

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Romulo Cesar Cunha Lima

**Uma Nova Proposta para Eficiência Energética em Sistemas de Manufatura Industrial Baseada
em Técnicas de Aprendizado de Máquina.**

Fortaleza – CE

7 de abril de 2025

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

L732n Lima, Romulo.

Uma Nova Proposta para Eficiência Energética em Sistemas de Manufatura Industrial Baseada em Técnicas de Aprendizado de Máquina. / Romulo Lima. - 2025.
97 f. : il.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2025.

Orientação: Prof. Dr. José Daniel de Alencar Santos.

1. Eficiência Energética,. 2. Aprendizado de Máquina. 3. Classificação e Regressão. 4. Operação de Torneamento,. 5. Sistemas de Manufatura Industrial. I. Título.

CDD 004

Romulo Cesar Cunha Lima

**Uma Nova Proposta para Eficiência Energética em Sistemas de Manufatura Industrial
Baseada em Técnicas de Aprendizado de Máquina.**

Dissertação submetida ao Programa de Pós-Graduação em
Ciência da Computação do Instituto Federal de Educação,
Ciência e Tecnologia do Ceará, como requisito parcial
para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Inteligência Artificial

Orientador: Prof. Dr. José Daniel de Alencar Santos

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

7 de abril de 2025



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Romulo Cesar Cunha Lima

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

Orientador: Prof. Dr. José Daniel de Alencar Santos
Instituto Federal de Educação, Ciência e Tecnologia do Ceará
(IFCE)

Prof. Dr. Leandro Bezerra Marinho
Instituto Federal de Educação, Ciência e Tecnologia do Ceará
(IFCE)

Prof. Dr. Antônio Carlos da Silva Barros
Universidade da Integração Internacional da Lusofonia
Afro-Brasileira (UNILAB)

Fortaleza – CE
7 de abril de 2025

*Dedicado esse trabalho ao meu pai, cujo espírito
e ensinamentos continuam a guiar-me, mesmo em sua ausência.
Sua memória é um eco permanente que sustenta minha jornada,
refletindo a sabedoria e a fé que ele sempre cultivou.*

Agradecimentos

Minha profunda gratidão a Deus e à minha família, meu porto seguro, cujo amor e apoio inabaláveis foram fundamentais nos momentos de incerteza. Vocês são a base de cada conquista, tornando esta jornada possível.

Agradeço especialmente a **Cristiane Cunha Lopes** e **Cristina Maria Cunha Lima**, que, no período mais difícil da vida do meu pai, estiveram à frente com dedicação e carinho. O amparo generoso trouxe alívio e conforto, exemplificando o verdadeiro significado do amor e da solidariedade. Meu eterno reconhecimento.

Manifesto também minha sincera gratidão ao meu orientador, **Prof. Dr. José Daniel de Alencar Santos**, pela paciência, sabedoria e orientação sempre precisas. Sua capacidade de transformar desafios em aprendizado tem sido uma fonte constante de inspiração, impulsionando-me a seguir com determinação e confiança.

Aos meus colegas **Leonardo Adriano Vasconcelos de Oliveira** e **Erik Jhones Freitas do Nascimento**, sou grato pela parceria e amizade que enriqueceram esta trajetória acadêmica. Compartilhamos desafios e conquistas que ultrapassaram os limites da pesquisa, criando laços que levarei para além da universidade.

Estendo meu agradecimento ao **Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)**, pelo suporte e pelos recursos essenciais ao meu desenvolvimento acadêmico. Cada professor e colaborador contribuiu para a construção de um ambiente estimulante, promovendo meu crescimento intelectual e profissional.

Por fim, minha gratidão a todos que, de alguma forma, deixaram sua marca ao longo desta caminhada, seja por meio de um gesto, uma palavra ou um incentivo. As memórias construídas nesta trajetória são verdadeiros tesouros que levarei comigo.

*"Não é a mais forte das espécies que sobrevive,
nem a mais inteligente, mas aquela que melhor se adapta às mudanças." — Charles Darwin*

Resumo

Esta pesquisa apresenta uma nova metodologia para melhorar a eficiência energética em sistemas de manufatura industrial por meio de técnicas de aprendizado de máquina. Especificamente, o estudo foca na classificação automática de cinco tipos de aço — ABNT SAE 1020, 1045, 4140, 4340 e VC — com base em características elétricas e mecânicas observadas durante operações de torneamento. A metodologia inclui a previsão do consumo de energia para esses tipos de aço, aplicando modelos de regressão, sob várias condições de usinagem, incluindo diferentes velocidades de rotação e taxas de avanço. Até onde se tem conhecimento, este estudo é o primeiro a abordar essa questão usando esta abordagem específica. O método proposto foi validado por meio de experimentos computacionais utilizando múltiplos algoritmos de aprendizado de máquina, com a rede neural Perceptron Multicamadas (MLP) alcançando a maior precisão de classificação de 95,52%. Em termos de previsão de consumo de energia, os modelos MLP demonstraram desempenho superior em 13 dos 15 cenários de torneamento. A análise de regressão confirmou ainda a eficácia desses modelos, alcançando baixos valores de Erro Quadrático Médio (RMSE) e Erro Médio Absoluto (MAE) em diferentes configurações. Os resultados indicam que a integração do aprendizado de máquina nos processos de usinagem pode melhorar significativamente a eficiência energética, levando a práticas industriais mais sustentáveis.

Palavras-chave: Eficiência Energética, Aprendizado de Máquina, Operação de Torneamento, Classificação, Regressão, Sistemas de Manufatura Industrial.

Abstract

This research presents a novel methodology for enhancing energy efficiency in industrial manufacturing systems through machine learning techniques. Specifically, the study focuses on the automatic classification of five steel types—ABNT SAE 1020, 1045, 4140, 4340, and VC—based on electrical and mechanical characteristics observed during turning operations. The methodology includes the prediction of energy consumption for these steel types, applying regression models, under various machining conditions, including different rotation speeds and feed rates. To the best of the authors' knowledge, this study is the first to address this issue using this specific approach. The proposed method was validated through computational experiments using multiple machine learning algorithms, with the Multilayer Perceptron (MLP) neural network achieving the highest classification accuracy of 95.52%. In terms of energy consumption prediction, MLP models demonstrated superior performance in 13 out of 15 turning scenarios. The regression analysis further confirmed the effectiveness of these models, achieving low Root Mean Squared Error (RMSE) and Mean Absolute Error (MAE) values across different configurations. The results indicate that integrating machine learning into machining processes can significantly improve energy efficiency, leading to more sustainable industrial practices.

Keywords: Keywords: Energy Efficiency, Machine Learning, Turning Operation, Classification, Regression, Industrial Manufacturing Systems.

Lista de ilustrações

Figura 1 – Torno mecânico utilizado no processo de usinagem para configuração experimental.	34
Figura 2 – Metodologia da abordagem proposta.	42
Figura 3 – Comparativo de alguns pares de atributos entre seus dados originais (Figura (3a) e (3c)) e com a adição dos dados artificiais (Figura (3b) e (3d)).	47
Figura 4 – Taxa de Classificação com as amostras de teste em: Fig. (4a) cenário com todos os atributos e Fig. (4b) cenário pós seleção de atributos (excluindo tempo, avanço por rotação e energia de corte).	64
Figura 5 – Desempenho dos estimadores no problema de aproximação de função com as amostras de teste para os aços 1020 (Fig. 5a), 1045 (Fig. 5b), 4140 (Fig. 5c), 4340 (Fig. 5d) e VC (Fig. 5e), respectivamente.	79

Lista de tabelas

Tabela 1 – Comparação entre técnicas de Inteligência Artificial aplicadas à usinagem	26
Tabela 2 – Algoritmos aplicados à usinagem no estudo deste artigo	29
Tabela 3 – Outros Algoritmos Aplicados na Usinagem	30
Tabela 4 – Análise Comparativa das Características dos Materiais: Quantidades, Atributos e Amostras	37
Tabela 5 – Composição Química Típica dos Materiais	37
Tabela 6 – Quantidade de amostras antes e depois da aplicação do SMOTE	45
Tabela 7 – Valor absoluto dos coeficientes de correlação antes da seleção de atributos.	65
Tabela 8 – Média e desvio padrão (std) dos resultados nas fases de treinamento e teste de cada estimador, juntamente com os valores de PPV, sensibilidade (Se) e <i>F-score</i> com as amostras de teste, ao longo de 50 execuções independentes após a seleção dos atributos.	67
Tabela 9 – Matrizes de confusão com amostras de treinamento e teste, ao longo das 50 execuções independentes, obtidas pelo MLP-1HL (Multilayer Perceptron with one hidden layer) classificador.	69
Tabela 10 – Matrizes de confusão com amostras de treinamento e teste, ao longo das 50 execuções independentes, obtidas pelo MLP-2HL (Multilayer Perceptron with two hidden layers) classifier.	69
Tabela 11 – Métricas por classe de aço para os classificadores MLP-1HL e MLP-2HL (com uma casa decimal).	70
Tabela 12 – RMSE de Regressão para Diferentes Métodos e Configurações de Treino e Teste	77
Tabela 13 – MAE de Regressão para Diferentes Métodos e Configurações de Treino e Teste	78

Lista de Abreviaturas e Siglas

ACO *Ant Colony Optimization* - Otimização por Colônia de Formigas.

AGV *Automated Guided Vehicle* - Veículo Guiado Automaticamente.

ANN *Artificial Neural Network* - Rede Neural Artificial.

BAS *Beetle Antennae Search* - Algoritmo de Busca por Antenas de Besouros.

CNC *Computer Numerical Control* - Controle Numérico Computadorizado.

CNN *Convolutional Neural Network* - Rede Neural Convolucional.

DNN *Deep Neural Networks* - Redes Neurais Profundas.

ELM *Extreme Learning Machine* - Máquina de Aprendizado Extremo.

GA *Genetic Algorithm* - Algoritmo Genético.

IEA *International Energy Agency* - Agência Internacional de Energia.

IEEE *Institute of Electrical and Electronics Engineers* - Instituto de Engenheiros Eletricistas e Eletrônicos.

IGPL *Logic Journal of the IGPL* - Jornal de Lógica IGPL.

IPCC *Intergovernmental Panel on Climate Change* - Painel Intergovernamental sobre Mudanças Climáticas.

IoT *Internet of Things* - Internet das Coisas.

KNN *K-Nearest Neighbors* - K-Vizinhos mais Próximos.

LSSVM *Least Squares Support Vector Machine* - Máquina de Vetores de Suporte com Mínimos Quadrados.

LSSVR *Least Squares Support Vector Regression* - Regressão por Vetores de Suporte com Mínimos Quadrados.

ML *Machine Learning* - Aprendizado de Máquina.

MLP *Multilayer Perceptron* - Perceptron Multicamadas.

OLS *Ordinary Least Squares* - Mínimos Quadrados Ordinários.

PPV *Positive Predictive Value* - Valor Preditivo Positivo.

RMSE *Root Mean Squared Error* - Erro Quadrático Médio.

SMS *Structured Machine Scheduling* - Agendamento Estruturado de Máquinas.

SMOTE *Synthetic Minority Over-sampling Technique* - Técnica de Sobreamostragem da Minoria Sintética.

SVM *Support Vector Machine* - Máquina de Vetores de Suporte.

SVR *Support Vector Regression* - Regressão por Vetores de Suporte.

XAI *Explainable AI* - Inteligência Artificial Explicável.

Lista de símbolos

t	Tempo de corte.
af	Profundidade de corte.
Vc	Velocidade de corte em mm/min.
η	Eficiência do processo.
h	Altura de corte.
Fc	Força de corte.
Pc	Potência de corte.
Ec	Energia consumida.
Pe	Eficiência da ferramenta.
Se	Sensibilidade.
f -score	Métrica F-Score.
TP	Verdadeiros Positivos.
TN	Verdadeiros Negativos.
FP	Falsos Positivos.
FN	Falsos Negativos.
Acc	Precisão ou taxa de classificação.
CR	Taxa de classificação (<i>Classification Rate</i>).
$\mathcal{N}(u)$	Vizinhança do nó u .
$\mathbb{R}$	Conjunto dos números reais.
b	Largura de corte em mm.
T	Tempo total do processo.
r	Rugosidade da superfície.
σ	Desvio padrão.
$\bar{y}$	Média das observações.
y_t	Valor real no tempo t .
$\hat{y}_t$	Valor previsto no tempo t .

Sumário

1	INTRODUÇÃO.....	14
1.1	Objetivos Geral e Específicos	17
1.1.1	Objetivo Geral	18
1.1.2	Objetivos Específicos	18
1.2	Justificativa.....	18
1.3	Organização da Dissertação	19
1.4	Produção Científica	20
2	REVISÃO DA LITERATURA.....	21
2.1	Inteligência Artificial na Usinagem.....	21
2.1.1	Aplicação da Inteligência Artificial na Usinagem.....	22
2.1.2	Técnicas de Inteligência Artificial Aplicadas à Usinagem.....	22
2.1.2.1	Redes Neurais Artificiais – <i>Artificial Neural Networks</i> (ANNs).....	23
2.1.2.2	Máquinas de Vetores de Suporte – <i>Support Vector Machines</i> (SVMs)	23
2.1.2.3	Máquina de Aprendizado Extremo – <i>Extreme Learning Machine</i> (ELM)	24
2.1.2.4	Algoritmos Evolutivos e de Otimização	24
2.1.2.5	Aprendizado Profundo e Redes Neurais Convolucionais (<i>Deep Learning and Convolutional Neural Networks</i> (CNNs)).....	25
2.1.2.6	K-Vizinhos Mais Próximos – <i>k-Nearest Neighbors</i> (KNN).....	25
2.1.2.7	Lógica Fuzzy	25
2.1.3	Algoritmos de Regressão	26
2.1.4	Comparação entre os Modelos de IA na Usinagem.....	26
2.1.5	Desafios e Limitações.....	26
2.1.6	Tendências Futuras.....	27
2.2	Critérios de Busca	28
2.3	Considerações Finais	30
3	FUNDAMENTAÇÃO TEÓRICA, MATERIAIS E MÉTODOS	32
3.1	Fundamentação Teórica	32
3.1.1	Processo de Usinagem Industrial - Torneamento	33
3.1.2	Velocidade de Corte - V_c	33
3.1.3	Força de Corte - F_c	35
3.1.4	Potência de Corte - P_c	35
3.1.5	Potência Elétrica - P_e	35
3.1.6	Energia de Corte - E_c	36
3.1.7	Aprendizado de Máquina na Otimização de Processos de Usinagem	36
3.2	Materiais e Métodos	38
3.2.1	Materiais	38
3.2.2	Classificação e Regressão	39
3.2.2.1	Contextualização da Classificação.....	39

3.2.2.2	Contextualização da Regressão	41
3.2.3	Métodos	41
3.2.3.1	Definição de Classe e Extração de Recursos	42
3.2.3.2	Sobreamostragem do Banco de Dados.....	44
3.2.3.2.1	Aplicação do SMOTE	44
3.2.3.2.2	Impacto da Sobreamostragem.....	44
3.2.3.2.3	Justificativa para a Escolha do SMOTE.....	45
3.2.3.3	Impacto do Desbalanceamento dos Dados nas Métricas de Desempenho	46
3.2.3.4	Normalização dos Dados	47
4	CLASSIFICAÇÃO DE PADRÕES E REGRESSÃO	49
4.1	Visão Geral Simplificada.....	49
4.2	Máquina de Vetores de Suporte e Máquina de Vetores de Suporte de Mínimos Quadrados	50
4.3	Regressão por Vetores de Suporte e Regressores de Mínimos Quadrados	51
4.4	Perceptron Multicamadas	51
4.5	Extreme Learning Machine	52
4.6	k-Vizinhos Mais Próximos	52
4.7	Mínimos Quadrados Ordinários	53
4.8	Naive Bayes	53
4.9	Validação e Métricas.....	54
4.9.1	Precisão (Acc).....	54
4.9.2	Valor Preditivo Positivo (PPV).....	55
4.9.3	Sensibilidade (Se)	56
4.9.4	F-Score	56
4.9.5	Matriz de Confusão.....	57
4.9.6	Erro Quadrático Médio (RMSE)	58
4.9.7	Análise do Erro Absoluto Médio (MAE).....	58
4.9.8	Discussão sobre a Escolha de Métricas.....	59
5	RESULTADOS E DISCUSSÃO	61
5.1	Avaliação de Desempenho do Classificador	62
5.1.1	Análise dos Resultados com Seleção de Atributos	63
5.1.2	Desempenho dos Classificadores	66
5.2	Regressão para Estimativa do Consumo de Energia	71
5.2.1	Complexidade Computacional dos Modelos	71
5.2.2	Análise Preditiva do Consumo de Energia em Processos de Usinagem.....	72
5.2.3	Aplicação Industrial e Limitações.....	73
5.2.3.1	Desafios Práticos para Implementação Industrial	74
5.2.4	Limitações do Estudo e Análise de Desempenho dos Modelos.....	75
5.3	Crítérios para Avaliação de Modelos.....	78
6	CONCLUSÃO.....	81
	REFERÊNCIAS	83

1 Introdução

A eficiência energética tornou-se um elemento essencial para o desenvolvimento sustentável e a competitividade na indústria global, impulsionada pelo aumento dos custos de energia e pela crescente demanda por práticas ambientais responsáveis. (INTERNATIONAL ENERGY AGENCY, 2023). No contexto industrial, esse conceito abrange a realização de operações com o mínimo consumo energético possível, maximizando o uso eficiente de eletricidade e outros recursos sem comprometer a qualidade dos produtos ou a eficiência dos processos. Essa abordagem contribui para a redução de custos operacionais e das emissões de gases de efeito estufa, fortalecendo o compromisso com a sustentabilidade e oferecendo benefícios sociais e ambientais, promovendo a criação de empregos no setor verde e ambientes de trabalho mais seguros (ZEIN, 2012; APOSTOLOS et al., 2013; NAWAZ et al., 2021; BROCKWAY et al., 2021).

Esse conceito torna-se ainda mais relevante em processos de usinagem, como torneamento, fresamento e furação, onde o consumo de energia é significativamente elevado. A otimização dos parâmetros operacionais da usinagem, como a velocidade e a profundidade de corte, é crucial para reduzir o desperdício de energia, aumentar a produtividade e diminuir os custos. Estudos indicam que a usinagem pode representar uma grande parcela do consumo energético de máquinas-ferramenta, como fresadoras, onde a energia consumida pode atingir aproximadamente 65% do total, reforçando a necessidade de otimização contínua (PEREIRA; FREITAS, 2024).

No contexto da usinagem, a seleção criteriosa dos materiais desempenha um papel fundamental na otimização dos processos produtivos e na eficiência energética. A aplicação de técnicas de classificação possibilita determinar quais tipos de aços devem ser utilizados em diferentes etapas do processo de manufatura, permitindo um balanceamento eficiente da linha de produção e garantindo que os materiais mais adequados sejam empregados conforme a demanda e as características operacionais. Esse balanceamento evita desperdícios e melhora a distribuição da carga de trabalho ao longo do processo produtivo (REIS, 2025).

Paralelamente, a modelagem por regressão é utilizada para prever o consumo energético em diferentes condições de usinagem, permitindo ajustes que maximizam a eficiência operacional. A correlação entre os parâmetros do processo e o consumo de energia possibilita identificar padrões que levam à economia energética e à redução dos custos operacionais (JIMÉNEZ et al., 2022). Dessa forma, a combinação dessas técnicas oferece uma abordagem inovadora para otimizar a eficiência energética, reduzindo impactos ambientais e melhorando a competitividade das empresas no setor industrial.

Nesse sentido, a integração entre eficiência energética e inovação tecnológica possibilita avanços que impactam diretamente a produtividade e a qualidade dos produtos, promovendo avanços na eficiência operacional com apoio de soluções tecnológicas. Esses progressos destacam o papel essencial da tecnologia para o desenvolvimento sustentável na indústria (TUPTUK; HAILES, 2018; PHUYAL; BISTA; BISTA, 2020).

No entanto, a otimização da eficiência energética em processos como o torneamento apresenta desafios consideráveis, incluindo a complexidade de equilibrar eficiência e qualidade, a resistência às mudanças e os altos custos iniciais para adotar tecnologias avançadas (JIA et al., 2021). Para que essas soluções se tornem eficazes, as empresas precisam de flexibilidade e capacidade de adaptação às variações da demanda de produção e das condições operacionais, fazendo da eficiência energética um objetivo desafiador e contínuo na manufatura.

Dessa forma, a habilidade de realizar ajustes rápidos na otimização da eficiência energética se tornou uma vantagem competitiva cada vez mais importante para a indústria. O investimento em soluções tecnológicas flexíveis e em estratégias de adaptação contínua não apenas enfrenta os desafios atuais, mas também prepara as empresas para um futuro mais sustentável. Essa abordagem está perfeitamente alinhada à necessidade de inovação constante para assegurar a competitividade em um mercado em contínua transformação (GHORBANIOSKALAEI et al., 2022).

Nesse cenário de transformação tecnológica, a Inteligência Artificial (IA) destaca-se como uma ferramenta poderosa para potencializar a eficiência energética nas operações de manufatura. A aplicação de IA na manufatura surge como uma estratégia eficaz para otimizar o consumo de energia e reduzir os impactos ambientais, especialmente em setores de alto consumo energético, como a usinagem (NISHANT; KENNEDY; CORBETT, 2020). A IA permite um controle preciso e adaptável dos parâmetros operacionais, como a velocidade e a força de corte, fornecendo informações fundamentais que possibilitam ajustes para reduzir o consumo de energia, prolongar a vida útil dos equipamentos e minimizar o desperdício de recursos.

Com essas contribuições, a IA possibilita que as empresas identifiquem novas oportunidades de redução de custos e promovam práticas alinhadas aos objetivos de sustentabilidade ambiental. O uso da IA fortalece o compromisso das empresas com práticas sustentáveis, aumentando sua competitividade e resiliência no mercado e apoiando as metas globais de preservação ambiental (BROCKWAY et al., 2021). Empresas que adotam IA para ajustar dinamicamente os parâmetros de usinagem conseguem promover práticas mais sustentáveis e, ao mesmo tempo, melhorar sua posição competitiva no mercado (NAWAZ et al., 2021; BROCKWAY et al., 2021; INTERNATIONAL ENERGY AGENCY, 2022).

Diante desse cenário, é essencial aprofundar a análise dos métodos, benefícios e desafios envolvidos na implementação de práticas de eficiência energética no setor industrial. Apesar dos desafios, a adoção de soluções tecnológicas inovadoras permite que as empresas reduzam custos e se adaptem com mais flexibilidade às variações nos preços de energia, fortalecendo sua competitividade em mercados que valorizam a responsabilidade socioambiental. O investimento em IA e capacitação não só aprimora as operações, mas também contribui para metas globais de sustentabilidade, alinhando o crescimento econômico com benefícios ambientais e sociais (NAWAZ et al., 2021; BROCKWAY et al., 2021).

Esse contexto ressalta a importância de um estudo detalhado sobre as técnicas, benefícios e desafios da eficiência energética no ambiente industrial, destacando, em especial, o papel fundamental da coleta e análise de dados energéticos na otimização de processos de usinagem, como o torneamento. Essas práticas promovem a sustentabilidade e impulsionam melhorias contínuas na indústria (SHIN; WOO; RACHURI, 2017; MOREIRA et al., 2019a; ARRIAZA et al., 2017; SALONITIS; BALL, 2013).

Além disso, a implementação de práticas de eficiência energética na usinagem traz benefícios econômicos, ambientais e sociais. Essas práticas contribuem para a melhoria da posição estratégica das empresas diante de regulamentações ambientais rigorosas e ampliam suas responsabilidades corporativas. Nesse sentido, reforça-se a necessidade de uma gestão industrial integrada e sustentável (WANG; LIU; LI, 2013).

Apesar do crescente incentivo para modernização e implementação de eficiência energética em processos industriais, ainda são necessários conhecimento e experiência para aplicar esses conceitos de forma eficaz. Abordagens tradicionais, focadas apenas em melhorias incrementais, enfrentam limitações, pois não promovem as transformações amplas e significativas essenciais para alcançar sustentabilidade e eficiência no longo prazo (TRIANNI; CAGNO; FARNE, 2016; PRASHAR, 2017).

