

**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA CELSO SUCKOW DA FONSECA**  
**Coordenação do Curso de Engenharia Mecânica**  
**Engenharia Mecânica**

**Lucas da Silva Magalhães**  
**Pedro Bastos de Mello**

**Aplicação da Inteligência Artificial na Manutenção Preditiva de Fresadoras Industriais**

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Engenharia Mecânica, da Coordenação do Curso de Engenharia Mecânica, do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca.

Orientador: Prof. Jonatas Motta Quirino

**Rio de Janeiro**  
**2025**

Ficha catalográfica elaborada pela Biblioteca Central do CEFET/RJ

M189 Magalhães, Lucas da Silva  
Aplicação da Inteligência Artificial na manutenção preditiva de fresadoras industriais / Lucas da Silva Magalhães [e] Pedro Bastos de Mello – 2025.  
71f.: il. color., enc.  
Projeto Final (Graduação) Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, 2025.  
Bibliografia: f. 66-71.  
Orientador: Jonatas Motta Quirino.  
  
1. Engenharia mecânica. 2. Inteligência artificial.  
3. Fresadoras – Manutenção e reparos. 4. Confiabilidade (Engenharia). I. Mello, Pedro Bastos de. II. Quirino, Jonatas Motta (Orient.). III. Título.  
  
CDD 620.1

Elaborada pelo bibliotecário Leandro Mota de Menezes – CRB/7 nº 5281

## **AGRADECIMENTOS**

Ao final desta jornada acadêmica, não poderíamos deixar de expressar nossa gratidão a todos que, de alguma forma, contribuíram para a realização deste trabalho.

Primeiramente, agradecemos ao nosso professor orientador, Jonatas Motta Quirino, por todo suporte e disponibilidade. Sua experiência e incentivo foram essenciais para que este trabalho pudesse ser desenvolvido com a profundidade e a qualidade necessárias.

Agradecemos às nossas famílias e amigos, por todo o apoio, compreensão e incentivo incondicional ao longo de nossa trajetória. O apoio e a motivação de vocês nos impulsionaram a seguir em frente e concluir mais esta etapa de nossas vidas, sem vocês, nada disso teria sido possível.

À banca examinadora, agradecemos por aceitar fazer parte deste momento importante e trazer contribuições essenciais para a conclusão deste projeto.

Por fim, agradecemos ao CEFET/RJ e ao corpo docente que o constitui, por serem parte essencial e fundante da nossa formação acadêmica. Certamente levaremos seus ensinamentos para a vida.

## RESUMO

MAGALHÃES, L.S., MELLO, P.B., Aplicação da Inteligência Artificial na Manutenção Preditiva de Fresadoras Industriais. 2025. 72. Trabalho de Conclusão de Curso – Centro Federal de Educação Tecnológica Celso Suckow da Fonseca. Rio de Janeiro, 2025.

A necessidade crescente de otimização da manutenção industrial impulsionou o uso de Inteligência Artificial para prever falhas em fresadoras. Este estudo foca na aplicação da IA na manutenção preditiva, utilizando um modelo de árvore de decisão para classificar e prever falhas. O objetivo foi avaliar a eficácia da IA na redução de falhas inesperadas e no aumento da disponibilidade operacional. Dados simulados do *UCI Repository*, contendo leituras de sensores de temperatura, rotação, torque e desgaste da ferramenta, foram analisados para identificar padrões de falha. A metodologia incluiu aprendizado supervisionado, destacando árvores de decisão e *Support Vector Machine* (SVM), demonstrando alta precisão e possibilitando manutenções corretivas antes de danos severos. Melhorias em indicadores como *Mean Time Between Failures* (MTBF) e *Mean Time to Repair* (MTTR) evidenciaram a eficiência do modelo frente às abordagens tradicionais. A integração com a análise FMEA permitiu priorizar intervenções conforme a criticidade das falhas. Contudo, desafios como qualidade dos dados e variabilidade operacional exigem estudos adicionais para integrar estatísticas convencionais com IA. Recomenda-se expandir o estudo com redes neurais e algoritmos híbridos para aprimorar a precisão. Conclui-se que a IA na manutenção preditiva melhora a confiabilidade dos equipamentos e se alinha à Indústria 4.0.

**Palavras-chave:** Inteligência Artificial. Manutenção preditiva. Árvores de decisão. Confiabilidade. Indústria 4.0.

## ABSTRACT

MAGALHÃES, L.S. MELLO, P.B. Application of Artificial Intelligence in Predictive Maintenance of Industrial Milling Machines. 2025. 72. Course Completion Work - Federal Center of Technological Education Celso Suckow da Fonseca – Rio de Janeiro, 2025.

The growing need for optimizing industrial maintenance has driven the use of Artificial Intelligence (AI) to predict failures in milling machines. This study focuses on the application of AI in predictive maintenance, using a decision tree model to classify and predict failures. The objective was to evaluate the effectiveness of AI in reducing unexpected failures and increasing operational availability. Simulated data from the UCI Repository, containing sensor readings such as temperature, rotation, torque, and tool wear, were analyzed to identify failure patterns. The methodology included supervised learning, highlighting decision trees and Support Vector Machine (SVM), demonstrating high accuracy and enabling corrective maintenance before severe damage occurs. Improvements in indicators such as Mean Time Between Failures (MTBF) and Mean Time to Repair (MTTR) evidenced the model's efficiency compared to traditional approaches. Integration with FMEA analysis allowed prioritizing interventions based on failure criticality. However, challenges such as data quality and operational variability require further studies to integrate conventional statistics with AI. It is recommended to expand the study with neural networks and hybrid algorithms to enhance accuracy. It is concluded that AI in predictive maintenance improves equipment reliability and aligns with Industry 4.0.

**Keywords:** Artificial Intelligence. Predictive maintenance. Decision trees. Reliability. Industry 4.0

## LISTA DE ILUSTRAÇÕES

Figura 1 - Tipos de fresadoras .....	22
Figura 2 - Fresadora CNC .....	23
Figura 3 - Definições de IA e seus subconjuntos .....	25
Figura 4 - Fresadora Servomill Universal UWF 1200. Fonte: Knuth Machine Tools, 2025 .....	33
Figura 5 - Análise de FRN .....	43
Figura 6 - Ferramenta de corte.....	44
Figura 7 - Ferramenta de corte com lascamento.....	44
Figura 8 - Falha por Sobretensão.....	45
Figura 9 - Distribuição de calor em ferramenta de corte .....	46
Figura 10 - Falha por Dissipação de Calor .....	47
Figura 11 - Falha por Potência .....	49
Figura 12 - Falha por Desgaste da Ferramenta .....	51
Figura 13 - Resultados da Matriz de Confusão .....	52
Figura 14 - Regiões de falha (SVM) FRN.....	55
Figura 15 - Regiões de falha (SVM) FST .....	56
Figura 16 - Regiões de falha (SVM) FDC.....	58
Figura 17 - Regiões de falha (SVM) FPT .....	59
Figura 18 - Regiões de falha (SVM) FDF .....	60
Figura 19 - Probabilidade Falha em função da Potência e do Desgaste.....	61

**LISTA DE TABELAS**

Tabela 1 - Matriz de Confusão Padrão.....	38
Tabela 2 - Região de Falha 1 para FRN.....	43
Tabela 3 - Região de Falha 2 para FRN.....	43
Tabela 4 - Região de Falha 3 para FRN.....	43
Tabela 5 - Região de Falha para FST .....	45
Tabela 6 - Região de falha para FDC.....	47
Tabela 7 - Região de falha 1 para FPT .....	49
Tabela 8 - Região de falha 2 para FPT .....	49
Tabela 9 - Região de falha para FDF .....	51
Tabela 10 - Resultados da Matriz de Confusão .....	52
Tabela 11 - Resultados de Desempenho .....	53

## LISTA DE ABREVIATURAS

IA	Inteligência Artificial
ML	<i>Machine Learning</i>
IOT	Internet das Coisas
SVM	Support Vector Machine
MCC	Manutenção Centrada em Confiabilidade
RNA	Redes Neurais Artificiais
PCA	<i>Principal Component Analysis</i>
FDF	Falha por Desgaste
FDC	Falha por Dissipação de calor
FPT	Falha de Potência
FST	Falha por Sobretensão
FRN	Falhas Aleatórias

## LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
MTBF	<i>Mean Time Between Failures</i>
MTTF	<i>Mean Time to Failure</i>

## LISTA DE ACRÔNIMOS

FMEA	<i>Failure Mode and Effects Analysis</i>
------	--

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>11</b>
<b>1.1 CONTEXTUALIZAÇÃO.....</b>	<b>11</b>
<b>1.2 MOTIVAÇÃO.....</b>	<b>13</b>
<b>1.3 OBJETIVO.....</b>	<b>14</b>
<b>1.4 METODOLOGIA.....</b>	<b>15</b>
<b>2 REVISÃO BIBLIOGRÁFICA .....</b>	<b>16</b>
<b>2.1 MANUTENÇÃO INDUSTRIAL .....</b>	<b>16</b>
2.1.1 Manutenção Corretiva.....	16
2.1.2 Manutenção Preventiva .....	17
2.1.3 Manutenção Preditiva .....	17
2.1.4 MTBF .....	18
2.1.5 MTTF .....	18
<b>2.2 CONFIABILIDADE .....</b>	<b>19</b>
2.2.1 Reparáveis e não reparáveis .....	20
2.2.2 Funções utilizadas em análise de confiabilidade .....	20
2.2.3 Manutenção Centrada em Confiabilidade.....	21
2.2.4 FMEA.....	21
<b>2.3 PROCESSOS DE USINAGEM .....</b>	<b>21</b>
2.3.1 Fresadora.....	22
2.3.2 Fresa.....	23
2.3.3 Parâmetros de Corte para Fresamento .....	23
<b>2.4 INTELIGÊNCIA ARTIFICIAL.....</b>	<b>25</b>
2.4.1 Redes Neurais Artificiais .....	26
2.4.2 Métodos de Machine Learning.....	26
2.4.3 Regressão.....	27
2.4.4 Classificação.....	27
2.4.5 Aprendizado Supervisionado .....	27
2.4.6 Regressão linear e regressão logística.....	28
2.4.6.1 Árvores de decisão .....	28
2.4.6.2 <i>Support vector machine</i> (SVM) .....	29
2.4.6.3 Redes neurais artificiais e <i>Deep Learning</i> .....	29
2.4.7 Aprendizado Não Supervisionado.....	30
2.4.7.1 Algoritmos de agrupamento .....	30
2.4.7.2 <i>Principal Component Analysis</i> .....	31
2.4.7.3 Redes neurais <i>autoencoders</i> .....	31
2.4.8 Aprendizado Por Reforço.....	31
<b>3 MÉTODO PROPOSTO .....</b>	<b>33</b>
<b>3.1 FRESADORA .....</b>	<b>33</b>
<b>3.2 BANCO DE DADOS.....</b>	<b>34</b>
<b>3.3 O MODELO PREDITIVO .....</b>	<b>36</b>

3.3.1 Medidas de desempenho.....	38
3.3.2 Método probabilístico.....	39
<b>4 RESULTADOS .....</b>	<b>41</b>
<b>4.1 REGIÕES DE FALHA PARA ÁRVORE DE DECISÃO .....</b>	<b>42</b>
4.1.1 Falhas aleatórias – FRN .....	42
4.1.2 Falhas de Sobretensão – FST .....	44
4.1.3 Falha por Dissipação de Calor – FDC .....	46
4.1.4 Falha de Potência – FPT .....	48
4.1.5 Falha por Desgaste da Ferramenta – FDF .....	50
<b>4.2 DESEMPENHO DO MODELO DE ÁRVORE DE DECISÃO .....</b>	<b>52</b>
<b>4.3 REGIÕES DE FALHA POR SVM .....</b>	<b>54</b>
4.3.1 Falha Randômica por SVM.....	54
4.3.2 Falha de Sobretensão por SVM.....	55
4.3.3 Falha por Dissipação de Calor por SVM.....	57
4.3.4 Falha de Potência por SVM.....	58
4.3.5 Falha por Desgaste da Ferramenta por SVM .....	60
<b>4.4 PROBABILIDADE DE FALHA: POTÊNCIA POR DEFORMAÇÃO.....</b>	<b>61</b>
<b>5 CONCLUSÃO .....</b>	<b>64</b>
<b>REFERÊNCIA BIBLIOGRÁFICA.....</b>	<b>67</b>

## 1 INTRODUÇÃO

Esta seção contextualiza a aplicação da Inteligência Artificial na manutenção preditiva, destacando como as técnicas de *Machine Learning*, subtema de IA, e *Deep Learning*, subtema de ML, podem aprimorar a detecção de falhas e otimizar a eficiência operacional. Foram discutidos os principais desafios e benefícios dessa abordagem, bem como sua contribuição para a redução de custos e aumento da disponibilidade dos equipamentos no contexto da Indústria 4.0.

### 1.1 CONTEXTUALIZAÇÃO

A demanda no mercado pela disponibilidade e confiabilidade de equipamentos e redução de custos é cada vez maior. Essas mudanças exigem novos recursos e habilidades de todo corpo da manutenção (BALDISSARELLI e FABRO, 2019). Seja atrelado ao produto (ou serviço) principal, seja aos periféricos, a manutenção preditiva é fator crucial para acompanhar essas mudanças. Ela trabalha com previsões a partir da aquisição de dados sobre um equipamento ao longo de um período. Nesse sentido, o uso da IA na aquisição desses dados se torna cada vez mais indispensável, gerando indicadores que servem de base para tomada de decisões estratégicas a fim de manter a produção operante.

A indústria 4.0 revolucionou a forma de condução das fábricas e dos processos industriais. Essa nova era da indústria tem como principal marco a fusão do mundo físico com o digital. Tecnologias como Internet das Coisas (IoT, do inglês *Internet of Things*), IA, robótica avançada e a computação em nuvem sustentam essa transformação. A integração de todas essas tecnologias possibilita que quantidades massivas de dados sejam geradas em tempo real, aumentando a eficiência e o controle dos processos industriais de forma geral (SACOMANO *et al*, 2018).

A manutenção ainda é encarada por alguns com certo preconceito ou como um mal necessário, principalmente para aqueles que enxergam sob a ótica de que os equipamentos irão em algum momento quebrar ou falhar, para que sejam consertados

ou substituídos. Todavia, o custo da manutenção é ínfimo quando comparado com os possíveis prejuízos encontrados em linhas de produção que não valorizam a conservação dos equipamentos (NEPOMUCENO, 2018).

A IA está em processo de constante evolução. Sua aplicação já torna possível reduzir significativamente o desperdício de tempo e custo em diferentes mercados e situações. Pensando especificamente no mercado de manutenção preditiva, as aplicações são diversas, auxiliando na eficiência operacional através da previsão de falhas de forma extremamente eficaz (BERTENE, 2024).

