHM 2012 (0.1875) consideravelmente inferior ao valor de referência (0.56) do estudo de Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020). A principal causa para essa discrepância reside, muito provavelmente, na dificuldade intrínseca de generalização do modelo LSTM com o número extremamente limitado de dados de treinamento (apenas seis rolamentos "run-to-failure"). O dataset PRONOSTIA, embora seja um benchmark padrão, oferece apenas dois exemplos de cada uma das três condições operacionais para treinamento. A alta variabilidade nos tempos de vida útil e nas trajetórias de degradação, mesmo entre rolamentos operados sob as mesmas condições, torna a tarefa de aprender uma representação robusta da falha a partir de tão poucos exemplos um desafio formidável para um modelo complexo como o LSTM. A instabilidade observada nas previsões dos modelos individuais do ensemble (Figura 14) corrobora essa hipótese, sugerindo que cada fold da validação cruzada Leave-One-Out pode ter resultado em modelos com características de aprendizado ligeiramente diferentes.

Análise de Risco (FMEA) e a Natureza Conservadora do Prognóstico.

Apesar das limitações de precisão, a avaliação de um sistema de prognóstico deve ser primariamente guiada pelo risco, conforme antecipado na Seção 3.3.2. O Quadro 2 detalha a Análise de Modos e Efeitos de Falha (FMEA) para o sistema de predição de RUL.

Quadro 2: Análise FMEA detalhada para o sistema de IA de prognóstico de rolamentos.

Função / Processo	Requisito	Modo de Falha Potencial	S	Efeito Potencial da Falha	O	Causa Potencial da Falha	D	RPN	Ações Recomendadas
Sistema de Prognóstico de RUL	Prever a vida útil remanescente para permitir o planejamento da manutenção e evitar falhas não planejadas.	Previsão Tardia (RUL Predita > RUL Real)	10	Parada de produção não planejada; danos secundários a componentes adjacentes (eixo, motor); risco à segurança do operador .	4	1. Modelo não generaliza devido à escassez de dados de treinamento. 2. Trajetória de degradação do rolamento é atípica e não vista no treino.	7	280	1. Implementar o modelo com um fator de segurança , ajustando a predição para ser mais conservadora. 2. Iniciar um plano de coleta de dados contínua (Melhoria Contínua - ISO 42001). 3. Manter alarmes de vibração de alto nível como redundância.
		Previsão Precoce (RUL Predita < RUL Real)	5	Custo de manutenção (mão de obra, peça); parada de produção planejada; desperdício da vida útil remanescente do componente.	6	1. Modelo excessivamente conservador para evitar o risco de previsão tardia. 2. Ruído no sinal de vibração interpretado erroneamente como degradação severa.	2	60	1. Aprimorar o algoritmo de ajuste de curva para ser mais robusto a ruídos. 2. Usar a análise de sensibilidade (XAI) para entender os gatilhos das previsões e refinar o modelo. 3. Implementar um processo de feedback onde os técnicos reportam o estado real das peças substituídas.

Fonte: Elaboração própria.

A análise FMEA evidencia que o RPN de uma Previsão Tardia (280) é drasticamente maior que o de uma Previsão Precoce (60), primariamente devido à severidade máxima associada aos riscos de segurança. Isso reforça que, mesmo um modelo com precisão limitada, pode agregar valor se sua implementação for conservadora, favorecendo erros de previsão precoce. A escolha da curva exponencial para a extrapolação da RUL foi uma decisão pragmática alinhada a este princípio, visando garantir a convergência e favorecer previsões antecipadas.

Validação da Confiança via Análise de Sensibilidade.

Apesar do desempenho quantitativo abaixo do esperado, a análise de sensibilidade proporcionou aprendizados valiosos para a validação da confiança no modelo. A confirmação de que o modelo aprendeu relações direcionalmente corretas e fisicamente coerentes com as *features* de similaridade é um ponto crucial. Isso indica que, mesmo com dados limitados, o modelo não se tornou uma "caixa-preta" que aprende correlações espúrias, mas sim capturou, ao menos parcialmente, a lógica esperada da degradação. A maior sensibilidade observada na correlação com o *template* normal (F_n) sugere que o afastamento gradual do estado saudável é um indicador robusto da degradação. Este achado é fundamental, pois demonstra a importância da explicabilidade como ferramenta para validar o conhecimento aprendido, mesmo quando as métricas de resultado final não são ótimas.