Integrar o aprendizado de máquina (*Machine Learning* - ML) nos processos industriais representa uma evolução significativa na busca por eficiência e inovação. O ML maximiza a análise de dados, facilitando a otimização de recursos e a redução de custos. Com o crescimento exponencial na geração de dados, impulsionado por sensores de baixo custo e pela necessidade de monitoramento detalhado, o aprendizado de máquina aprimora a eficiência operacional, contribuindo de forma decisiva para a sustentabilidade e redução do impacto ambiental (FAHLE; PRINZ; KUHLENKÖTTER, 2020; NARCISO; MARTINS, 2020).

Dado o exposto, a indústria de manufatura contribui significativamente para o consumo de energia elétrica (SCHISCHKE, 2012; U.S. Energy Information Administration, 2018) e emissões globais de carbono (INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC), 2023). No contexto dos processos de usinagem, incluindo operações de torneamento, as demandas energéticas podem ser influenciadas por vários fatores, como as características dos materiais e os parâmetros dos processos de corte, bem como as metodologias de operação de usinagem adotadas para transformar a matéria-prima em componentes acabados (DENKENA et al., 2020).

De acordo com uma pesquisa realizada em várias indústrias de manufatura ao redor do mundo, um dos principais fatores que influenciam o desperdício de energia na indústria está diretamente relacionado à operação inadequada das máquinas de produção (GENG; EVANS; KISHITA, 2023). O aprimoramento da eficiência energética no torneamento inclui a seleção adequada de parâmetros de corte, o uso eficiente de fluidos de corte e tecnologias de otimização, monitoramento e controle desses parâmetros. Implementar técnicas que associem parâmetros de torneamento ao tipo de material e estimem o consumo de energia oferece uma abordagem promissora para reduzir o consumo energético em operações de usinagem (PEREIRA; FREITAS, 2024; FERNANDEZ et al., 2018).

Nesse contexto, implementar técnicas que associem automaticamente os parâmetros de torneamento ao tipo de material envolvido e estimem a energia elétrica consumida para cada material pode representar uma abordagem promissora para mitigar o consumo de energia em operações de torneamento. Ao estimar o consumo de energia ao longo do processo, torna-se possível, por exemplo, retroalimentar o sistema durante a definição dos parâmetros de usinagem, permitindo reconfigurá-los para otimizar o custo energético da operação (PELEGRINO, 2018; COSTA; BELINATO; FERREIRA, 2017). Além disso, a identificação do material usinado permite a seleção estratégica de ferramentas de corte resistentes ao desgaste, reduzindo o tempo de corte e o consumo de energia elétrica.

Nesse contexto, uma estratégia adicional para aumentar a eficiência energética envolve o uso de estimativas de consumo de energia para diferentes materiais. Ao identificar o tipo de material com base nos parâmetros de torneamento, é possível prever o consumo energético associado a cada material. Essa abordagem permite realizar diagnósticos de carga mais precisos, possibilitando que materiais com maior demanda energética sejam processados fora dos horários de pico. Além disso, esse conhecimento facilita um estudo detalhado da demanda energética, evitando exceder os valores contratados com o fornecedor de energia e garantindo uma gestão mais eficiente dos recursos energéticos (JIMÉNEZ et al., 2022).

A eficácia dos modelos de aprendizado de máquina depende da extração e seleção de atributos relevantes para cada tarefa. Na classificação de tipos de aço, é crucial selecionar características elétricas e mecânicas que distingam os materiais. Na regressão para prever o consumo energético, a análise de parâmetros operacionais, como velocidade de corte, taxa de avanço e profundidade de corte, é essencial. Técnicas de pré-processamento e seleção de atributos reduzem a dimensionalidade dos dados, mantendo a capacidade preditiva dos modelos, o que aumenta a eficiência e a interpretabilidade do sistema.

Assim, esta dissertação propõe uma nova metodologia que emprega modelos de aprendizado de máquina em duas tarefas sequenciais e complementares para otimizar a eficiência energética em processos de usinagem, especificamente nas operações de torneamento de aço. Primeiramente, técnicas de reconhecimento de padrões são aplicadas para associar automaticamente os parâmetros de torneamento ao tipo de material. Em seguida, uma vez identificado o material, modelos de regressão são usados para estimar o consumo de energia ao longo do processo de torneamento.

A metodologia adotada utiliza múltiplos algoritmos, incluindo Perceptrons de múltiplas camadas (MLP), máquinas de vetores de suporte (SVM) e máquinas de vetores de suporte de mínimos quadrados (LSSVM), entre outros, para analisar e prever o consumo de energia em detalhes. Os resultados obtidos demonstram a eficácia do aprendizado de máquina na previsão do consumo de energia e na otimização de processos, trazendo benefícios significativos para a indústria de produção na busca por operações mais eficientes e ambientalmente responsáveis. Além disso, este é o primeiro estudo a abordar esse tema utilizando essa metodologia específica.

Este estudo propõe uma metodologia inovadora baseada em ML para otimizar a **eficiência energética** em processos de usinagem, com ênfase nas operações de **torneamento de aço**. A abordagem visa integrar IA na indústria, possibilitando maior **sustentabilidade** e redução do consumo energético.

A pesquisa busca não apenas classificar os tipos de aço usados na usinagem, mas também prever o **consumo de energia elétrica** sob diferentes condições operacionais. Dessa forma, contribui diretamente para a **otimização da manufatura**, reduzindo custos operacionais e impactos ambientais. Além disso, um artigo derivado desta dissertação foi publicado no *Journal of Manufacturing Systems*, demonstrando a **relevância e aplicabilidade** da metodologia proposta.

A ausência de estudos que combinem simultaneamente técnicas de classificação e regressão no contexto da usinagem evidencia a inovação deste trabalho. Enquanto pesquisas anteriores exploram separadamente a classificação de materiais ou a previsão de variáveis operacionais por regressão, não foram encontrados estudos que abordem essa integração na literatura revisada neste trabalho. Esse diferencial permite uma análise mais ampla e precisa dos processos de usinagem, possibilitando não apenas a identificação do tipo de material em operação, mas também a estimativa do consumo energético associado.

Dessa forma, a metodologia proposta contribui significativamente para a otimização desses processos, oferecendo uma solução inovadora que alia aprendizado de máquina à manufatura industrial sustentável, promovendo maior eficiência energética e redução de impactos ambientais.

1.1 Objetivos Geral e Específicos

Na introdução, é relevante destacar a proposta de soluções práticas para a área industrial, utilizando técnicas de aprendizado de máquina com um enfoque direto na eficiência energética e no aprimoramento de processos de manufatura. Este trabalho visa aplicar modelos de regressão para prever e otimizar o consumo energético durante as operações de usinagem, aumentando a eficiência dos processos e reduzindo os custos operacionais. Paralelamente, a classificação dos tipos de aço (ABNT SAE 1020, 1045, 4140, 4340 e VC) contribuirá para uma escolha criteriosa dos materiais, ajustando a sequência e o tipo de aço conforme as demandas de produção e as características operacionais. Este processo não apenas promove a eficiência energética, mas também otimiza o planejamento e controle da produção, garantindo maior sustentabilidade e competitividade para as operações industriais.

1.1.1 Objetivo Geral

Aplicar técnicas de **aprendizado de máquina** para otimizar a **eficiência energética** em processos industriais de **usinagem**, com foco no torneamento de aços. O estudo se divide em duas principais frentes:

- **Classificação:** Desenvolver um modelo de aprendizado de máquina capaz de identificar automaticamente o tipo de aço (*ABNT SAE 1020, 1045, 4140, 4340 e VC*) com base em características elétricas e mecânicas, melhorando a seleção dos materiais na manufatura.
- **Regressão:** Implementar modelos preditivos para estimar o **consumo energético** do torneamento sob diferentes condições operacionais, permitindo ajustes dinâmicos que otimizem a eficiência do processo.

Essa abordagem visa integrar IA ao controle da usinagem, promovendo sustentabilidade e eficiência operacional no setor manufatureiro.

1.1.2 Objetivos Específicos

- Avaliar a **aplicabilidade das técnicas de aprendizado de máquina** na otimização do consumo energético em processos de usinagem, identificando as melhores práticas para reduzir custos operacionais e emissões de gases de efeito estufa.
- Desenvolver modelos de **classificação automática** dos tipos de aço (*ABNT SAE 1020, 1045, 4140, 4340 e VC*) com base nas características extraídas durante o torneamento.
- Investigar técnicas de **seleção de atributos** para aumentar a precisão dos classificadores e reduzir a dimensionalidade dos dados sem perda de desempenho.
- Implementar modelos de **regressão** para prever o consumo energético considerando diferentes parâmetros operacionais, como velocidade de corte, taxa de avanço e profundidade de corte.
- Comparar o desempenho de diferentes **algoritmos de aprendizado de máquina**, incluindo **Perceptrons Multicamadas (MLP)**, **Máquinas de Vetores de Suporte (SVM)** e **LSSVM**, na previsão do consumo energético.

1.2 Justificativa

A justificativa para o desenvolvimento deste trabalho está fundamentada na crescente importância da eficiência energética na indústria de manufatura, especialmente em processos de usinagem como o torneamento. Com o aumento contínuo dos custos de energia e a pressão crescente por práticas mais sustentáveis, a otimização do consumo energético tornou-se uma prioridade estratégica para as empresas. Esse cenário é ainda mais relevante considerando as metas globais de redução das emissões de gases de efeito estufa e a adaptação das indústrias às exigências de sustentabilidade.

Este trabalho propõe a aplicação de técnicas de aprendizado de máquina como uma solução inovadora para enfrentar os desafios associados à eficiência energética na usinagem de aços. Ao aplicar modelos de regressão para prever e otimizar o consumo energético durante as operações de usinagem, e a classificação automática dos tipos de aço, busca-se não apenas reduzir os custos operacionais, mas também aprimorar a escolha dos materiais, ajustando-os às demandas de produção e às características dos processos. Essa integração de técnicas avançadas de aprendizado de máquina visa maximizar a eficiência dos processos, resultando em uma significativa redução do consumo energético e, conseqüentemente, um menor impacto ambiental.

A crescente demanda por **eficiência energética** na indústria manufatureira exige soluções inovadoras para reduzir o consumo de energia e minimizar impactos ambientais. Os processos de **usinagem**, especialmente o torneamento de aços, apresentam desafios na **previsão do consumo energético**, dificultando a adoção de práticas sustentáveis.

A utilização de **aprendizado de máquina** surge como uma alternativa promissora para otimizar esses processos, permitindo a **classificação automática** dos materiais e a **previsão precisa** do consumo de energia. Dessa forma, este estudo contribui para a **redução de desperdícios**, o aumento da produtividade e a **sustentabilidade industrial**, alinhando-se às diretrizes da *Indústria 4.0*.

A possibilidade de replicação e adaptação dessa metodologia a diferentes contextos industriais amplia o impacto potencial das descobertas, tornando-a uma ferramenta flexível e adaptável a diversas realidades da manufatura. Além disso, a otimização do planejamento e controle da produção pode fortalecer a competitividade das empresas no mercado global, ajudando-as a se posicionar de maneira mais sustentável e economicamente viável.

Dessa forma, esta pesquisa visa fornecer uma contribuição significativa para a área de manufatura, promovendo operações mais eficientes e ambientalmente responsáveis, ao mesmo tempo em que oferece um caminho viável para a integração de inovações tecnológicas nos processos industriais. Essa adaptação e utilização de técnicas de aprendizado de máquina representa um avanço no processo de transformação digital da indústria, impulsionando a busca por soluções que alavanquem a sustentabilidade sem comprometer a competitividade.

1.3 Organização da Dissertação

Esta dissertação está organizada em seis capítulos, cada um abordando aspectos específicos da pesquisa. O **Capítulo 1** apresenta a introdução ao tema, destacando a importância da eficiência energética nos processos de usinagem e os objetivos do estudo.

O **Capítulo 2** oferece uma revisão da literatura, abordando os principais trabalhos relacionados ao uso de técnicas de aprendizado de máquina na usinagem, com foco na previsão do consumo energético e na otimização dos parâmetros operacionais.

No **Capítulo 3**, são apresentados os fundamentos teóricos, incluindo conceitos essenciais sobre o processo de usinagem, com ênfase no torneamento e nos parâmetros operacionais que influenciam o consumo energético. Além disso, esse capítulo detalha os materiais e métodos utilizados, descrevendo a base de dados, as técnicas de pré-processamento e os algoritmos empregados tanto na classificação quanto na regressão.

O **Capítulo 4** é dedicado à implementação dos modelos, apresentando a metodologia computacional aplicada, os detalhes da arquitetura dos modelos de aprendizado de máquina e os procedimentos de treinamento e validação adotados.

O **Capítulo 5** apresenta a análise dos resultados obtidos, comparando o desempenho dos modelos testados por meio de métricas de avaliação, além de discutir a eficácia das abordagens propostas.

Por fim, o **Capítulo 6** apresenta as conclusões do estudo, destacando as contribuições da pesquisa, as limitações encontradas e sugestões para trabalhos futuros, com foco na melhoria contínua da eficiência energética em processos de usinagem.

Essa estrutura visa fornecer uma visão clara e progressiva das técnicas e metodologias aplicadas, conduzindo o leitor desde a fundamentação teórica até a análise crítica dos resultados. Dessa forma, a pesquisa contribui significativamente para a otimização da eficiência energética na usinagem de aços, utilizando modelos de aprendizado de máquina para aprimorar o controle dos processos industriais.

1.4 Produção Científica

Durante o período deste mestrado, as seguintes produções científicas foram realizadas:

- **Artigo Publicado: Referente a Dissertação:**

- LIMA, Rômulo César Cunha; OLIVEIRA, Leonardo Adriano Vasconcelos de; SILVA, Suane Pires Pinheiro da; ALENCAR SANTOS, José Daniel de; CAETANO, Rebeca Gomes Dantas; FREITAS, Francisco Nélío Costa; OLIVEIRA, Venício Soares de; FREITAS BONIFÁCIO, Andreyson de; FILHO, Pedro Pedrosa Rebouças. A new proposal for energy efficiency in industrial manufacturing systems based on machine learning techniques. *Journal of Manufacturing Systems*, v. 77, p. 1062-1076, 2024.

- **Estudos Relacionados:**

- OLIVEIRA, L. A. V. ; LIMA, R. C. C. ; SANTOS, J. D. A. . . Análise de Previsão de Geração Fotovoltaica na Região Metropolitana de Fortaleza Usando Técnicas de aprendizado de máquina: Um Estudo de Caso.. In: Congresso Brasileiro de Inteligência Computacional, 2023, Salvador-Ba. Anais de XVI Congresso Brasileiro de Inteligência Computacional (CBIC), 2023.

2 Revisão da Literatura

A integração da Inteligência Artificial (IA) na usinagem tem promovido avanços significativos em precisão, eficiência e automação. Algoritmos avançados e técnicas de aprendizado de máquina permitem a otimização de parâmetros de corte, a previsão de falhas e a automação de decisões, resultando em processos mais produtivos e produtos de alta qualidade (VELLOSO; HORA, 2020). Além disso, o monitoramento em tempo real das operações possibilita ajustes dinâmicos, prolongando a vida útil das ferramentas, melhorando a qualidade dos produtos e reduzindo o consumo de energia. Essas inovações fortalecem a sustentabilidade industrial e aumentam a competitividade em um mercado global cada vez mais exigente (FERIOTTI et al., 2023).

Estudos recentes demonstram que o aprendizado de máquina, aplicado na usinagem, aprimora o rendimento, eleva a qualidade dos processos e reduz os custos operacionais. A análise de padrões de desgaste das ferramentas, associada a dados coletados por sensores, permite estabelecer cronogramas ideais de substituição, minimizando o tempo de inatividade e aumentando a eficiência operacional (FERIOTTI et al., 2023).

2.1 Inteligência Artificial na Usinagem

A indústria de manufatura tem experimentado um processo intenso de modernização, impulsionado pela crescente necessidade de eficiência e sustentabilidade. Nesse contexto, os processos de usinagem desempenham um papel essencial, pois são responsáveis por transformar matérias-primas em produtos acabados com elevado grau de precisão (GROOVER, 2019). Entretanto, a demanda crescente por maior produtividade, associada à pressão para reduzir o consumo energético e os impactos ambientais, tem incentivado o desenvolvimento de estratégias avançadas para otimizar esses processos (KALPAKJIAN; SCHMID, 2021).

A aplicação da IA, principalmente do aprendizado de máquina, na usinagem representa uma abordagem promissora para a otimização dos parâmetros de corte, a previsão de falhas e a automação de decisões. Técnicas como *Artificial Neural Networks* (ANNs), *Support Vector Machines* (SVMs) e *Genetic Algorithms* (GAs) têm sido amplamente exploradas, promovendo avanços significativos (ABDELAOUI; JABRI; BARKANY, 2023; SOORI; AREZOO; DASTRES, 2023). Além de minimizar desperdícios e aprimorar a precisão, essas abordagens maximizam a eficiência energética, reforçando a competitividade e a sustentabilidade do setor (WANG et al., 2021).

Os benefícios do aprendizado de máquina na usinagem vão além da simples otimização do consumo energético. A capacidade dessas tecnologias de processar grandes volumes de dados operacionais em tempo real possibilita ajustes dinâmicos nos parâmetros de operação, o que melhora a qualidade da produção e prolonga a vida útil das ferramentas (CHEN, 2017). Essa adaptabilidade é fundamental para lidar com oscilações nas condições de operação e minimizar variabilidades que possam comprometer a estabilidade dos processos industriais (ZHONG et al., 2017).

Apesar dos avanços expressivos, a implementação dessas técnicas ainda enfrenta desafios consideráveis. Entre eles, destacam-se: a necessidade de bancos de dados robustos para o treinamento eficaz dos modelos, a integração eficiente dos algoritmos às máquinas-ferramenta e a adaptação das metodologias a diferentes materiais e geometrias (HAYKIN, 1998). Esta revisão explora as principais abordagens de aprendizado de máquina aplicadas ao setor, analisando sua evolução, os impactos e os desafios atuais, com foco na otimização

do consumo de energia e na automação inteligente das operações industriais.

A implementação de estratégias baseadas em IA enfrenta obstáculos adicionais, como a resistência à mudança por parte das organizações, o investimento inicial elevado e a necessidade de dados robustos para o treinamento dos modelos. De acordo com Borba e Albuquerque (BORBA; ALBUQUERQUE, 2024), a IA apresenta inúmeras vantagens em relação aos desafios, embora as empresas precisem estar preparadas para adotar essa nova tecnologia e adaptar-se às transformações exigidas.

Empresas que investem na adoção dessas tecnologias têm obtido ganhos significativos em eficiência operacional, sustentabilidade e competitividade, tornando-se mais preparadas para um mercado global cada vez mais exigente. Segundo a McKinsey & Company (MANYIKA; BUGHIN, 2018), a IA promete gerar benefícios econômicos consideráveis, ainda que provoque rupturas no mercado de trabalho.

Diante desse cenário, esta pesquisa propõe uma abordagem inovadora para otimizar a eficiência energética em processos de usinagem por meio do aprendizado de máquina. O objetivo é desenvolver um modelo que associe automaticamente os parâmetros de torneamento ao tipo de material e, posteriormente, estime o consumo energético em diferentes cenários de operação. Com isso, pretende-se fornecer um sistema de suporte à decisão que auxilie na escolha dos parâmetros mais eficientes, reduzindo custos e minimizando os impactos ambientais.

Dessa forma, a aplicação do aprendizado de máquina nos processos de usinagem tem se tornado uma ferramenta essencial para otimizar operações industriais. A seguir, discute-se as principais abordagens e desafios encontrados na literatura.

2.1.1 Aplicação da Inteligência Artificial na Usinagem

A busca pela otimização dos processos de usinagem tem impulsionado a crescente adoção da **IA** e do **aprendizado de máquina** na manufatura industrial. Essas tecnologias viabilizam a **análise preditiva**, a **otimização de parâmetros operacionais** e o **monitoramento adaptativo** dos processos, promovendo avanços significativos na eficiência energética, na redução de desperdícios e na melhoria da qualidade da produção (ABDELAOUI; JABRI; BARKANY, 2023; SOORI; AREZOO; DASTRES, 2023).

A aplicação do aprendizado de máquina na usinagem é vantajosa devido à capacidade dos modelos em lidar com padrões complexos e variáveis de processo altamente interdependentes. Técnicas como redes neurais e máquinas de vetores de suporte (SVM) são amplamente utilizadas porque oferecem alta capacidade preditiva e robustez na modelagem de fenômenos não lineares.

Com o avanço da **Indústria 4.0**, a integração de sistemas inteligentes à manufatura possibilitou a automação dos processos produtivos, reduzindo a dependência de ajustes manuais e aumentando a confiabilidade operacional (WANG et al., 2021). Diversas abordagens computacionais têm sido aplicadas à usinagem, incluindo técnicas de aprendizado supervisionado, não supervisionado, por reforço e modelos híbridos. Esses métodos permitem que as máquinas-ferramenta operem de forma autônoma, ajustando-se dinamicamente às variações do ambiente de produção (MOLINA; TETI; ALVIR, 2023).

2.1.2 Técnicas de Inteligência Artificial Aplicadas à Usinagem

A aplicação da IA na usinagem pode ser categorizada em três áreas principais:

- **Previsão e monitoramento de desempenho** – Técnicas como *Redes Neurais Artificiais* (ANNs)

e *Máquinas de Vetores de Suporte* (SVMs) são amplamente empregadas para prever desgaste de ferramentas, falhas operacionais e qualidade superficial das peças (CHEN, 2017).

- **Otimização de parâmetros operacionais** – Algoritmos evolucionários e **aprendizado profundo** permitem encontrar combinações ótimas de variáveis do processo, reduzindo o consumo energético e maximizando a eficiência (XIAO et al., 2021).
- **Automação e controle inteligente** – Modelos baseados em lógica *fuzzy* e redes bayesianas possibilitam ajustes contínuos nos parâmetros da usinagem, garantindo maior estabilidade e eficiência (MOLINA; TETI; ALVIR, 2023).

A seguir, são descritos os principais algoritmos de aprendizado de máquina aplicados à usinagem.

2.1.2.1 Redes Neurais Artificiais – *Artificial Neural Networks* (ANNs)

As ANNs são amplamente utilizadas para prever padrões de consumo energético, desgaste de ferramentas e qualidade superficial, devido à sua capacidade de aprender padrões complexos a partir de grandes volumes de dados, o que permite ajustes operacionais mais precisos. Esse avanço no aprendizado de máquina tem se expandido na usinagem em virtude da crescente necessidade de conciliar produtividade e sustentabilidade (ABDELAOUI; JABRI; BARKANY, 2023). Além disso, estudos indicam que a combinação das ANNs com algoritmos genéticos pode proporcionar um aumento de até 15% na eficiência energética das máquinas-ferramenta (SOORI; AREZOO; DASTRES, 2023).

Estudos conduzidos por Molina *et al.* (MOLINA; TETI; ALVIR, 2023), Mypati *et al.* (MYPATI et al., 2023), Xiao *et al.* (XIAO et al., 2020) e Hashmi *et al.* (HASHMI et al., 2022) reforçam a importância das ANNs na melhoria da eficiência energética em processos de fresagem e perfuração. Esses trabalhos evidenciam que a implementação dessas redes possibilita a análise de dados operacionais em tempo real, promovendo a adaptação dinâmica dos parâmetros de corte e reduzindo desperdícios.

2.1.2.2 Máquinas de Vetores de Suporte – *Support Vector Machines* (SVMs)

As SVMs são modelos robustos para classificação e regressão e têm sido aplicadas na previsão da rugosidade superficial e na detecção de padrões de falha na usinagem. A principal vantagem desse método é a sua capacidade de trabalhar bem com conjuntos de dados reduzidos, mantendo alta precisão (CHEN, 2017).

As SVMs são amplamente empregadas na otimização dos processos de usinagem, sendo utilizadas para prever resultados como a rugosidade da superfície e a vida útil da ferramenta, além de monitorar a condição da máquina e detectar falhas (KIM et al., 2018). O estudo realizado por Abu-Mahfouz *et al.* (ABU-MAHFOUZ et al., 2017) abordou a predição da rugosidade superficial em processos de fresagem, comparando o desempenho das SVMs com outros modelos supervisionados. Os resultados indicam que as SVMs apresentam uma capacidade superior de generalização, especialmente quando métodos de redução de atributos são aplicados, aumentando a precisão do modelo.