A IA tem se destacado cada vez mais pela capacidade de analisar, em tempo real, grandes volumes de dados e pela identificação de padrões de degradação ou alertas de possíveis falhas que, por métodos convencionais, poderiam passar despercebidos (KAUFMAN, 2018).

Algoritmos de *Machine Learning* foram aplicados em um estudo para avaliar a vibração de máquinas rotativas, visando identificar padrões indicativos de falhas antes que estas se manifestassem de forma crítica (ZHANG *et al*, 2018). Através desse trabalho, foi possível destacar como a análise preditiva baseada em IA superou as abordagens tradicionais de manutenção, o fornecimento de alertas antecipados contribuiu significativamente para a redução do número de paradas não planejadas.

Paralelamente, a maior eficiência na identificação de falhas e a possibilidade de programar manutenções de forma mais efetiva, frutos da manutenção preditiva, impactam diretamente na redução de elevados custos de reparos emergenciais, ao mesmo tempo que também prolongam a vida útil dos equipamentos (ABECOM, 2024).

A empresa turca Akenerji, que presta serviços de solução energética, por exemplo, utilizou a plataforma Predix baseada em IA, da *General Electric*, para monitorar turbinas a gás em uma de suas usinas de energia (GENERAL ELECTRIC, 2017). Essa análise preditiva foi capaz de detectar previamente padrões de desgaste que poderiam ter levado a severas falhas e consequentes paralisações da operação. Essa aplicação possibilitou uma redução significativa nos custos de manutenção e aumentou a confiabilidade operacional.

Outro exemplo interessante vem da Siemens, que através de uma nova solução, utiliza a funcionalidade de IA generativa para auxiliar na manutenção preditiva (SIEMENS, 2024). Essa ferramenta gera modelos de comportamento de máquinas através do uso da IA possibilitando o direcionamento das equipes de

manutenção para as áreas com maior necessidade de intervenção, resultando na economia de tempo e recurso.

O uso das técnicas avançadas de *Machine Learning*, método utilizado para treinar algoritmos a identificar padrões para análise de dados, no geral, melhora a eficiência das máquinas. Dentro do mesmo contexto, e acompanhando a natural evolução da IA, é cada vez mais intensificado a exploração do conceito de *Deep Learnig*, que por essência pode ser comparado ao *Machine Learning*, entretanto o aprendizado se utiliza de redes neurais mais profundas, sendo comparado inclusive ao cérebro humano e capaz de reconhecer padrões de maior complexidade com precisão (KAUFMAN, 2018).

## 1.2 MOTIVAÇÃO

A necessidade de as indústrias modernas evoluírem continuamente suas práticas de manutenção para atender às crescentes exigências de eficiência, confiabilidade e controle de custos é um fator decisivo para a inovação. O avanço das tecnologias digitais e o surgimento da Indústria 4.0 trouxeram uma nova era de possibilidades, onde a manutenção preditiva se tornou uma peça-chave para a operação bem-sucedida de sistemas complexos. No entanto, as técnicas tradicionais de manutenção preditiva frequentemente enfrentam limitações na análise de grandes volumes de dados e na precisão das previsões de falhas (MOBLEY, 2002).

A IA se apresenta como uma solução transformadora, capaz de revolucionar a manutenção preditiva por meio de algoritmos que aprendem padrões de operação e identificam anomalias em tempo real. Essa tecnologia viabiliza uma análise mais profunda e precisa, permitindo a antecipação de falhas de forma eficaz e minimizando interrupções não planejadas (KAUFMAN, 2018). Os benefícios dessa integração vão além da redução de custos com manutenções emergenciais, estendendo-se ao aumento da vida útil dos equipamentos e à otimização dos recursos, promovendo uma maior sustentabilidade operacional (MARQUES, 2019).

O potencial da IA para superar as limitações das abordagens tradicionais e sua capacidade de adaptação a ambientes de produção complexos e dinâmicos tornam a sua aplicação prática para melhoria da confiabilidade de uma máquina. A

implementação dessa tecnologia pode transformar a manutenção em um processo mais proativo e estratégico, maximizando a produtividade e garantindo um controle mais eficiente das operações industriais (BARBOSA, 2023).

Este trabalho explorará como a integração da IA pode aprimorar a manutenção preditiva, abordando os fundamentos teóricos da tecnologia e sua aplicação prática. A pesquisa também incluirá a análise de um estudo de caso, onde terá como abordagem principal o uso da IA como ferramenta de confiabilidade na Manutenção preditiva de uma fresadora, explorando resultados de análise encontrados para diferentes parâmetros, além de discussões sobre os desafios e as melhores estratégias para a aplicação dessa tecnologia, evidenciando suas vantagens e o impacto positivo na eficiência e gestão industrial.

### 1.3 OBJETIVO

O objetivo deste trabalho é investigar de que maneira a IA pode ser aplicada para aprimorar a manutenção preditiva em ambientes industriais, aumentando a precisão na previsão de falhas e otimizando a eficiência das operações.

Especificamente, busca-se analisar como o uso de técnicas avançadas de IA pode superar as limitações dos métodos tradicionais de manutenção, permitindo implementação de práticas de manutenção mais eficazes e estratégicas.

Especificamente, o trabalho será direcionado à análise da aplicação da IA na manutenção preditiva de uma fresadora, avaliando parâmetros como temperatura do ar e do processo, velocidade de rotação, torque e desgaste da ferramenta de corte.

Com base nesses dados, pretende-se apresentar, através de diferentes combinações dos parâmetros, as condições que levam à falha ou à operação segura do equipamento, apresentando as análises de forma contextualizada e embasada em dados explorados durante o estudo.

## 1.4 METODOLOGIA

O método adotado para esse estudo foi estruturado em modelos preditivos de classificação: Árvore de decisão e *Support Vector Machine* (SVM)

Na etapa inicial os dados são coletados e então tratados. Todas as técnicas foram abordadas e aplicadas no contexto de manutenção preditiva, a fim de avaliar a eficácia da aplicação da IA na identificação de padrões de desgaste e previsão de falhas em equipamentos industriais.

De forma complementar à análise teórica, o trabalho conta com um estudo de caso prático, no qual serão utilizados dados simulados de uma máquina de fresa para avaliar os resultados de modelos preditivos.

O programa Matlab foi utilizado para construção do modelo, sendo o mesmo utilizado para gerar gráficos, tabelas e matrizes que possibilitam visualização dos resultados obtidos e compreensão mais clara dos padrões de falha identificados pelos modelos preditivos. Essa simulação traz a teoria para cenários similares a casos reais de manutenção e validação da eficácia de modelos propostos.

Essa metodologia possibilitará um entendimento abrangente de como a IA pode ser aplicada de forma eficaz na predição de falhas e na otimização das operações de manutenção industrial.

## 2 REVISÃO BIBLIOGRÁFICA

Nesta seção serão revisados os conceitos e referencial teórico para melhor compreensão deste trabalho. Serão abordados conceitos de manutenção industrial, IA, métodos de *Machine Learning*, *business intelligence*, processos de usinagem, dentre outros.

### 2.1 MANUTENÇÃO INDUSTRIAL

A manutenção é a combinação de ações técnicas e administrativas destinadas a manter ou recolocar um item em condições de executar suas funções requeridas, sob condições de uso especificadas, quando é executada sob condições determinadas e mediante procedimentos e meios prescritos ABNT (1994, p. 3).

A manutenção nasce com a industrialização e a necessidade de reparo do maquinário industrial. Era vista antes como um mal necessário, realizada apenas quando o equipamento falhava.

Hoje, com o aumento da quantidade de itens a serem mantidos e da maior complexidade desses itens, há uma demanda por técnicas cada vez mais refinadas e precisas de manutenção e faz com que a manutenção seja incorporada nas estratégias de negócio das empresas. Sendo incorporada, passa a receber muito mais atenção ao que deve ser mantido e o que precisa ser melhorado. Adiante são abordados os tipos de manutenção que se relacionam ao objeto de estudo desse trabalho: Manutenção corretiva, preventiva e preditiva.

#### 2.1.1 Manutenção Corretiva

Como o nome sugere, é realizada uma correção em uma falha já existente. É efetuada após a ocorrência de uma pane destinada a recolocar um item em condições de executar uma função requerida ABNT (1994, p. 7).

Quando a falha já ocorreu, pode-se atuar de duas formas: realizando uma corretiva programada e não programada. Na primeira, entende-se que o item, ainda que em falha é mantido em funcionamento, com limitações, até que seja feita a intervenção. Por outro lado, a não programada é emergencial, geralmente, inesperada e prejudica o processo produtivo (PINTO, 2021). Em ambos os casos, o custo de manutenção pode ser demasiado alto. Por esse motivo, este tipo de manutenção deve ser evitado sempre e é cada vez menos utilizado. Nosso trabalho tem por objetivo apresentar vias onde a IA é utilizada para evitar a ocorrência desse tipo de manutenção.

### 2.1.2 Manutenção Preventiva

De acordo com a ABNT (1994, p. 7), é a manutenção realizada em intervalos predeterminados, ou de acordo com critérios prescritos, objetivando reduzir a probabilidade de falha ou desgaste.

Geralmente são realizadas em intervalos recomendados pelo fabricante ou de acordo com a necessidade devido ao histórico do equipamento. Com isso, ela pode ser programada previamente, sendo então parte cronograma do processo produtivo, e garantir menores custos.

### 2.1.3 Manutenção Preditiva

Manutenção realizada com base na aplicação sistemática de técnicas de análise, utilizando-se de meios de supervisão centralizados ou de amostragem, para reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva ABNT (1994, p. 7).

É um trabalho realizado como parte de uma estratégia de manutenção baseada em condição, que envolve monitorar as características operacionais do equipamento, analisar dados operacionais e/ou a funcionalidade do equipamento, identificar que existe um problema, ou potencial problema, e resolvê-lo antes que ocorra uma falha no equipamento (SCAIFE, 2023).

Esse tipo de manutenção requer uso de mão de obra qualificada, uso de equipamentos de diagnóstico e sistemas de aquisição de dados via monitoramento

constante. Todos esses recursos são de alto custo para implementar, mas uma vez implementados, geram economia a longo prazo por evitar custo de manutenção corretiva.

#### 2.1.4 MTBF

O MTBF (*Mean Time Between Failures*, ou Tempo Médio Entre Falhas) é um indicador utilizado na área de manutenção para medir a confiabilidade de sistemas e equipamentos. Essa métrica indica o tempo médio entre falhas de um equipamento ou sistema, sendo um parâmetro crucial para o planejamento e execução de estratégias de manutenção. Sua importância está na capacidade de fornecer dados consistentes para antecipar paradas, otimizar recursos e aumentar a disponibilidade operacional.

No contexto da manutenção preditiva, o MTBF ganha uma dimensão ainda mais impactante, visto que a combinação de análises históricas com dados em tempo real aumenta a precisão na previsão de falhas.

Ao aplicar IA, as limitações tradicionais do cálculo de MTBF, como a dependência de dados estáticos e a dificuldade em capturar padrões complexos, são superadas, refinando seus cálculos. Essa integração potencializa a confiabilidade dos equipamentos e a tomada de decisão estratégica, fornecendo maior precisão para intervenções preventivas e reduzindo custos operacionais.

A utilização de IA no cálculo e aplicação do MTBF permite uma manutenção mais eficiente, com benefícios diretos em ambientes industriais complexos, como linhas de produção automatizadas e sistemas críticos de energia (TAMURA *et al*, 2023).

Tais avanços consolidam o MTBF como uma métrica fundamental na evolução da manutenção tradicional para um paradigma mais eficiente e proativo.

#### 2.1.5 MTTF

O MTTF (*Mean Time to Failure*, ou Tempo Médio até a Falha) é um indicador utilizado na área de manutenção para medir a expectativa de vida útil de um equipamento ou componente antes de apresentar sua primeira falha. Diferentemente

do MTBF, o MTTF é aplicado, na maior parte das vezes, a itens que não reparáveis, possibilitando avaliar a durabilidade de componentes e auxiliar no planejamento de substituições preventivas. A sua aplicação diretamente relacionada a capacidade de prever com maior precisão a necessidade de intervenções, de forma a minimizar interrupções e maximizar a eficiência operacional.

No contexto da IA aplicada à manutenção preditiva, o MTTF ganha relevância como uma métrica que pode ser significativamente aprimorada pelo uso de algoritmos avançados. Por meio da IA, os dados históricos são analisados em tempo real, permitindo não apenas calcular o MTTF com maior precisão, mas também identificar fatores que afetam diretamente sua variabilidade, facilitando a observação de condições operacionais adversas e falhas inesperadas.

Assim como mencionado para o indicador MTBF, com o uso da IA é possível perceber uma abordagem que vai além das limitações das técnicas tradicionais, que se baseiam, em sua maioria, apenas em médias históricas, sem considerar dados em tempo real em sistemas dinâmicos. Estudos indicam que a aplicação de IA no cálculo de MTTF em setores como o de energia e automotivo possuem um impacto direto na confiabilidade e redução de custos operacionais (TRACTIAN, 2024), de maneira a reforçar sua importância como métrica essencial em estratégias de manutenção modernas.

## 2.2 CONFIABILIDADE

Confiabilidade, segundo Lafraia (2001), é a probabilidade de um equipamento ou sistema tem de exercer sua função, por um período previsto, sob condições de operações especificadas, sem apresentar falhas.

A confiabilidade nasce durante a segunda guerra, no desenvolvimento de projetos de engenharia, principalmente no desenvolvimento de armamentos. Após, na Década de 1950, com o uso crescente de componentes eletrônicos, a necessidade por produtos com maior confiabilidade aumentou significativamente. Nesse período, entendeu-se que era preciso implementar melhorias na coleta de dados de falha para desenvolver melhores componentes. Estabelecendo requisitos e objetivos de

confiabilidade, realizar testes antes de iniciar uma produção e estabelecer um comitê para estabelecer os padrões de confiabilidade a serem seguidos. A partir dessa demanda surgiram programas, técnicas estatísticas e manuais (DENSON, 1998)

A aplicação da IA na confiabilidade representa um avanço significativo, permitindo análises mais precisas (VINCENT *et al*, 2024). Por meio do aprendizado de máquina e técnicas de análise preditiva, a IA potencializa a capacidade de modelar o comportamento dos equipamentos e identificar padrões complexos que indicam possíveis falhas (KUMAR *et al*, 2021).

### 2.2.1 Reparáveis e não reparáveis

Itens podem ser classificados em reparáveis ou não reparáveis. Os reparáveis utilizam o conceito de tempo médio entre falhas (MTBF – *Mean Time Between Failure*). Quando se tem itens não reparáveis, o conceito usado é Tempo médio até falhas (MTTF – *Mean Time to Failure*).