Enquadramento no Ciclo de Governança e Melhoria da ISO 42001.

A análise FMEA e de sensibilidade, em conjunto, fornecem o contexto essencial para enquadrar este estudo de caso sob a ótica de um sistema de gestão como o da ABNT NBR ISO/IEC 42001. A FMEA (Quadro 2) quantifica o risco, validando que o modelo, apesar de seu score preditivo subótimo, se qualifica como uma ferramenta válida para o **tratamento de risco de IA (Seção 8.3)**, especialmente por mitigar o modo de falha de maior severidade (Previsão Tardia).

Nesse cenário de risco gerenciado, a confiança na tecnologia torna-se o fator decisivo para sua adoção. É aqui que a explicabilidade se mostra fundamental. A validação da coerência física do modelo (via análise de sensibilidade) serve como a evidência técnica crucial para que a gestão possa, durante a **Análise Crítica pela Direção (Seção 9.3)**, aprovar o uso da tecnologia com um grau de confiança informado, assegurando que o sistema não opera como uma "caixa-preta" inexplicável.

O sistema de gestão, por sua vez, enquadra as limitações identificadas em ações estruturadas. A escassez de dados é formalmente tratada como um ponto de partida para os processos de **Não conformidade e ação corretiva (Seção 10.2)** e **Melhoria Contínua (Seção 10.1)**. A estrutura da norma exige, então, que a organização planeje ações para tratar essa causa-raiz, como a coleta sistemática de mais dados "run-to-failure".

Desta forma, o modelo desenvolvido assume seu papel como o componente inicial e validado de um ciclo de vida gerenciado. A estrutura da ISO 42001 garante seu aprimoramento contínuo, processo este viabilizado pela confiança que a XAI proporciona.

4.3 Discussão Consolidada e Comparativa

Os dois estudos de caso apresentados neste trabalho, embora abordem domínios distintos da engenharia mecânica – a predição da qualidade na moldagem por injeção plástica e o prognóstico da vida útil remanescente de rolamentos – compartilham o objetivo

fundamental de explorar a aplicação de técnicas de Inteligência Artificial para solucionar problemas práticos e relevantes. A análise individual de cada estudo já forneceu insights específicos sobre o desempenho e a explicabilidade dos modelos desenvolvidos. Esta subseção visa consolidar esses aprendizados, comparando e contrastando as metodologias, os desafios enfrentados, os resultados obtidos e as lições transversais extraídas, com o intuito de fornecer uma perspectiva mais ampla sobre a aplicação da IA na engenharia.

A natureza intrínseca dos problemas investigados apresentou distinções fundamentais. O estudo de caso da injeção plástica configurou-se como um problema de **diagnóstico preditivo**, visando a classificação multiclasse da qualidade de uma peça (*OK*, *NOK Rebarba*, *NOK Preenchimento*) com base nos parâmetros de máquina configurados para o próximo ciclo de produção. Em contraste, o estudo de rolamentos abordou um problema de **prognóstico**, focado na predição de um estado futuro distante – a Vida Útil Restante (RUL) – através da estimação de um Indicador de Saúde (HI) como uma variável de regressão intermediária. Esta diferença inerente implicou maior complexidade e incerteza no problema de prognóstico, onde a extrapolação para o futuro distante amplifica os erros da predição do HI. As métricas de avaliação também refletiram essa distinção: F1-Score e Recall foram cruciais para o diagnóstico na injeção, enquanto o score PHM 2012, sensível a erros percentuais e assimétricos na RUL, foi o critério principal para os rolamentos.

A análise dos dados e a etapa de engenharia de features também revelaram particularidades. Para a injeção plástica, os dados consistiam em parâmetros de processo diretamente mensuráveis da máquina, permitindo uma engenharia de features relativamente direta (razões, produtos, transformações polinomiais) para capturar interações. No estudo de rolamentos, partiu-se de sinais brutos de vibração do dataset PRONOSTIA, exigindo um processamento mais elaborado para a extração de features estatísticas do domínio do tempo e, notavelmente, das features de similaridade baseadas em espectros de frequência, conforme proposto por Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020). Esta última abordagem, embora conceitualmente rica e informada pelo conhecimento do domínio da dinâmica de falhas, adiciona uma camada de complexidade na geração das variáveis de entrada. Ambos os estudos, no entanto, enfrentaram desafios relacionados aos dados: um forte **desbalanceamento de classes** no caso da injeção, que exigiu o uso de pesos de classe para mitigar o viés do modelo; e uma crítica **escassez de dados de treinamento** no estudo de rolamentos, com apenas seis rolamentos "run-to-failure" do PRONOSTIA, o que se mostrou um fator limitante severo para a capacidade de generalização do modelo LSTM.