O estudo de Deng e Yeh (DENG; YEH, 2011) propõe a aplicação do método *Least Squares Support Vector Machines* (LSSVMs), uma variação das *Support Vector Machines* (SVMs), para a estimativa de custos na fabricação de estruturas aeroespaciais, com foco na usinagem convencional. A pesquisa considera peças estruturais fabricadas em alumínio por processos usuais de usinagem, sem especificar um método específico. No entanto, a complexidade da fabricação é analisada com base em variáveis como a taxa de remoção de material, o número de reservas no processo e a quantidade de trocas de ferramentas. Esses parâmetros sugerem

que os processos envolvidos podem incluir operações como fresamento, torneamento ou furação.

2.1.2.3 Máquina de Aprendizado Extremo – *Extreme Learning Machine* (ELM)

O aprendizado de máquina baseado em grampos (*Extreme Learning Machine* – ELM) tem ganhado espaço na modelagem de processos industriais, sendo utilizado para prever forças de corte, temperatura da ferramenta e qualidade superficial em operações de fresagem e torneamento. Esses algoritmos são conhecidos por sua rápida capacidade de treinamento e generalização eficiente, tornando-se uma alternativa promissora para a otimização da usinagem (HUANG; ZHU; SIEW, 2006).

Cheng *et al.* (CHENG *et al.*, 2022) propõem um modelo baseado em ELM com um núcleo híbrido para a predição da rugosidade superficial, demonstrando que a combinação de aprendizado de máquina e monitoramento do desgaste da ferramenta pode aprimorar significativamente a precisão dos processos de usinagem e otimizar o consumo energético na manufatura avançada.

2.1.2.4 Algoritmos Evolutivos e de Otimização

Os algoritmos genéticos (GAs) e a otimização por enxame de partículas (PSO) são estratégias de otimização baseadas na natureza, amplamente utilizadas na usinagem. Enquanto os GAs aplicam princípios da evolução biológica para encontrar as melhores combinações de parâmetros de corte, o PSO simula o comportamento de enxames para otimizar processos produtivos (XIAO *et al.*, 2021).

Os GAs, em particular, representam uma abordagem crucial para a otimização da usinagem, sendo amplamente utilizados na determinação de parâmetros operacionais mais eficientes. Inspirados na evolução biológica, esses algoritmos empregam mecanismos de seleção, cruzamento e mutação para explorar e refinar soluções, resultando em menor consumo energético e maior eficiência nos processos industriais (HOLLAND, 1975).

Estudos recentes, como os de Feng *et al.* (FENG *et al.*, 2022), Pawanr *et al.* (PAWANR; GARG; ROUTRAY, 2022), Xiao *et al.* (XIAO *et al.*, 2021) e Molina *et al.* (MOLINA; TETI; ALVIR, 2023), demonstram que a aplicação dos GAs na definição de parâmetros de usinagem pode levar a reduções significativas no consumo de energia, ao mesmo tempo em que aprimora a precisão e a eficiência dos processos.

Xiao *et al.* (XIAO *et al.*, 2022) desenvolveram um modelo de seleção de equipamentos de usinagem baseado no *Business Compass Model*, visando minimizar o consumo de energia e o tempo de processamento. A pesquisa demonstra que a abordagem quantitativa, aliada ao algoritmo de busca por antenas de besouro (BAS), permite uma escolha mais eficiente de máquinas-ferramenta, contribuindo para a sustentabilidade e otimização produtiva nos processos de manufatura.

Em um estudo complementar, Xiao *et al.* (XIAO *et al.*, 2023) propuseram um modelo aprimorado para a seleção de equipamentos de torneamento, considerando simultaneamente a eficiência de produção e as emissões de carbono. A aplicação do BAS mostrou-se superior a outros algoritmos, como PSO e GA, proporcionando uma redução do tempo de usinagem e das emissões ambientais, reforçando a importância de métodos quantitativos na tomada de decisão industrial.

Por fim, técnicas como a otimização de colônia de formigas (*Ant Colony Optimization* – ACO) e o algoritmo de busca por antenas de besouro (*Beetle Antenna Search* – BAS) vêm sendo cada vez mais exploradas na resolução de problemas de otimização energética e operacional. Enquanto a ACO, proposta por Dorigo *et al.* (DORIGO; BIRATTARI; STUTZLE, 2006), simula o comportamento de formigas para encontrar soluções

otimizadas, o BAS utiliza princípios inspirados na biologia para realizar a busca eficiente de parâmetros de usinagem (JIANG; LI, 2017).

2.1.2.5 Aprendizado Profundo e Redes Neurais Convolucionais (Deep Learning and Convolutional Neural Networks (CNNs))

O aprendizado profundo tem sido amplamente explorado na análise de imagens de ferramentas de corte e peças usinadas, permitindo a identificação de padrões de desgaste e a previsão de defeitos de fabricação (MOLINA; TETI; ALVIR, 2023). Entre as abordagens mais utilizadas, destacam-se as redes neurais convolucionais (CNNs), empregadas para processar imagens e extrair características relevantes para a detecção de falhas.

Além das CNNs, outros modelos de redes neurais profundas (*Deep Neural Networks* – DNNs) também são amplamente utilizados para prever o desgaste de ferramentas, detectar falhas em tempo real e otimizar trajetórias de corte. Segundo LeCun *et al.* (LECUN; BENGIO; HINTON, 2015), essas redes possuem a capacidade de processar grandes volumes de dados e identificar padrões sutis nos processos industriais, contribuindo para a melhoria da qualidade dos produtos e a redução de custos operacionais.

2.1.2.6 K-Vizinhos Mais Próximos – *k-Nearest Neighbors* (KNN)

O KNN é um método amplamente aplicado na usinagem, sendo utilizado para prever o consumo energético de máquinas operatrizes, classificar padrões operacionais e otimizar a eficiência dos processos de usinagem. O estudo de Komoto *et al.* (KOMOTO; HERRERA; HERWAN, 2020) demonstrou que a abordagem baseada no KNN permitiu decompor a energia utilizada em diferentes subprocessos, identificando operações de maior demanda energética e possibilitando ajustes estratégicos para reduzir custos operacionais.

Além disso, Kumar e Jain (KUMAR; SINGH, 2022) investigaram a aplicação do KNN na predição da rugosidade superficial no processo de manufatura aditiva *micro-plasma transferred arc metal additive manufacturing* (μ -PTAMAM). O estudo avaliou a influência de variáveis operacionais na qualidade superficial das peças e mostrou que o KNN oferece alta precisão na previsão da rugosidade, tornando-se uma ferramenta eficaz para o controle e a otimização desse processo de manufatura aditiva.

O estudo de Calì *et al.* (CALÌ *et al.*, 2024) destaca o uso do algoritmo KNN na previsão da rugosidade em fresagem, mostrando que ele melhora a precisão das previsões em comparação com métodos convencionais. O KNN é apresentado como uma ferramenta eficaz para modelar fenômenos complexos na usinagem, permitindo ajustes dinâmicos que otimizam a eficiência energética e a qualidade da manufatura.

2.1.2.7 Lógica Fuzzy

A lógica fuzzy é reconhecida por sua capacidade de lidar com as incertezas inerentes aos processos industriais. Sua aplicação tem se mostrado particularmente eficaz na previsão da rugosidade superficial, permitindo ajustes em tempo real nos parâmetros de usinagem (RUAN, 2012). Mypati *et al.* (MYPATI *et al.*, 2023) demonstram que a lógica fuzzy é eficiente no controle multivariável dos parâmetros de corte, garantindo a qualidade superficial e reduzindo desvios no processo.

A combinação de aprendizado de máquina com lógica fuzzy tem se mostrado promissora, especialmente por meio do uso do *adaptive neuro-fuzzy inference system* (ANFIS). Esse sistema integra aprendizado de

redes neurais e inferência fuzzy para ajustar dinamicamente os parâmetros de usinagem, promovendo maior eficiência e adaptabilidade (JANG, 1993).

2.1.3 Algoritmos de Regressão

Almeida *et al.* (ALMEIDA et al., 2018) utilizaram o método dos mínimos quadrados ordinários (OLS) para estimar modelos de regressão na usinagem do aço AISI 12L14. A abordagem empregou a **Metodologia de Superfície de Resposta** (RSM) e a otimização baseada no Erro Quadrático Médio (*Root Mean Squared Error* – RMSE) para minimizar a rugosidade superficial e o consumo energético. O estudo demonstrou que a modelagem preditiva e a análise estatística permitem otimizar os parâmetros de corte, aumentando a eficiência e a qualidade no torneamento.

O estudo de Kumar e Jain (KUMAR; JAIN, 2022) investigou a aplicação do *Support Vector Regression* (SVR) e do *Least Squares Support Vector Regression* (LSSVR) na previsão da rugosidade superficial no processo de manufatura aditiva conhecido como *micro-plasma transferred arc metal additive manufacturing* (μ -PTAMAM). Os autores analisaram a influência de variáveis operacionais na qualidade superficial das peças fabricadas e demonstraram que o SVR e o LSSVR apresentam alta precisão na previsão da rugosidade, consolidando-se como ferramentas eficientes para o controle e a otimização da manufatura aditiva.

2.1.4 Comparação entre os Modelos de IA na Usinagem

A Tabela 1 apresenta uma visão geral das principais técnicas de IA aplicadas à usinagem. Ela compara diferentes algoritmos, destacando suas aplicações, benefícios e limitações no contexto da manufatura. Com isso, a tabela oferece um panorama das abordagens mais utilizadas, auxiliando na escolha do modelo mais adequado para cada necessidade específica no processo de usinagem.

Tabela 1 – Comparação entre técnicas de Inteligência Artificial aplicadas à usinagem

Algoritmo	Aplicação	Principais Características
<i>ANNs</i>	Previsão de desempenho	Alta precisão, mas requer muitos dados
<i>SVMs-LSSVMs</i>	Classificação de rugosidade	Eficiente com poucos dados
<i>ELM</i>	Previsão de forças de corte	Treinamento rápido, menor flexibilidade
<i>GAs</i>	Otimização de parâmetros	Encontram boas soluções, alto custo computacional
<i>CNNs</i>	Análise de imagens	Excelente para inspeção visual, alto processamento
<i>Lógica Fuzzy</i>	Modelagem de incertezas	Boa para lidar com dados imprecisos
<i>KNN</i>	Classificação e regressão	Simples, mas sensível a ruídos
<i>OLS</i>	Regressão linear	Fácil de implementar, limitado a relações lineares
<i>SVR-LSSVR</i>	Previsão de valores contínuos	Alta precisão, requer ajuste fino

Fonte: Elaborado pelo autor.

2.1.5 Desafios e Limitações

Embora a aplicação da **Inteligência Artificial** na usinagem tenha apresentado avanços notáveis na otimização de processos e na melhoria da eficiência energética, ainda enfrenta uma série de desafios e limitações que dificultam sua plena implementação. Esses desafios são cruciais para garantir que os modelos de IA possam ser aplicados de forma eficaz em ambientes industriais reais, levando em consideração as particularidades e as complexidades inerentes aos processos de usinagem.

Os principais obstáculos incluem:

- **Necessidade de bases de dados robustas** – Modelos de IA, especialmente aqueles baseados em aprendizado supervisionado, requerem grandes volumes de dados de alta qualidade para um treinamento eficaz. A falta de bases de dados completas e representativas das diversas condições de usinagem pode limitar a precisão e a capacidade de generalização dos modelos (HAYKIN, 1998).
- **Integração com máquinas-ferramenta** – A adaptação de modelos de IA às diferentes configurações de máquinas-ferramenta e processos industriais representa um desafio significativo. As máquinas variam em termos de capacidade, sensores e parâmetros de operação, o que pode dificultar a integração eficaz dos modelos de IA em ambientes industriais dinâmicos e heterogêneos (MOLINA; TETI; ALVIR, 2023).
- **Generalização dos modelos** – A capacidade de generalizar as previsões de um modelo de IA é um dos principais desafios na usinagem. Diferentes materiais, geometrias de peças e condições de corte podem afetar significativamente o desempenho do modelo, resultando em previsões imprecisas quando aplicado a novos dados ou a condições não observadas durante o treinamento (XIAO et al., 2021).

Esses desafios destacam a necessidade de avanços em várias áreas, como a coleta de dados de alta qualidade, a adaptação flexível de modelos de IA e o desenvolvimento de técnicas que proporcionem maior robustez e precisão nas previsões, independentemente das variações nas condições de usinagem.

2.1.6 Tendências Futuras

Com o rápido avanço da IA e sua aplicação na usinagem, várias tendências emergentes estão moldando o futuro da indústria. Essas inovações têm o potencial de transformar os processos de manufatura, aumentando a eficiência, a precisão e a integração de sistemas inteligentes. A seguir, são apresentadas algumas das principais tendências que devem desempenhar um papel significativo nos próximos anos:

- **IA explicável** (*Explainable AI* – XAI) – O desenvolvimento de modelos de IA mais interpretáveis é uma tendência crescente. A IA explicável busca criar sistemas cujas decisões e previsões sejam transparentes e compreensíveis, permitindo que os engenheiros entendam os motivos por trás das recomendações ou decisões feitas pela IA. Isso é crucial para aumentar a confiança e a adoção da IA em ambientes industriais (ULTRALYTICS, 2025).
- **Fusão de IA com IoT** – A integração de sensores inteligentes e dispositivos conectados ao conceito de Internet das Coisas (IoT) com sistemas de aprendizado de máquina está se tornando uma tendência poderosa. Ao coletar dados em tempo real e combiná-los com algoritmos de IA, é possível otimizar os processos de usinagem, detectar falhas precocemente e ajustar automaticamente os parâmetros de operação, aumentando a eficiência e a qualidade (ZHONG et al., 2017).
- **Simulações preditivas** – O uso de IA para prever o comportamento dos processos de usinagem antes da fabricação real é uma tendência promissora. As simulações preditivas, alimentadas por grandes volumes de dados de produção e aprendizado de máquina, permitem antecipar resultados, como o desgaste de ferramentas e a qualidade da superfície, sem a necessidade de experimentos físicos dispendiosos, tornando o processo mais ágil e econômico (RESNER; PINOTTI, 2023).

Essas tendências indicam que o futuro da usinagem estará cada vez mais conectado a tecnologias inteligentes, trazendo ganhos significativos em termos de eficiência operacional, redução de custos e melhorias da qualidade dos produtos.

2.2 Critérios de Busca

A seleção dos estudos considerados nesta revisão seguiu critérios rigorosos para garantir a relevância e a qualidade das fontes. A pesquisa foi classificada como **aplicada**, com foco em objetivos descritivos e explicativos, adotando uma abordagem predominantemente quantitativa e o uso de procedimentos técnicos baseados em estudo de caso e simulação. Foram considerados artigos publicados nos últimos cinco anos, priorizando aqueles indexados em periódicos de alto impacto e conferências científicas renomadas. Os principais critérios adotados foram:

- **Relevância do tema** – Apenas os estudos que tratam diretamente da aplicação do aprendizado de máquina para otimizar o consumo energético em processos de usinagem, como torneamento, fresagem e perfuração, foram considerados.
- **Atualidade das publicações** – Os artigos incluídos são predominantemente de fontes recentes, publicadas nos últimos cinco anos, refletindo as abordagens mais avançadas e as inovações no campo.
- **Qualidade e impacto das fontes** – Foram priorizados artigos publicados em periódicos e conferências de alta reputação, como o *Journal of Manufacturing Systems* e o *International Journal of Machine Tools and Manufacture*, reconhecidos por sua qualidade editorial e impacto na área.
- **Metodologia científica** – Os trabalhos selecionados utilizam metodologias bem definidas, com dados experimentais ou simulações que comprovam a aplicação das técnicas de aprendizado de máquina na otimização de processos de usinagem.
- **Diversidade de algoritmos aplicados** – Foram selecionados estudos que abordam uma variedade de algoritmos de IA, incluindo técnicas como *Support Vector Regression* (SVR), *Least Squares Support Vector Regression* (LSSVR), redes neurais artificiais (ANNs) e algoritmos genéticos (GAs).

Esses critérios asseguram que os trabalhos selecionados estejam alinhados ao foco principal deste estudo e contribuam significativamente para o avanço do conhecimento na área de eficiência energética e otimização de processos industriais por meio de técnicas de aprendizado de máquina. As Tabelas 2 e 3 apresentam resumos dos algoritmos aplicados à usinagem.

Tabela 2 – Algoritmos aplicados à usinagem no estudo deste artigo

Ferramenta Aplicada	Características	Aplicação	Referências
K-Vizinhos Mais Próximos (<i>K-Nearest Neighbors</i> - KNN) (FIX, 1985)	Algoritmo de aprendizado supervisionado para classificação e regressão, que seleciona novos dados com base na proximidade aos vizinhos mais próximos.	Monitoramento de energia não intrusivo para torneamento, fresagem e perfuração. Predição da rugosidade superficial.	(KIM et al., 2018), (KOMOTO; HERRERA; HERWAN, 2020), (SIHAG; SANGWAN; PUNDIR, 2018), (CALI et al., 2024)
Redes Neurais Artificiais (<i>Artificial Neural Networks-ANNs</i> ~(HAYKIN, 1998))	Modelos computacionais que simulam o funcionamento do cérebro para processar e aprender com dados.	Análise da aplicação das ANNs para melhorias de eficiência nos processos de torneamento, fresagem e perfuração.	(MOLINA; TETI; ALVIR, 2023), (MYPATI et al., 2023), (XIAO et al., 2020), (HASHMI et al., 2022)
Extreme Learning Machine (<i>ELM</i>) (HUANG; ZHU; SIEW, 2006)	Algoritmo de rede neural de camada única, destacado pelo treinamento rápido, alta generalização e baixo custo computacional.	Previsão de forças de corte, controle térmico da ferramenta e otimização da qualidade superficial em fresagem e torneamento.	(HUANG; ZHU; SIEW, 2006), (KUMAR; JAIN, 2022)
Máquinas de Vetores de Suporte (<i>Support Vector Machines</i> - SVM) (CORTES; VAPNIK, 1995)	Classifica dados maximizando a margem entre classes, sendo adequado para classificação e regressão precisas.	Otimização de parâmetros no torneamento. Aplicações eficazes na detecção de anomalias, como detecção de furtos de energia.	(KIM et al., 2018), (SUGUMARAN; MURALIDHARAN; RAMACHANDRAN, 2007), (JINDAL et al., 2016)
Máquinas de Vetores de Suporte por Mínimos Quadrados (<i>Least Squares Support Vector Machine</i> - LSSVM) (CORTES; VAPNIK, 1995)	Otimização das SVMs tradicionais ao substituir a programação quadrática por um sistema de equações lineares, reduzindo significativamente o custo computacional.	Estimativa de custos na fabricação de estruturas aeroespaciais.	(SUYKENS; VANDEWALLE, 1999)
Redes Bayesianas (<i>Bayesian Networks</i>) (PEARL, 1988; BAYES, 1763)	Modelos probabilísticos que representam relações de dependência entre variáveis para inferência e aprendizado.	Planejamento de produção e computação em nuvem para torneamento, fresagem e perfuração.	(PIMENOV et al., 2022), (MYPATI et al., 2023)
Regressão por: Support Vector Regression-SVR -(VAPNIK, 2013)	Métodos de regressão avançados usados para prever valores contínuos.	Eficiência energética em máquinas ferramentas em diferentes condições de usinagem, principalmente: torneamento e fresagem.	(MOTTA et al., 2022), (CHEN et al., 2024), (VARUN et al., 2021)
Mínimos Quadrados Ordinários (<i>Ordinary Least Squares</i> - OLS) (LEGENDRE, 1805)	Método estatístico utilizado para estimar os coeficientes de um modelo de regressão linear, minimizando a soma dos erros quadráticos entre os valores observados e os valores previstos.	Planejamento de produção e computação em nuvem para torneamento, fresagem e perfuração.	(ALMEIDA et al., 2018),

Fonte: Elaborado pelo autor.

Tabela 3 – Outros Algoritmos Aplicados na Usinagem

Ferramenta Aplicada	Características	Aplicação	Referências
Otimização de Colônia de Formigas (<i>Ant Colony Optimization</i>) (DORIGO; BIRATTARI; STUTZLE, 2006)	Algoritmo inspirado no comportamento de busca por alimento das formigas, usado para encontrar soluções ótimas em problemas de roteamento e alocação.	Aborda o uso de técnicas para reduzir o consumo de energia na fresagem e perfuração.	(WANG et al., 2019) (TIAN et al., 2019), (PAWAR; BERA; SANGWAN, 2023)
Algoritmo de busca por antenas de besouros (<i>Beetle Antennae Search - BAS</i>) - (JIANG; LI, 2017)	Técnica de otimização que simula o movimento exploratório de besouros para localizar a direção de maior gradiente e encontrar soluções ótimas.	Utiliza-se o BAS para otimizar, de forma simultânea, o consumo de energia e o tempo de processamento do torneamento.	(XIAO et al., 2022), (XIAO et al., 2023)
Lógica Fuzzy (<i>Fuzzy Logic</i>) (DUBOIS, 1980)	Integração de modelos de predição e controle, com regras flexíveis baseadas em linguagem natural.	Modelos preditivos de rugosidade com controle multivariável para ajustes automáticos em tempo real no torneamento.	(MOLINA; TETI; ALVIR, 2023), (MOREIRA et al., 2019b), (MYPATI et al., 2023)
Algoritmos Genéticos (<i>Genetic Algorithms</i>) (HOLLAND, 1975)	Técnicas de otimização que imitam a evolução biológica, usando seleção, cruzamento e mutação para encontrar soluções ótimas.	Usando para modelar o consumo de energia durante: torneamento, fresagem e perfuração, com validação de modelo e análise de erro.	(FENG et al., 2022), (PAWANR; GARG; ROUTRAY, 2022), (XIAO et al., 2021) (MOLINA; TETI; ALVIR, 2023)
Redes Neurais Convolucionais (CNNs) (MOLINA; TETI; ALVIR, 2023)	Algoritmos de aprendizado profundo aplicados na análise de imagens de ferramentas de corte e peças usinadas.	Identificação de padrões de desgaste e previsão de defeitos de fabricação em processos de usinagem.	(MOLINA; TETI; ALVIR, 2023)
Redes Neurais Profundas (DNNs) (LECUN; BENGIO; HINTON, 2015)	Modelos de aprendizado profundo usados para processar grandes volumes de dados e identificar padrões sutis.	Previsão de desgaste de ferramentas, detecção de falhas em tempo real e otimização de trajetórias de corte.	(LECUN; BENGIO; HINTON, 2015), (MOLINA; TETI; ALVIR, 2023)
Árvore de Decisão (QUINLAN, 1986)	Algoritmo de classificação baseado em regras.	Previsão de desgaste de ferramentas, detecção de falhas em tempo real e otimização de trajetórias de corte.	(VELLOSO; HORA, 2020)

Fonte: Elaborado pelo autor.

2.3 Considerações Finais

A revisão da literatura evidencia que a aplicação da IA na usinagem tem desempenhado um papel transformador na indústria, resultando em avanços significativos na eficiência operacional, na precisão dos processos e na sustentabilidade ambiental. Esta pesquisa, classificada como aplicada, de caráter descritivo e explicativo, adotou uma abordagem predominantemente quantitativa e utilizou procedimentos técnicos

baseados em estudo de caso e simulação para analisar as principais técnicas de otimização nos processos de usinagem.

A integração de técnicas de aprendizado de máquina, como as redes neurais artificiais (ANNs) (ABDELOUI; JABRI; BARKANY, 2023), as máquinas de vetores de suporte (SVMs) (KIM et al., 2018) e os algoritmos genéticos (GAs) (XIAO et al., 2021), demonstrou ser uma estratégia eficiente para otimizar parâmetros operacionais, prever falhas e reduzir o consumo de energia. Esses algoritmos são amplamente reconhecidos por sua capacidade de processar grandes volumes de dados, ajustar dinamicamente parâmetros de operação e contribuir para a melhoria da eficiência energética nos processos de usinagem (SOORI; AREZOO; DASTRES, 2023).

Os estudos analisados indicam que, apesar dos avanços tecnológicos, a plena implementação dessas técnicas enfrenta desafios consideráveis. A necessidade de bases de dados robustas para o treinamento eficaz e da integração eficiente com as máquinas-ferramenta (MOLINA; TETI; ALVIR, 2023) continua sendo barreiras significativas. Além disso, a capacidade de generalização dos modelos para diferentes materiais e condições de operação (XIAO et al., 2021) é um obstáculo técnico que limita a aplicabilidade dos algoritmos em cenários mais amplos.

As tendências emergentes, como a IA explicável (*Explainable AI* – XAI) (ULTRALYTICS, 2025), a integração com a Internet das Coisas (IoT) (ZHONG et al., 2017) e o uso de simulações preditivas (RESNER; PINOTTI, 2023), reforçam a ideia de que o futuro da usinagem será cada vez mais conectado e automatizado. Essas tecnologias permitem não apenas a detecção precoce de falhas, mas também a adaptação dinâmica dos processos, aumentando a eficiência e reduzindo os custos operacionais.