Sistemas reparáveis são aqueles onde, após a ocorrência de uma falha, a operação pode ser restabelecida por alguma intervenção. Nesse tipo de sistema, dois tipos de distribuição são considerados: a de falha e a de reparo. A primeira descreve o tempo para a ocorrência de uma falha de um componente, enquanto a segunda descreve o tempo que leva para efetivamente reparar o componente. A partir dessas duas distribuições, pode-se determinar a disponibilidade do sistema, ou seja, o percentual de tempo em que este se encontra operante (NIST/SEMATECH, 2006; RELIASOFT, 2007).

### 2.2.2 Funções utilizadas em análise de confiabilidade

As principais funções utilizadas em estudos de confiabilidade são: a função de risco, a função confiabilidade, a função densidade de falhas e a função acumulada de falhas. A maioria dos problemas da engenharia de confiabilidade podem ser resolvidos com essas funções (KECECIOGLU, 2002).

### 2.2.3 Manutenção Centrada em Confiabilidade

A manutenção centrada em confiabilidade (MCC) é uma abordagem estruturada para a gestão de manutenção, com foco na confiabilidade e eficiência de operação dos sistemas, para atender os objetivos operacionais de forma satisfatória. O conceito de MCC foi desenvolvido na década de 1960, oriundo inicialmente da indústria aeronáutica, posteriormente foi adotado em setores industriais devido ao aumento de confiabilidade e redução de custos operacionais notado (MOUBRAY, 1997). Essa metodologia identifica as funções de um sistema, as falhas funcionais associadas e as estratégias de manutenção adequadas para mitigar os riscos de falhas.

O foco principal do MCC é priorizar ações de manutenção que sejam técnica e economicamente justificáveis, de forma que o sistema possa ser mantido em funcionamento previsto, sem interrupções indesejadas. Tal processo engloba a análise dos modos de falhas potenciais (FMEA) e a seleção de estratégias de manutenção conforme criticidade do equipamento (SMITH *et al*, 2003).

### 2.2.4 FMEA

A FMEA (*Failure Mode and Effects Analysis* ou Análise dos Modos e Efeitos de Falha) é uma técnica de confiabilidade que tem como objetivos reconhecer e avaliar as falhas potenciais que podem surgir em um produto ou processo e identificar ações que possam eliminar ou reduzir a chance de ocorrência dessas falhas. Essa técnica revela os pontos fracos do sistema e, assim, fornece subsídios para as atividades de melhoria contínua (FOGLIATO e RIBEIRO, 2009).

## 2.3 PROCESSOS DE USINAGEM

Nesse tópico serão abordados os processos de usinagem, com foco para fresadoras industriais.

### 2.3.1 Fresadora

A fresadora é uma máquina-ferramenta utilizada para usinar superfícies de peças por meio da remoção de material, utilizando uma ferramenta rotativa chamada fresa. O movimento de corte é realizado pela rotação da fresa, enquanto a peça a ser usinada pode se mover em diferentes eixos, dependendo do tipo de fresadora e do processo de usinagem. De acordo com Martins e Aguiar (2012), a fresadora é uma máquina essencial na indústria mecânica, caracterizada pela sua capacidade de realizar operações variadas como faceamento, usinagem de canais, perfis e engrenagens.

Sua operação remove material de uma peça com a fresa, que possui múltiplos gumes cortantes, onde cada um remove uma pequena quantidade de metal. Essa operação pode ser considerada multidimensional, pois tanto a peça quanto a ferramentas podem, simultaneamente, serem movimentadas em mais de uma direção (CHIAVERINI, 1986).

Existem diversos tipos de fresadoras na indústria, sendo os mais comuns o Universal, o vertical e o horizontal. Hoje com o avanço da tecnologia, as fresadoras CNC automatizadas têm se tornado cada vez mais populares.

Na fresadora horizontal a fresa é montada em um eixo horizontal e a peça se move em relação a ele. Já na fresadora vertical, a fresa é montada em um eixo vertical, permitindo operações como faceamento e furação. A Fresadora Universal combina características das fresadoras horizontais e verticais, permitindo maior versatilidade. A Figura 1 exemplifica cada modelo.



**Figura 1 - Tipos de fresadoras**  
Fonte: Bitfab, 2025

A Fresadora CNC controlada numericamente por computador, permitindo alta precisão e automação e envolve diversas tecnologias. A Figura 2 mostra uma Fresadora desse tipo.



**Figura 2 - Fresadora CNC**  
**Fonte: Haas CNC, 2025**

### 2.3.2 Fresa

Chiaverini (1986, p. 218) explica que Fresa é a ferramenta giratória que tem em sua superfície certo número de arestas corte iguais, equidistantes e dispostas simetricamente. As arestas realizam o corte uma por vez durante o movimento circular, produzindo cavaco de espessuras variáveis.

### 2.3.3 Parâmetros de Corte para Fresamento

São as variáveis controláveis que influenciam diretamente o desempenho, a qualidade do acabamento, a eficiência da operação e a vida útil das ferramentas. Suas variações influenciam diretamente a falha de uma máquina e por isso tem grande valor na manutenção preditiva.

A velocidade de corte pode ser considerada a mais importante dos parâmetros. Ela é definida como a velocidade instantânea do ponto da aresta de corte da ferramenta e pode ser calculada pela Equação (1):

$$V_c = \frac{\pi \cdot D \cdot n}{1000} \text{ [m/min]} \quad (1)$$

Onde D é o diâmetro da ferramenta, em mm, n é o número de rotações por minuto, em rpm.

O que permite entender a relação diretamente proporcional entre velocidade de rotação e de corte da ferramenta que será estudada mais a frente neste trabalho.

Combinando corretamente uma baixa taxa de avanço e baixa profundidade de corte com alta velocidade de corte é ideal para reduzir as forças de usinagem (Suresh, Basavarajappa e Samuel, 2012)

Para operações em baixas velocidades Suresh, Basavarajappa e Samuel (2012) dizem que a ferramenta de corte sofre maior atrito na superfície da peça e a aresta de corte sofre grande pressão. Isso pode causar ou mesmo acelerar o desgaste da ferramenta e que isso pode ainda ser relacionado à formação de cavacos, que não se dá de forma ideal, pois o material é submetido a menores taxas de deformação. Com isso, a força de corte específica aumenta. Os três autores concluem afirmando que velocidade de corte tem influência considerável na vida útil de uma ferramenta.

Do ponto de vista da manutenção preditiva, é essencial entender como e quando a velocidade de corte pode causar falha em um equipamento. Do ponto de vista da confiabilidade, é crucial entender como o monitoramento dessas variações a partir da aquisição de dados em tempo real pode trazer maior assertividade na qualidade da usinagem.

Apesar de a temperatura não ser um dos parâmetros de corte da usinagem, ela merece a devida atenção, parte do processo é influenciado por sua variação. A principal consequência sendo a vida útil da ferramenta.

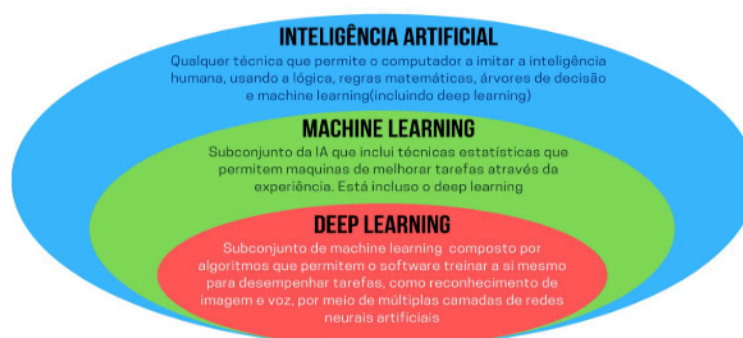
Com o aumento da velocidade de corte a fricção entre a ferramenta e a peça de trabalho é maior, gerando mais calor. A geração de calor amolece a aresta de corte promovendo maior desgaste (SURESH, BASAVARAJAPPA e SAMUEL, 2012). Portanto, regular a temperatura durante o corte de uma peça é crucial para prolongar a vida útil da ferramenta.

Segundo Zeilmann *et al* (2008), a geração de calor em velocidades menores é menor, porém, com velocidades maiores, por conta da maior taxa de remoção de cavacos, há maior dissipação de calor durante a usinagem.

## 2.4 INTELIGÊNCIA ARTIFICIAL

Segundo Scaife (2023), IA é um termo generalista que engloba diversos modelos estatísticos de Classificação e Regressão. Destes, os mais comuns são as Redes Neurais Artificiais, que são englobadas por *Machine Learning*, que por sua vez são englobadas por IA. Todos são programas capazes de avaliar dados para apresentar proposta de uso funcional a partir desses dados e suas aplicações continuam se ampliando. As aplicações de IA incluem tradução de idiomas, reconhecimento de fala, robótica, identificação visual, com reconhecimento de imagens via câmeras ou arquivo de imagens, análise de dados e solução de problemas e, com isso, fornecer propostas de tomada de decisão.

A IA é um campo multidisciplinar que visa desenvolver sistemas capazes de simular a cognição humana, incluindo a capacidade de aprendizado, raciocínio e tomada de decisões (RUSSELL *et al*, 2021). Dentro deste amplo domínio, o aprendizado de máquina (ML, do inglês *Machine Learning*) emerge como um subconjunto essencial, como pode ser observado na Figura 3, sendo definido como a capacidade de algoritmos ajustarem seu desempenho com base em dados sem a necessidade de programação explícita para cada tarefa (MITCHELL, 1997).



**Figura 3 - Definições de IA e seus subconjuntos**  
Fonte: Medium, 2020

### 2.4.1 Redes Neurais Artificiais

*Machine Learning* e seu subconjunto, *Deep Learning*, são duas tecnologias englobadas por Redes Neurais Artificiais, que tiveram crescimento exponencial nos últimos anos e são os que mais se destacam dentro da IA, principalmente por sua capacidade de realizar previsões, análise de banco de dados grandes e oferecer informações (SHARIFANI *et al*, 2023).

Ambas usam algoritmos para aprender a partir de um banco de dados para aumentar a precisão e eficiência de previsões ou decisões. Embora tenham a mesma finalidade, o fazem por caminhos diferentes. Enquanto *Machine Learning* utiliza de métodos estatísticos para aprender com os dados, *Deep Learning* usa uma rede neural artificial para aprender com grandes conjuntos de dados (SHARIFANI *et al*, 2023).

As redes neurais artificiais (RNA) constituem um subcampo do *Deep Learning* que se baseia no princípio de funcionamento das redes neurais biológicas, presentes no cérebro humano. No sistema biológico, os neurônios, que são as células nervosas, estão interconectados, formando uma rede complexa que transmite informações de forma contínua. Inspiradas nesse modelo, as RNAs reproduzem essas conexões por meio de modelos matemáticos e algoritmos, permitindo que a rede aprenda padrões e resolva problemas sem a necessidade de ser explicitamente programada para tal. A capacidade de aprendizado automático das RNAs, que se dá a partir do treinamento com grandes volumes de dados, resulta em respostas mais assertivas e contextualizadas, oferecendo soluções adaptativas em função das exigências impostas pelas tarefas específicas.

### 2.4.2 Métodos de Machine Learning

De maneira a aprofundar o assunto, *Machine Learning* é um ramo da IA que se baseia no desenvolvimento de algoritmos capazes de aprender padrões a partir de dados, priorizando a busca pela melhoria de desempenho em uma tarefa específica sem a necessidade de reprogramação explícita (MITCHELL,1997). Em geral, os métodos de *Machine Learning* podem ser classificados em três categorias centrais, que são: aprendizado supervisionado, não supervisionado e por reforço (BISHOP,

2006). Cada uma dessas categorias possui abordagens distintas e podem ser aplicadas em diferentes contextos, dentre eles a manutenção preditiva na indústria.

### 2.4.3 Regressão

“A regressão é utilizada para entender a relação entre variáveis dependentes e independentes. É geralmente usada para fazer projeções, como receita de vendas de um determinado negócio” (Supervised learning, IBM, 2024).

Os algoritmos de Regressão são Regressão Linear, *Support Vector Regression* (SVR), *Random Forest Regressor* e Redes Neurais com saída contínua.

### 2.4.4 Classificação

“A classificação usa um algoritmo para atribuir dados de teste com precisão a categorias específicas. Reconhece entidades específicas dentro do conjunto de dados e tenta tirar algumas conclusões sobre como essas entidades devem ser rotuladas ou definidas” (Supervised learning, IBM, 2024). É a ferramenta de aprendizado para classes binárias, como diagnósticos de falhas em equipamentos e máquinas.

Os algoritmos de classificação são Regressão Logística, Máquinas de Vetores de Suporte (SVM), Árvores de Decisão, K-Nearest Neighbors (KNN), Random Forest, Naive Bayes, Redes Neurais e de Modelos de Ensemble.

Regressão Logística e Árvore de decisão são ambas ferramentas binárias, ao passo que um calcula a probabilidade de um resultado ser positivo ou negativo, enquanto o outro cria uma estrutura de decisões para decidir se um resultado será positivo ou negativo.

### 2.4.5 Aprendizado Supervisionado

O aprendizado supervisionado é uma técnica de *Machine Learning* utilizada para desenvolver modelos treinados a partir de um conjunto de dados rotulados, onde cada entrada possui uma saída correspondente previamente conhecida (GOODFELLOW *et al*, 2016). Esse método é amplamente utilizado para resolver problemas de classificação e regressão, sendo aplicado em diversas áreas como

reconhecimento de padrões, processamento de linguagem natural, manutenção preditiva, controle de qualidade na indústria e diagnósticos médicos (BISHOP, 2006).

O treinamento ocorre por meio da minimização de uma função de perda, que quantifica a discrepância entre as previsões do modelo e os valores reais. Essa otimização geralmente é feita por meio de algoritmos como gradiente descendente e suas variantes (RUMELHART *et al*, 1986).

Um dos desafios centrais do aprendizado supervisionado é a generalização do modelo, ou seja, sua capacidade de fazer previsões precisas em novos dados. A ocorrência de problemas como *overfitting* (quando o modelo memoriza os dados de treinamento, mas falha em generalizar) e *underfitting* (quando o modelo não aprende os padrões subjacentes) devem ser cuidadosamente tratados por meio de técnicas como regularização e validação cruzada (HASTIE *et al*, 2009).

Um dos maiores usos de Aprendizado supervisionado é em modelos de Análise Preditiva. A criação de sistemas de análise preditiva para fornecer insights profundos, permite que as empresas antecipem determinados resultados com base numa determinada variável de produção, ajudando os líderes empresariais a justificarem decisões (Supervised learning, IBM, 2024).

#### 2.4.6 Regressão linear e regressão logística

A regressão linear é um dos métodos mais antigos e fundamentais do aprendizado supervisionado, sendo utilizada para modelar a relação entre variáveis preditoras contínuas e uma variável de saída também contínua, sendo amplamente utilizada para prever valores futuros (DRAPER *et al*, 1998).

A regressão logística, por outro lado, é amplamente empregada em problemas de classificação binária, onde a variável de saída assume apenas dois valores, geralmente representados como 0 e 1 (HOSMER *et al*, 2013).