As abordagens de modelagem refletiram as características de cada problema. No estudo de injeção, uma gama de modelos clássicos (Random Forest, XGBoost) e uma Rede Neural Artificial (RNA) otimizada foram explorados. Enquanto modelos baseados em árvores demonstraram F1-Scores Macro competitivos, a RNA otimizada foi o foco da análise de explicabilidade XAI e apresentou um bom recall para as classes de defeito minoritárias.

Para o prognóstico de rolamentos, a escolha recaiu sobre um ensemble de LSTMs, alinhando-se com a literatura de referência e com a adequação desta arquitetura para modelar dados sequenciais de degradação. O desempenho, contudo, divergiu significativamente: na injeção, obteve-se alta performance preditiva geral (acurácia > 99%, F1-Macro da RNA 0.92), enquanto no estudo de rolamentos, o score PHM 2012 (0.1875) ficou aquém do valor de referência (0.56), evidenciando o desafio da generalização com dados limitados, mesmo com uma estratégia de ensemble Leave-One-Out. O contraste entre o bom ajuste do HI nos dados de treinamento dos rolamentos e o desempenho inferior no teste (Figuras 15 e 14) ilustrou claramente este ponto.

A **explicabilidade e interpretabilidade (XAI)** dos modelos foram componentes centrais de análise em ambos os estudos, embora com técnicas e resultados distintos. Para a RNA no estudo de injeção plástica, a aplicação do SHAP (Figuras 9 a 12) permitiu identificar a importância relativa das features (como Almofada A e a razão TI.TP) e, com ressalvas, a direção de suas influências para cada classe de defeito. No entanto, conforme discutido na Seção 4.1, a baixa magnitude geral dos valores SHAP e a concentração de pontos próximos a zero indicaram que, embora preditivamente eficaz, a RNA opera de maneira complexa, dificultando uma atribuição causal simples e direta a features individuais. No estudo de rolamentos, a análise de sensibilidade (Tabelas 6 e 7), mesmo sendo uma técnica mais simples, foi fundamental para confirmar a coerência física do aprendizado do modelo LSTM em relação às features de similaridade: o modelo corretamente associou maior similaridade com o template normal a um menor nível de degradação, e vice-versa para o template de falha. Este achado é metodologicamente relevante, pois valida parcialmente o conhecimento aprendido pelo modelo, mesmo que seu desempenho preditivo global na RUL tenha sido subótimo. Ambos os casos ressaltam que, enquanto a XAI oferece ferramentas valiosas, a interpretabilidade de modelos complexos como redes neurais permanece um campo ativo de pesquisa e desafio (ARRIETA et al., 2020).

Alguns desafios e aprendizados transversais emergiram da comparação destes estudos. A **qualidade e quantidade de dados** são, inegavelmente, os pilares para o sucesso de qualquer aplicação de IA. O desbalanceamento e, principalmente, a escassez de dados representativos de todas as fases de operação e falha, limitam diretamente o potencial de generalização dos modelos. A engenharia de features informada pelo domínio (como as features de similaridade) demonstrou ser uma estratégia valiosa, mas não elimina a necessidade de dados suficientes. Além disso, a etapa final do prognóstico – converter um indicador de saúde em uma estimativa de RUL precisa através de ajuste de curvas e extrapolação – introduz sua própria camada de incerteza e sensibilidade a erros na predição do indicador base. A dificuldade em replicar exatamente os resultados de estudos da literatura, mesmo seguindo metodologias descritas, também é um lembrete da sensibilidade dos modelos de IA a pequenos detalhes de implementação e à variabilidade intrínseca dos dados.