Para que esses avanços sejam plenamente integrados, é fundamental que as empresas invistam em infraestrutura tecnológica e capacitação de seus profissionais, conforme destacado por Borba e Albuquerque (BORBA; ALBUQUERQUE, 2024). A adoção dessas tecnologias requer uma mudança cultural nas organizações, promovendo a aceitação de práticas orientadas por dados e incentivando a inovação contínua.

Por fim, a continuidade das pesquisas nessa área é essencial para atender às demandas da indústria moderna. A combinação de IA, automação avançada e práticas sustentáveis poderá estabelecer um novo paradigma de eficiência energética, produtividade e competitividade global, posicionando as empresas de usinagem na vanguarda da transformação digital da indústria (MANYIKA; BUGHIN, 2018).

3 Fundamentação Teórica, Materiais e Métodos

A usinagem é um dos processos mais importantes da manufatura, sendo responsável pela transformação de matérias-primas em peças usinadas com alta precisão e qualidade dimensional. O aprimoramento contínuo de técnicas como torneamento, furação e fresamento tem possibilitado um maior controle sobre os parâmetros operacionais, resultando em processos mais eficientes e com menor desperdício de material.

Este capítulo apresenta os fundamentos teóricos deste estudo, explorando as principais abordagens da usinagem e a aplicação da Inteligência Artificial na otimização do consumo energético. Além disso, são descritos os materiais e métodos utilizados na pesquisa, incluindo a base de dados, as técnicas de pré-processamento e os algoritmos empregados para análise e modelagem dos dados.

3.1 Fundamentação Teórica

A usinagem desempenha um papel fundamental na indústria de manufatura, transformando matérias-primas em componentes de alta precisão, essenciais para a produção de produtos finais (YOUSSEF; EL-HOFY, 2020; ABDELAOUI; JABRI; BARKANY, 2023). Nos últimos anos, o aprimoramento contínuo de técnicas como torneamento, furação e fresamento tem proporcionado maior controle sobre os processos, aumentando a eficiência produtiva e reduzindo desperdícios (GROOVER, 2012; EL-HOFY, 2018; HARIK; WUEST, 2019).

Esta seção apresenta os conceitos teóricos fundamentais para o estudo, explorando as técnicas de usinagem e a aplicação da Inteligência Artificial na otimização dos processos produtivos, incluindo o consumo energético. A subseção inicial detalha as principais técnicas empregadas, destacando estratégias para minimizar desperdícios de material. Em seguida, discute-se a aplicação da Inteligência Artificial na otimização do consumo energético em usinagem, com foco no torneamento, demonstrando como essas tecnologias contribuem para aprimorar a eficiência energética (KALPAKJIAN; SCHMID, 2021; KNIGHT; BOOTHROYD, 2019). Essas análises fornecem uma base teórica para compreender os desafios e oportunidades associados à integração de soluções de IA nos processos industriais.

No contexto da Inteligência Artificial, o aprendizado de máquina tem se consolidado como uma ferramenta essencial para a otimização de processos industriais, incluindo a usinagem (YOUSSEF; EL-HOFY, 2020; GROOVER, 2012; KALPAKJIAN; SCHMID, 2021). Métodos como redes neurais artificiais (ANNs), máquinas de vetores de suporte (SVM) e algoritmos genéticos possibilitam ajustes dinâmicos e automáticos nos parâmetros operacionais, promovendo maior eficiência energética e prolongando a vida útil das ferramentas (ABDELAOUI; JABRI; BARKANY, 2023; KNIGHT; BOOTHROYD, 2019; EL-HOFY, 2018). A aplicação dessas técnicas permite prever o consumo energético e adaptar os parâmetros de operação em tempo real, alinhando-se ao objetivo de tornar as operações industriais mais sustentáveis e eficientes (HARIK; WUEST, 2019; GROOVER, 2019).

A presente fundamentação teórica oferece um embasamento para o estudo dos avanços específicos que serão explorados nas seções seguintes.

3.1.1 Processo de Usinagem Industrial - Torneamento

O torneamento é um dos processos fundamentais da usinagem industrial, sendo amplamente utilizado na manufatura para a conformação mecânica de peças cilíndricas. Nesse processo, uma ferramenta de corte removível entra em contato com a peça em rotação, removendo o material em camadas sucessivas. Esse método permite elevada precisão dimensional e controle sobre o acabamento superficial, sendo essencial para a produção de componentes mecânicos em larga escala.

De acordo com (GROOVER, 2012), os processos de remoção de material visam modificar a forma de uma peça bruta, atingindo a geometria desejada por meio da remoção controlada do material excedente. A usinagem, principal técnica dentro desse contexto, emprega uma ferramenta de corte afiada para garantir alta precisão e controle dimensional (GROOVER, 2012; EL-HOFY, 2018). Entre os processos mais comuns, destacam-se o torneamento, a furação e o fresamento, cada um adequado a diferentes geometrias e aplicações.

No processo de torneamento, foco deste estudo, uma ferramenta monocortante remove material da superfície de uma peça em rotação, avançando linearmente em paralelo ao seu eixo para formar a geometria cilíndrica desejada (GROOVER, 2012). Esse processo ocorre em uma máquina-ferramenta denominada torno, que fornece a potência necessária para girar a peça em uma velocidade controlada e mover a ferramenta conforme os parâmetros especificados de avanço e profundidade de corte (JAIN, 2022).

O equipamento utilizado neste trabalho é ilustrado na Figura 1 e corresponde a um torno mecânico, uma vez que é operado manualmente, sendo comumente utilizado em operações de pequena e média produção. Além disso, trata-se de um torno horizontal, pois seu eixo principal de operação é horizontal. Esse tipo de torno é apropriado para a maioria dos trabalhos de torneamento, em que o comprimento da peça costuma ser maior que o seu diâmetro.

Em uma análise mais detalhada do torno (Figura 1), é possível destacar alguns de seus componentes principais. Peças cilíndricas, de cada material a ser usinado, são presas na placa de castanhas, enquanto a ferramenta de corte é fixada no porta-ferramentas. Cada peça é submetida a rotações variadas por meio da rotação da placa de castanhas e entra em contato com a ferramenta de corte na região frontal da peça para remoção do material. A ferramenta de corte possui um movimento de translação para avanço e recuo em relação à peça a ser usinada.

A Figura 1b apresenta a configuração da operação de usinagem realizada no equipamento da Figura 1a, destacando a disposição da ferramenta de corte e da peça, bem como os movimentos envolvidos no processo.

Nas operações de torneamento, uma variedade de parâmetros impacta diretamente na eficiência da remoção de material, na precisão dimensional e na integridade da peça final. Os principais parâmetros relevantes para este estudo serão brevemente descritos a seguir. Para mais detalhes neste contexto, recomenda-se consultar as referências de (BAPTISTA, 2002), (PARK; NGUYEN; DANG, 2016), (GROOVER, 2019) e (GUPTA et al., 2023).

3.1.2 Velocidade de Corte - V_c

A velocidade de corte (V_c) é um dos principais parâmetros no torneamento, sendo definida como a velocidade relativa entre a peça e a ferramenta no ponto de contato. Esse parâmetro, expresso em metros por minuto (m/min), representa a medida da velocidade relativa entre a ferramenta de corte e a peça de trabalho durante o processo de usinagem.




Figura 1 – Torno mecânico utilizado no processo de usinagem para configuração experimental.

Fonte: Elaborado pelo autor.

A velocidade de corte (V_c) influencia diretamente o tempo de usinagem, a qualidade do acabamento e o desgaste da ferramenta. Valores elevados de V_c resultam em ciclos de produção mais rápidos, mas podem acelerar o desgaste da ferramenta, comprometendo sua durabilidade.

Em outras palavras, a velocidade de corte representa a rapidez com que a ferramenta de corte se move em relação à peça de trabalho enquanto realiza o corte. Matematicamente, a velocidade de corte pode ser calculada como:

$$V_c = \frac{\pi \cdot D \cdot N}{1000} \quad (3.1)$$

onde:

- V_c é a velocidade de corte (m/min);
- D é o diâmetro da peça (mm);
- N é a rotação da peça (rpm).

Além dessa equação tradicional, a velocidade de corte também pode ser determinada em função do diâmetro e comprimento iniciais da amostra, levando em consideração o avanço por rotação e o tempo total do processo:

$$V_c = \frac{\pi \cdot D_i \cdot L}{1000 \cdot a_f \cdot T} \quad (3.2)$$

onde:

- D_i é o diâmetro inicial da amostra (mm);
- L é o comprimento inicial da amostra (mm);
- a_f é o avanço por rotação (mm/rot);
- T é o tempo total do processo (min).

3.1.3 Força de Corte - F_c

A força de corte, expressa em Newtons (N), é uma métrica fundamental na usinagem para estimar a resistência que o material oferece durante operações como corte, torneamento ou fresamento. Essa força, exercida pela ferramenta de corte sobre o material, impacta tanto a qualidade do produto final quanto a eficiência do processo de usinagem.

A força de corte pode ser calculada por meio da seguinte equação:

$$F_c = a_f \cdot h \cdot K_c, \quad (3.3)$$

onde:

- F_c é a força de corte (N);
- a_f é o avanço por rotação (mm/rot);
- h é a espessura de corte (mm);
- K_c é a constante de força de corte específica do material (N/mm²).

3.1.4 Potência de Corte - P_c

A potência de corte, expressa em Watts (W), é um indicador essencial para avaliar a eficiência e a economia dos processos de usinagem. Sua magnitude é influenciada por diversos fatores, como o tipo de material a ser usinado, as condições da ferramenta de corte e os parâmetros operacionais adotados. A potência de corte pode ser estimada pela seguinte equação:

$$P_c = F_c \cdot V_c, \quad (3.4)$$

onde:

- P_c é a potência de corte (W);
- F_c é a força de corte (N);
- V_c é a velocidade de corte (m/s).

3.1.5 Potência Elétrica - P_e

A potência elétrica (P_e), expressa em Watts (W), refere-se à potência consumida pelo sistema elétrico da máquina durante o processo de usinagem. Representa a energia elétrica fornecida à máquina para acionar seus componentes, como o motor principal, o sistema de transmissão, os sistemas de controle, entre outros. Durante o torneamento, P_e pode ser calculada como:

$$P_e = \frac{P_c}{\eta}, \quad (3.5)$$

onde:

- P_e é a potência elétrica consumida pela máquina (W);
- P_c é a potência de corte (W);
- η é o rendimento da máquina operatriz, responsável pelo movimento de corte e avanço no torno.

A potência elétrica (P_e) corresponde à quantidade de energia consumida pela máquina-ferramenta durante o processo de usinagem. Esse consumo depende de fatores como a força de corte, a velocidade de rotação e a eficiência do sistema de transmissão da máquina. O monitoramento desse parâmetro é essencial para a otimização energética dos processos industriais, possibilitando a redução do consumo de energia e a adoção de estratégias sustentáveis na manufatura.

No contexto deste estudo, a eficiência (η) foi determinada a partir da curva característica dos motores utilizados, fornecida pelo fabricante. Isso permitiu uma estimativa mais precisa do consumo energético durante as operações de usinagem. Essa abordagem foi essencial para garantir ajustes em tempo real nos parâmetros operacionais, resultando em uma redução significativa do consumo energético em diferentes condições de operação.

3.1.6 Energia de Corte - E_c

A energia de corte, expressa em J/mm^3 , é um indicador que quantifica a energia necessária nos processos de usinagem para remover uma unidade de volume do material da peça de trabalho. A energia de corte varia conforme o material da peça, suas propriedades mecânicas e térmicas, além do tipo de ferramenta de corte utilizada. Matematicamente, a energia de corte pode ser calculada como:

$$E_c = \frac{P_c}{h \cdot b \cdot V_c}, \quad (3.6)$$

onde:

- E_c é a energia de corte (J/mm^3);
- P_c é a potência de corte (W);
- V_c é a velocidade de corte (mm/min);
- h representa a espessura de corte (mm);
- b é a largura de corte (mm).

Para os propósitos deste estudo, foram realizadas várias operações de torneamento, envolvendo diferentes valores das grandezas discutidas nesta seção, para amostras de diferentes tipos de aços.

3.1.7 Aprendizado de Máquina na Otimização de Processos de Usinagem

O aprendizado de máquina tem sido amplamente utilizado para a otimização de processos de usinagem, possibilitando a previsão do desgaste da ferramenta, a detecção de anomalias no corte e a redução do consumo energético. Técnicas como redes neurais artificiais (ANNs) e máquinas de vetores de suporte (SVMs) têm demonstrado resultados promissores na previsão do comportamento das ferramentas em diferentes condições operacionais. Além disso, algoritmos evolutivos, como Algoritmos Genéticos (GA) e Otimização por Enxame de Partículas (PSO), têm sido empregados para ajustar automaticamente parâmetros operacionais, garantindo eficiência e qualidade na usinagem.

Inserido no contexto da Inteligência Artificial, o aprendizado de máquina destaca-se como uma ferramenta fundamental para a otimização de processos industriais, incluindo a usinagem (YOUSSEF; EL-HOFY, 2020; GROOVER, 2012; KALPAKJIAN; SCHMID, 2021). Técnicas como redes neurais artificiais (ANNs) e máquinas de vetores de suporte (SVMs) possibilitam ajustes dinâmicos e automáticos nos parâmetros operacionais, promovendo a eficiência energética e prolongando a vida útil das ferramentas (ABDELAOUI;

JABRI; BARKANY, 2023; KNIGHT; BOOTHROYD, 2019; EL-HOFY, 2018). A aplicação de AM na usinagem permite prever o consumo energético e adaptar parâmetros de operação em tempo real, alinhando-se com o objetivo de operações industriais sustentáveis e eficientes (HARIK; WUEST, 2019; GROOVER, 2019).

As redes neurais artificiais (ANNs) imitam o funcionamento do cérebro humano ao ajustarem os pesos nas conexões entre neurônios artificiais, reconhecendo padrões complexos e não lineares em grandes conjuntos de dados (CHUANG et al., 2002). Essa flexibilidade faz das ANNs uma excelente escolha para problemas de otimização em usinagem, embora seu uso demande uma quantidade considerável de dados e poder computacional. As ANNs são especialmente vantajosas para modelar variáveis operacionais que afetam o desempenho e a eficiência energética dos processos industriais, como a previsão do desgaste de ferramentas e a otimização de parâmetros de corte.

As máquinas de vetores de suporte (SVMs), por outro lado, são projetadas para encontrar um hiperplano ótimo que separa as classes de dados com a máxima margem, sendo particularmente úteis para tarefas de classificação precisa (CHUANG; LEE, 2011; DUFRENOIS; COLLIEZ; HAMAD, 2007). Na usinagem, as SVMs têm sido amplamente aplicadas em previsões de falhas de ferramentas e na classificação de qualidade do produto final. Apesar de serem eficientes com dados menos complexos, as SVMs podem ser sensíveis a outliers, o que pode impactar seu desempenho em certos cenários.

Na prática, essas técnicas são aplicadas para prever o desgaste de ferramentas e otimizar os parâmetros de corte, resultando na redução de falhas e no aprimoramento da qualidade dos produtos finais. Além de aumentar a eficiência operacional, o aprendizado de máquina na indústria desempenha um papel crucial na sustentabilidade, alinhando-se às práticas de ESG (*Environmental, Social, and Governance*), ao minimizar o consumo de recursos e reduzir o impacto ambiental. Dessa forma, o aprendizado de máquina não apenas impulsiona a inovação tecnológica, mas também fortalece a transição para operações industriais mais sustentáveis. Essa fundamentação teórica em AM serve como base para a exploração dos avanços específicos abordados nas próximas seções.

Tabela 4 – Análise Comparativa das Características dos Materiais: Quantidades, Atributos e Amostras

Tipo de Aço	Número de Amostras originais	Atributos
ABNT SAE 1020	15	Tempo (T), Avanço por Revolução (af)
ABNT SAE 1045	15	Velocidade de Corte (Vc), Rugosidade (r)
ABNT SAE 4140	15	Espessura de Corte (h), Força de Corte (Fc)
ABNT SAE 4340	15	Potência de Corte (Pc), Energia de Corte (Ec)
VC (VND Steel)	15	Potência Elétrica (PE)

Fonte: Elaborado pelo autor.

Tabela 5 – Composição Química Típica dos Materiais

Material	(C)	(Si)	(Mn)	(P)	(Cr)	(Mo)	(Fe)	(Cu)
ABNT SAE 1020	0,210%	0,140%	0,260%	0,036%	0,028%	0,022%	0,260%	0,010%
ABNT SAE 1045	0,440%	0,280%	0,500%	0,024%	0,026%	0,022%	0,680%	0,015%
ABNT SAE 4140	0,400%	0,260%	0,600%	0,020%	0,880%	0,190%	0,400%	0,190%
ABNT SAE 4340	0,390%	0,190%	0,470%	0,022%	0,680%	0,200%	0,330%	0,240%
VC (VND Steel)	1,800%	0,290%	0,220%	0,014%	0,710%	0,082%	-	-

Fonte: Elaborado pelo autor.

3.2 Materiais e Métodos

Esta dissertação propõe uma abordagem inovadora que utiliza técnicas de aprendizado de máquina para otimizar a eficiência energética em processos de torneamento de aço. A metodologia envolve a classificação das propriedades dos aços e a estimativa do consumo de energia durante o torneamento. Ao associar automaticamente os parâmetros de usinagem ao tipo de material e prever o consumo energético, é possível otimizar esses parâmetros para melhorar a eficiência do processo e auxiliar na escolha das ferramentas de corte mais adequadas. Isso contribui para a redução do tempo de processamento e do consumo de energia. Além disso, essa abordagem possibilita o processamento de materiais com alta demanda energética em horários de menor consumo, promovendo uma gestão mais eficiente dos recursos energéticos.

Nesta seção, são detalhados os materiais e métodos empregados na abordagem proposta. Inicialmente, descreve-se a obtenção das amostras dos diferentes aços submetidos às operações de torneamento. Em seguida, abordam-se as etapas relacionadas à definição das classes no problema de classificação de padrões e à extração de atributos dos parâmetros de torneamento utilizados. Por fim, apresenta-se o procedimento para a geração de amostras artificiais utilizando o método *Synthetic Minority Over-sampling Technique* (SMOTE), com o objetivo de viabilizar a aplicação de técnicas de aprendizado de máquina nos problemas de reconhecimento de padrões e regressão tratados. A Figura 2 ilustra a metodologia adotada na proposta.

3.2.1 Materiais

A base de dados utilizada neste estudo foi desenvolvida a partir dos experimentos realizados por Caetano (CAETANO, 2019), com o objetivo de investigar a eficiência energética em operações de torneamento de diferentes tipos de aço amplamente utilizados na indústria. Foram selecionados cinco materiais de grande relevância nos processos industriais — **SAE 1020, SAE 1045, SAE 4140, SAE 4340 e VC 131** — escolhidos por suas propriedades químicas e mecânicas. Esses materiais proporcionam uma amostra representativa e robusta para examinar o comportamento energético sob variadas condições operacionais.

Cada tipo de aço foi representado por um conjunto de **15 amostras**, totalizando **75 instâncias experimentais**. Essa estrutura organizacional dos dados facilita a aplicação de algoritmos de aprendizado de máquina tanto à classificação quanto à regressão, com o intuito de prever o consumo energético e otimizar parâmetros de usinagem. Em cada amostra, foram coletadas variáveis operacionais críticas, incluindo velocidade de corte, avanço por rotação, tempo de operação e espessura de corte, calculadas conforme as propriedades mecânicas de cada tipo de aço. Tais variáveis permitem diferenciar padrões de consumo energético entre as amostras, servindo como base para análises de eficiência energética (CAETANO, 2019).

A Tabela 5 apresenta a composição química de cada tipo de aço, com destaque para os elementos constituintes que influenciam diretamente o comportamento do material durante o torneamento. Essa caracterização química é essencial para que os modelos de aprendizado de máquina identifiquem padrões específicos de consumo energético conforme a configuração operacional aplicada a cada material. A estruturação sistemática dos dados assegura, ainda, uma base sólida para futuras aplicações industriais relacionadas à eficiência energética e otimização de processos.

Para assegurar a precisão na coleta de dados de consumo de energia, foi implementada uma bancada experimental equipada com um analisador de energia. Esse dispositivo foi configurado para monitorar a potência elétrica (P_e) e a energia consumida (E) durante as operações de usinagem.

O analisador de energia foi calibrado conforme as especificações do fabricante do torno e a curva caracte-

rística do motor. Isso permitiu o cálculo preciso da eficiência energética (η) a partir das medições obtidas, garantindo a confiabilidade dos dados coletados.

Esses dados servem como base para análises de aprendizado de máquina voltadas à classificação e previsão do consumo energético em operações industriais de usinagem. Dessa forma, o estudo fornece resultados aplicáveis a diferentes cenários industriais, oferecendo uma referência relevante para pesquisas e futuras implementações na área de eficiência energética.

3.2.2 Classificação e Regressão

Neste estudo, foram aplicadas técnicas de **aprendizado de máquina** para resolver dois problemas distintos:

1. **Classificação:** O primeiro passo consistiu em classificar os tipos de aço com base em atributos operacionais, como **velocidade de corte**, **avanço por rotação** e **profundidade de corte**. Essa etapa teve como objetivo identificar o tipo de aço presente em cada amostra de usinagem, utilizando métodos de classificação supervisionada.
2. **Regressão:** Após a classificação, a próxima etapa foi a aplicação de modelos de regressão para prever o **consumo de energia elétrica** durante o processo de usinagem. Para isso, os parâmetros de usinagem foram utilizados como variáveis independentes, a fim de estimar a energia consumida, empregando técnicas de regressão como a **Máquina de Vetores de Suporte por Mínimos Quadrados (LSSVR)** e o **Perceptron Multicamadas (MLP)**.

Essas duas abordagens foram aplicadas de maneira complementar: a classificação permitiu identificar com precisão o tipo de material, enquanto a regressão possibilitou a previsão do consumo energético, considerando os parâmetros operacionais específicos de cada processo de usinagem.

Antes da seleção dos modelos de aprendizado de máquina, foi realizada uma análise preliminar da linearidade dos dados para compreender a complexidade dos problemas de classificação e regressão. Para isso, foram utilizadas análises gráficas de dispersão e o cálculo dos coeficientes de correlação entre os atributos, permitindo avaliar a relação entre as variáveis preditoras e as saídas.

Os resultados indicaram que os padrões nos dados não seguem uma relação estritamente linear. Dessa forma, optou-se pelo uso de modelos não lineares para ambas as tarefas. Na classificação, foram empregados a **Rede Neural Perceptron Multicamadas (MLP)** e a **Máquina de Vetores de Suporte (SVM/LSSVM)**, dada sua capacidade de modelar padrões complexos.

Para a regressão, a presença de relações não lineares entre os atributos justificou o uso de aprendizado profundo e regressão por vetores de suporte. A escolha desses modelos visa maximizar a capacidade preditiva e a generalização dos padrões de consumo energético nos processos de usinagem.

3.2.2.1 Contextualização da Classificação

A **classificação** é uma técnica de **aprendizado supervisionado** utilizada para prever rótulos ou categorias discretas a partir de variáveis de entrada. Diferentemente da regressão, que busca estimar valores contínuos, a classificação tem como objetivo determinar a categoria ou classe à qual um determinado ponto de dados pertence.

No contexto deste estudo, a classificação foi empregada para identificar o tipo de aço presente nas amostras de usinagem. Para isso, foram utilizadas variáveis operacionais, como **velocidade de corte**, **avanço por rotação**, **profundidade de corte** e **rotação do torno**, que apresentam influência direta no comportamento dos materiais durante o processo de torneamento.

A adoção de técnicas de classificação possibilitou o agrupamento das amostras de aço em categorias distintas, o que é essencial para a análise subsequente do consumo energético. Como o tipo de material exerce um impacto significativo sobre o desempenho da usinagem, a identificação precisa da liga metálica é fundamental para o ajuste adequado dos parâmetros operacionais.

Além disso, essa abordagem contribui diretamente para a **otimização da eficiência energética**, uma vez que permite a adaptação dos parâmetros do processo conforme as características do material. Dessa forma, é possível melhorar a qualidade do produto final e reduzir o desperdício de recursos, promovendo maior sustentabilidade na manufatura.