##### 2.4.6.1 Árvores de decisão

As árvores de decisão são modelos hierárquicos que estruturam os dados em nós de decisão, onde cada nó representa um teste sobre uma variável de entrada, e cada ramo representa um possível resultado desse teste (QUINLAN, 1996).

Uma evolução das árvores de decisão é o *Random Forest* (Floresta Aleatória), esse modelo tem sido amplamente empregado em aplicações industriais e consiste em um método que combina múltiplas árvores de decisão para reduzir o *overfitting* e melhorar a precisão (BREIMAN, 2001).

#### 2.4.6.2 *Support vector machine* (SVM)

*Support Vector Machine* (SVM) é um método de aprendizado de máquina supervisionado utilizado para classificação e regressão, método amplamente utilizado para aplicação na manutenção preditiva devido à sua capacidade de identificar padrões complexos em grandes volumes de dados operacionais. O algoritmo opera organizando os dados em diferentes classes por meio de um hiperplano ótimo, maximizando a margem entre as classes visando melhorar a precisão das previsões. Dessa forma, sua aplicação na manutenção preditiva permite detectar falhas em equipamentos industriais ao analisar variáveis operacionais, como vibração, temperatura e consumo de energia, possibilitando a antecipação de falhas e a redução de custos operacionais (SOMVANSHI *et al*, 2016).

No contexto da manutenção preditiva baseada em IA, o método SVM é frequentemente utilizado em conjunto com técnicas de pré-processamento de dados para aprimorar a classificação de padrões de falhas e otimizar a tomada de decisão. Estudos apontam que, quando aplicada a máquinas rotativas, a SVM apresenta alta precisão na identificação de anomalias em motores elétricos e compressores, permitindo intervenções preventivas antes do advento das falhas críticas (YANG *et al*, 2005).

Adicionalmente, esse método possui aplicações nas áreas de biometria, reconhecimento de padrões, processamento de sinais, além da sua aplicação expressiva na área de manutenção preditiva (WIDODO *et al*, 2007).

#### 2.4.6.3 Redes neurais artificiais e *Deep Learning*

As Redes Neurais Artificiais (RNA) são modelos inspirados no funcionamento do cérebro humano, compostos por neurônios artificiais interconectados em múltiplas camadas (LECUN *et al*, 2015).

- Os modelos mais básicos possuem três camadas:
  1. Camada de Entrada: recebe os dados brutos;
  2. Camada Oculta: processa os dados por meio de pesos e funções de ativação;
  3. Camada de Saída: gera a previsão final.

Com o avanço do *Deep Learning*, surgiram arquiteturas como Redes Neurais Convolucionais (CNNs), amplamente utilizadas para visão computacional, e Redes Neurais Recorrentes (RNNs), aplicadas ao processamento de séries temporais e linguagem natural (GOODFELLOW *et al*, 2016).

#### 2.4.7 Aprendizado Não Supervisionado

O aprendizado não supervisionado é um paradigma de *Machine Learning* que ainda exige bastante pesquisas, sendo caracterizado pelo treinamento de modelos sem a necessidade de rótulos predefinidos nos dados (HASTIE *et al*, 2009). Diferente do aprendizado supervisionado, onde os algoritmos aprendem a partir de um conjunto de entradas e saídas previamente mapeadas, no aprendizado não supervisionado o objetivo é identificar padrões, estruturas e agrupamentos nos dados sem informações explícitas sobre a classificação ou valor esperado (Murphy, 2022).

Essa abordagem pode ser observada sendo amplamente utilizada em problemas que envolvem a descoberta de conhecimento em grandes volumes de dados, como segmentação de clientes, detecção de anomalias, agrupamento de documentos, reconhecimento de padrões e redução de dimensionalidade (AGGARWAL, 2013). Os métodos de aprendizado não supervisionado geralmente operam por meio de duas abordagens principais: Aprendizado baseado em agrupamento e aprendizado Baseado em Redução de Dimensionalidade.

##### 2.4.7.1 Algoritmos de agrupamento

Técnicas como *K-Means* e DBSCAN são amplamente utilizadas para segmentação de dados, agrupando amostras semelhantes sem conhecimento prévio das categorias (MACQUEEN, 1967). Embora seja um algoritmo eficiente e simples, o *K-Means* tem limitações, como a necessidade de definir o número de *clusters* previamente e a sensibilidade a pontos de dados discrepantes (JAIN, 2010).

Esses métodos são aplicados para monitoramento da condição de equipamentos industriais, identificando padrões anômalos que podem indicar falhas iminentes. O algoritmo *DBSCAN* é amplamente utilizado em detecção de anomalias, segmentação de imagens e análise de tráfego de redes (SCHUBERT *et al*, 2017).

#### 2.4.7.2 *Principal Component Analysis*

O PCA é um método matemático que transforma os dados originais em um novo sistema de coordenadas, onde as variáveis são organizadas em componentes principais, ordenadas pela quantidade de variação que explicam nos dados (JOLLIFFE *et al*, 2016). Na manutenção preditiva, essa técnica facilita a identificação de variáveis críticas para a predição de falhas (YAN *et al*, 2017).

#### 2.4.7.3 *Redes neurais autoencoders*

Essas redes são treinadas para comprimir e reconstruir dados, permitindo a detecção de anomalias por meio da identificação de desvios em padrões reconstruídos. Os *autoencoders* são um tipo de rede neural projetada para aprender uma representação compacta dos dados. Eles consistem em duas partes:

- Codificador (*Encoder*): comprime os dados em uma representação de menor dimensão.
- Decodificador (*Decoder*): reconstrói os dados originais a partir dessa representação comprimida.

Esses modelos são úteis para remoção de ruído em imagens, aprendizado de características latentes e geração de novos dados sintéticos (HINTON *et al*, 2006).

#### 2.4.8 *Aprendizado Por Reforço*

O *Aprendizado por Reforço (Reinforcement Learning - RL)* é um dos paradigmas fundamentais da IA e aprendizado de máquina, sendo amplamente utilizado para modelar problemas onde um agente interage com um ambiente dinâmico para aprender a tomar decisões ótimas com base em um sistema de recompensas. Essa abordagem tem sido aplicada com sucesso em diversas áreas,

como robótica, jogos, finanças e controle de processos industriais (SUTTON, 2018). Os algoritmos mais comuns incluem:

- *Q-Learning*: Um método baseado em tabelas que atualiza valores de recompensa para diferentes ações ao longo do tempo, sendo utilizado em sistemas autônomos de manutenção industrial (WATKINS *et al*, 1992).
- *Deep Q-Networks (DQN)*: Uma extensão do *Q-Learning* que utiliza redes neurais profundas para lidar com espaços de estado contínuos, possibilitando otimizações mais sofisticadas em processos industriais (MNIH *et al*, 2015).

A aplicação do aprendizado por reforço na manutenção preditiva ainda é um campo emergente, mas pesquisas indicam que ele pode ser útil para otimizar estratégias de intervenção e minimizar custos operacionais (LAZIC *et al*, 2018).

### 3 MÉTODO PROPOSTO

Este trabalho visa entender como a Inteligência Artificial pode ser utilizada como ferramenta de confiabilidade na Manutenção preditiva de uma fresadora.

A escolha de realizar esta análise com IA foi feita para mostrar como ela é uma ferramenta poderosa para auxiliar análises FMEA e, conforme será mostrado, com uma programação simples, pode trazer resultados interessantes para serem implementados na indústria da manutenção.

A plataforma utilizada para desenvolvimento do código foi o programa Matlab. Primeiramente os dados foram tratados para remover inconsistências, após, foram gerados gráficos a partir do banco de dados para entender visualmente quais parâmetros estavam mais relacionados às falhas, ou seja, as causas raiz, e, por fim, foram utilizadas técnicas de *Árvore de decisão* e *Support Vector Machine* para prever as falhas.

#### 3.1 FRESADORA

A máquina considerada aqui foi uma fresadora universal de piso, conforme ilustra a Figura 4.



Figura 4 - Fresadora Servomill Universal UWF 1200. Fonte: Knuth Machine Tools, 2025

O estudo utilizou este tipo de fresadora como uma referência para base de parâmetros, uma vez que os dados obtidos são dados simulados. A proposta foi realizar uma análise do tipo de máquina comum na indústria.

No mercado, há fresadoras podem trabalhar com velocidades de rotação variando de 1800rpm a mais de 15000rpm, com potência acima de 10kW e torques acima de 100Nm, porém, para este estudo, foram consideradas os seguintes parâmetros, obtidas no banco de dados:

- Velocidade de rotação máxima: 3000rpm
- Potência máxima: 11kW
- Torque máximo: 80Nm

### 3.2 BANCO DE DADOS

O banco de dados é parte de uma plataforma da Universidade da Califórnia (*UCI Machine Learning Repository, 2020*) para estudos dentro do campo de Aprendizado de Máquina com o objetivo de fornecer insumos para trabalhar com IA e educar estudantes mais sobre o assunto (*MATZKA, 2020*).

Devido ao fato de ser difícil obter dados reais desses equipamentos, os dados simulam, de maneira coerente com o mundo real, sensores instalados no motor de uma fresadora e registra informações como temperatura do ar e do processo, velocidade de rotação, torque e desgaste da ferramenta de corte (a partir do tempo de uso).

O banco objetiva encontrar novos métodos e resultados de aprendizado de máquina para explicar de forma acessível a todos. Ele contém 10.000 linhas que representam, cada uma, um possível cenário de leitura de sensores acoplados ao motor, com 14 colunas que representam parâmetros de leitura do sensor e os modos de falha atrelados a cada parâmetro. Para cada cenário, tem-se um resultado de falha ou não falha da máquina.

As 14 colunas do banco são:

- UDI: identificador único variando de 1 a 10.000.

- ID do Produto: composto por uma letra L, M ou H, representando a qualidade do produto – baixa (50% de todos os produtos), média (30%) e alta (20%), respectivamente – e um número de série específico para cada variante
- Tipo: apenas o tipo do produto L, M ou H;
- TemperaturaAr [K]: gerada por um processo de caminhada aleatória (*random walk*), posteriormente normalizada para um desvio padrão de 2 K em torno de 300 K.
- TemperaturaProcesso [K]: obtida a partir de um processo de caminhada aleatória, normalizada para um desvio padrão de 1 K, somada à temperatura do ar mais 10 K
- VelocidadeRotacao [rpm]: calculada a partir de uma potência de 2860 W, sobreposta com ruído distribuído normalmente.
- Torque [Nm]: valores de torque distribuídos normalmente em torno de 40 Nm, com desvio padrão ( $\sigma$ ) de 10 Nm e sem valores negativos.
- DesgasteFerramenta [min]: as variantes de qualidade H/M/L adicionam, respectivamente, 5/3/2 minutos de desgaste à ferramenta utilizada no processo.
- FalhaMaquina: rótulo que indica se houve falha da máquina em um determinado ponto de dados, considerando qualquer um dos modos de falha.

Sendo cinco delas os modos de falha:

- **FDF – Falha por desgaste:** O desgaste da ferramenta pode resultar em falha ou substituição quando o tempo acumulado de uso está entre 200 e 240 minutos, definido aleatoriamente. Esse evento ocorre 120 vezes no conjunto de dados, sendo que a substituição acontece em 69 dessas ocasiões, enquanto a falha real é registrada 51 vezes, ambas de forma aleatória.
- **FDC – Falha por dissipação de calor:** Uma falha relacionada à dissipação de calor ocorre quando a diferença entre a temperatura do ar e a temperatura do processo cai para menos de 8,6 K, enquanto a

velocidade de rotação da ferramenta está abaixo de 1380 rpm. Esta condição aparece em 115 registros.

- **FPT – Falha de Potência:** A potência necessária para o processo é determinada pelo produto entre o torque e a velocidade de rotação da ferramenta (em rad/s). Ocorre falha no processo se a potência calculada for inferior a 3500 W ou superior a 9000 W, o que acontece em 95 registros no conjunto de dados.
- **FST – Falha por Sobretensão:** Esta falha ocorre quando o produto entre o desgaste da ferramenta e o torque ultrapassa valores críticos específicos para cada variante de produto: 11.000 minNm para a variante L, 12.000 minNm para a M e 13.000 minNm para a H. Esse tipo de falha foi observado em 98 pontos de dados.
- **FRN – Falhas Aleatórias:** Existe uma probabilidade de 0,1% de falha aleatória em cada processo, independente das condições operacionais. Esse tipo de falha foi identificado em apenas 5 casos, um número menor do que o esperado em um conjunto de 10.000 registros.

Foi considerado que se pelo menos um dos modos de falha acima for verdadeiro, o processo falha e a variável *FalhaMáquina* também é verdadeira.

### 3.3 O MODELO PREDITIVO

Primeiramente foi feito ajuste na variável *FalhaMaquina*, corrigindo inconsistências com base em condições relacionadas aos 5 modos de falha. Redefinição de falhas mal classificadas e identificação de falsos positivos e negativos.

Utilizando do conceito de FMEA, análise de variáveis críticas, e os conceitos de Processos de Usinagem, definiu-se que as variáveis *DiferencaTemperatura* [K], conforme Equação (1) *Potencia* [W], conforme Equação (2) e *Deformacao* [minNm], conforme Equação (3), afetam a confiabilidade do equipamento e reduzem a vida útil da ferramenta pois são modos de falha típicos desses equipamento. Com isso, foram criadas colunas para calcular cada nova varável:

$$DiferencaTemperatura [K] = T_p - T_a \quad (1)$$

$$P [W] = \tau [Nm] \cdot \omega [rpm] \cdot \frac{2\pi}{60} \quad (2)$$

$$Deformacao [minNm] = \tau [Nm] \cdot DesgasteFerramenta [min] \quad (3)$$

Onde  $T_p$  é a Temperatura do processo,  $T_{ar}$  é a temperatura do ar,  $\tau$  é o torque e  $\omega$  a velocidade de rotação.

Para aprendizado do modelo, foram aplicados dois modelos de aprendizado, *Árvore de decisão* e *Support Vector Machine*. No modelo de *Árvore de decisão* a técnica 80/20 foi utilizada. É uma abordagem comum em aprendizado de máquina para a divisão de dados em treinamento e teste, onde 80% dos dados são usados para treinar o modelo e 20% são reservados para avaliação. Essa prática é amplamente adotada para garantir que o modelo aprenda a identificar padrões sem se tornar dependente dos dados utilizados no treinamento.

A proporção 80/20 fornece uma boa base para medir o desempenho do modelo, equilibrando a quantidade de dados disponíveis para aprendizado e para validação. Durante o processo de aprendizado, o modelo foi ajustado com os 80% dos dados, aprendendo a relacionar as variáveis de entrada, que são os parâmetros da máquina, com a saída esperada, a falha.

Após o treinamento, o modelo é aplicado aos 20% restantes para testar sua capacidade de fazer previsões em dados que nunca viu antes. Isso simula o comportamento real do modelo ao lidar com novos dados e permite a avaliação de desempenho para verificar a qualidade das previsões.