Em termos de implicações práticas, o modelo de predição de qualidade para injeção plástica, com seu bom recall para defeitos e os insights da análise SHAP, tem potencial para auxiliar operadores na configuração proativa da máquina. Já a aplicação para prognóstico de rolamentos, embora com desempenho de RUL abaixo do ideal neste estudo, reforça a importância de validar o aprendizado dos modelos e sugere que, para aplicações industriais críticas com dados limitados, abordagens híbridas ou a integração com modelos baseados em física podem ser necessárias. Em ambos os casos, a capacidade de explicar, mesmo que parcialmente, as decisões do modelo é crucial para construir a confiança necessária para sua adoção em ambientes industriais.

Concluindo esta análise comparativa, os estudos de caso ilustram a adaptabilidade da IA para diferentes problemas na engenharia mecânica, mas também sublinham que não há soluções genéricas. O sucesso depende de uma compreensão profunda do problema, da qualidade dos dados, de uma metodologia de modelagem rigorosa e, cada vez mais, da capacidade de interpretar e validar o conhecimento incorporado nos modelos desenvolvidos.

5 CONCLUSÃO

Este Trabalho de Conclusão de Curso dedicou-se a investigar a aplicação e a análise metodológica de técnicas de Inteligência Artificial, com particular ênfase no Aprendizado de Máquina e no Aprendizado Profundo, para a solução de problemas práticos de diagnóstico e prognóstico na engenharia mecânica. Através de dois estudos de caso distintos – a predição da qualidade de peças no processo de moldagem por injeção plástica e o prognóstico da vida útil remanescente (RUL) de rolamentos – buscou-se não apenas desenvolver modelos preditivos, mas, crucialmente, avaliar sua explicabilidade e a coerência do conhecimento por eles aprendido, ressaltando os desafios e aprendizados inerentes a cada abordagem.

No primeiro estudo de caso, focado na predição antecipada da qualidade das peças produzidas por injeção plástica, o objetivo de desenvolver um modelo capaz de classificar peças como conformes (OK) ou com defeitos específicos (NOK Rebarba, NOK Preenchimento) antes do ciclo produtivo foi alcançado com sucesso considerável. O modelo de Rede Neural Artificial (RNA) otimizado demonstrou alta capacidade preditiva, alcançando uma acurácia geral de 99,39% e, mais importante, um recall de 0.91 para a classe crítica "NOK (Preenchimento)", minimizando falsas conformidades. A análise de explicabilidade via SHAP, embora tenha revelado a complexidade interpretativa inerente à RNA, identificou parâmetros de processo chave, como a Almofada (A) e a razão entre Tempo de Injeção e Tempo de Plastificação (TI_TP), como os mais influentes, com direções de impacto que, em muitos casos, alinharam-se com o conhecimento técnico do processo.

O segundo estudo de caso, dedicado ao prognóstico da RUL de rolamentos, visou replicar e analisar a metodologia de Huang et al. (2020) (HUANG; FARAHAT; GUPTA, 2020), empregando features de similaridade e um ensemble de LSTMs no dataset PRONOS-TIA. Embora a análise de sensibilidade tenha validado a coerência física do aprendizado do modelo em relação às inovadoras features de similaridade – um achado metodológico importante –, o desempenho preditivo na estimativa do Indicador de Saúde (HI) e, consequentemente, da RUL (score PHM 2012 de 0.1875) mostrou-se significativamente inferior ao reportado na literatura de referência. Este resultado foi primariamente atribuído à escassez crítica de dados de treinamento (apenas seis rolamentos "run-to-failure"), que limitou severamente a capacidade de generalização do complexo modelo LSTM. Mesmo assim, o estudo proporcionou aprendizados valiosos sobre os desafios da replicação e da aplicação de aprendizado profundo em cenários com dados limitados.

As principais contribuições deste trabalho residem na aplicação prática e na análise comparativa de abordagens de IA em diferentes contextos da engenharia mecânica, com uma ênfase metodológica na validação do conhecimento aprendido pelos modelos através de técnicas de XAI. Demonstrou-se que a interpretabilidade, mesmo que parcial, é fundamental para construir confiança e extrair valor, independentemente do nível de desempenho preditivo absoluto. Os estudos sublinharam a criticidade da qualidade e quantidade dos

dados, bem como os desafios intrínsecos ao desbalanceamento de classes e à generalização de modelos.