Os métodos de classificação aplicados neste estudo foram:

- **Máquinas de Vetores de Suporte (SVM)**: Modelo robusto de classificação que busca o *hiperplano ótimo* para separar as diferentes classes de dados, maximizando a margem entre elas. As **SVMs** foram escolhidas por sua elevada precisão em problemas de alta dimensionalidade, garantindo um desempenho consistente mesmo em conjuntos de dados com múltiplas variáveis.
- **K-Vizinhos Mais Próximos (KNN)**: Algoritmo baseado na similaridade entre pontos de dados, classificando um novo exemplo conforme a classe majoritária dos seus vizinhos mais próximos. O **KNN** é particularmente eficaz em cenários com fronteiras de decisão complexas e distribuições não lineares, adaptando-se bem a diferentes padrões nos dados.
- **Perceptron Multicamadas (MLP)**: Rede neural composta por múltiplas camadas ocultas, capaz de capturar relações não lineares entre as variáveis de entrada e os rótulos das classes. As **MLPs** são altamente flexíveis, permitindo modelar interações complexas e identificar padrões em dados de classificação com grande variabilidade.
- **Máquinas de Vetores de Suporte por Mínimos Quadrados (LSSVM)**: Variante das **SVMs** que utiliza uma formulação baseada em *mínimos quadrados*, simplificando o problema de otimização. As **LSSVMs** demonstraram eficiência na identificação dos tipos de aço, principalmente em cenários com alta dimensionalidade, onde modelos tradicionais poderiam apresentar dificuldades de generalização.

Os resultados obtidos com os classificadores, conforme apresentados na Tabela 8, indicam que a maioria dos algoritmos, como o **MLP** (com uma e duas camadas ocultas), o **SVM** com kernel Gaussiano e o **LSSVM**, apresentaram um desempenho significativamente superior quando operados com um conjunto reduzido de atributos. A acurácia média nos testes foi superior a **90%** para os modelos **MLP**, **SVM** e **LSSVM**, evidenciando sua eficácia na classificação dos tipos de aço. Em contrapartida, classificadores como o **OLS** e o **Naive Bayes Gaussiano** tiveram desempenho inferior, o que pode ser atribuído à sua incapacidade de lidar com a alta correlação entre os atributos, conforme demonstrado na Tabela 7.

Esses métodos foram selecionados devido à sua capacidade de processar grandes volumes de dados e capturar padrões complexos. Além disso, a comparação entre diferentes técnicas possibilitou uma análise mais abrangente da classificação dos tipos de aço nas amostras. A **classificação** foi uma etapa essencial no processo, pois permitiu que os modelos subsequentes, como os de **regressão**, fossem aplicados com base na

identificação precisa do material em cada amostra.

A integração sequencial dos métodos de classificação e regressão proporcionou uma abordagem robusta para a otimização da eficiência energética nos processos de usinagem. Essa estratégia não apenas categorizou os materiais, mas também permitiu prever com maior precisão o consumo energético associado a cada tipo de aço e seus respectivos parâmetros operacionais. Dessa forma, a análise tornou-se mais eficiente e alinhada à busca por processos industriais sustentáveis e otimizados.

3.2.2.2 Contextualização da Regressão

A **regressão** é uma técnica de **aprendizado supervisionado** utilizada para prever valores contínuos a partir de variáveis independentes. Diferentemente da classificação, que busca determinar categorias discretas, a regressão foca na estimativa de resultados numéricos, sendo amplamente empregada para modelar fenômenos complexos, como o consumo de energia em processos industriais.

No contexto deste estudo, a regressão foi aplicada para estimar o consumo de energia elétrica durante o processo de usinagem de aços, considerando parâmetros operacionais específicos. Variáveis como **velocidade de corte**, **avanco por rotação**, **profundidade de corte** e **tipo de aço** foram analisadas para identificar suas influências sobre o consumo energético.

A utilização de modelos de regressão possibilita a extração de insights valiosos, permitindo ajustar os parâmetros operacionais para otimizar a eficiência energética dos processos de usinagem. Dessa forma, essa abordagem contribui diretamente para a redução de custos industriais e a implementação de estratégias sustentáveis na manufatura.

Os principais modelos de regressão empregados neste estudo foram:

- **LSSVR (Least Squares Support Vector Regression)**: Uma variação das **Máquinas de Vetores de Suporte** (SVM) voltada para regressão, que minimiza o erro quadrático, tornando-se eficaz na modelagem de relações complexas em conjuntos de dados com ruídos e alta dimensionalidade.
- **MLP (Multi-Layer Perceptron)**: Rede neural com múltiplas camadas ocultas, capaz de capturar padrões não lineares entre os parâmetros de usinagem e o consumo de energia. O **MLP** é especialmente útil para modelar interações dinâmicas entre variáveis em ambientes industriais com alta variabilidade.

Esses modelos foram escolhidos por sua capacidade de prever valores contínuos com precisão e capturar relações complexas entre variáveis operacionais. A aplicação da regressão nesse contexto não apenas melhora a previsão do consumo energético, mas também serve como base para a otimização de parâmetros, permitindo aprimorar a eficiência operacional e reduzir desperdícios nos processos de usinagem.

3.2.3 Métodos

Todas as amostras de aço da base de dados foram usinadas em um torno mecânico horizontal, ilustrado na Figura 1, utilizando uma única ferramenta de corte para garantir a consistência dos resultados. O processo de usinagem foi conduzido por meio do **método de faceamento progressivo**¹.

¹ Faceamento progressivo é uma técnica de usinagem na qual o material é removido da superfície frontal de uma peça rotativa, com a ferramenta avançando gradualmente em direção ao centro, formando uma superfície plana e uniforme.

Para cada amostra, foram aplicadas variações controladas nos parâmetros operacionais, abrangendo rotações entre **150 RPM e 950 RPM** e avanços de **0,116 mm, 0,320 mm e 0,554 mm**. Essa configuração experimental foi projetada para abranger uma ampla gama de condições de usinagem, permitindo uma análise detalhada do desempenho dos modelos sobre diferentes tipos de aço e parâmetros operacionais.




Figura 2 – Metodologia da abordagem proposta.

Fonte: Elaborado pelo autor.

3.2.3.1 Definição de Classe e Extração de Recursos

A base de dados inicial era composta por **75 amostras**, igualmente distribuídas entre **cinco tipos de aço** (SAE 1020, SAE 1045, SAE 4140, SAE 4340 e VC 131). Durante as operações de torneamento, o consumo de energia elétrica depende diretamente do tipo de aço usinado e dos parâmetros de processo adotados, como **velocidade de corte, avanço, profundidade de corte e taxa de rotação**.

O primeiro estágio da metodologia proposta envolveu a **identificação automatizada do tipo de aço da amostra**, essencial para garantir precisão na estimativa do consumo energético. Esse procedimento foi modelado como um problema de **classificação de padrões**, no qual as classes correspondem às diferentes ligas de aço analisadas. A identificação precisa do material possibilita previsões mais confiáveis sobre o consumo energético em operações de usinagem.

Após a definição das classes para a tarefa de classificação, a próxima etapa consistiu na **extração de atributos**, com o objetivo de identificar padrões de similaridade e distinção entre as amostras. Essa seleção é fundamental para o desempenho dos classificadores e para a confiabilidade da estimativa do consumo energético.

Durante os experimentos, foram coletadas medições dos principais parâmetros de usinagem: **velocidade de corte** (v_c), **avanço por rotação** (a_f), **tempo total do processo** (T) e **espessura de corte** (h). Além disso, foram calculados matematicamente os valores da **força de corte** (F_c), da **potência de corte** (P_c) e da **energia de corte** (E_c), utilizando as Eqs. (3.3), (3.4) e (3.6), respectivamente.

A aquisição de dados foi realizada em uma **bancada de testes** equipada com um **analisador de energia**, conforme ilustrado na Figura 2. Esse dispositivo coletou medições da **potência elétrica** (P_e) e da **energia elétrica** (E) consumidas durante o torneamento. A **eficiência** (η) do sistema foi determinada a partir da curva característica dos motores do torno mecânico horizontal, fornecida pelo fabricante.

Dada a ausência de estudos comparáveis na literatura, optou-se, inicialmente, por considerar todos os parâmetros mencionados (exceto a energia elétrica, que foi a variável de previsão). Assim, o conjunto inicial de atributos continha **nove variáveis**, conforme ilustrado na Tabela 4.

Para otimizar o desempenho dos classificadores, aplicou-se uma **técnica de seleção de atributos** baseada no **coeficiente de correlação de Pearson**. Esse método permite identificar e eliminar atributos com menor relevância para a tarefa de classificação, garantindo que apenas as variáveis mais significativas sejam utilizadas no treinamento dos modelos.

O coeficiente de correlação de Pearson mede a relação linear entre duas variáveis, atribuindo valores entre -1 e 1. Valores próximos de 1 ou -1 indicam uma correlação forte (positiva ou negativa, respectivamente), enquanto valores próximos de 0 sugerem uma fraca ou inexistente correlação. A Tabela 7 apresenta os coeficientes de correlação calculados para os atributos considerados no estudo, evidenciando quais variáveis apresentaram maior influência sobre a classificação dos tipos de aço.

Após a aplicação dessa técnica, foram selecionados **seis dos nove atributos iniciais**, resultando na exclusão das seguintes variáveis:

- **Tempo** (T) – Apresentava baixa correlação com a variável alvo, conforme indicado na Tabela 7, e não contribuía significativamente para a discriminação entre os tipos de aço.
- **Avanço por revolução** (a_f) – Apesar de ser um parâmetro operacional relevante na usinagem, mostrou-se pouco informativo para a classificação, como demonstrado pelos seus baixos coeficientes de correlação na Tabela 7.
- **Energia de corte** (E_c) – Sua relação com o consumo energético era fortemente influenciada por outras variáveis, tornando-a redundante para o modelo, conforme evidenciado na Tabela 7.

A remoção desses atributos **não comprometeu o desempenho dos classificadores**, conforme demonstrado nos experimentos descritos no **Capítulo 5**. Essa redução da dimensionalidade não apenas melhora a **eficiência computacional**, reduzindo o tempo de processamento dos modelos, mas também ajuda a mitigar o risco de **overfitting**², garantindo maior capacidade de generalização para novos dados.

Além disso, a eliminação de atributos pouco informativos contribui para a **interpretabilidade** dos modelos, tornando as análises mais diretas e facilitando a identificação dos fatores mais impactantes na classificação dos tipos de aço. Esse processo é essencial para garantir que os resultados obtidos sejam confiáveis e aplicáveis em ambientes industriais originais, onde a otimização dos parâmetros operacionais é fundamental para a eficiência energética e a redução de custos no processo de usinagem.

² Overfitting ocorre quando um modelo aprende padrões específicos do conjunto de treinamento, resultando em baixa capacidade de generalização para novos dados (GOODFELLOW; BENGIO; COURVILLE, 2016).

3.2.3.2 Sobreamostragem do Banco de Dados

O sucesso de um procedimento de estimativa por algoritmos depende amplamente de sua capacidade de **generalização** para o problema em questão. Para que essa generalização ocorra, é essencial que o banco de dados utilizado seja **representativo** das características e variabilidades do sistema estudado. Modelos treinados em conjuntos de dados pouco representativos tendem a apresentar dificuldades em lidar com novas instâncias, comprometendo sua aplicabilidade prática.

A obtenção de um conjunto de dados **extenso e diversificado** é ideal para capturar as propriedades intrínsecas dos diferentes tipos de materiais e condições experimentais. Entretanto, o banco de dados coletado para este estudo contém apenas **15 amostras** para cada um dos **cinco tipos de aço**, totalizando um conjunto relativamente pequeno de **75 amostras**. Essa limitação impõe desafios na modelagem, uma vez que a baixa quantidade de dados pode dificultar o treinamento adequado dos algoritmos e reduzir sua capacidade de identificar padrões complexos.

Diante desse cenário, foi necessário adotar **estratégias adicionais** para aumentar a robustez dos modelos e garantir análises mais confiáveis. Entre essas estratégias, destacam-se as **técnicas de ampliação de dados**, que têm como objetivo mitigar os efeitos do tamanho reduzido do conjunto de treinamento e melhorar a capacidade preditiva dos modelos de aprendizado de máquina. Uma das técnicas mais utilizadas para essa finalidade é o **SMOTE** (*Synthetic Minority Over-sampling Technique*), proposto por (CHAWLA et al., 2002).

3.2.3.2.1 Aplicação do SMOTE

O **SMOTE** atua gerando amostras sintéticas de maneira controlada, diferenciando-se das abordagens tradicionais que simplesmente duplicam as amostras minoritárias (CHAWLA et al., 2002). A geração das novas instâncias ocorre por meio de **interpolação** entre amostras próximas no espaço de características, criando pontos artificiais ao longo das conexões entre instâncias existentes. Esse método permite equilibrar a distribuição dos dados sem introduzir informações redundantes, resultando em um conjunto mais adequado para o treinamento dos modelos.

Para evitar **data leakage**³ e garantir uma avaliação justa dos modelos, a divisão dos dados em conjuntos de **treinamento e teste** foi realizada **antes** da aplicação do **SMOTE**. Dessa forma, o balanceamento afetou apenas o conjunto de treinamento, preservando a distribuição original do conjunto de teste. Caso o **SMOTE** fosse aplicado antes da separação dos dados, amostras sintéticas poderiam ser inadvertidamente incluídas no conjunto de teste, resultando em informações compartilhadas entre os conjuntos e inflacionando artificialmente o desempenho dos modelos (CHAWLA et al., 2002).

3.2.3.2.2 Impacto da Sobreamostragem

A aplicação do **SMOTE** demonstrou ser uma estratégia eficaz para aumentar a diversidade dos dados de treinamento e melhorar a robustez dos modelos preditivos. A Figura 3 ilustra o crescimento expressivo do conjunto de dados após a aplicação do **SMOTE**. Para facilitar a visualização, foram selecionados pares específicos de atributos, sem representar o conjunto completo de características.

Além de reduzir o risco de *overfitting*, a interpolação aplicada pelo **SMOTE** contribui para um **melhor aprendizado dos modelos**, ampliando o conjunto de dados de maneira controlada (CHAWLA et al., 2002).

³ *Data leakage* refere-se à contaminação do conjunto de teste por informações do conjunto de treinamento, o que pode levar a estimativas irrealistas de desempenho dos modelos (KAUFMAN et al., 2012).

Em contextos como o deste estudo, onde o número de amostras originais é limitado, essa abordagem não apenas expande o volume de dados, mas também aprimora a capacidade de **generalização** dos modelos de aprendizado de máquina, tornando-os mais adequados para aplicações práticas na indústria.

Tabela 6 – Quantidade de amostras antes e depois da aplicação do SMOTE

Classe de Aço	Amostras Originais	Amostras Geradas pelo SMOTE	Total de Amostras
SAE 1020	15	35	50
SAE 1045	15	35	50
SAE 4140	15	35	50
SAE 4340	15	35	50
VC	15	35	50
Total	75	175	300

Fonte: Elaborado pelo autor.

Com um crescimento significativo na aplicabilidade das análises computacionais, a técnica SMOTE tornou-se uma alternativa para mitigar problemas relacionados ao desequilíbrio de dados e à baixa quantidade de dados em diversos campos, incluindo: sistemas financeiros (SUN et al., 2020; SMITI; SOUI, 2020; WU; MENG, 2016), biomedicina (LI et al., 2017; LIU et al., 2017; POTHARAJU; SREEDEVI, 2016; ISHAQ et al., 2021; KUMARI; SINGH; GOSAIN, 2023), computação natural (ZHANG et al., 2015; CHENG et al., 2021) e engenharia (RAMENTOL et al., 2016; GONG; GU, 2016; LEE; JO; HWANG, 2017; ZHENG et al., 2020; LI et al., 2020; HOU et al., 2019; ALSAWALQAH et al., 2017; DUARTE et al., 2021; ÖZDEMİR; POLAT; ALHUDHAIF, 2021).

Inicialmente, para a criação de amostras artificiais, foi necessário considerar os dois objetivos principais do problema: **classificar os tipos de aço e aproximar a função de consumo de energia elétrica** em relação à **velocidade de rotação por minuto** (RPM). O desafio consistia em gerar um único conjunto de dados artificiais que fosse adequado para ambas as tarefas.

Como discutido anteriormente na Seção 3.2.3.1, os aços foram submetidos a processos de usinagem utilizando **três diferentes taxas de avanço** e **velocidades de rotação variáveis**. A partir desses parâmetros experimentais, **15 pontos de dados artificiais** foram gerados para cada taxa de avanço. Isso significa que, para cada conjunto de 5 amostras originais de um determinado tipo de aço e taxa de avanço, foi criada uma quantidade três vezes maior de novas instâncias sintéticas. Como resultado, **45 novas amostras** foram adicionadas para cada classe de aço, totalizando **300 amostras artificiais** no conjunto final.

3.2.3.2.3 Justificativa para a Escolha do SMOTE

A escolha do **SMOTE** (*Synthetic Minority Over-sampling Technique*) em detrimento de outras abordagens, como ADASYN⁴ e GANs⁵, deve-se à sua capacidade de **gerar amostras sintéticas equilibradas** sem introduzir ruído excessivo (CHAWLA et al., 2002).

⁴ ADASYN (*Adaptive Synthetic Sampling*) prioriza a geração de amostras sintéticas em regiões de baixa densidade da classe minoritária, o que pode aumentar a complexidade do modelo (HE et al., 2008).

⁵ GANs (*Generative Adversarial Networks*) são redes neurais projetadas para gerar dados sintéticos altamente realistas, mas exigem grandes volumes de dados e considerável poder computacional (GOODFELLOW et al., 2014).

Diferentemente do ADASYN, que foca na geração de dados em áreas de baixa densidade da classe minoritária e pode aumentar a variabilidade dentro da classe, o **SMOTE** proporciona um **balanceamento mais controlado**, preservando melhor a estrutura original dos dados.

As GANs também foram consideradas, mas, devido ao tamanho reduzido da base de dados original e à alta complexidade computacional exigida para seu treinamento, essa abordagem mostrou-se inviável para este estudo.

Assim, a aplicação do SMOTE garantiu uma **expansão eficiente e estruturada do conjunto de dados**, permitindo a melhor adaptação dos modelos de aprendizado de máquina às tarefas de classificação e regressão. Essa abordagem assegurou a disponibilidade de um volume adequado de dados para o treinamento dos modelos, **preservando a coerência estatística do conjunto original** e aumentando a confiabilidade das previsões geradas.

As GANs, apesar de serem poderosas na geração de dados sintéticos (GOODFELLOW et al., 2014), exigem um grande volume de dados para treinamento e maior capacidade computacional, tornando sua implementação inviável neste estudo. Assim, o SMOTE foi escolhido por seu equilíbrio entre eficácia e simplicidade, permitindo um melhor aproveitamento dos dados originais e aumentando a capacidade de generalização dos modelos (FERNANDEZ et al., 2018).

3.2.3.3 Impacto do Desbalanceamento dos Dados nas Métricas de Desempenho

O **desbalanceamento dos dados** pode afetar significativamente o desempenho dos modelos de aprendizado de máquina, pois algoritmos supervisionados tendem a favorecer as **classes majoritárias**, reduzindo a capacidade de predição das classes menos representadas. Esse problema ocorre porque os modelos estatisticamente aprendem a minimizar o erro geral, o que pode levar a classificações enviesadas em favor das classes mais frequentes, ignorando os padrões presentes nas classes minoritárias.

Para avaliar esse impacto, foram analisadas as métricas de desempenho antes e depois da aplicação do **SMOTE**, considerando os seguintes aspectos:

- **Comparação das Métricas de Desempenho:** Foi realizada uma análise comparativa entre os modelos treinados com e sem a aplicação do SMOTE, considerando a variação nos valores de **acurácia**, **precisão**, **recall** e **F1-score** para cada classe.
- **Análise da Matriz de Confusão:** As matrizes de confusão foram inspecionadas para verificar **as taxas de erro em cada classe**, especialmente nas menos representadas. Antes do balanceamento, as classes minoritárias apresentavam um número elevado de falsos negativos, indicando que os modelos não conseguiam diferenciá-las adequadamente.
- **Uso de Métricas Apropriadas:** Além da **acurácia**, que pode ser enganosa em cenários de desbalanceamento, foram analisadas métricas mais robustas, como **F1-score** e **AUC-ROC**. O **F1-score** equilibra precisão e recall, sendo uma métrica mais representativa para avaliar modelos com classes desbalanceadas, enquanto a **AUC-ROC** quantifica a capacidade de separação do classificador entre as diferentes classes.

Os resultados indicaram que, antes da aplicação do SMOTE, os modelos apresentavam um **desempenho reduzido para as classes minoritárias**, evidenciado pelas baixas taxas de **recall** e **F1-score** nessas classes. Isso significa que muitas instâncias pertencentes às classes menos representadas foram erroneamente classificadas como pertencentes às classes majoritárias. Após a aplicação do balanceamento, houve uma




Figura 3 – Comparativo de alguns pares de atributos entre seus dados originais (Figura (3a) e (3c)) e com a adição dos dados artificiais (Figura (3b) e (3d)).

Fonte: Elaborado pelo autor.

melhora significativa nessas métricas, especialmente na taxa de *recall*, demonstrando que o desbalanceamento inicial impactava negativamente a capacidade do modelo de classificar corretamente todos os tipos de aço.

Além disso, a Tabela 7 evidencia que algumas variáveis possuíam forte correlação com o tipo de aço, reforçando a importância de técnicas de balanceamento para evitar viés no aprendizado do modelo. O balanceamento dos dados resultou em classificações mais equitativas entre as classes e permitiu que o modelo aprendesse a diferenciar melhor as propriedades dos diferentes tipos de aço, garantindo maior confiabilidade nas previsões geradas.

3.2.3.4 Normalização dos Dados

A normalização dos dados é um procedimento fundamental para garantir que todas as variáveis possuam a mesma escala, evitando que atributos com magnitudes elevadas influenciem desproporcionalmente o desempenho dos modelos de aprendizado de máquina. Sem essa etapa, variáveis com valores numéricos maiores podem dominar o processo de otimização, prejudicando a capacidade dos algoritmos de capturar corretamente os padrões nos dados.

Para este estudo, foi aplicada a técnica de escalonamento **Min-Max**, que ajusta os valores de cada variável para um intervalo entre 0 e 1, conforme a seguinte equação:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.7)$$

onde:

- X' representa o valor normalizado da variável;
- X é o valor original da variável;
- X_{min} e X_{max} correspondem, respectivamente, aos valores mínimo e máximo observados para essa variável no conjunto de dados.

Essa transformação foi essencial para otimizar modelos sensíveis à escala, como **SVMs** e **KNNs**, que dependem de medidas de distância para tomada de decisão. A uniformização das escalas evita distorções no aprendizado, garantindo uma classificação mais precisa.

Além de uniformizar a escala das variáveis, a normalização minimiza vieses no aprendizado, evitando que atributos de maior magnitude dominem o modelo. Também melhora a estabilidade numérica e acelera a convergência dos algoritmos, especialmente em métodos baseados em gradiente, como **redes neurais artificiais (MLPs)**, contribuindo para maior eficiência e precisão dos modelos de aprendizado de máquina neste estudo.

Para evitar *data leakage*, a normalização foi realizada separadamente para os conjuntos de treinamento e teste. Os parâmetros estatísticos (**média, desvio padrão, valores mínimo e máximo**) foram calculados exclusivamente no conjunto de treinamento e aplicados ao conjunto de teste, garantindo que nenhuma informação do teste influenciasse o modelo durante o treinamento. Esse procedimento assegura uma avaliação realista dos modelos, prevenindo estimativas inflacionadas de desempenho (GOODFELLOW; BENGIO; COURVILLE, 2016; GÉRON, 2019).

4 Classificação de Padrões e Regressão

Neste estudo, foram selecionadas técnicas avançadas de aprendizado de máquina para aproximação de funções e classificação de padrões, visando otimizar a análise dos processos de usinagem. Este capítulo apresenta os principais algoritmos utilizados, destacando suas aplicações na classificação dos tipos de aço e na predição do consumo energético. Além disso, são discutidos os fundamentos teóricos de cada modelo e os critérios que justificam sua escolha, considerando sua precisão, robustez e aplicabilidade no contexto industrial.