Foi gerada uma matriz de confusão para exposição dos resultados obtidos pelo modelo e, então, feita a análise de desempenho, onde foram aplicadas as métricas acurácias, precisão, recall e F1-score, abordadas no item seguinte.

Já o algoritmo de SVM foi utilizado para analisar e identificar regiões de falha nas combinações de variáveis operacionais Potência, Torque, Deformação e Velocidade de Rotação, para prever falhas específicas do sistema (FPT, FST, FDC, FDF, FRN).

O SVM foi aplicado para capturar padrões não lineares nas variáveis de entrada e construir uma fronteira de decisão suave entre regiões de falha e não-falha.

### 3.3.1 Medidas de desempenho

Para análise de desempenho do modelo gerou-se a matriz de confusão e, então, foram aplicadas as métricas de acurácia, precisão, *Recall* (Sensibilidade), e *F1-Score*. A matriz de confusão faz uma comparação dos valores reais com os preditos pelo modelo, expondo a veracidade das predições, conforme exemplifica a Tabela 1

**Tabela 1 - Matriz de Confusão Padrão**

		Valor predito	
		Falha	Não Falha
Valor real	Falha	Verdadeiro positivo	Falso negativo
	Não falha	Falso positivo	Verdadeiro negativo

Acurácia foi aplicada para medir o desempenho de modo geral ao calcular a proporção de predições corretas em relação ao total, Equação (4), e como resultado obteve o percentual de predições corretas. Uma alta acurácia, acima de 80% para modelos desbalanceados, indica que o modelo fez muitas predições corretas.

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (4)$$

A precisão foi utilizada para medir a proporção de predições positivas corretas entre todas as predições positivas feitas pelo modelo, Equação (5), e como resultado obteve o percentual de Verdadeiros positivos. Uma alta precisão, valores acima de 90%, indica que o modelo raramente faz uma predição de falha quando não deveria. Já uma baixa precisão, abaixo de 70%, indica que o modelo cometeu erros identificando falhas que não existem.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (5)$$

A Sensitividade foi aplicada para medir a capacidade do modelo de identificar corretamente todos os casos positivos, Equação (6). Ela define, dentre todas as falhas reais, quantas o modelo identificou corretamente. Uma alta sensibilidade, acima de 85%, indica que o modelo conseguiu capturar a maioria dos casos de falha, indicando poucos falsos positivos. A baixa sensibilidade, abaixo de 70%, que o modelo não identificou um número considerável de casos de falha.

$$\text{Sensitividade} = \frac{VP}{VP + FN} \quad (6)$$

O *F1-Score* é a média harmônica entre precisão e sensibilidade, Equação (7), resultando em uma métrica equilibrada que considera tanto falsos positivos quanto falsos negativos. É especialmente útil quando há desbalanceamento entre as classes, onde o volume de falhas é menor que o de não falhas, como é o caso do conjunto de dados utilizado neste estudo. É importante onde tanto falsos positivos quanto falsos negativos devem ser minimizados para garantir confiabilidade. Um resultado alto, acima de 80%, indica que há um bom equilíbrio entre sensibilidade e precisão. Um resultado baixo, abaixo de 60%, que o modelo está falhando em uma dessas métricas.

$$F1 - Score = \frac{2 \cdot \text{Precisão} \cdot \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}} \quad (7)$$

### 3.3.2 Método probabilístico

O cálculo da probabilidade de falha pode ser realizado em duas etapas: Segmentação dos Dados pela Árvore de Decisão e Cálculo da Frequência Relativa de Falha. A primeira no qual cada nó terminal (folha) da árvore representa uma subdivisão específica do espaço de dados, contendo um subconjunto de amostras que compartilham condições semelhantes, por exemplo, potência entre 3500 W e 4000 W e deformação entre 900 minNm e 1000 minNm. Na segunda, a probabilidade de falha em cada folha pode ser calculada usando a Equação (8):

$$P(\text{Falha} | \text{Folha}) = \frac{N^{\circ} \text{ de folhas}}{N^{\circ} \text{ de falhas na folha}} \quad (8)$$

Essa relação fornece a chance condicional de falha para cada região do espaço definido pela árvore de decisão.

## 4 RESULTADOS

O modelo de foi desenvolvido para tratamento de dados e para predição de falhas. Por ser um banco de dados volumoso, foram gerados gráficos para os 5 modos de falha, FPT, FDC FDF, FST e FRN, a fim se obter uma interpretação visual de todo o banco. Os padrões identificados ajudam a priorizar os modos de falha:

- Severidade: Falhas relacionadas ao torque podem ser mais graves, afetando diretamente a integridade do motor. Entende-se que as falhas relacionadas ao torque estão ligadas diretamente ao desgaste da ferramenta (perda de sua aresta de corte) exigindo mais do equipamento ao realizar uma operação.
- Ocorrência: Dados históricos do banco de dados fornecem informações sobre a frequência de cada falha, auxiliando previsão de quando as falhas tornarão a ocorrer (MTBF e MTTF).

Foi gerado também um gráfico de probabilidade de falha em função da variação de Potência e Deformação. A probabilidade de falha na árvore de decisão é gerada durante a predição, fornecendo, além da classificação binária (falha ou não-falha), um valor contínuo entre 0 e 1, que representa a chance de uma combinação específica de potência ( $W$ ) e deformação ( $\text{minNm}$ ) estar associada a uma falha. Esse valor probabilístico é calculado com base na frequência relativa de ocorrências de falha nas folhas finais da árvore, fornecendo uma indicação probabilística da vulnerabilidade à falha para diferentes combinações de parâmetros operacionais.

Por exemplo, uma combinação de potência de 3800 W e deformação acumulada de 920 minNm pode gerar uma probabilidade de falha de 70%, alertando para a necessidade de uma intervenção preventiva para evitar danos à ferramenta.

Os resultados indicam o ponto ótimo entre eficiência operacional e economia, sugerindo ajustes nos parâmetros de usinagem sem comprometer a produção. Por exemplo, ao limitar a operação para 76% da potência nominal do equipamento, é possível evitar 96% das falhas por alta potência, considerando a acurácia de 96% obtida no modelo.

## 4.1 REGIÕES DE FALHA PARA ÁRVORE DE DECISÃO


O modelo de Árvore de decisão criou regras hierárquicas para separar os dados em diferentes regiões, demarcadas por linhas retas em verde nos gráficos a seguir. Essas regiões de falha são as áreas consideradas críticas. Com elas é possível delimitar uma região onde não se recomenda operar pois há alta probabilidade de falha.

Esse método classifica as falhas de modo linear e com isso tem maior chance de conter falsos resultados. A matriz de confusão e as métricas de resultado ajudaram a entender os resultados e avaliar o seu desempenho. Abaixo estão identificadas as regiões de falha por modo de falha.

### 4.1.1 Falhas aleatórias – FRN

Falhas aleatórias são mais difíceis de prever, pois não têm uma relação clara com parâmetros específicos. Elas podem resultar de fatores externos, como flutuações de energia, erros operacionais ou defeitos em componentes.

Devido à aleatoriedade, o modelo, apesar de identificar regiões de falha, englobou diversos pontos de não falha, como pode ser observado na Figura 5, isso pode indicar uma quantidade considerável de falsos resultados. Elas foram consideradas neste trabalho pois ainda que não tenham fácil previsibilidade, contribuem para os resultados de análise de falha. As Tabelas 2, 3 e 4 mostram os limites das regiões de falha encontradas



**Figura 5 - Análise de FRN**  
**Fonte: Próprios autores do projeto**

**Tabela 2 - Região de Falha 1 para FRN**

	Mínimo	Máximo
Deformacao [minNm]	64,6	2.631,5
Torque [Nm]	27,7	57,5

**Tabela 3 - Região de Falha 2 para FRN**

	Mínimo	Máximo
Deformacao [minNm]	4.732,0	7.525,0
Torque [Nm]	28,7	52

**Tabela 4 - Região de Falha 3 para FRN**


	Mínimo	Máximo
Deformacao [minNm]	9.604,8	10.404,0
Torque [Nm]	46,4	61,2

#### 4.1.2 Falhas de Sobretensão – FST

A sobretensão ocorre quando há uma carga excessiva sendo aplicada à ferramenta de corte, à peça ou à própria estrutura da máquina, seja por desgaste da ferramenta, seja por parâmetros de operação inadequados. As Figuras 6 e 7 mostram, respectivamente, uma ferramenta de corte íntegra e outra com perda de pequenas lascas, que podem ser causadas por cargas excessivas.

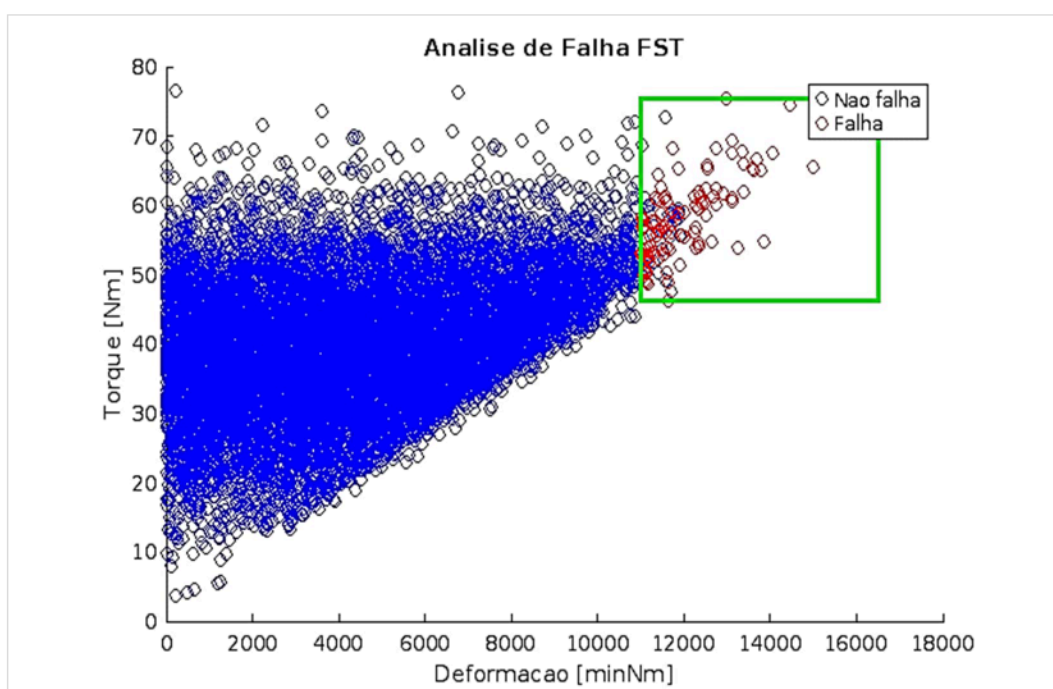


**Figura 6 - Ferramenta de corte.**  
**Fonte: Harvey Performance, 2020.**



**Figura 7 - Ferramenta de corte com lascamento**  
**Fonte: Harvey Performance, 2020**

O gráfico da Figura 8 mostra que à medida que a ferramenta se desgasta mais torque é necessário para realizar a operação até que se atinja a região de sobretensão onde a máquina falha por esforços acima da capacidade.



**Figura 8 - Falha por Sobretensão.**  
**Fonte: Próprios autores do projeto**


O uso prolongado do equipamento acima do especificado pode causar sérios danos: Trincas, rupturas ou mesmo quebra de componentes como eixos e engrenagens. Em casos de imperfeições na aresta de corte, essas podem ser transferidas à peça e danificar sua superfície. A tabela 5 mostra os valores do limite da região de falhas FST.

**Tabela 5 - Região de Falha para FST**

	Mínimo	Máximo
Deformacao [minNm]	11.003,2	16.497,0
Torque [Nm]	46,3	75,4

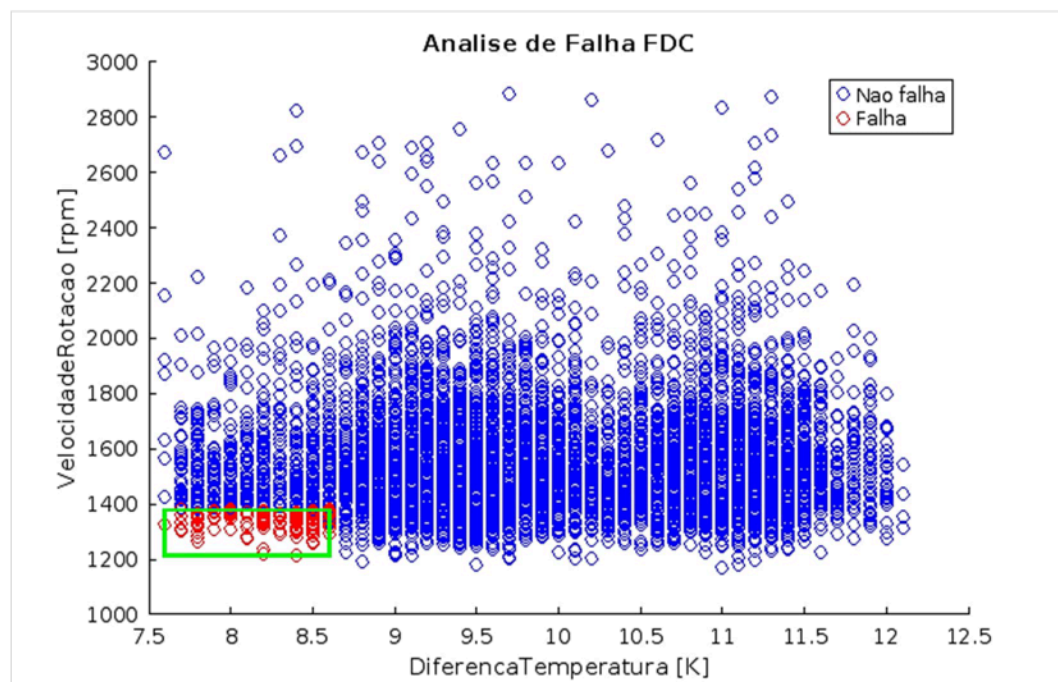
#### 4.1.3 Falha por Dissipação de Calor – FDC

A falha por dissipação ocorre quando a temperatura do processo está próxima da temperatura do ar. A Dissipação de Calor foi relacionada à velocidade de rotação da ferramenta, que está diretamente ligada à velocidade de corte. A temperatura aumenta com a velocidade de corte na região usinada, como mostra a Figura 9, entretanto, como foi mostrado anteriormente, altas velocidades permitem uma melhor formação e remoção de cavaco, o que permite melhor dissipação do calor. O curto tempo de contato entre as superfícies também favorece a dissipação de calor.