As limitações inerentes a este estudo incluem a dependência dos datasets específicos utilizados, que podem não representar toda a gama de variabilidade industrial. No caso dos rolamentos, a escassez de dados foi a principal barreira. Para a injeção plástica, a complexidade da interpretabilidade da RNA, mesmo com SHAP, aponta para a necessidade contínua de desenvolvimento em XAI. Adicionalmente, a replicação exata de metodologias da literatura pode ser dificultada por detalhes de implementação não totalmente especificados nos trabalhos originais.

Em termos de implicações práticas para a engenharia, os resultados apontam caminhos distintos. O modelo de predição de qualidade para injeção plástica, com seu bom recall para defeitos e os insights da análise SHAP, demonstra potencial imediato para auxiliar operadores na configuração proativa de máquinas. Já a aplicação para prognóstico de rolamentos, embora com desempenho de RUL abaixo do ideal neste estudo, reforça a importância crítica de validar o aprendizado dos modelos. O estudo sugere que, para aplicações industriais críticas com dados limitados, abordagens híbridas ou a integração com modelos baseados em física podem ser necessárias para garantir a robustez exigida.

Concluindo, este trabalho ilustra a adaptabilidade da IA para diferentes problemas na engenharia mecânica, mas sublinha que não há soluções genéricas. O sucesso depende de uma compreensão profunda do problema, da qualidade dos dados e de uma metodologia de modelagem rigorosa. Em suma, reforça-se o papel transformador da Inteligência Artificial, destacando que a busca por modelos que não apenas prevejam com precisão, mas que também ofereçam um grau de transparência e interpretabilidade, continuará a ser o vetor crucial para a inovação e a adoção bem-sucedida e segura dessas tecnologias na indústria.

5.1 Trabalhos Futuros

Com base nos aprendizados e limitações identificadas ao longo deste trabalho, diversas direções promissoras para pesquisas futuras podem ser delineadas, visando aprimorar a aplicação da Inteligência Artificial nos contextos estudados e em desafios similares na engenharia mecânica:

- **Para o Estudo de Caso de Injeção Plástica:**
 - Investigar de forma mais aprofundada técnicas de tratamento de desbalanceamento de classes, como algoritmos de data augmentation específicos para dados tabulares ou o desenvolvimento de funções de perda customizadas que penalizem mais severamente erros nas classes minoritárias.
 - Explorar arquiteturas de ensemble mais sofisticadas, combinando as forças de diferentes tipos de modelos (ex: árvores de decisão e redes neurais) para potencialmente melhorar a precisão e o F1-Score da classe "NOK (Preenchimento)".

- Expandir o conjunto de features, incorporando, se possível, dados sobre as propriedades do material polimérico utilizado em cada ciclo ou medições diretas da temperatura do molde, que podem influenciar significativamente a qualidade da peça.
- Desenvolver um protótipo de sistema de suporte à decisão ou alerta para operadores, que integre o modelo preditivo e traduza os insights da análise SHAP em recomendações práticas para o ajuste dos parâmetros da máquina antes do início da produção.

- **Para o Estudo de Caso de Prognóstico de Rolamentos:**

- Priorizar a investigação de técnicas robustas para aprendizado com dados escassos, como o uso de transfer learning (aproveitando conhecimento de modelos pré-treinados em datasets de vibração maiores ou em simulações de degradação) ou meta-learning.
- Explorar arquiteturas de aprendizado profundo alternativas ou híbridas, como modelos que combinem Redes Neurais Convolucionais (CNNs) para extração automática de features dos sinais de vibração brutos e LSTMs para modelagem temporal (CNN-LSTM), ou o uso de arquiteturas baseadas em Transformers, que têm mostrado promessa em séries temporais.
- Aprimorar a metodologia de estimativa da RUL a partir do HI, investigando métodos de ajuste de curva mais flexíveis e robustos a ruídos, ou abordagens que modelem diretamente a RUL ou a probabilidade de falha, como modelos de sobrevivência ou abordagens bayesianas para propagação de incerteza.
- Validar a eficácia das features de similaridade em outros datasets de rolamentos ou com diferentes métodos para aprendizado e atualização dos templates de condição normal e de falha.