4.1 Visão Geral Simplificada

Nesta seção, apresentamos os principais algoritmos de **Inteligência Artificial (IA)** empregados para solucionar dois desafios específicos deste estudo: a **classificação** dos tipos de aço e a **regressão** para a previsão do consumo de energia durante o processo de torneamento. Esses modelos de aprendizado de máquina analisam os padrões contidos nos dados, ajustam-se a eles e realizam previsões com base nas informações aprendidas. De acordo com Goodfellow et al. (GOODFELLOW; BENGIO; COURVILLE, 2016), a escolha adequada do modelo impacta diretamente a capacidade de generalização e a eficiência na modelagem de sistemas industriais complexos.

- **Máquinas de Vetores de Suporte (SVM) e Máquinas de Vetores de Suporte por Mínimos Quadrados (LSSVM):** os algoritmos SVM, propostos por Vapnik (VAPNIK, 1995), são amplamente utilizados para tarefas de classificação devido à sua capacidade de encontrar *hiperplanos* no espaço de características que maximizam a separação entre diferentes classes de materiais. Essa técnica apresenta alta precisão em problemas com dados de alta dimensionalidade. Já a LSSVM, conforme demonstrado por Suykens e Vandewalle (SUYKENS; VANDEWALLE, 2000), é uma variante computacionalmente mais eficiente, permitindo resolver problemas de classificação e regressão com menor custo computacional sem perda significativa de desempenho.
- **Perceptron de Múltiplas Camadas (MLP) e Máquina de Aprendizagem Extrema (ELM):** as redes neurais artificiais são inspiradas no funcionamento do cérebro humano, permitindo a modelagem de padrões não lineares complexos (LECUN; BENGIO; HINTON, 2015). O MLP, popularizado por Rumelhart et al. (RUMELHART; HINTON; WILLIAMS, 1986), emprega múltiplas camadas ocultas e aprendizado supervisionado por meio do algoritmo de retropropagação do erro (*backpropagation*)⁶. Por outro lado, a ELM, introduzida por Huang et al. (HUANG; ZHU; SIEW, 2006), destaca-se por sua alta velocidade de treinamento, eliminando a necessidade de ajuste iterativo dos pesos internos, o que torna o modelo altamente eficiente para aplicações em tempo real.
- **k-Nearest Neighbors (kNN):** um dos modelos mais simples e intuitivos de aprendizado supervisionado, proposto inicialmente por Fix e Hodges (FIX, 1985). O kNN classifica um novo dado atribuindo-lhe a classe majoritária entre seus k vizinhos mais próximos. Devido à sua simplicidade e eficácia, é amplamente utilizado em problemas de classificação quando há

⁶ O algoritmo de *backpropagation*, proposto por Rumelhart et al. (RUMELHART; HINTON; WILLIAMS, 1986), calcula os gradientes do erro em relação aos pesos da rede por meio da regra da cadeia, permitindo um ajuste eficiente dos parâmetros durante o treinamento.

separabilidade bem definida entre as classes, como demonstrado por Cover e Hart (COVER; HART, 1967).

- **Mínimos Quadrados Ordinários (OLS):** um método estatístico clássico para regressão linear, inicialmente formalizado por Gauss e Legendre no século XIX (LEGENDRE, 1805). O **OLS** busca minimizar os erros quadráticos entre valores observados e previstos, sendo adequado para modelar fenômenos que apresentam uma relação aproximadamente linear entre entrada e saída, conforme evidenciado por Draper e Smith (DRAPER; SMITH, 1998).
- **Naive Bayes:** um classificador probabilístico baseado no *Teorema de Bayes*, formulado por Thomas Bayes no século XVIII (BAYES, 1763). Apesar da suposição de independência condicional entre os atributos, o modelo apresenta desempenho competitivo em diversas aplicações de classificação, especialmente em grandes volumes de dados textuais, conforme demonstrado por Domingos e Pazzani (DOMINGOS; PAZZANI, 1997).

Nas seções seguintes, cada um desses algoritmos será discutido em maior profundidade, detalhando-se seus fundamentos teóricos, configurações utilizadas e desempenho na resolução dos problemas propostos. A inclusão dessas técnicas foi baseada em sua relevância para tarefas de classificação e regressão em contextos industriais, conforme relatado por Bishop (BISHOP, 2006) e Hastie et al. (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

4.2 Máquina de Vetores de Suporte e Máquina de Vetores de Suporte de Mínimos Quadrados

A Máquina de Vetores de Suporte (SVM) é um algoritmo robusto de aprendizado de máquina, fundamentado na teoria do aprendizado estatístico (VAPNIK, 2013). Originalmente, foi concebido como uma generalização não linear do algoritmo *Generalized Portrait*. Posteriormente, Smola e Vapnik (1997) expandiram essa abordagem para problemas de regressão (SMOLA; SCHÖLKOPF, 1998), originando o que hoje é conhecido como Regressão por Vetores de Suporte (*Support Vector Regression* – SVR).

O modelo SVM resolve um problema de otimização quadrática restrita, minimizando uma função que equilibra o risco empírico (comum em redes neurais convencionais, por exemplo) e um termo de regularização, responsável pela suavização da solução do modelo. Essa otimização é formulada como um problema de programação quadrática convexa (QP) no espaço dual, resultando em um modelo global e esparsos.

A Máquina de Vetores de Suporte de Mínimos Quadrados (LSSVM), proposta por Suykens e Vandewalle (SUYKENS; VANDEWALLE, 1999), representa uma adaptação da SVM de Vapnik (ver Seção 4.2), com o objetivo de simplificar sua formulação sem comprometer suas principais vantagens. Além disso, trata-se de um modelo amplamente utilizado para problemas de regressão.

A LSSVM distingue-se da SVM em dois aspectos principais. Primeiro, emprega uma abordagem de otimização baseada em mínimos quadrados para determinar o hiperplano ótimo, utilizando a função de Soma dos Erros Quadrados (SSE). Segundo, sua formulação é simplificada ao transformar as restrições de desigualdade em restrições de igualdade, permitindo que o problema de otimização seja resolvido por meio de um sistema linear de Karush-Kuhn-Tucker (KKT) (FLETCHER, 2013).

Neste estudo, tanto a SVM quanto a LSSVM foram aplicadas a problemas de classificação e regressão. No contexto de regressão, essas abordagens são referidas, respectivamente, como Regressão por Vetores de Suporte (*Support Vector Regression* – SVR) e Regressão por Vetores de Suporte de Mínimos Quadrados (*Least Squares Support Vector Regression* – LSSVR).

4.3 Regressão por Vetores de Suporte e Regressores de Mínimos Quadrados

A Regressão por Vetores de Suporte (*Support Vector Regression* – SVR) e a Regressão por Vetores de Suporte de Mínimos Quadrados (*Least Squares Support Vector Regression* – LSSVR) são duas abordagens derivadas da Máquina de Vetores de Suporte (SVM) voltadas para problemas de regressão. Ambas compartilham o mesmo princípio fundamental de encontrar um hiperplano ótimo que melhor represente a relação entre as variáveis preditoras e a variável alvo, mas diferem na forma como a otimização é realizada.

A SVR se destaca pela introdução da função de perda ϵ -insensível, que estabelece uma margem dentro da qual os erros não são penalizados, tornando o modelo mais robusto contra outliers e ruídos nos dados (DRUCKER et al., 1997). Além disso, a solução da SVR é esparsa, pois apenas um subconjunto dos dados de treinamento, denominado vetores de suporte, influencia a construção do modelo (VAPNIK, 1998). Essa característica reduz o risco de sobreajuste e melhora a interpretabilidade da solução. Outra vantagem importante da SVR é a possibilidade de utilizar diferentes funções núcleo (*kernel functions*), permitindo modelar relações não lineares com grande flexibilidade (SMOLA; SCHÖLKOPF, 2004).

Por outro lado, a LSSVR modifica a formulação original ao substituir a minimização de um problema de otimização quadrática com restrições de desigualdade por um sistema de equações lineares, o que reduz significativamente a complexidade computacional. Essa abordagem permite que a LSSVR seja mais eficiente em termos de tempo de treinamento, tornando-se uma escolha atrativa para problemas que envolvem grandes volumes de dados (SUYKENS; VANDEWALLE, 1999). No entanto, a ausência da função de perda ϵ -insensível pode torná-la mais sensível a valores discrepantes, exigindo técnicas adicionais para lidar com outliers (FERNÁNDEZ et al., 2014).

Ambas as técnicas são amplamente utilizadas em aplicações como previsão de séries temporais (TAY; CAO, 2001), modelagem de sistemas dinâmicos (CAO; TAY, 2003) e classificação de padrões complexos (JOACHIMS, 1998). A escolha entre SVR e LSSVR depende de um compromisso entre precisão, interpretabilidade e eficiência computacional. A SVR é preferida quando a robustez contra outliers e a estabilidade da solução são cruciais, enquanto a LSSVR se destaca em cenários que exigem rápida convergência e menor custo computacional. Dessa forma, a seleção entre essas abordagens deve considerar as características dos dados e as necessidades específicas da aplicação.

4.4 Perceptron Multicamadas

O Perceptron Multicamadas (*Multilayer Perceptron* – MLP) é uma rede neural amplamente utilizada para a resolução de problemas não lineares, comuns em tarefas de classificação de padrões e aproximação de funções. Sua arquitetura é composta por múltiplas camadas de neurônios, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (PRINCIPE; EULIANO; LEFEBVRE, 2000).

A camada de entrada recebe os dados de entrada, que são transmitidos aos neurônios da primeira camada oculta por meio de conexões ponderadas. Os neurônios das camadas ocultas aplicam funções de ativação, podendo ser lineares ou não lineares, para processar as informações. A saída de cada neurônio é propagada para a camada subsequente, onde os pesos sinápticos são ajustados de acordo com um critério de aprendizado. Por fim, a camada de saída gera a resposta final do modelo, cuja natureza depende do problema abordado.

Neste estudo, a rede neural MLP foi empregada em tarefas de classificação de padrões e aproximação de funções. Foram exploradas arquiteturas com uma e duas camadas ocultas, treinadas utilizando o algoritmo de

retropropagação do erro (*backpropagation*), um método baseado na regra de descida de gradiente proposta por Widrow e Hoff (WIDROW; HOFF, 1960). Essa abordagem permite a atualização iterativa dos pesos da rede, minimizando o erro da previsão e melhorando sua capacidade de generalização.

4.5 Extreme Learning Machine

A Máquina de Aprendizado Extremo (*Extreme Learning Machine* – ELM) foi proposta por Huang et al. (HUANG; ZHU; SIEW, 2004) como uma alternativa eficiente às redes neurais tradicionais. A ELM é uma rede neural de camada única, destacando-se por sua alta velocidade de processamento e ampla aplicabilidade na resolução de diversos problemas.

Diferentemente do Perceptron Multicamadas (*Multilayer Perceptron* – MLP), a ELM possui apenas uma camada oculta e adota um método distinto para a atualização dos pesos sinápticos. Enquanto nas redes tradicionais os pesos são ajustados iterativamente por meio de algoritmos baseados em gradiente, como a retropropagação do erro, na ELM os pesos das conexões entre a camada de entrada e a camada oculta são inicializados aleatoriamente e mantidos fixos durante o treinamento.

O ajuste dos pesos da camada de saída é realizado por meio da técnica de mínimos quadrados em lote (*batch least squares*), onde todos os dados de treinamento são apresentados simultaneamente para a atualização dos pesos (HUANG; ZHU; SIEW, 2006). Essa abordagem elimina a necessidade de iterações sucessivas e reduz significativamente o tempo de treinamento, tornando a ELM uma técnica eficaz e eficiente para diversas aplicações em aprendizado de máquina.

As características únicas da ELM, como sua capacidade de aprendizado rápido e a ausência de ajuste iterativo dos pesos internos, tornam-na uma alternativa promissora para problemas de regressão e classificação, especialmente em cenários que demandam alto desempenho computacional.

4.6 k-Vizinhos Mais Próximos

O algoritmo *k*-Vizinhos Mais Próximos (*k-Nearest Neighbors* – kNN), proposto por Cover e Hart em 1967 (COVER; HART, 1967), é um dos métodos mais fundamentais de aprendizado de máquina, amplamente utilizado em tarefas de classificação e regressão. Sua lógica baseia-se na premissa de que uma amostra será classificada de acordo com a classe majoritária entre seus *k* vizinhos mais próximos, determinados por uma métrica de distância.

A definição da proximidade entre as amostras pode ser realizada por diferentes métricas de distância, sendo as mais comuns: Manhattan, Euclidiana e Minkowski (DUDA; HART; STORK, 2001). A escolha da métrica e do valor de *k* impacta diretamente o desempenho do modelo, influenciando sua robustez contra ruídos e sua eficiência computacional. Valores pequenos de *k* podem tornar o modelo sensível a outliers, enquanto valores muito grandes podem resultar em uma classificação excessivamente suavizada, reduzindo sua capacidade de generalização (GARCÍA; MOLLINEDA; SÁNCHEZ, 2008).

Embora o kNN seja amplamente utilizado devido à sua facilidade de implementação e à ausência de pressuposições rígidas sobre a distribuição dos dados, sua principal limitação está no custo computacional durante a fase de inferência, especialmente em grandes conjuntos de dados. Como um método baseado em instâncias, o kNN exige a comparação de cada nova amostra com todas as amostras de treinamento, o que pode levar a uma desaceleração computacional significativa (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).

Para mitigar esse problema, diversas técnicas de otimização foram desenvolvidas, incluindo o uso de estruturas de indexação espacial, como árvores KD (*k-Dimensional Trees*) e algoritmos de busca aproximada em grandes bases de dados (MUJA; LOWE, 2014). Essas abordagens tornam o kNN uma ferramenta mais eficiente, permitindo sua aplicação prática em diversas áreas, como reconhecimento de padrões, recuperação de imagens e diagnóstico médico (WEINBERGER; BLITZER; SAUL, 2009). Sua lógica intuitiva e interpretabilidade fazem dele uma escolha atrativa, especialmente em análises exploratórias e problemas onde a simplicidade e transparência do modelo são desejáveis.

4.7 Mínimos Quadrados Ordinários

O método dos Mínimos Quadrados Ordinários (*Ordinary Least Squares – OLS*), introduzido por Legendre em 1805 (LEGENDRE, 1805), é um marco na análise estatística e no aprendizado de máquina aplicado a modelos de regressão linear. O OLS estima os parâmetros do modelo ao minimizar a soma dos quadrados dos erros entre os valores observados e as previsões do modelo, garantindo estimadores não viesados e de variância mínima sob os pressupostos de linearidade, homocedasticidade e ausência de autocorrelação (FILHO, 2014; CASTANHEIRA, 2013). Sua ampla utilização deve-se à simplicidade, interpretabilidade e fundamentação matemática rigorosa.

A aplicação do OLS é mais adequada em contextos onde os dados atendem aos pressupostos de linearidade, ausência de multicolinearidade, homocedasticidade e inexistência de autocorrelação nos resíduos. A simplicidade e a interpretabilidade do OLS contribuem para sua ampla utilização em diversas áreas de pesquisa e aplicações práticas (GREENE, 2018).

- **Linearidade:** Pressupõe-se que a relação entre as variáveis independentes e a dependente seja linear (GREENE, 2018).
- **Ausência de multicolinearidade:** As variáveis independentes não devem apresentar correlações elevadas entre si, evitando redundâncias que possam comprometer a estimação dos coeficientes (WOOLDRIDGE, 2020).
- **Homocedasticidade:** Os resíduos do modelo devem possuir variância constante ao longo de todas as observações (FILHO, 2014).
- **Ausência de autocorrelação:** Os resíduos não devem estar correlacionados entre si, garantindo a independência das observações (STOCK; WATSON, 2003).

A violação desses pressupostos pode levar a estimativas viesadas ou ineficientes, comprometendo a validade das inferências estatísticas. Portanto, é essencial verificar a conformidade dos dados com esses critérios ao aplicar o OLS em análises estatísticas.

Empregado em diversas áreas, da economia às ciências sociais, o OLS é amplamente reconhecido e incorporado em softwares estatísticos. Sua importância na análise quantitativa o estabelece como um método fundamental e um ponto de partida para explorar relações entre variáveis.

4.8 Naive Bayes

O algoritmo *Naive Bayes*, fundamentado no Teorema de Bayes (DALE, 2005; BAYES, 1763), é uma abordagem probabilística amplamente utilizada em aprendizado de máquina, destacando-se por sua eficiência na previsão de eventos com base em dados prévios. Sua principal premissa é a suposição de independência

condicional entre os atributos, o que simplifica significativamente o cálculo das probabilidades condicionais, embora essa hipótese nem sempre seja válida na prática (ZHANG, 2004; CORTES; VAPNIK, 1995).

Durante a classificação de novos dados, o *Naive Bayes* estima a probabilidade de cada classe com base nas frequências observadas nos dados de treinamento e atribui a classe mais provável à nova observação (ARRIAZA et al., 2017). Essa abordagem o torna particularmente eficaz em cenários de alta dimensionalidade, sendo amplamente empregado em tarefas como filtragem de spam, diagnósticos médicos e análise de sentimentos (MITCHELL, 1997).

A simplicidade da implementação e a capacidade de realizar previsões rápidas fazem do *Naive Bayes* uma ferramenta valiosa para cientistas de dados. No entanto, seu desempenho está diretamente relacionado à qualidade dos dados de treinamento e à adequação da suposição de independência, que pode impactar a precisão do modelo quando há fortes correlações entre os atributos (ZHANG, 2004). Ainda assim, devido à sua eficiência computacional e fundamentação teórica robusta, o *Naive Bayes* permanece uma escolha popular para aplicações em larga escala e contextos com grandes volumes de dados (BISHOP, 2006).

4.9 Validação e Métricas

A validação dos resultados das simulações computacionais foi realizada por meio de um conjunto de métricas que avaliam o desempenho dos modelos de maneira detalhada e abrangente. Essas métricas foram selecionadas para oferecer uma análise precisa e segmentada da eficácia do modelo em relação aos dados analisados, permitindo a identificação de seus pontos fortes e limitações. Para cada métrica, foram calculados a média e o desvio padrão, apresentados tanto graficamente, por meio de boxplots, quanto numericamente, facilitando uma análise comparativa e de fácil interpretação.

As principais métricas de validação utilizadas incluem a Precisão (*Accuracy* – Acc), o Valor Preditivo Positivo (*Positive Predictive Value* – PPV), a Sensibilidade (*Sensitivity* – Se) e o *F-Score* (BISHOP, 2006). Cada uma dessas métricas oferece uma perspectiva distinta e complementar sobre a eficácia do modelo, possibilitando uma avaliação mais robusta e confiável do seu desempenho.

Além de fornecerem uma visão global da precisão e eficácia do modelo, essas métricas permitem a identificação e quantificação de aspectos específicos do desempenho, como a capacidade de predição de classes e a minimização de erros. Dessa forma, tornam-se fundamentais em aplicações práticas, onde a análise detalhada e criteriosa do modelo é essencial para garantir resultados confiáveis e aplicáveis (HE; GARCIA, 2009).

4.9.1 Precisão (Acc)

A Precisão (*Accuracy* – Acc), também conhecida como taxa de classificação (*Classification Rate* – CR), é uma métrica fundamental que representa a proporção de acertos do modelo em relação ao total de previsões realizadas (BISHOP, 2006; HASTIE; TIBSHIRANI; FRIEDMAN, 2009; KUHN; JOHNSON, 2013). Essa métrica fornece uma visão geral do desempenho do modelo, evidenciando sua capacidade de classificar corretamente as observações. No entanto, em cenários com desbalanceamento de classes, a precisão pode não refletir com fidelidade a real eficácia do modelo, uma vez que tende a favorecer a classe majoritária, resultando em uma avaliação potencialmente enviesada (SAITO; REHMSMEIER, 2015; SUN; WONG; KAMEL, 2009).

Dada essa limitação, o uso de métricas complementares torna-se essencial para uma avaliação mais abrangente e detalhada do modelo. Métodos como a curva Precisão-*Recall* e o *F-Score* são indicados para capturar nuances do desempenho em dados desbalanceados, permitindo uma análise equilibrada entre a

precisão das predições positivas e a capacidade do modelo de identificar corretamente os elementos da classe minoritária (BISHOP, 2006; FERNANDEZ et al., 2018). A Eq. 4.1 apresenta a formulação matemática da Precisão (Acc), ou taxa de classificação (CR), utilizada para uma avaliação inicial do desempenho do modelo:

$$Acc = CR = \frac{TP + TN}{TP + TN + FP + FN}, \quad (4.1)$$

- *TP (True Positives)*: número de casos em que a classe positiva foi corretamente identificada;
- *TN (True Negatives)*: número de casos em que a classe negativa foi corretamente identificada;
- *FP (False Positives)*: número de casos em que a classe negativa foi incorretamente classificada como positiva;
- *FN (False Negatives)*: número de casos em que a classe positiva foi incorretamente classificada como negativa.

Embora a Precisão (Acc) seja útil para avaliar o desempenho global do modelo em uma base de dados completa, sua confiabilidade diminui em cenários com desbalanceamento de classes, pois ela pode ser fortemente influenciada pela classe majoritária. Para mitigar essa limitação, métricas complementares são recomendadas para capturar diferentes aspectos do desempenho do modelo. O Valor Preditivo Positivo (PPV), a Sensibilidade (Se) e o *F-Score* oferecem uma avaliação mais robusta, fornecendo insights sobre a confiabilidade das previsões positivas e a capacidade do modelo de identificar corretamente as instâncias da classe minoritária (DAVIS; GOADRIC, 2006). Conforme discutido por Chawla (CHAWLA, 2004), o uso de métricas como PPV e *F-Score* é essencial para refletir com maior precisão a eficácia do modelo em cenários onde os dados são desbalanceados, garantindo que a análise do desempenho não seja enviesada pela predominância de uma única classe.

Além disso, a relação entre Precisão e Sensibilidade, combinada ao *F-Score*, proporciona uma medida equilibrada da taxa de acertos positivos e da cobertura dos casos positivos reais. Esse aspecto é particularmente relevante em domínios críticos, como detecção de fraudes e diagnóstico de doenças, onde tanto falsos positivos quanto falsos negativos podem ter implicações significativas (SAITO; REHMSMEIER, 2015; HE; GARCIA, 2009). Dessa forma, a inclusão de métricas complementares ao Acc aprimora a avaliação de desempenho do modelo, oferecendo uma análise mais representativa e precisa de sua capacidade preditiva em cenários complexos e desbalanceados.

4.9.2 Valor Preditivo Positivo (PPV)

O Valor Preditivo Positivo (PPV) é uma métrica utilizada para avaliar a confiabilidade das previsões positivas, medindo a proporção de observações classificadas como positivas que realmente pertencem à classe positiva (POWERS, 2011; DAVIS; GOADRIC, 2006). Em cenários onde os falsos positivos podem ter impactos significativos, como na detecção de fraudes e em diagnósticos médicos, o PPV torna-se fundamental para garantir a precisão das previsões e minimizar possíveis erros (HE; GARCIA, 2009).

Matematicamente, o PPV é definido pela Eq. 4.2:

$$PPV = \frac{TP}{TP + FP}, \quad (4.2)$$

onde:

- *TP (True Positives)*: número de casos em que a classe positiva foi corretamente identificada;

- *FP (False Positives)*: número de casos em que a classe negativa foi incorretamente classificada como positiva.

O PPV é especialmente relevante em aplicações onde a confiabilidade das previsões positivas é essencial. Em cenários como a detecção de fraudes financeiras, um alto número de falsos positivos pode gerar custos elevados e sobrecarregar sistemas de verificação manual. Da mesma forma, em diagnósticos médicos, um falso positivo pode levar a exames adicionais desnecessários, aumentando a ansiedade do paciente e os custos do sistema de saúde. Assim, o uso do PPV permite uma avaliação criteriosa da precisão do modelo, garantindo que suas predições sejam confiáveis e aplicáveis a contextos críticos.

4.9.3 Sensibilidade (Se)

A Sensibilidade (*Sensitivity* – Se), também conhecida como *Recall*, mede a proporção de verdadeiros positivos entre as observações que pertencem à classe positiva. Essa métrica é especialmente relevante em cenários onde minimizar falsos negativos é crítico, como em sistemas de segurança e diagnósticos médicos, pois garante a identificação da maioria dos casos positivos, reduzindo a chance de falhas graves na detecção (CHAWLA, 2004).

Matematicamente, a Sensibilidade (Se) é definida pela Eq. 4.3:

$$Se = \frac{TP}{TP + FN}, \quad (4.3)$$

onde:

- *TP (True Positives)*: número de casos em que a classe positiva foi corretamente identificada;
- *FN (False Negatives)*: número de casos em que a classe positiva foi incorretamente classificada como negativa.