**Figura 9 - Distribuição de calor em ferramenta de corte**  
Fonte: Brito, Tarcísio, 2014.

A temperatura do processo aumenta em baixas velocidades, porém não é dissipada. Os cavacos acumulados retêm o calor na região. Aqui, o gráfico da Figura 10 mostrou que altas temperaturas podem ser causadas por baixa velocidade de rotação.



**Figura 10 - Falha por Dissipação de Calor**  
**Fonte: Próprios autores do Projeto**

A região deve ser ponto de atenção no momento de definição dos parâmetros de corte, pois pode levar a falhas como desgaste prematuro, redução de vida útil e perda da aresta de corte, aumentando a força de corte necessária. Pode também causar endurecimento superficial da peça usinada. A tabela 6 mostra numericamente a região a ser evitada

**Tabela 6 - Região de falha para FDC**

	Mínimo	Máximo
DiferencaTemperatura [K]	7,6	8,6
VelocidadeRotacao [rpm]	1.212,0	1.379,0

A região deve ser ponto de atenção no momento de definição dos parâmetros de corte, pois pode levar a falhas como desgaste prematuro, redução de vida útil e perda da aresta de corte, aumentando a força de corte necessária. Pode também causar endurecimento superficial da peça usinada.

Pode se estimar uma taxa de desgaste por (TAYLOR, 1907), através da Equação (9), que define a vida útil de uma ferramenta a partir do desgaste.

Nesta expressão,  $V_c$  representa a velocidade de corte, enquanto  $T$  refere-se à vida útil da ferramenta medida em minutos, correspondente ao tempo necessário para alcançar um desgaste da aresta de corte. O parâmetro  $n$  é um expoente que varia de acordo com os parâmetros de corte e o tipo de material utilizado, e  $C$  é uma constante característica da combinação entre a ferramenta e o material da peça. É importante ressaltar que  $C$  corresponde à velocidade de corte quando a vida útil da ferramenta é exatamente 1 minuto.

Dessa forma, cada combinação específica de material da ferramenta, material da peça de trabalho e condições de corte possui valores próprios para  $n$  e  $C$ , que devem ser determinados experimentalmente.

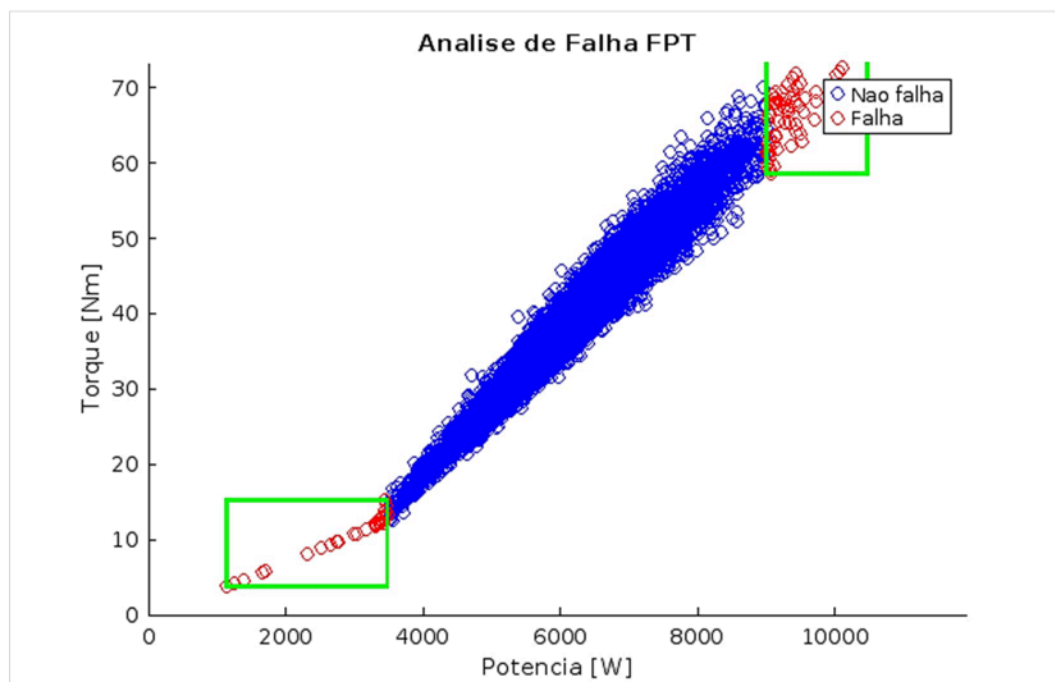
$$V_c \cdot T^n = C \quad (9)$$

#### 4.1.4 Falha de Potência – FPT

O torque é uma variável essencial na operação de uma fresadora, pois reflete diretamente a força aplicada ao eixo principal durante o corte. Para corresponder a essa força, a Potência do motor é demandada conforme a Equação (10):

$$P [W] = \tau [Nm] \cdot \omega [w] \quad (10)$$

A Figura 11 mostra a região de falha com baixo Torque, numericamente pode ser vista na Tabela 7, que pode estar relacionada à queda de tensão na alimentação elétrica. A instabilidade pode levar à queima de componentes.



**Figura 11 - Falha por Potência**  
**Fonte: Próprios autores do projeto**

**Tabela 7 - Região de falha 1 para FPT**

	Mínimo	Máximo
Potencia [W]	1148.4406	3477.2404
Torque [Nm]	3.8	15.3

A região de falha com alto torque, numericamente na Tabela 8, pode indicar sobrecarga do equipamento. Como visto anteriormente no item 4.1.2, a sobretensão por alto torque é prejudicial.

O aumento de tensões gera desgaste de componentes mecânicos internos e levam ao superaquecimento do motor. Não somente, os impactos no acabamento da peça pela instabilidade dos parâmetros de corte formam peças com irregularidade superficial.

**Tabela 8 - Região de falha 2 para FPT**


	Mínimo	Máximo
Potencia [W]	9.004,4	10.469,9
Torque [Nm]	58,5	76,6

#### 4.1.5 Falha por Desgaste da Ferramenta – FDF

O desgaste progressivo da ferramenta é uma das principais causas que levam à sua falha. Para evitar danos severos à máquina-ferramenta e custos excessivos decorrentes de falhas inesperadas, é essencial definir o limite de vida útil da ferramenta, assegurando que ela continue atendendo aos requisitos operacionais e de qualidade (ASTAKHOV, 2008).

O gráfico na Figura 12 representa a análise de falha por desgaste da ferramenta (FDF), indicando claramente uma região crítica de operação, delimitada pelo retângulo verde. Essa região corresponde a uma combinação específica de tempo de uso da ferramenta (entre 198 e 253 minutos) e velocidade de rotação (entre 1323 e 2271 rpm). Dentro desses limites, a probabilidade de falha da ferramenta aumenta significativamente.

O desgaste, quando não monitorado adequadamente, pode levar a falhas catastróficas, comprometendo a qualidade das peças usinadas e causando danos ao equipamento. O modelo preditivo identificou que, após aproximadamente 200 minutos de operação, a ferramenta entra em uma zona de risco, onde a probabilidade de falha aumenta rapidamente. Essa informação é crucial para a elaboração de estratégias de manutenção preditiva, que visam substituir ou recondicionar a ferramenta antes que ela atinja essa condição crítica.



**Figura 12 - Falha por Desgaste da Ferramenta**  
**Fonte: Próprios autores do projeto**

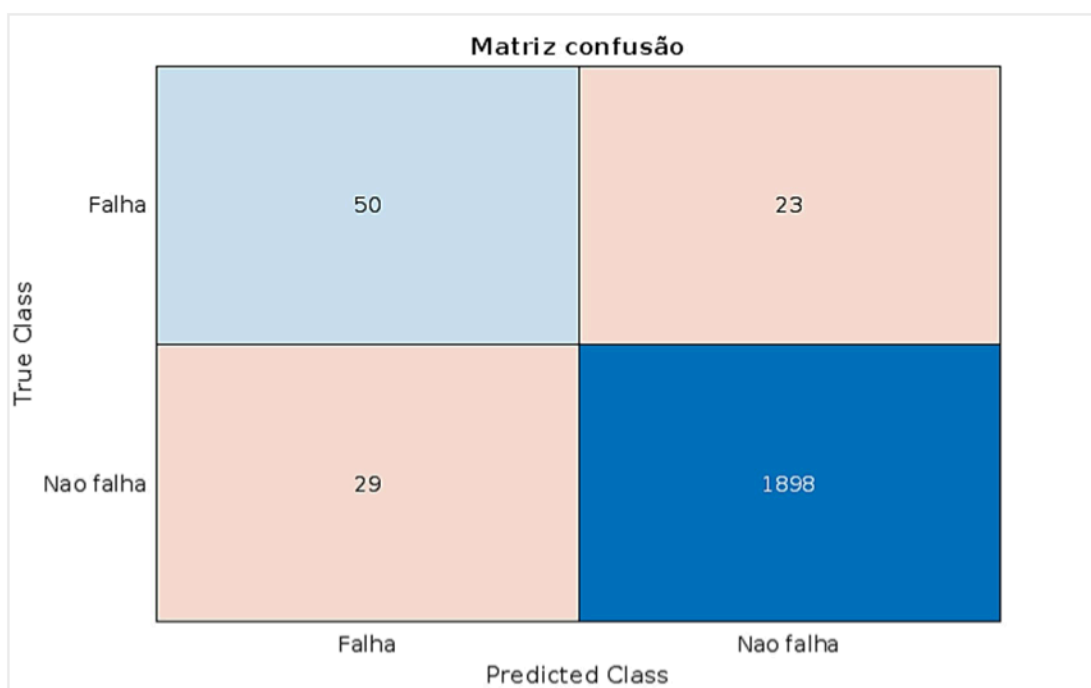
Com base nos limites identificados na Tabela 9, seria possível estabelecer um plano de manutenção preventiva, programando a substituição da ferramenta quando o desgaste atingir aproximadamente 190 minutos de uso, garantindo uma margem de segurança. Essa prática não apenas minimiza o risco de falha, mas também melhora a confiabilidade do processo e reduz o custo operacional a longo prazo, evitando paradas inesperadas e retrabalhos associados à quebra de ferramenta.

**Tabela 9 - Região de falha para FDF**

	Mínimo	Máximo
DesgasteFerramenta [min]	198	253
VelocidadeRotacao [rpm]	1323	2271

## 4.2 DESEMPENHO DO MODELO DE ÁRVORE DE DECISÃO

O modelo de árvore de decisão foi avaliado por meio da divisão dos dados em treinamento e teste (80/20), e seus resultados foram analisados através de métricas como acurácia, precisão, recall e F1-score. A matriz de confusão, Figura 13, indicou que o modelo possui alta acurácia geral, cerca de 96,95%, o que sugere um desempenho consistente para prever os casos de não-falha.



**Figura 13 - Resultados da Matriz de Confusão**  
**Fonte: Próprios autores do projeto**

Isso é especialmente crítico para a manutenção preditiva, já que uma falha não detectada pode levar a danos catastróficos e paradas não planejadas. A Tabela 10 mostra os resultados da Matriz de Confusão e taxa de falsos negativos em torno de 46% evidencia a necessidade de ajustes nos parâmetros do modelo ou na seleção de variáveis preditoras.

**Tabela 10 - Resultados da Matriz de Confusão**

Verdadeiros Positivos	50
Falsos Positivos	29
Verdadeiros Negativos	1.898
Falsos Negativos	23

No entanto, as métricas de precisão e recall demonstram fragilidade na identificação correta dos casos de falha. A Tabela 11 traz os resultados da avaliação de desempenho do modelo, na qual resultou em uma precisão de 54,54% e um recall de 53,73%, apresentando baixa capacidade de detecção de falhas reais e, portanto, um número significativo de falsos negativos.

**Tabela 11 - Resultados de Desempenho**

Acurácia:	0,9695
Precisão:	0,54545
Recall(Sensibilidade):	0,53731
F1-Score:	0,54135

Na análise de Especificidade o modelo consegue identificar corretamente os casos negativos na maioria das vezes, logo, tem um baixo índice de falsos positivos. Uma Alta Especificidade mostra que o modelo é excelente para identificar corretamente os casos negativos, mas tem dificuldades na identificação dos positivos. Isso é um indicativo de desbalanceamento do banco de dados.

A Taxa de Falsos Positivos indica que apenas 1,55% dos casos negativos foram incorretamente classificados como positivos.

A Taxa de Falsos Negativos indica que cerca de 46,27% dos casos positivos foram erroneamente classificados como negativos, indicando que o modelo tem dificuldades em identificar corretamente os casos positivos.

A Razão de Verossimilhança Positiva teve um valor alto, indicando que um teste positivo é muito mais provável de vir de um caso verdadeiramente positivo do que de um negativo.

A Razão de Verossimilhança Negativa, por outro lado, apresentou um valor moderado, sugerindo que um resultado negativo reduz a probabilidade de um caso positivo, mas ainda não de forma muito confiável.

O modelo tem alta Acurácia, mostrando que tem um bom desempenho global, mas isso pode ser influenciado pelo grande número de verdadeiros negativos. Isso é um forte indicativo de um banco de dados desbalanceado.

Baixa Precisão e Recall indicam que o modelo tem dificuldade em prever corretamente os casos positivos, resultando em falsos negativos e falsos positivos.

Para melhorar o desempenho do modelo pode ser feito um balanceamento dos dados e uma integração de análises com outros modelos mais complexos, como Redes Neurais, Random Forest ou mesmo SVM, que foi abordado abaixo.

### 4.3 REGIÕES DE FALHA POR SVM

O modelo de SVM (*Support Vector Machine*) utilizado no código delimitou as regiões de falha dos modos de falha, capturando relações não lineares entre as variáveis. O modelo se fez necessário para identificar padrões complexos e construir fronteiras de decisão mais suaves e precisas em comparação com a árvore de decisão, que possui uma estrutura hierárquica e segmenta o espaço de forma linear.

Enquanto a árvore de decisão forneceu uma interpretação mais intuitiva e regras claras para identificar as condições de falha, o SVM apresentou melhor desempenho na separação de classes em casos de variáveis contínuas e alta dimensionalidade, reduzindo falsos negativos.

No contexto de manutenção preditiva, a integração de ambos os modelos pode ser uma solução eficiente, combinando precisão preditiva com clareza na tomada de decisão operacional.


#### 4.3.1 Falha Randômica por SVM

A falha aleatória (Randômica) foi considerada em função da probabilidade que todo sistema pode ter de falhas não relacionadas. Neste caso, não relacionadas aos modos de falha considerados. São falhas que podem ocorrer por fatores diversos e, certas vezes, externos, como por exemplo mal uso do equipamento ou defeito de fabricação de uma ferramenta.

O SVM trabalha definindo hiperplanos para separação de classes. Identifica cada classe e separa traçando uma reta ou mesmo curvas de separação. É assim que delimita suas fronteiras.