- **Direções Gerais para Aplicação de IA na Engenharia Mecânica:**

- Continuar o desenvolvimento e a aplicação de técnicas de Inteligência Artificial Explicável (XAI) que sejam não apenas capazes de fornecer importâncias de features, mas também de gerar explicações contrafactuais ou baseadas em regras que sejam mais intuitivas para engenheiros e operadores.
- Realizar estudos de caso sobre a implementação e o impacto de sistemas de IA em ambientes de produção reais, avaliando não apenas o desempenho técnico, mas também a usabilidade, a aceitação pelos usuários e o retorno sobre o investimento.
- Incentivar a criação e disponibilização de benchmarks e datasets públicos mais ricos e diversificados para problemas de diagnóstico e prognóstico em engenharia

mecânica, especialmente aqueles que incluem dados de múltiplos sensores e informações contextuais detalhadas sobre os processos e falhas.

- Investigar abordagens de aprendizado online ou adaptativo, onde os modelos de IA possam ser continuamente atualizados e refinados com novos dados coletados em tempo real durante a operação dos sistemas.

A contínua exploração dessas linhas de pesquisa é essencial para desbloquear todo o potencial da Inteligência Artificial na transformação da engenharia mecânica e na otimização dos processos industriais.

APÊNDICES

A CRITÉRIOS DE PONTUAÇÃO PARA ANÁLISE FMEA

O Quadro 3 apresenta os critérios utilizados para a atribuição das pontuações de Ocorrência (O), Severidade (S) e Detecção (D) nas análises FMEA conduzidas neste trabalho. As escalas e descrições foram adaptadas de manuais de referência em engenharia de confiabilidade.

Quadro 3: Tabela de referência para pontuação FMEA.


OCORRÊNCIA (O)		SEVERIDADE (S)		DETECÇÃO (D)	
Nota	Probabilidade	Nota	Critério	Nota	Probabilidade
1	Remota / Improvável	1	Efeito não detectável	1	Praticamente Certa
2	Muito Baixa	2	Baixa Severidade	2	Muito Alta
3	Pouco Frequente	3		3	Alta
4	Baixa	4	Severidade Moderada	4	Moderadamente Alta
5	Ocasional	5		5	Moderada
6	Moderada	6	Severidade Alta	6	Baixa
7	Frequente	7		7	Muito Baixa
8	Elevada	8		8	Remota
9	Muito Elevada	9	Severidade Muito Alta	9	Muito Remota
10	Máxima / Inevitável	10		10	Pratic. Impossível

Fonte: Elaborado pelo autor, baseado na Associação Brasileira de Normas Técnicas (2013).


B GRÁFICOS COMPLETOS DE PREDIÇÃO DE RUL

B.1 Condição Operacional 1


Figura 17: Resultado da predição de RUL para rolamentos 1.3, 1.4 e 1.5 (Condição Operacional 1).



(a) Rolamento 1_3




(b) Rolamento 1_4




(c) Rolamento 1_5

Fonte: Elaboração própria.

Figura 18: Resultado da predição de RUL para rolamentos 1.6 e 1.7 (Condição Operacional 1).



(a) Rolamento 1.6




(b) Rolamento 1.7


Fonte: Elaboração própria.

B.2 Condições Operacionais 2 e 3


Figura 19: Resultado da predição de RUL para rolamentos 2.3, 2.4 e 2.5 (Condições Operacionais 2 e 3).



(a) Rolamento 2.3




(b) Rolamento 2.4




(c) Rolamento 2.5

Fonte: Elaboração própria.


Figura 20: Resultado da predição de RUL para rolamentos 2.6, 2.7 e 3.3 (Condições Operacionais 2 e 3).



(a) Rolamento 2.6



(b) Rolamento 2.7



(c) Rolamento 3.3

Fonte: Elaboração própria.