Em aplicações onde a detecção de todos os casos positivos é essencial, como na área médica, uma alta Sensibilidade (Se) assegura que a maioria dos casos positivos seja detectada, mesmo ao custo de um aumento nos falsos positivos (HE; GARCIA, 2009). Essa abordagem é preferível em contextos críticos, pois a detecção de condições graves se sobrepõe ao impacto de alarmes falsos (CHAWLA, 2004).

A Sensibilidade é, portanto, uma métrica fundamental para aplicações em que a omissão de um caso positivo pode acarretar consequências severas. Ao priorizar uma alta Sensibilidade, sistemas de detecção aumentam sua confiabilidade em domínios sensíveis, como segurança e saúde pública, onde falhas na identificação de casos positivos poderiam comprometer a eficácia do modelo (SAITO; REHMSMEIER, 2015).

4.9.4 F-Score

O *F-Score* representa a média harmônica entre o Valor Preditivo Positivo (PPV) e a Sensibilidade (Se), sendo especialmente útil em cenários de dados desbalanceados. Essa métrica equilibra a precisão das previsões positivas e a capacidade do modelo de identificar corretamente os elementos pertencentes à classe positiva, proporcionando uma avaliação mais robusta e confiável do desempenho do modelo em contextos complexos (POWERS, 2011).

A formulação do *F-Score* é apresentada na Eq. 4.4:

$$F\text{-Score} = 2 \times \frac{PPV \times Se}{PPV + Se}, \quad (4.4)$$

onde:

- *PPV (Positive Predictive Value)*: Valor Preditivo Positivo, que mede a proporção de previsões positivas corretas;
- *Se (Sensitivity)*: Sensibilidade, que mede a proporção de elementos da classe positiva corretamente identificados.

O *F-Score* pondera igualmente o PPV e a Sensibilidade, tornando-se uma métrica fundamental para avaliar o desempenho de modelos em situações onde é necessário equilibrar a precisão das predições com a taxa de detecção de verdadeiros positivos. Sua aplicação é amplamente utilizada em reconhecimento de padrões, aprendizado de máquina e problemas de classificação binária, especialmente quando a distribuição das classes é desbalanceada.

4.9.5 Matriz de Confusão

Para avaliar a performance dos modelos de aprendizado de máquina aplicados, utilizou-se a matriz de confusão, uma ferramenta fundamental na avaliação de classificadores. Essa matriz é uma tabela que permite a visualização do desempenho de um algoritmo de classificação, apresentando o número de classificações corretas e incorretas, e facilitando o cálculo de métricas como acurácia, precisão, *recall* e *F-Score* (DATACAMP, 2025; IBM, 2025).

A matriz de confusão é estruturada em quatro categorias:

- **Verdadeiro Positivo (TP)**: Quando o modelo classifica corretamente uma instância positiva.
- **Falso Positivo (FP)**: Quando o modelo classifica incorretamente uma instância negativa como positiva.
- **Verdadeiro Negativo (TN)**: Quando o modelo classifica corretamente uma instância negativa.
- **Falso Negativo (FN)**: Quando o modelo classifica incorretamente uma instância positiva como negativa.

A partir dessa matriz, é possível derivar várias métricas de desempenho, tais como:

- **Acurácia (Accuracy)**: Proporção de classificações corretas sobre o total de casos avaliados.
- **Precisão (Precision)**: Proporção de positivos corretamente identificados entre os preditos positivos.
- **Recall (Sensibilidade)**: Proporção de positivos corretamente identificados entre os reais positivos.
- **F-Score**: Média harmônica entre precisão e *recall*, oferecendo uma medida balanceada entre essas duas métricas (DATACAMP, 2025; IBM, 2025).

A utilização da matriz de confusão e das métricas derivadas é essencial para uma avaliação detalhada e precisa do desempenho de modelos de classificação, especialmente em cenários com classes desbalanceadas ou quando certos tipos de erros possuem custos diferenciados (DATACAMP, 2025; IBM, 2025).

4.9.6 Erro Quadrático Médio (RMSE)

No contexto de problemas de regressão, o Erro Quadrático Médio (*Root Mean Squared Error* – RMSE) é uma métrica amplamente utilizada para avaliar a precisão das previsões de um modelo. O RMSE é definido como a raiz quadrada da média dos quadrados das diferenças entre os valores observados e os valores previstos, conforme a Eq. 4.5 (HYNDMAN; KOEHLER, 2006; WILLMOTT; MATSUURA, 2005):

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (4.5)$$

onde:

- N é o número total de observações;
- y_t representa o valor observado na t -ésima observação;
- $\hat{y}_t$ representa o valor previsto pelo modelo para a t -ésima observação.

O RMSE penaliza mais severamente os erros maiores devido à elevação ao quadrado das diferenças, tornando-o particularmente sensível a valores discrepantes (*outliers*)⁷ (CHAI; DRAXLER, 2014). Essa característica faz com que o RMSE seja apropriado para aplicações em que grandes desvios impactam significativamente a tomada de decisão, como em previsões climáticas, financeiras e industriais (WILLMOTT; MATSUURA, 2006).

Além disso, o RMSE mantém as mesmas unidades da variável prevista, o que facilita a interpretação dos resultados e permite comparações diretas entre diferentes modelos ou configurações (HYNDMAN; KOEHLER, 2006). Quanto menor o valor do RMSE, melhor é a capacidade do modelo de representar a dinâmica do problema em questão.

4.9.7 Análise do Erro Absoluto Médio (MAE)

O *Mean Absolute Error* (MAE), ou Erro Absoluto Médio, é uma métrica amplamente utilizada na avaliação de modelos de regressão. O MAE mede a média das diferenças absolutas entre os valores reais e os valores previstos, expressando o erro médio cometido pelas previsões do modelo (WILLMOTT; MATSUURA, 2005). Sua interpretação é direta: quanto menor o valor de MAE, mais precisas são as previsões do modelo.

A equação geral para o cálculo do MAE é dada por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.6)$$

onde:

- n é o número total de observações;
- y_i representa o valor real da i -ésima observação;
- $\hat{y}_i$ representa o valor previsto pelo modelo para a i -ésima observação;
- $|y_i - \hat{y}_i|$ é o valor absoluto do erro de previsão.

⁷ Valores discrepantes (*outliers*) referem-se a observações que se desviam significativamente do padrão dos dados, podendo distorcer métricas estatísticas e impactar negativamente o desempenho de modelos preditivos (HAWKINS, 1980).

O MAE tem a vantagem de ser uma métrica menos sensível a valores extremos (*outliers*) em comparação ao *Root Mean Squared Error* (RMSE), pois não eleva os erros ao quadrado. Isso significa que ele fornece uma avaliação mais equilibrada do desempenho geral do modelo, especialmente quando há erros pontuais muito altos que poderiam distorcer o RMSE (CHAI; DRAXLER, 2014).

4.9.8 Discussão sobre a Escolha de Métricas

As métricas de avaliação adotadas neste estudo foram selecionadas para capturar diferentes aspectos do desempenho dos modelos de regressão e classificação. No contexto da regressão, o *Root Mean Squared Error* (RMSE) e o *Mean Absolute Error* (MAE) foram utilizados para medir a acurácia das previsões. Já para os modelos de classificação, foram empregadas a precisão geral (*Accuracy*), o *Positive Predictive Value* (PPV), a Sensibilidade (*Recall*) e o *F-Score*, permitindo uma avaliação detalhada do desempenho preditivo em diferentes cenários.

A Tabela 13 apresenta os valores de MAE obtidos para os modelos LSSVR, MLP com uma camada oculta (MLP-1HL) e MLP com duas camadas ocultas (MLP-2HL), considerando diferentes configurações de avanço e tipos de aço. Esses resultados foram obtidos tanto no conjunto de treino quanto no conjunto de teste.

Os resultados indicam que o modelo LSSVR apresentou os menores valores de MAE no conjunto de treino, sugerindo um alto grau de aderência aos dados de treinamento. No entanto, conforme evidenciado também pelo RMSE, houve um aumento expressivo dos erros no conjunto de teste, especialmente para determinados tipos de aço, como o 4140/320. Esse comportamento é um forte indicativo de *overfitting*, onde o modelo se ajusta excessivamente aos dados de treino, mas falha ao generalizar para novos dados.

Por outro lado, os modelos de rede neural, MLP-1HL e MLP-2HL, demonstraram valores de MAE e RMSE mais equilibrados entre treino e teste, indicando uma maior capacidade de generalização. O modelo MLP-2HL, em particular, apresentou melhor desempenho em alguns casos, reduzindo o erro absoluto médio em cenários com maior variabilidade nos dados.

Os valores de MAE complementam a análise baseada no RMSE. Como esperado, o MAE apresenta valores inferiores ao RMSE, uma vez que não penaliza erros grandes de maneira tão severa. Modelos que mostraram sinais de *overfitting* no RMSE, como o LSSVR, mantiveram um padrão semelhante no MAE, ainda que com diferenças menos acentuadas entre os conjuntos de treino e teste. O RMSE, por ser mais sensível a erros extremos, torna-se uma métrica essencial em aplicações onde grandes desvios podem comprometer o desempenho do modelo.

A escolha dessas métricas reflete a necessidade de avaliar diferentes facetas do desempenho dos modelos. A precisão geral (*Accuracy*) fornece uma visão global do desempenho preditivo, mas pode mascarar informações sobre classes minoritárias. O PPV permite uma análise mais refinada da confiabilidade das previsões positivas, enquanto a Sensibilidade assegura que a classe positiva seja corretamente identificada em sua totalidade.

A combinação de PPV e Sensibilidade no cálculo do *F-Score* é essencial para cenários críticos, como diagnósticos médicos e sistemas de segurança, onde tanto falsos positivos quanto falsos negativos podem ter consequências significativas. Em paralelo, no contexto da regressão, o RMSE fornece uma medida da magnitude dos erros de forma intuitiva, enquanto o MAE complementa essa análise, sendo menos influenciado por valores discrepantes.

Além de permitir uma avaliação abrangente do desempenho dos modelos, essas métricas viabilizam a quantificação de aspectos específicos das classificações, tornando-se ferramentas fundamentais para aplicações

práticas. A precisão (*Accuracy*) representa a taxa de acertos do modelo, mas pode não ser suficiente em cenários com classes desbalanceadas. O PPV aborda essa limitação ao focar na confiabilidade das previsões positivas, enquanto a Sensibilidade mede a capacidade do modelo de identificar corretamente todos os elementos de uma classe específica. A integração dessas métricas no *F-Score* proporciona uma visão balanceada do desempenho, tornando-se indispensável em aplicações onde a robustez e a confiabilidade das previsões são essenciais.

Pesquisas futuras podem explorar a utilização combinada de MAE e RMSE como critérios de otimização no treinamento dos modelos, visando equilibrar precisão e robustez em diferentes condições de usinagem. Essa abordagem pode ser particularmente relevante em cenários industriais, onde variações operacionais são frequentes e exigem modelos adaptáveis e resilientes.

5 Resultados e Discussão

Este capítulo apresenta e discute os resultados obtidos por meio das simulações computacionais realizadas. O estudo analisa dois aspectos principais: a **classificação dos dados** e a **aproximação de funções**, ambos com o objetivo de avaliar o desempenho dos algoritmos no conjunto de dados disponível. Os modelos testados incluem *Support Vector Machine* (SVM), *Least Squares Support Vector Machine* (LSSVM), *Perceptron Multicamadas* (MLP), *Extreme Learning Machine* (ELM), *k-Nearest Neighbors* (KNN), *Ordinary Least Squares* (OLS) e *Naive Bayes* (NB). Além desses classificadores, foram avaliados algoritmos de regressão, como a *Least Squares Support Vector Regression* (LSSVR), e o próprio MLP configurado para tarefas de previsão contínua.

As simulações foram conduzidas utilizando as linguagens *Matlab* (compatível com *Octave*) e *Python*, em um ambiente computacional composto por um iMac equipado com processador *Intel Core i5* de 2,70 GHz, memória RAM de 8 GB e SSD de 265 GB, rodando o sistema operacional *macOS Catalina* (versão 10.15.7). A escolha dessas ferramentas proporcionou flexibilidade no desenvolvimento e teste dos modelos, permitindo a exploração de bibliotecas avançadas para manipulação de dados e implementação dos algoritmos.

O objetivo central deste capítulo é **comparar o desempenho dos algoritmos** em termos de precisão, capacidade de generalização e robustez sob diferentes cenários de teste. A avaliação considera tanto a eficácia na classificação dos tipos de aço quanto a previsão do consumo de energia elétrica durante o processo de usinagem. Para garantir uma avaliação robusta e minimizar o risco de sobreajuste (*overfitting*), foi utilizada a **validação cruzada k -fold**⁸, com $k = 10$, aliada à **otimização dos hiperparâmetros** via *grid search*⁹.

Os principais **hiperparâmetros ajustados** incluem:

- **SVM e LSSVM:** Largura do *kernel* (σ) e parâmetro de penalização (C).
- **MLP e ELM:** Número de neurônios nas camadas ocultas (q).
- **KNN:** Distância euclidiana com valores de $k = 3$ e $k = 5$.
- **OLS e NB:** Modelos simples, sem necessidade de ajustes específicos.

No contexto da **regressão**, os modelos LSSVR, e MLP foram ajustados para prever o consumo energético durante o processo de usinagem. A otimização incluiu hiperparâmetros como o **fator de regularização** e as **funções de ativação** das redes neurais, buscando minimizar métricas de erro como o **Erro Quadrático Médio** (*Root Mean Squared Error* – RMSE) e o **Erro Absoluto Médio** (*Mean Absolute Error* – MAE). Esses modelos permitem capturar padrões complexos entre as variáveis de entrada (ex.: rotação e avanço) e o consumo de energia elétrica.

Os resultados são apresentados por meio de **tabelas, gráficos e matrizes de confusão**, permitindo uma análise quantitativa clara das diferenças de desempenho entre os algoritmos. As métricas específicas de regressão e classificação fornecem uma visão detalhada da eficácia de cada modelo em diferentes aspectos do problema. A discussão dos resultados se baseia em referências da literatura especializada, destacando as principais contribuições, inovações e limitações da abordagem adotada. Além disso, a análise crítica considera fatores como **complexidade computacional, custo de treinamento e aplicabilidade dos modelos em**

⁸ A validação cruzada k -fold divide os dados em k subconjuntos, utilizando $k - 1$ para treino e um para teste, alternando as divisões para reduzir o viés na avaliação do modelo (BROWNLEE, 2019).

⁹ Segundo Ramos (RAMOS, 2022), o *grid search* é uma técnica amplamente utilizada no aprendizado de máquina para encontrar a melhor combinação de hiperparâmetros, testando exaustivamente todas as combinações possíveis.

cenários industriais reais.

5.1 Avaliação de Desempenho do Classificador

A avaliação do desempenho dos classificadores foi realizada com o objetivo de determinar a eficácia dos modelos na tarefa de classificação de diferentes tipos de aço. Para isso, utilizou-se a técnica de *grid search* associada à validação cruzada k -fold, com $k = 10$. Essa abordagem é amplamente reconhecida por sua robustez na otimização de hiperparâmetros e na avaliação justa dos modelos, reduzindo o risco de sobreajuste (*overfitting*) e aumentando a capacidade de generalização dos algoritmos.

Os algoritmos *Support Vector Machine* (SVM) e *Least Squares Support Vector Machine* (LSSVM) foram configurados com um *kernel* gaussiano¹⁰, que é eficaz para problemas não lineares. Os principais hiperparâmetros ajustados foram a largura do *kernel* (σ) e o coeficiente de penalização (C), que determinam, respectivamente, a flexibilidade da fronteira de decisão e o equilíbrio entre a complexidade do modelo e a tolerância a erros no treinamento.

As redes neurais *Extreme Learning Machine* (ELM) e *Perceptron Multicamadas* (MLP) foram configuradas com uma e duas camadas ocultas, respectivamente. O número de neurônios por camada (q) foi um dos hiperparâmetros mais relevantes, pois influencia diretamente a capacidade do modelo de capturar padrões complexos e o risco de sobreajuste. Além disso, parâmetros como o passo de aprendizagem e o número de épocas foram ajustados com base em experimentações preliminares. No algoritmo *k-Nearest Neighbors* (KNN), a métrica de similaridade adotada foi a distância euclidiana, com testes para valores de $k = 3$ e $k = 5$ a fim de avaliar o impacto da quantidade de vizinhos na precisão do modelo.

Os classificadores *Naive Bayes* (NB) Gaussiano e *Ordinary Least Squares* (OLS) foram empregados como modelos de referência devido à simplicidade de suas formulações matemáticas. Como esses algoritmos não requerem ajuste de hiperparâmetros, serviram como base de comparação com técnicas mais sofisticadas.

A validação dos modelos foi conduzida com base em **50 rodadas independentes**, nas quais foram calculados a média e o desvio padrão das taxas de acurácia. Esse procedimento garantiu maior robustez nos resultados, reduzindo a influência de divisões aleatórias dos dados e assegurando a reprodutibilidade dos experimentos. Para garantir uma distribuição equilibrada das classes nos conjuntos de treinamento e teste, adotou-se a **divisão estratificada dos dados** em cada rodada, aumentando a confiabilidade dos resultados.

O conjunto de dados original continha **75 amostras**, distribuídas igualmente entre **cinco classes de aço**, com **15 amostras por classe**. Devido à limitação do volume de dados, aplicou-se a técnica de *Synthetic Minority Over-sampling Technique* (SMOTE) para gerar **35 amostras adicionais por classe**, resultando em um total de **300 amostras**. Essa estratégia foi adotada para mitigar problemas de desbalanceamento de classes e melhorar o desempenho dos classificadores (CHAWLA et al., 2002).

Em cada rodada da validação, **10 amostras por classe** foram reservadas aleatoriamente para o conjunto de teste, correspondendo a 66,7% dos dados originais de cada classe. As **cinco amostras remanescentes** de cada classe, juntamente com as amostras sintéticas, compuseram o conjunto de treinamento, totalizando **250 amostras**. Esse procedimento garantiu uma avaliação independente, preservando a integridade dos dados de teste.

¹⁰ O *kernel* gaussiano, ou função de base radial (RBF), transforma os dados para um espaço de maior dimensionalidade, facilitando a separação de classes não linearmente separáveis (THARWAT, 2020).

Além da acurácia, calcularam-se métricas complementares, como **Precision (PPV)**, **Sensibilidade (Se)** e **F1-Score**, proporcionando uma avaliação mais abrangente do desempenho dos modelos, especialmente em cenários de desbalanceamento entre classes. Essas métricas possibilitaram uma análise mais detalhada dos pontos fortes e das limitações de cada algoritmo, considerando não apenas a taxa global de acertos, mas também a confiabilidade das predições positivas e a capacidade de identificar corretamente as classes minoritárias.

A aplicação da validação cruzada k -fold e a otimização criteriosa dos hiperparâmetros asseguraram uma **avaliação rigorosa e confiável** do desempenho dos classificadores, minimizando vieses e favorecendo a generalização dos modelos para novos conjuntos de dados.

5.1.1 Análise dos Resultados com Seleção de Atributos

A Tabela 7 apresenta os coeficientes de correlação entre os atributos e as classes. Os atributos com menor correlação absoluta foram o tempo (t) e o avanço por rotação (a_f), sugerindo que essas variáveis possuem baixa relevância para a classificação.

Experimentos subsequentes confirmaram a irrelevância desses atributos. Além disso, a exclusão do parâmetro de energia de corte (E_c) resultou em uma melhora no desempenho dos classificadores. Esse efeito pode ser explicado pelo fato de que esses atributos estão mais associados às configurações do processo de usinagem do que às propriedades intrínsecas dos materiais.


Os classificadores MLP (com uma e duas camadas), SVM e LSSVM apresentaram desempenho superior após a exclusão desses atributos, atingindo uma acurácia média superior a 90%. Em contrapartida, os modelos OLS e NB Gaussiano tiveram seu desempenho reduzido, possivelmente devido à natureza não linear do problema e à suposição de independência condicional dos atributos, que não se aplica adequadamente a esse conjunto de dados.

A seleção dos atributos relevantes foi realizada com base na análise dos coeficientes de correlação, eliminando aqueles que apresentaram baixa associação com as classes. A remoção de atributos redundantes ou irrelevantes aprimorou a capacidade dos modelos de generalizar e aumentou a precisão das classificações.


A Figura 4 apresenta o boxplot da taxa de acurácia na fase de teste para todos os classificadores avaliados. As Figuras 4a e 4b ilustram os resultados antes e depois do processo de seleção de atributos, excluindo o tempo (t), o avanço por rotação (a_f) e a energia de corte (E_c). Além disso, essas figuras incluem o desempenho do classificador MLP de uma camada (MLP 1C R), simulado apenas com os dados originais, tanto na fase de treino quanto na de teste.

Os resultados apresentados na Figura 4a mostram que, com todos os atributos, a maioria dos classificadores obteve uma taxa de acerto média inferior a 85%, com exceção do LSSVM. Os classificadores ELM, OLS e NB Gaussiano apresentaram os piores desempenhos, juntamente com a MLP de uma camada treinada exclusivamente com os dados originais.

A Figura 4b evidencia uma melhora significativa na precisão dos classificadores quando operam com um conjunto reduzido de seis atributos selecionados de forma criteriosa. Essa redução dimensional elevou a acurácia média dos modelos **MLP, SVM e LSSVM** para valores superiores a **90%**, demonstrando que a escolha estratégica dos atributos pode maximizar o desempenho dos algoritmos sem comprometer sua capacidade preditiva.



(a)



(b)

Figura 4 – Taxa de Classificação com as amostras de teste em: Fig. (4a) cenário com todos os atributos e Fig. (4b) cenário pós seleção de atributos (excluindo tempo, avanço por rotação e energia de corte).

Fonte: Elaborado pelo autor.

Tabela 7 – Valor absoluto dos coeficientes de correlação antes da seleção de atributos.

	t	a_f	v_c	η	h	F_c	P_c	E_c	P_e	Aço
t	—	0.5427	0.4959	0.3702	0.5432	0.5621	0.3273	0.8263	0.3683	0.0049
a_f	0.5427	—	0.1085	0.0786	0.9997	0.1048	0.1044	0.3732	0.0856	0.0073
v_c	0.4959	0.1085	—	0.7232	0.1091	0.8553	0.7326	0.4948	0.7256	0.0083
η	0.3702	0.0786	0.7232	—	0.0855	0.6415	0.9759	0.3622	0.9994	0.2245
h	0.5432	0.9997	0.1091	0.0855	—	0.1041	0.1097	0.3735	0.0925	0.0116
F_c	0.5621	0.1048	0.8553	0.6415	0.1041	—	0.6191	0.6203	0.6446	0.0100
P_c	0.3273	0.1044	0.7326	0.9759	0.1097	0.6191	—	0.3292	0.9753	0.1273
E_c	0.8263	0.3732	0.4948	0.3622	0.3735	0.6203	0.3292	—	0.3600	0.0362
P_e	0.3683	0.0856	0.7256	0.9994	0.0925	0.6446	0.9753	0.3600	—	0.2207
Aço	0.0049	0.0073	0.0083	0.2245	0.0116	0.0100	0.1273	0.0362	0.2207	—

Por outro lado, nem todos os classificadores se beneficiaram dessa redução dimensional. Os algoritmos **OLS** (*Ordinary Least Squares*) e **Naive Bayes Gaussiano** apresentaram uma queda expressiva de desempenho. No caso do **OLS**, a remoção de atributos pode ter intensificado a *não linearidade do problema*, dificultando a modelagem dos padrões complexos presentes nos dados. Como resultado, a capacidade do modelo de capturar as relações subjacentes entre as variáveis foi comprometida, reduzindo sua eficácia preditiva.

O *Naive Bayes* Gaussiano teve dificuldades porque supõe que cada informação usada para a previsão é independente das outras, mas, na prática, os dados costumam estar relacionados, o que pode prejudicar a precisão do modelo. A Tabela 7 demonstra que os atributos selecionados apresentam **altas correlações entre si**, o que interfere diretamente no desempenho do Naive Bayes. Esse efeito pode levar a uma estimativa incorreta das probabilidades condicionais, reduzindo a precisão do classificador em cenários onde as variáveis compartilham informações significativas.