Existem casos em que não é possível separar as duas classes de maneira simples, pois uma das classes está no território de outra (*outlier*). O SVM tem um recurso para ignorar valores discrepantes e encontrar o hiperplano que tem margem

máxima. Porém, em casos como o de FDF, onde a sobreposição de dados é significativa, o modelo pode ter dificuldade de definir um hiperplano de classificação, como demonstrado na Figura 14 a seguir.



**Figura 14 - Regiões de falha (SVM) FRN**  
**Fonte: Próprios autores do projeto**

Isso pode ocorrer em cenários onde os parâmetros do modelo SVM não tenham sido ajustados corretamente, onde a distribuição é não-linear e densa, especialmente em regiões com poucos pontos de falha e, também, onde as classes de falha ou não-falha não são separáveis, como este caso de falhas aleatórias.

Elas foram consideradas neste estudo porque, apesar de sua difícil previsão, estão presentes e somam-se às falhas totais do equipamento.


#### 4.3.2 Falha de Sobretensão por SVM

A árvore de decisão ofereceu uma abordagem estruturada e hierárquica, que facilita a interpretação dos resultados e permite a criação de regras explícitas para identificar zonas operacionais de risco, como limites máximos de torque e deformação que podem indicar falhas iminentes por sobrecarga

Entretanto, por trabalhar com segmentações lineares no espaço de variáveis, a árvore de decisão pode deixar de capturar relações mais sutis e não lineares entre esses parâmetros, reduzindo a precisão em condições de transição entre operação normal e falha.

O SVM constrói fronteiras de decisão mais precisas e adaptativas, especialmente em cenários onde a interação entre deformação e torque não segue uma lógica claramente linear. Isso é fundamental em falhas por sobretensão, onde a combinação de pequenos aumentos de torque e deformação acumulada pode, gradualmente, levar a um estado crítico.

O modelo demonstra maior capacidade de identificar essas zonas de risco progressivo, resultando em menor taxa de falsos negativos, o que é crucial para manutenção preditiva, onde a antecipação de falhas evita danos maiores e paradas não planejadas. Entretanto, o SVM não fornece uma regra explícita e direta para definir os limites de operação segura, tornando-o menos intuitivo para operadores e equipes de manutenção. Na Figura 15, é possível observar a fronteira de decisão para as regiões de falha por sobretensão.



**Figura 15 - Regiões de falha (SVM) FST**  
**Fonte: Próprios autores do projeto**

Em aplicações de manutenção preditiva, o modelo de árvore de decisão seria útil para alertas operacionais diretos, por exemplo, sinalizando quando o torque ultrapassa um limite crítico associado a sobrecarga, orientando intervenções preventivas imediatas.


Já o modelo de SVM pode ser aplicado para monitoramento contínuo, detectando padrões complexos e indicando tendências de degradação progressiva antes mesmo de uma falha ser evidente.

A integração dessas abordagens permitiria combinar a interpretação clara da árvore de decisão com a precisão preditiva do SVM, proporcionando uma estratégia mais completa para evitar falhas por sobretensão e sobrecarga em fresadoras.

#### 4.3.3 Falha por Dissipação de Calor por SVM

O modelo SVM é particularmente eficiente na separação não linear dessas regiões de risco térmico, permitindo identificar pontos críticos que não são facilmente detectáveis por métodos lineares. Porém, quando comparado ao modelo de Árvore de decisão, seu desempenho de previsão da região de falha não se mostrou superior como no modo FST.

A precisão das medições de temperatura era baixa, com marcações a cada 0,1K. Isso resulta em uma região bem definida. Regiões bem definidas e lineares são de fácil interpretação para o modelo de Árvore de decisão, equiparando os dois modelos.



**Figura 16 - Regiões de falha (SVM) FDC**  
**Fonte: Próprios autores do projeto**

Como dito anteriormente e ao observar a Figura 16, é possível perceber que o algoritmo SVM tem vantagens sobre Árvore de decisão em sua não-linearidade, em que permite um monitoramento contínuo. Sua capacidade de construir fronteiras de decisão suaves e adaptativas proporciona uma detecção mais precisa das condições que levam ao acúmulo térmico. Em cenários onde as variáveis apresentam grande variabilidade, como flutuações na temperatura e mudanças na rotação, o modelo consegue capturar padrões complexos e prever zonas de risco progressivo.

Do mesmo modo que para FST a integração dos modelos é recomendada, aqui não seria diferente. Aplicar SVM para monitoramento contínuo das condições térmicas, destacando padrões de degradação progressiva, enquanto a árvore de decisão poderia fornecer alertas diretos para eventos críticos, como a identificação de uma combinação específica de baixa velocidade e baixa diferença de temperatura.

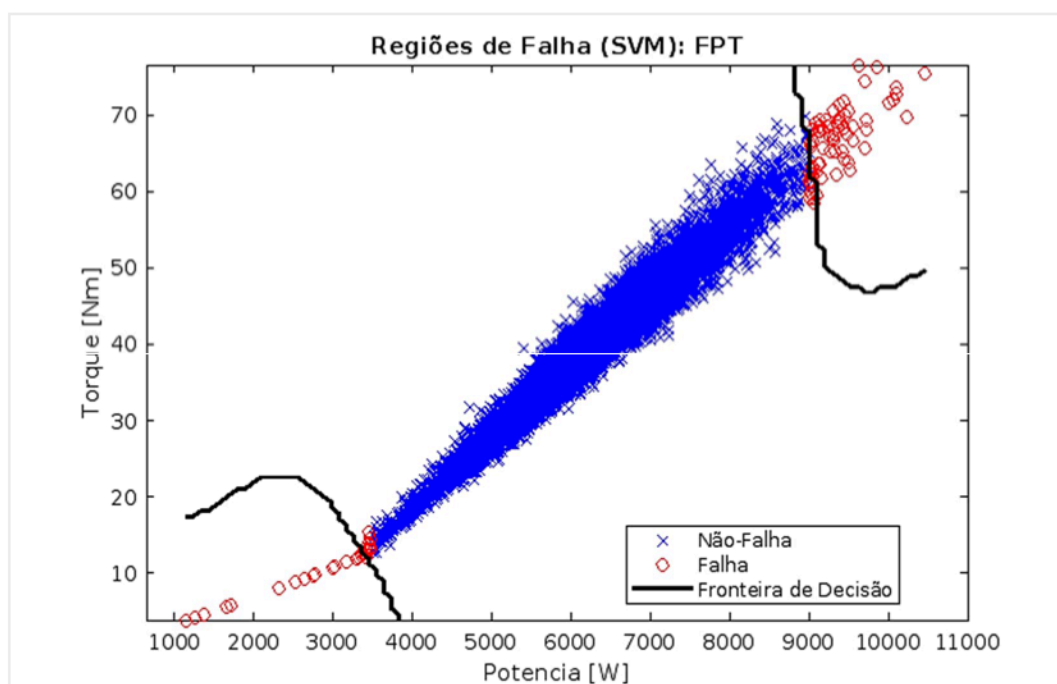
Essa combinação permitiria uma abordagem mais robusta, garantindo maior confiabilidade da manutenção.

#### 4.3.4 Falha de Potência por SVM

SVM apresenta um desempenho significativo ao identificar regiões de risco onde a potência ultrapassa limites aceitáveis, resultando em sobrecarga ou insuficiência energética. Esse tipo de falha ocorre quando a potência está fora da faixa

recomendada, o que pode levar a danos na ferramenta, perda de precisão no corte e até falhas elétricas.

Assim como nos modos de falha FDC e FST, o SVM é especialmente eficaz para capturar a relação não linear entre potência e torque, garantindo uma separação mais precisa das zonas de falha.



**Figura 17 - Regiões de falha (SVM) FPT**  
**Fonte: Próprios autores do projeto**

Através da Figura 17, pode-se observar que o modo FPT apresenta um comportamento dinâmico. A potência não depende exclusivamente do torque, mas também de fatores indiretos como condições de corte e desgaste acumulado da ferramenta. O SVM, nesse contexto, demonstra uma melhor capacidade de adaptação a essas flutuações, reduzindo a taxa de falsos negativos e oferecendo maior confiabilidade para prever situações de risco por excesso ou insuficiência de potência.

A abordagem linear da Árvore de decisão pode levar a uma simplificação excessiva das condições reais do processo. Isso pode resultar em erros nas zonas de transição, onde a potência oscila em níveis próximos ao limite de falha. O SVM, ao contrário, identifica essas variações com maior precisão, criando zonas de risco contínuas que refletem melhor o comportamento real do sistema.


Para o modo FPT, o SVM é uma ferramenta essencial para monitoramento contínuo e detecção de tendências de sobrecarga ou insuficiência energética. Em contraste com o modelo SVM aplicado ao modo FST, onde o foco está na integridade mecânica da ferramenta.

A aplicação do SVM para prever picos de potência pode reduzir paradas de manutenção não planejadas.

#### 4.3.5 Falha por Desgaste da Ferramenta por SVM

Do mesmo modo que para falhas aleatórias o modelo não foi capaz de definir uma fronteira, aqui também não foi.

Em FRN, a dificuldade estava em separar as classes que eram espaçadas entre si. Em FDF, as classes se sobrepõem de maneira que não é capaz de definir uma fronteira clara e apresentaria falsos positivos, como pode-se observar na Figura 18 a seguir.



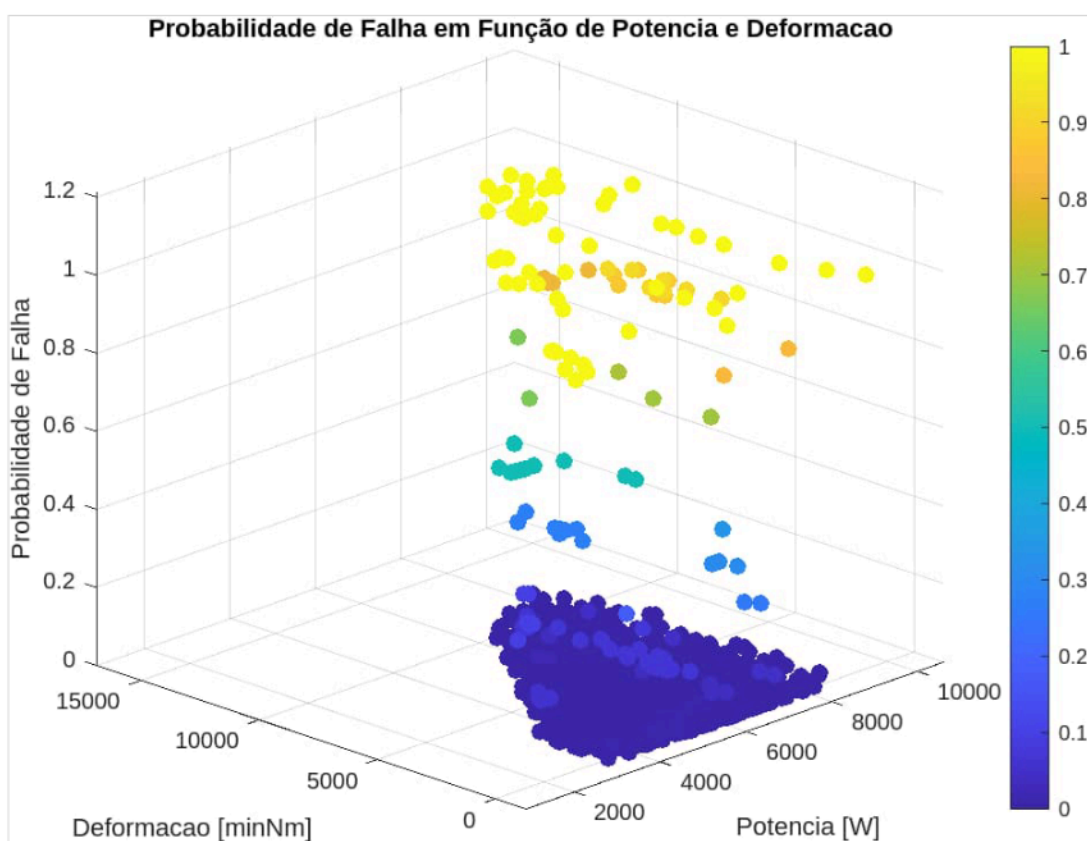
**Figura 18 - Regiões de falha (SVM) FDF**  
Fonte: Próprios autores do projeto

Novamente, isso pode ocorrer em cenários onde os parâmetros do modelo SVM não tenham sido ajustados corretamente, onde a distribuição é não-linear e densa ou onde as classes de falha ou não-falha não são separáveis, como a combinação Velocidade de rotação e desgaste da ferramenta.

#### 4.4 PROBABILIDADE DE FALHA: POTÊNCIA POR DEFORMAÇÃO

A probabilidade de falha foi gerada durante a predição da árvore de decisão. O modelo forneceu além de classificação binária (falha ou não-falha), também uma classificação em valor contínuo representando a probabilidade de que uma determinada combinação de potência (W) e deformação (minNm) esteja associada a uma condição de falha.

A probabilidade atua como um indicador de risco operacional, identificando zonas onde a combinação de potência e deformação leva a uma maior probabilidade de falha, através da Figura 19 a seguir é possível observar essa tendência.



**Figura 19 - Probabilidade Falha em função da Potência e do Desgaste**  
Fonte: Próprios autores do projeto

A visualização gráfica das probabilidades permite identificar picos de risco e regiões de transição, que são fundamentais para decisões de gestão de riscos em preventivas.

As zonas de risco foram identificadas como Regiões de baixa potência e baixa deformação indicam operações normais, onde o risco de falha é mínimo. Isso geralmente ocorre no início da vida útil da ferramenta, quando o desgaste ainda é insignificante.

Regiões de alta deformação combinadas com potência elevada representam condições críticas, indicando que a ferramenta já atingiu um nível avançado de desgaste, exigindo mais potência para manter o processo de corte. Essa situação está diretamente ligada ao risco de falhas por desgaste excessivo, sobrecarregamento do motor e até mesmo perda da aresta de corte.

Zonas de transição, onde a probabilidade de falha aumenta gradualmente, são essenciais para o planejamento de manutenção preditiva. Elas oferecem uma oportunidade de intervenção antes que o processo entre na região crítica, reduzindo o risco de falhas catastróficas.

Essa probabilidade fornece uma visão preditiva macro do comportamento da máquina, oferecendo não somente à gerência, mas também ao operador a possibilidade de tomada de decisão ativa.

Permite uma detecção antecipada ao identificar as regiões de alta probabilidade de falha, otimização dos parâmetros de corte para evitar zonas de prováveis falhas. Diferentemente da avaliação binária realizada anteriormente.

Permite um planejamento preventivo inteligente críticas identificadas podem ser usadas para definir pontos de inspeção periódica e determinar quando uma ferramenta deve ser substituída ou reafiada, evitando desperdício e aumentando a produtividade.

Considerando uma operação com parâmetros de Potência igual a 3500W e uma deformação acumulada de 8000minNm, há 75% de probabilidade de falha. Isso indica que está próximo do limite crítico de operação. O modelo prevê que dentro de 30min contínuos a ferramenta haverá falha e com isso causando parada não planejada do equipamento afetando a linha de produção.