REFERÊNCIAS

- ABNT. *NBR 5462: Confiabilidade e manutenibilidade - Terminologia*. Rio de Janeiro, 1994. 37 p.
- AMIT. *How to Visualize a Decision Tree in Python with Scikit-Learn?* 2024. *VitalFlux*. Publicado em 4 de jan. de 2024. Disponível em: <https://vitalflux.com/visualize-decision-tree-python-sklearn-library/>. Acesso em: 12 jun. 2025.
- ARABACI, H.; LAVING, S. Weld defect categorization from welding current using principle component analysis. *International Journal of Advanced Computer Science and Applications*, v. 10, n. 6, p. 205–211, 2019.
- ARRIETA, A. B. et al. Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges. *Information Fusion*, Elsevier, v. 58, p. 82–115, 2020.
- Associação Brasileira de Normas Técnicas. *ABNT NBR IEC 60812: Técnicas de análise de confiabilidade de sistema - Procedimento para análise dos modos de falha e seus efeitos (FMEA)*. Rio de Janeiro, 2013. 73 p.
- Associação Brasileira de Normas Técnicas. *ABNT NBR ISO/IEC 42001:2024 - Tecnologia da informação — Inteligência artificial — Sistema de gestão*. Rio de Janeiro, Brazil, 2024. Based on ISO/IEC 42001:2023.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001.
- BRYCE, D. M. *Plastic Injection Molding: Manufacturing Process Fundamentals*. [S.l.]: Society of Manufacturing Engineers, 1996.
- CARVALHO, E. et al. Uso de redes neurais recorrentes para localização de agentes em ambientes internos. 2012.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. [S.l.: s.n.], 2016. p. 785–794.
- CHIFFRE, L. D. et al. Industrial applications of computed tomography. *CIRP annals*, Elsevier, v. 63, n. 2, p. 655–677, 2014.
- CHU, H.-H.; WANG, Z.-Y. A vision-based system for post-welding quality measurement and defect detection. *International Journal of Advanced Manufacturing Technology*, v. 86, p. 3007–3014, 2016.
- DIAO, Y. et al. Machine learning-based prediction of comprehensive properties of selective laser melted 18ni300 maraging steel parts for plastic injection molding dies. *Additive Manufacturing*, v. 45, p. 102068, 2021.
- FELTRAN, L. C. Identificação de fraudes de pagamentos no tribunal de justiça de são paulo. 2020.
- FÁVERO, L. P.; BELFIORE, P. *Manual de análise de dados: Estatística e modelagem multivariada com Excel®, SPSS® e Stata®*. [S.l.]: Elsevier Brasil, 2017.

- GREZMAK, J.; EVERSON, L.; JOHNSON, D. Interpretable machine learning for defect prediction in additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 116, n. 9, p. 2827–2841, 2021.
- HASSIJA, V. et al. Interpreting black-box models: A review on explainable artificial intelligence. *Cognitive Computation*, 2023.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 1997.
- HUANG, W.; FARAHAT, A. K.; GUPTA, C. Similarity-based feature extraction from vibration data for prognostics. In: *Annual Conference of the PHM Society*. [S.l.: s.n.], 2020. v. 12, n. 1.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. Non-destructive testing of welds – Visual testing of fusion-welded joints. n. ISO 17637, 2016.
- JIA, F. et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery. *Mechanical systems and signal processing*, Elsevier, v. 72, p. 311–324, 2016.
- JIN, C. et al. Prediction model for back-bead monitoring during gas metal arc welding using supervised deep learning. *IEEE Access*, v. 8, p. 224044–224058, 2020.
- KAGERMANN, H.; WAHLSTER, W. Ten years of industrie 4.0. *Sci*, MDPI, v. 4, n. 3, p. 26, 2022.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.
- LEI, Y. et al. Machinery health prognostics: A systematic review from data-driven methods. *Mechanical Systems and Signal Processing*, Elsevier, v. 135, p. 106385, 2020.
- LOPES, B.; SOUSA, J.; ALENYÀ, G. Machine learning methods for quality prediction in thermoplastics injection molding. In: *2021 IEEE International Conference on Electrical, Computer and Energy Technologies (ICECET)*. Cape Town, South Africa (Virtual): [s.n.], 2021. p. 1–6.
- LOPEZ, A. et al. Non-destructive testing application of radiography and ultrasound for wire and arc additive manufacturing. *Additive Manufacturing*, v. 21, p. 298–306, 2018.
- LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. In: *Advances in Neural Information Processing Systems 30 (NIPS 2017)*. [S.l.: s.n.], 2017. p. 4765–4774.
- MALDAGUE, X. Theory and practice of infrared technology for nondestructive testing. (*No Title*), 2001.
- MOBLEY, R. K. *An introduction to predictive maintenance*. [S.l.]: Elsevier, 2002.
- MOUBRAY, J. *Reliability-centered maintenance*. [S.l.]: Industrial Press Inc., 2001.