Com isso, pode ser programada uma intervenção de troca. Considerando uma parada não planejada de 2h (troca emergencial e ajuste da máquina, além do retrabalho na peça danificada), há um custo de parada de produção de R\$500,00/hora

e um custo de R\$300,00 de uma nova ferramenta. O custo da não intervenção é de R\$1.300,00. Enquanto na parada planejada, uma ferramenta pode ser substituída em alguns minutos, consumindo apenas o valor de uma nova ferramenta.

$$\% \text{ de economia} = \frac{R\$300}{R\$1300} = 0,231 = 23\%$$

## 5 CONCLUSÃO

A presente pesquisa teve como objetivo avaliar a aplicação da Inteligência Artificial na manutenção preditiva de uma fresadora, com foco na implementação de um modelo baseado em algoritmos de árvore de decisão para a classificação e predição de falhas. A problemática abordada buscou responder se a adoção de IA poderia melhorar a eficiência da manutenção preditiva, reduzindo falhas não planejadas e otimizando a disponibilidade operacional do equipamento.

Este estudo comprovou a eficiência da aplicação de Inteligência Artificial na manutenção preditiva de fresadoras. O modelo de Árvore de Decisão apresentou uma acurácia geral de 96,95%, evidenciando um desempenho consistente na classificação de falhas e não-falhas. No entanto, o modelo demonstrou fragilidade em detectar falhas reais, com uma precisão de 54,54% e recall de 53,73%, indicando uma alta taxa de falsos negativos (46%). Esse resultado ressalta a necessidade de ajustes nos parâmetros do modelo ou na seleção de variáveis preditoras para melhorar a capacidade de identificação das falhas. Modelos ideais devem ter precisão acima de 90%. Isso pode ser obtido com melhor balanceamento de dados em interação com outros métodos.

Para estudos futuros, recomenda-se a utilização do algoritmo *Random Forest* em substituição à árvore de decisão para aprimorar a precisão e a sensibilidade em problemas de classificação e regressão. Como um método de *ensemble learning*, o *Random Forest* reduz o *overfitting*, melhora a generalização do modelo e proporciona maior robustez na tomada de decisões, tornando-se uma alternativa mais eficiente para cenários onde a confiabilidade dos resultados é essencial.

O modelo de SVM demonstrou-se eficaz ao lidar com relações não lineares entre variáveis críticas, como potência, torque, diferença de temperatura e tempo de operação, identificando padrões complexos que a árvore de decisão não conseguiu delimitar com precisão. A análise mostrou que o modelo SVM oferece uma delimitação mais precisa das regiões críticas, reduzindo a taxa de falsos negativos e proporcionando uma visão mais confiável das condições de risco operacional.

Recomenda-se, para futuros estudos, explorar a combinação do SVM com algoritmos híbridos para aprimorar ainda mais a precisão e a interpretabilidade das

predições. Adicionalmente, também é indicado maior exploração de gráficos visuais tridimensionais, utilizando mais de 2 parâmetros na mesma análise e contribuindo para melhor visualização das regiões de falha gerada pelos algoritmos.

Pôde ser observada potencial de melhoria dos indicadores essenciais da manutenção preditiva, como o MTBF, MTTR (*Mean Time to Repair*) e a disponibilidade operacional da fresadora, como analisado no item 4.4. A visualização da probabilidade de falha em função da potência e deformação é uma ferramenta essencial para manutenção preditiva avançada. Ela oferece uma abordagem proativa para evitar falhas e otimizar a operação da fresadora, permitindo intervenções programadas e melhorando a confiabilidade do processo. Ao integrar essas informações com as métricas da árvore de decisão, é possível construir um modelo mais robusto e confiável, aprimorando continuamente a eficiência operacional e reduzindo riscos no ambiente de produção.

A comparação com metodologias tradicionais de manutenção revelou que o modelo baseado em IA contribuiu para a redução da incerteza associada à previsão de falhas, tornando o planejamento da manutenção mais eficiente.

Além disso, ao integrar técnicas de análise de falhas, como FMEA (*Failure Modes and Effects Analysis*), foi possível estabelecer uma criticidade de falhas mais precisa, priorizando intervenções com base na probabilidade de ocorrência e no impacto das falhas identificadas. Esses aspectos evidenciam que a adoção da IA está alinhada com as melhores práticas de engenharia da confiabilidade, garantindo uma gestão mais eficiente dos ativos industriais.

Apesar dos avanços observados, algumas limitações foram identificadas ao longo da pesquisa. A acurácia do modelo depende fortemente da qualidade dos dados coletados, o que reforça a necessidade de sistemas de monitoramento robustos e de técnicas aprimoradas de pré-processamento de dados. Além disso, a integração da IA com as metodologias clássicas de confiabilidade ainda demanda maior validação, especialmente no que se refere à definição de limites operacionais para a tomada de decisão

Outro ponto relevante é a variabilidade inerente às condições operacionais da fresadora, que pode influenciar os resultados do modelo de predição. Enquanto a IA permite uma análise dinâmica do estado do equipamento, a confiabilidade tradicional muitas vezes trabalha com distribuições estatísticas fixas. Esse aspecto exige estudos

adicionais para entender melhor como combinar ambas as abordagens, garantindo previsões mais robustas e adaptáveis às condições reais de operação.

Diante dos achados, sugere-se que pesquisas futuras explorem a integração de diferentes técnicas de aprendizado de máquina, como redes neurais artificiais e algoritmos híbridos, a fim de aprimorar ainda mais a capacidade preditiva dos modelos aplicados à manutenção preditiva. Além disso, recomenda-se a ampliação da base de dados utilizada, incorporando variáveis adicionais que possam melhorar a sensibilidade e especificidade das previsões.

A aplicação de Inteligência Artificial na manutenção preditiva representa um avanço significativo para a gestão da manutenção industrial, proporcionando maior confiabilidade, redução de custos e aumento da eficiência operacional. O estudo reforça a importância da digitalização dos processos industriais e o papel fundamental que a IA desempenha na transformação da manutenção preditiva, alinhando-se às diretrizes da Indústria 4.0.

Além disso, os resultados obtidos demonstram que a sinergia entre IA e engenharia da manutenção pode representar um novo paradigma na gestão de ativos, otimizando a disponibilidade dos equipamentos e garantindo um planejamento de manutenção mais eficiente e proativo.

## REFERÊNCIA BIBLIOGRÁFICA

ABRECOM, 2024, 6 ferramentas e técnicas para análise de falhas + Bônus passo a passo, São Paulo.

AGGARWAL, C.C., REDDY, C.K., 2013, Data clustering: algorithms and applications, Boca Raton.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR-5462: Confiabilidade e Manutenibilidade. Rio de Janeiro. 1994.

ASTAKHOV, V.P. Tools (Geometry and Material) and Tool Wear. Machining: Fundamentals and Recent Advances. Opole, v. 1, n. 2, p. 29-57. 2008.

BARBOSA, J.D.M., 2023, Manutenção preditiva com recurso a inteligência artificial, Coimbra.

BERTENE, L., 2024, CSN e Inteligência Artificial para Previsão de Falhas em Máquinas de Laminação, São Paulo.

BISHOP, C. M., 2006, Pattern recognition and *Machine Learning*, London.

BITFAB. Fresadoras: tudo o que você precisa saber. 2023. Disponível em: <https://bitfab.io/pt-pt/blog/fresadoras/>. Acesso em: 15 fev. 2025.

BREIMAN, L., 2001, Random forests. *Machine Learning*, London.

CIMM. Distribuição de calor em ferramenta de corte. Disponível em: [https://www.cimm.com.br/portal/material\\_didatico/imagem/3652](https://www.cimm.com.br/portal/material_didatico/imagem/3652). Acesso em: 8 fev. 2025.

FMEA. FM2S. Disponível em: [GOODFELLOW, I., BENGIO, Y., COURVILLE, A., 2016, \*Deep Learning\*, Cambridge.](https://www.fm2s.com.br/blog/fmea#:~:text=FMEA%20(Failure%20Mode%20and%20Effect,e%20aplica%C3%A7%C3%B5es%20desta%20incr%C3%ADvel%20ferramenta. Acesso em 02 jan. 2025.</a></p></div><div data-bbox=)

HARVEY PERFORMANCE COMPANY. Premature Tool Failure. Disponível em: <https://www.harveyperformance.com/in-the-loupe/tag/premature-tool-failure/>. Acesso em: 8 fev. 2025.

HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J., 2009, *The Elements of Statistical Learning*, London.

HAAS CNC. VF-6SS: Super-Speed Vertical Mill. Disponível em: <https://www.haascnc.com/pt/machines/vertical-mills/vf-series/models/large/vf-6ss.html>. Acesso em: 15 fev. 2025.

HINTON, G.E., SALAKHUTDINOV, R.R., 2006, Reducing the dimensionality of data with neural networks, *Science*, 313(5786), 504-507.

HOSMER, D.W., LEMESHOW, S., STURDIVAN, R.X., 2013, *Applied logistic regression (Vol. 398)*, Nova Jersey.

IBM. SUPERVISED LEARNING. Disponível em: [JAIN, A.K., 2010, \*Data clustering: 50 years beyond K-Means\*, Amsterdam.](https://www.ibm.com/br-pt/topics/supervised-learning#:~:text=A%20regress%C3%A3o%20%C3%A9%20utilizada%20para,vendas%20de%20um%20determinado%20neg%C3%B3cio. Acesso em: 22 dez. 2024.</a></p></div><div data-bbox=)

JOLLIFFE, I.T., CADIMA, J., 2016, *Principal component analysis: a review and recent developments*, Philosophical Transactions of the Royal Society A, 374(2065), 20150202.

KAUFMAN, D., 2018, A inteligência Artificial irá suplantar a inteligência humana?, São Paulo.

LAZIC, N., BOUTILIER, C., LU, T., WONG, E., ROY, B., FALTINGS, B., 2018, Data-driven approximate dynamic programming for bayesian maintenance scheduling, AAAI Conference on Artificial Intelligence.

LECUN, Y., BENGIO, Y., HINTON, G., 2015, *Deep Learning*, Nature, 521, 436-444.

MACQUEEN, J., 1967, Some methods for classification and analysis of multivariate observations, Berkeley Symposium on Mathematical Statistics and Probability.

MARTINS, R., AGUIAR, P. R., 2012, Processos de Usinagem: Princípios e Prática. LTC.

MARQUES, A.C., BRITO, J.N., 2019, Importância da manutenção preditiva para diminuir o custo em manutenção e aumentar a vida útil dos equipamentos, Paraná.

MATZKA, S., 2020, Explainable Artificial Intelligence for Predictive Maintenance Applications. 2020 Third International Conference on Artificial Intelligence for Industries (AI4I), 69-74.

MEDEIROS, Henrique. Aplicações de Machine Learning em marketing e vendas. Medium, 2023. Disponível em: <https://medium.com/@henriqm01/aplica%C3%A7%C3%B5es-de-machine-learning-em-marketing-e-vendas-da4221156ebe>. Acesso em: 17 fev. 2025.

MITECHELL, T. M., 1997, *Machine Learning*, Nova Iorque.

MNIH, V., KAYUKCUOGLU, K., SILVER, D., *et al*, 2015, Human-level control through deep reinforcement learning, *Nature*, 518, 529–533.

MOBLEY, R.K., 2002, *An Introduction to Predictive Maintenance 2nd Edition*, Butterworth-Heinemann.

MOUBRAY, J., 1997, *Reliability-Centered Maintenance. 2nd Edition*, Oxford.

MNIH, V., KAYUKCUOGLU, K., SILVER, D., *et al*, 2015, Human-level control through deep reinforcement learning, *Nature*, 518, 529–533.

MOBLEY, R.K., 2002, *An Introduction to Predictive Maintenance 2nd Edition*, Butterworth-Heinemann.

MOU-BRAY, J., 1997, *Reliability-Centered Maintenance. 2nd Edition*, Oxford.

NEPOMUCENO, L.X., 2018, *Técnicas de manutenção preditiva volume 1*, São Paulo.

PINTO, M. C. Sistema de manutenção preditiva de falhas em válvulas em um processo industrial utilizando inteligência artificial. 2021. 65 p. Monografia (Graduação em Engenharia de Controle e Automação) — Universidade Federal de Uberlândia.

QUINLAN, J.R., 1996, Improved use of continuous attributes in C4.5, *Journal of artificial intelligence research*.

RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J., 1986, *Learning representations by back-propagating errors*, California.

RUSSELL, S., NORVIG, P., 2021, *Artificial Intelligence: A Modern Approach (4th ed.)*, Pearson.

SACOMANO, J.B., GONÇALVES, R.F., DA SILVA, M.T., BONILLA, S.H., SÁTYRO, W.C., 2018, *Indústria 4.0 conceitos e fundamentos*, São Paulo.

SCAIFE, A.D., Improve predictive maintenance through the application of artificial intelligence: A systematic review, *ScienceDirect Journal*, Maryland, EUA, vol. 21, Dezembro, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2590123023007727?via%3Dihub>.

SCHUBERT, E., SANDER, J., ESTER, M., KRIEGEL, H.P., XU, X., 2017, *DBSCAN Revisited, Revisited: Why and How You Should (Still) Use DBSCAN*, Nova Iorque.

SMITH, A.M., HINCHCLIFFE, G., 2003, *RCM: Gateway to World Class Maintenance*, Oxford.

SOMVANSHI, M., CHAVAN, P., TAMBADE, S., SHINDE, S.V., 2016, *A review of Machine Learning techniques using decision tree and support vector machine*, Pune.

SUTTON, R.S., BARTO, A.G., 2018, *Reinforcement Learning: An Introduction*. MIT Press.

TAMURA, Y., UEKI, R., ANAND, YAMADA, S., 2023, Estimation and comparison of *Mean Time Between Failures* based on *Deep Learning* for OSS fault big data, *Int J Syst Assur Eng Manag* 15.

TRACTIAN, 2024, *Manutenção Assistida por Inteligência Artificial, a evolução da Manutenção Prescritiva*, São Paulo.

VINCENT, M., THOMAS, S., SURESH, S., BOPPURU, P.R., 2024, *Enhancing Industrial Equipment Reliability: Advanced Predictive Maintenance Strategies Using Data Analytics and Machine Learning*, Bengaluru.

WATKINS, C. J. C. H., DAYAN, P., 1992, Q-learning. *Machine Learning*, v. 8, n. 3-4, p. 279–292.

WIDODO, A., YANG, B.S., 2007, *Support vector machine* in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574.

YANG, B., HAN, T., HWANG, W., 2005, Fault diagnosis of rotating machinery based on multi-class support vector machines, Busan.

ZHAN, J., WANG, P., GAO, R.X., 2018, Modeling of layer-wise additive manufacturing for part quality prediction, Amsterdam.