NECTOUX, P. et al. PRONOSTIA: An experimental platform for bearings accelerated life test. In: *IEEE International Conference on Prognostics and Health Management (ICPHM)*. Denver, CO, USA: [s.n.], 2012.

Number Analytics. *Mastering FMEA in Systems Engineering*. 2025. <<https://www.numberanalytics.com/blog/mastering-fmea-in-systems-engineering>>. Acesso em 25 de agosto de 2025.

OGORODNYK, O. et al. Application of machine learning methods for prediction of parts quality in thermoplastics injection molding. In: *Lecture Notes in Electrical Engineering*. [S.l.: s.n.], 2019.

PALMA-RAMÍREZ, D. et al. Deep convolutional neural network for weld defect classification in radiographic images. *Heliyon*, v. 10, n. 9, p. e30590, 2024.

RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. "why should i trust you?": Explaining the predictions of any classifier. In: *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*. [S.l.: s.n.], 2016. p. 1135–1144.

RODRÍGUEZ-GONZÁLEZ, P. et al. 3d reconstruction methods and quality assessment for visual inspection of welds. *Automation in Construction*, v. 79, p. 49–58, 2017.

ROKACH, L.; MAIMON, O. Z. *Data Mining With Decision Trees: Theory And Applications*. [S.l.]: World Scientific, 2014. v. 69. (Series In Machine Perception And Artificial Intelligence, v. 69).

SAMUEL, A. L. Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, IBM, v. 3, n. 3, p. 210–229, 1959.

SIAHPOUR, S.; KIANFAR, K.; MOMENI, H. Online fault diagnosis of rolling element bearings using one-dimensional convolutional neural networks. *Journal of Vibration Engineering & Technologies*, Springer, v. 9, n. 4, p. 819–832, 2021.

SOARES, L. B. et al. A robotic passive vision system for texture analysis in weld beads. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, v. 45, n. 1, p. 1–12, 2023.

SOBREIRO, V. A. et al. Uma estimação do valor da commodity de açúcar utilizando redes neurais artificiais. *Pesquisa & Desenvolvimento em Engenharia de Produção*, v. 7, p. 36–52, 2008.

SOUALHI, A. et al. Application of the prognostic and health management to industrial systems. In: SPRINGER. *International conference on artificial intelligence in renewable energetic systems*. [S.l.], 2022. p. 652–664.

SOUZA, F. O. d. *Aplicação de Modelos de Aprendizado de Máquina para Predição na Qualidade de Peças Plásticas Injetadas*. Manaus, AM, 2023.

STAMATIS, D. H. *Failure mode and effect analysis*. [S.l.]: Quality Press, 2003.

TESSEMA, S. H.; BISMOR, D. Quality monitoring of hybrid welding processes: A comprehensive review. *Archives of Control Sciences*, v. 34, 2024.

VOEGELE, A.; PALM, G.; WEBER, M. A lightweight deep learning model for machinery fault diagnosis on edge devices. *Procedia Computer Science*, Elsevier, v. 200, p. 1159–1168, 2022.

WEN, L. et al. A new deep transfer learning based on sparse auto-encoder for fault diagnosis. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, IEEE, v. 49, n. 1, p. 143–153, 2019.

WILLARD, J. et al. Integrating scientific knowledge with machine learning for engineering and environmental systems. *ACM Computing Surveys (CSUR)*, ACM New York, NY, v. 55, n. 9, p. 1–37, 2022.

XU, H. et al. Defect detection in welding radiographic images based on semantic segmentation methods. *Measurement*, Elsevier, v. 188, p. 110569, 2022.

YAMANE, S.; MATSUO, K. Gap detection using convolutional neural network and adaptive control in robotic plasma welding. *International Journal of Automation Technology*, v. 13, n. 6, p. 796–802, 2019.

ZHANG, J.; LI, B.; WANG, X. Adversarial attacks on deep learning-based fault diagnosis models. *IEEE Transactions on Industrial Electronics*, IEEE, v. 67, n. 4, p. 3254–3263, 2020.

ZHAO, R. et al. Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, Elsevier, v. 115, p. 213–237, 2019.