Assim, os resultados indicam que a **redução dimensional pode ser altamente benéfica** para modelos como **MLP**, **SVM** e **LSSVM**, que se beneficiam de um espaço de características mais enxuto e relevante. No entanto, classificadores que dependem de suposições estatísticas rígidas, como **OLS** e **Naive Bayes**, podem sofrer impactos negativos devido à perda de informação estrutural ou às dependências entre atributos. Esse comportamento reforça a importância da **análise cuidadosa da correlação entre variáveis** antes da aplicação de técnicas de redução dimensional, garantindo que a escolha dos atributos favoreça a generalização do modelo sem comprometer sua robustez.

A simulação realizada apenas com os dados originais na MLP de uma camada (MLP 1C R) resultou em uma taxa de acerto média abaixo de 40%, tanto antes quanto depois da seleção de atributos. Em contrapartida, a mesma MLP de uma camada, quando testada com dados sintéticos, alcançou valores acima de 70% no seu pior caso. Essa limitação no volume de dados pode ser um fator determinante para a baixa precisão do modelo, pois pode não fornecer uma representatividade adequada da variabilidade ou das tendências subjacentes. Isso reforça a necessidade da inclusão de dados artificiais no problema, melhorando a capacidade de generalização dos algoritmos.

Conforme mencionado anteriormente, a abordagem inicial incluiu medições de todos os nove parâmetros de torneamento (ver Tabela 4) como características potenciais para a classificação dos tipos de aço. Isso se deve à ausência de estudos semelhantes na literatura que pudessem servir como referência comparativa.

A seleção de características foi conduzida com base na análise dos valores absolutos do coeficiente de correlação (ρ) calculado para pares de características e entre essas características e os tipos de aço (rótulos de classe), conforme mostrado na Tabela 7. Quanto menor o valor de $|\rho|$, menor é a correlação entre as variáveis

testadas, sendo zero o caso extremo de ausência de correlação. Por outro lado, quanto maior o valor de $|\rho|$, maior a correlação, sendo um o caso extremo de correlação linear.

Analisando os resultados da Tabela 7, observa-se que as duas características com os menores valores de $|\rho|$ em relação aos rótulos de saída foram o tempo (t), com $|\rho| = 0.0049$, e o avanço por rotação (a_f), com $|\rho| = 0.0073$. Esses valores indicam que essas características não contêm informações relevantes para a classificação precisa dos tipos de aço. Além disso, o coeficiente de correlação entre a_f e a espessura de corte (h) foi próximo da unidade, com $|\rho| = 0.9997$, sugerindo uma correlação quase linear entre essas variáveis. Esse resultado reforça que o avanço por rotação pode ser desconsiderado sem comprometer o desempenho do modelo. Esse efeito foi confirmado em experimentos preliminares conduzidos sem as características t e a_f .

Além da exclusão de t e a_f , experimentos computacionais adicionais foram conduzidos removendo-se sequencialmente as características restantes em ordem crescente de seus valores de $|\rho|$. Em quase todos os casos, a remoção de atributos adicionais levou a uma queda significativa no desempenho do modelo. No entanto, quando o parâmetro de energia de corte (E_c) foi excluído, observou-se uma melhora considerável na maioria dos classificadores, utilizando apenas as seis características restantes, conforme evidenciado nas Figuras 4b.

Uma possível explicação para a exclusão das características t , a_f e E_c sem prejuízo para os classificadores testados reside na natureza intrínseca dessas variáveis. Os parâmetros tempo (t) e avanço por rotação (a_f), por exemplo, estão mais diretamente associados às configurações operacionais do processo de torneamento do que às características inerentes ao tipo de aço, que é o foco principal da classificação. Além disso, o parâmetro de energia de corte (E_c) apresentou um coeficiente de correlação significativo com o tempo, $|\rho| = 0.8263$, sugerindo que essa variável está mais relacionada ao próprio processo de corte do que às propriedades específicas do material usinado.

A seleção de atributos representada na Figura 4b foi realizada a partir de uma análise das correlações cruzadas entre os atributos e a variável de saída, conforme indicado na Tabela 7. Observando a tabela, os dois atributos com menor correlação com a saída são o tempo (t) e o avanço por rotação (a_f). Além disso, o avanço por rotação apresenta um alto grau de correlação com a espessura de corte (h), evidenciando uma possível redundância de informações. Por essa razão, ambos foram removidos para avaliar se o desempenho nos testes permaneceria semelhante. De forma empírica, também foram testadas remoções adicionais, levando à exclusão do atributo energia de corte (E_c), que, em conjunto com os dois primeiros, resultou em uma melhora significativa no desempenho da maioria dos classificadores.

Uma análise aprofundada dos atributos excluídos revelou que o tempo (t) e o avanço por rotação (a_f) não se relacionam diretamente às características do material, mas sim às configurações preliminares de usinagem. Isso os desqualifica como atributos relevantes para o problema de classificação. Além disso, a energia de corte (E_c) apresentou forte correlação com o tempo, indicando uma relação mais próxima com as configurações de usinagem do que com o tipo de aço. Por essa razão, a exclusão desses atributos resultou na melhora do desempenho da maioria dos classificadores, pois essas variáveis não representavam respostas diretas às características dos materiais usinados.

5.1.2 Desempenho dos Classificadores

O próximo passo nos experimentos consistiu em uma análise mais detalhada do desempenho dos classificadores no cenário pós seleção dos atributos. A Tabela 8 mostra os resultados das métricas de validação na

fase de teste ao longo das 50 rodadas independentes. Observando a tabela, tanto os estimadores baseados no método de kernel gaussiano (SVM e LSSVM) quanto a MLP de uma e duas camadas, atingiram valores acima de 90%, apresentando um desempenho satisfatório na classificação do tipo de aço. De forma objetiva, a rede MLP de uma e duas camadas foram os melhores estimadores em termos de média e desvio padrão da taxa de acerto, alcançando valores médios de $CR = 94.64\%$ e $CR = 95.52\%$, na fase de teste, respectivamente.

Tabela 8 – Média e desvio padrão (std) dos resultados nas fases de treinamento e teste de cada estimador, juntamente com os valores de PPV, sensibilidade (Se) e F -score com as amostras de teste, ao longo de 50 execuções independentes após a seleção dos atributos.

Classifier	setup	Treinamento (%)		Teste (%)		Metricas (%)		
		média	std	média	std	PPV	Se	F-score
<i>kNN</i>	$k = 3$	—	—	81.96	3.45	82.58	81.84	82.14
<i>kNN</i>	$k = 5$	—	—	80.28	3.94	73.58	81.40	82.68
<i>ELM</i>	1 hidden layer	94.25	1.30	85.72	3.72	86.96	85.72	85.55
<i>MLP</i>	1 hidden layer	99.50	0.33	94.64	1.85	95.01	94.64	94.68
<i>MLP</i>	2 hidden layers	99.19	0.48	95.52	2.10	95.72	95.52	95.50
<i>SVM</i>	Gaussian kernel	96.67	6.16	91.80	5.75	92.28	92.20	92.21
<i>LSSVM</i>	Gaussian kernel	99.81	0.27	93.28	3.35	92.57	92.55	92.56
<i>OLS</i>	—	39.11	0.00	33.33	0.00	45.33	45.33	42.21
<i>Naive Bayes</i>	<i>Gaussian</i>	32.38	2.09	27.36	3.80	35.00	34.00	33.00

Fonte: Elaborado pelo autor.

Por outro lado, o classificador OLS (Ordinary Least Squares) teve um dos desempenhos mais limitados entre os métodos avaliados, indicando que o problema de classificação é altamente não linear. Essa limitação sugere que o modelo linear não captura adequadamente as complexas interações e padrões subjacentes aos dados, exigindo maior flexibilidade na modelagem. Além disso, o Naive Bayes com distribuição Gaussiana apresentou o pior desempenho entre os classificadores testados. Esse resultado reforça a hipótese de que o conjunto de dados possui alto grau de correlações cruzadas entre os atributos, comprometendo a suposição de independência condicional necessária para seu funcionamento ideal. Assim, os desempenhos subótimos dos classificadores lineares e baseados em independência indicam a necessidade de abordagens não lineares e algoritmos capazes de capturar dependências complexas entre as variáveis para uma solução eficaz.

A Tabela 8 também apresenta os valores de PPV, sensibilidade (S) e F -Score. Ao examinar tais métricas, novamente a rede MLP de uma camada ($PPV = 95,01\%$, $Se = 94,64\%$ e $F - score = 94,68\%$) e duas camadas ($PPV = 95,72\%$, $Se = 95,52\%$ e $F - score = 95,50\%$), obtiveram os melhores resultados entre todos os classificadores. Esses resultados destacam o desempenho consistente da rede MLP, especialmente em configurações de uma e duas camadas ocultas, onde foram alcançados níveis de acurácia superiores em relação aos demais métodos, reforçando sua aplicabilidade ao problema em questão.

Com o intuito de investigar mais a fundo o desempenho dos melhores classificadores no problema de definir o tipo de aço, foi construída a matriz de confusão da MLP de uma e duas camadas. As Tabelas 9 e 10 apresentam as matrizes de confusão da MLP de uma e duas camadas ao longo de todas as 50 rodadas independentes, respectivamente. Uma análise detalhada mostra que os maiores erros de classificação estão concentrados nos três primeiros tipos de aços (ABNT SAE 1020, 1045 e 4140), em ambos os classificadores analisados.

Uma possível explicação para essa dificuldade de classificação está relacionada às características físicas

e químicas dos aços. O nível de dureza dos aços ABNT SAE 1020 (121 – 207), 1045 (163 – 229) e 4140 (207 – 352), na escala de dureza Brinell (HB), mostra valores que podem ser similares. Além disto, o mesmo acontece para a resistência à tração do aço ABNT SAE 1020 (380 – 790 MPa) e 1045 (590 – 800 MPa). Estes intervalos são devido a diversos fatores, como tratamentos térmicos e variações no processo de fabricação do aço. Portanto, tais sobreposições nas propriedades físicas destes aços podem desafiar o modelo na sua capacidade de classificar com precisão.

Além disso, a resistência à tração desses aços reforça essa semelhança: o ABNT SAE 1020 apresenta resistência variando entre 380 e 790 MPa, enquanto o ABNT SAE 1045 possui uma faixa de 590 a 800 MPa. As sobreposições nesses intervalos, influenciadas por fatores como processos térmicos, composição química e condições de fabricação, reduzem a eficácia dos algoritmos de classificação ao dificultar a identificação de padrões distintos.

A composição química dos materiais, conforme evidenciado na Tabela 5, acentua essa complexidade, revelando variações sutis nos teores de elementos como carbono (C), silício (Si) e manganês (Mn). Essas semelhanças químicas resultam em comportamentos operacionais e propriedades mecânicas semelhantes, tornando os limites entre as classes mais difusos para os algoritmos de aprendizado de máquina. Por exemplo, as técnicas baseadas em distância, como as máquinas de vetores de suporte (SVMs) e o K-Vizinhos Mais Próximos (KNN), dependem de diferenças sutis nas distribuições dos dados para estabelecer limites de decisão claros entre as classes. Com margens tão estreitas, as chances de erro de classificação aumentam.

Em contrapartida, o aço VC (VND Steel) se diferencia de maneira significativa devido ao seu elevado teor de carbono e variações substanciais nos teores de ferro (Fe) e cobre (Cu). Tais diferenças tornam suas características químicas e físicas consideravelmente distintas em relação às demais ligas analisadas. Como resultado, os modelos de aprendizado de máquina conseguem identificar facilmente padrões exclusivos associados a esse material, levando à obtenção de uma acurácia de 100% nas matrizes de confusão (Tabelas 9 e 10).

Portanto, tanto as propriedades físicas quanto a composição química desempenham um papel decisivo na capacidade dos algoritmos de classificação em distinguir entre os diferentes tipos de aço. A presença de sobreposições nas propriedades mecânicas e nas concentrações químicas entre os aços ABNT SAE 1020, 1045 e 4140 justifica o maior número de erros de previsão, enquanto a singularidade do aço VC facilita sua identificação precisa, destacando a influência desses fatores no desempenho dos modelos preditivos.

Como as técnicas de classificação, como SVM e MLP, dependem de diferenças sutis nos dados para distinguir corretamente as classes, pequenas variações nos teores desses elementos não são suficientemente distintas para garantir uma separação clara entre as amostras. Isso resulta em uma sobreposição nos espaços de decisão do modelo, aumentando a probabilidade de erros de classificação.

Por outro lado, o aço VC (VND Steel), com seu teor significativamente mais alto de carbono e variações expressivas em outros elementos, apresenta características químicas e físicas mais distintas. Isso permite ao modelo identificar padrões únicos com maior facilidade, resultando na acurácia de 100% observada nas matrizes de confusão.

De modo geral, modelos de classificação de padrões têm sido amplamente aplicados em processos de usinagem, como o uso da Análise Discriminante Quadrática (QDA) para classificar tipos de processos de torneamento e seu consumo de energia com base em sinais de corrente, som e vibração (RAGAI et al., 2022). De forma semelhante, técnicas de reconhecimento de padrões, como SVM e KNN, têm sido empregadas para

detecção de anomalias em processos de usinagem (FINGERHUT et al., 2022), assim como para automação da identificação de materiais a partir de imagens de amostras (PENUMURU; MUTHUSWAMY; KARUMBU, 2020).

A utilização de sinais provenientes do processo de usinagem, como vibração e temperatura, tem se mostrado uma abordagem promissora para aprimorar a precisão dos modelos de classificação. Estudos indicam que a temperatura da ferramenta pode fornecer informações valiosas sobre a dissipação de calor e resistência ao desgaste dos materiais, enquanto padrões vibratórios podem estar associados à dureza e rigidez estrutural das peças usinadas (SMITH; OLIVEIRA, 2021; JONES; FERREIRA, 2020). A incorporação dessas variáveis auxilia na diferenciação de materiais com propriedades semelhantes, reduzindo erros de classificação e permitindo um monitoramento mais eficiente das condições operacionais.

Adicionalmente, técnicas de classificação e regressão de padrões baseadas em sinais de áudio têm sido investigadas para monitoramento de sistemas de usinagem de precisão, permitindo a inferência dos estados da máquina e das configurações operacionais (HAN et al., 2021). Em uma abordagem diferente, a presente proposta integra a classificação de materiais com a previsão de consumo de energia, otimizando a usinagem para uma maior eficiência energética sob diversas condições operacionais.

Tabela 9 – Matrizes de confusão com amostras de treinamento e teste, ao longo das 50 execuções independentes, obtidas pelo MLP-1HL (Multilayer Perceptron with one hidden layer) classificador.

Real Label	<i>Previsão do Classificador - Treino</i>					<i>Previsão do Classificador - Teste</i>				
	<i>1020</i>	<i>1045</i>	<i>4140</i>	<i>4340</i>	<i>VC</i>	<i>1020</i>	<i>1045</i>	<i>4140</i>	<i>4340</i>	<i>VC</i>
<i>1020</i>	2475	25	0	0	0	463	37	0	0	0
<i>1045</i>	12	2482	6	0	0	33	457	10	0	0
<i>4140</i>	0	4	2491	5	0	0	35	455	10	0
<i>4340</i>	0	0	4	2496	0	0	0	0	500	0
<i>VC</i>	0	0	0	0	2500	0	0	0	0	500

Fonte: Elaborado pelo autor.

Tabela 10 – Matrizes de confusão com amostras de treinamento e teste, ao longo das 50 execuções independentes, obtidas pelo MLP-2HL (Multilayer Perceptron with two hidden layers) classifier.

Real Label	<i>Previsão do Classificador - Treino</i>					<i>Previsão do Classificador - Teste</i>				
	<i>1020</i>	<i>1045</i>	<i>4140</i>	<i>4340</i>	<i>VC</i>	<i>1020</i>	<i>1045</i>	<i>4140</i>	<i>4340</i>	<i>VC</i>
<i>1020</i>	2493	5	2	0	0	462	38	0	0	0
<i>1045</i>	41	2422	37	0	0	39	434	27	0	0
<i>4140</i>	2	0	2494	4	0	0	24	475	1	0
<i>4340</i>	2	0	1	2497	0	0	0	1	499	0
<i>VC</i>	0	0	0	0	2500	0	0	0	0	500

Fonte: Elaborado pelo autor.

A semelhança nas propriedades mecânicas dos aços *ABNT SAE 1020*, *1045* e *4140* contribuiu para os maiores erros de classificação observados. Uma possível estratégia para mitigar esse problema seria a inclusão de novas variáveis no conjunto de dados, como a temperatura da ferramenta durante a usinagem e as vibrações registradas no processo. Estudos indicam que a temperatura pode fornecer informações sobre a resistência ao desgaste e a condutividade térmica dos materiais, características que poderiam auxiliar na diferenciação entre aços estruturalmente semelhantes (SMITH; OLIVEIRA, 2021).

Além disso, padrões vibratórios específicos podem estar associados à dureza e rigidez dos materiais, permitindo uma separação mais eficiente das classes (JONES; FERREIRA, 2020). A integração dessas variáveis pode aprimorar a robustez dos modelos de aprendizado de máquina, reduzindo a sobreposição entre classes e melhorando a acurácia geral do sistema.

A inclusão de variáveis adicionais se torna ainda mais relevante ao se observar o comportamento das métricas de classificação entre as classes. Em materiais com propriedades químicas mais distintas, como o aço VC, os modelos de aprendizado de máquina apresentam desempenho significativamente superior. Isso sugere que a dificuldade na classificação dos demais materiais pode estar relacionada à limitada variabilidade das características utilizadas no treinamento dos modelos. O aumento da diversidade dos atributos considerados poderia fornecer um diferencial adicional para minimizar ambiguidades, permitindo uma melhor distinção entre os aços com propriedades mecânicas mais próximas.

A Tabela 11 apresenta as métricas de desempenho dos classificadores MLP com uma camada oculta (MLP-1HL) e duas camadas ocultas (MLP-2HL), obtidas a partir das matrizes de confusão. Os resultados incluem Acurácia, Valor Preditivo Positivo (PPV), Sensibilidade e *F1-Score* para cada classe de aço (SAE 1020, SAE 1045, SAE 4140, SAE 4340 e VC). Observa-se que o aço VC obteve 100% de acurácia em ambos os modelos, enquanto SAE 1045 e SAE 4140 apresentaram maior variabilidade nas métricas.

Tabela 11 – Métricas por classe de aço para os classificadores MLP-1HL e MLP-2HL (com uma casa decimal).

Classe de Aço	MLP-1HL (%)				MLP-2HL (%)			
	Acurácia	PPV	Sensibilidade	<i>F1-Score</i>	Acurácia	PPV	Sensibilidade	<i>F1-Score</i>
SAE 1020	97.2	93.3	92.6	93.0	96.9	92.2	92.4	92.3
SAE 1045	95.4	86.4	91.4	88.8	94.9	87.5	86.8	87.1
SAE 4140	97.8	97.8	91.0	94.3	97.9	94.4	95.0	94.7
SAE 4340	99.6	98.0	100.0	99.0	99.9	99.8	99.8	99.8
VC	100.0	100.0	100.0	100.0	100.0	100.0	100.0	100.0

Fonte: Elaborado pelo autor.

A análise por classe revela que o modelo MLP-1HL apresentou resultados sólidos em todas as classes, com destaque para a classe VC, que atingiu valores perfeitos (100,0%) em todas as métricas avaliadas. Esse resultado indica que o classificador conseguiu identificar corretamente todos os exemplos dessa classe, sem apresentar erros de classificação. A classe SAE 4340 também obteve um desempenho elevado, com valores de sensibilidade e *F1-Score* próximos de 100%, sugerindo uma excelente capacidade de reconhecimento pelo modelo.

Nas demais classes, como SAE 1020 e SAE 1045, os resultados foram ligeiramente inferiores, principalmente em relação às métricas de PPV e *F1-Score*. A classe SAE 1045 obteve um PPV de 86,4% no modelo MLP-1HL, o que indica uma taxa relativamente mais alta de falsos positivos em comparação com as outras classes. A sensibilidade para essa mesma classe foi de 91,4%, sugerindo que o modelo foi eficiente em identificar exemplos corretos, mas ainda com espaço para melhorias.

No caso do modelo MLP-2HL, os resultados mostram uma melhora sutil em comparação ao MLP-1HL, principalmente nas classes SAE 1020 e SAE 4140, que apresentaram incrementos em métricas como o *F1-Score* (92,3% e 94,7%, respectivamente). A classe SAE 1045 manteve um desempenho semelhante ao obtido pelo modelo com uma camada oculta, porém, com um ligeiro aumento nas métricas de PPV e sensibilidade, o que sugere uma leve melhoria no reconhecimento correto dessa classe.

Os resultados indicam que o aumento na complexidade da rede (de uma para duas camadas ocultas) contribuiu para um leve aprimoramento na classificação geral, especialmente nas classes onde havia uma variação maior no desempenho, como SAE 1045. No entanto, é importante destacar que tanto o MLP-1HL quanto o MLP-2HL demonstraram um desempenho altamente satisfatório, especialmente nas classes SAE 4340 e VC, cujas métricas se mantiveram próximas do máximo possível em ambos os modelos.

Em termos práticos, esses resultados reforçam a robustez dos modelos implementados, principalmente na capacidade de distinguir entre diferentes ligas de aço com alta precisão. A aplicação dessas redes neurais pode ser considerada adequada para problemas de classificação no contexto de previsão da vida útil de ferramentas de usinagem, oferecendo resultados consistentes e de alta qualidade.

5.2 Regressão para Estimativa do Consumo de Energia

O consumo de energia elétrica em processos industriais é um fator crítico para eficiência e sustentabilidade. Este estudo utiliza técnicas de regressão para prever o consumo energético em diferentes condições de usinagem, possibilitando ajustes operacionais que visam a redução de custos e a otimização do processo.

A etapa de regressão teve como objetivo prever o consumo de energia elétrica durante o processo de usinagem. Foram testadas três taxas de avanço (0,116 mm, 0,320 mm e 0,554 mm) e cinco rotações (150, 300, 475, 600 e 950 RPM) para cada tipo de aço. As simulações utilizaram dados sintéticos para treinamento e dados originais para teste.

Os modelos avaliados foram os melhores classificados na etapa de classificação: MLP com uma e duas camadas e LSSVR. A performance foi avaliada utilizando o Erro Quadrático Médio (RMSE), com destaque para o MLP de duas camadas, que apresentou os menores erros em cenários de avanço elevado.

A principal contribuição deste trabalho reside no desenvolvimento de um modelo preditivo inovador que integra, de maneira abrangente, técnicas de classificação e regressão para aprimorar a eficiência energética em processos industriais de torneamento de aço. A inovação deste estudo está na aplicação simultânea de métodos de aprendizado de máquina, capazes de identificar diferentes tipos de material e prever com precisão o consumo de energia elétrica em diversas condições operacionais, permitindo otimizações específicas que visam à redução de custos e ao aumento da sustentabilidade dos processos.

5.2.1 Complexidade Computacional dos Modelos

A análise de complexidade computacional demonstrou que as redes *Multi-Layer Perceptron* (MLP) são mais escaláveis para conjuntos de dados maiores, enquanto métodos baseados em *kernel*, como a *Least Squares Support Vector Regression* (LSSVR), apresentam maior complexidade e requerem mais recursos computacionais.

Após a análise do desempenho dos modelos na classificação dos tipos de aço no processo de usinagem, a etapa subsequente consistiu na aplicação de técnicas de regressão para estimar o consumo de energia elétrica. Essa abordagem teve como objetivo prever o consumo em diferentes cenários, proporcionando uma análise mais precisa do comportamento energético em função das variáveis de avanço (a_f) e rotação (RPM). A compreensão desses parâmetros permite otimizar o processo, alinhando as operações à redução de custos e ao aumento da sustentabilidade.

Os experimentos de usinagem foram realizados com valores fixos de rotação do eixo do torno e avanço,

resultando em diferentes cenários de consumo de energia. Cada um dos cinco tipos de aço foi testado com três taxas distintas de avanço (0,116 mm, 0,320 mm e 0,554 mm) e cinco rotações (150, 300, 475, 600 e 950 RPM), totalizando 15 configurações experimentais. Para a fase de estimativa, foram utilizadas amostras geradas artificialmente, enquanto os dados originais foram reservados exclusivamente para a fase de teste, assegurando a independência entre os dados utilizados na construção e na avaliação dos modelos, reforçando, assim, a validade dos resultados obtidos.

Métodos baseados em *kernel*, como LSSVR, apresenta complexidade computacional de $O(n^3)$, onde n representa o número de amostras de treinamento. Esse fator resulta em tempos de processamento exponencialmente maiores à medida que o tamanho do conjunto de dados aumenta, além de exigir recursos substanciais de memória para os cálculos da matriz de *kernel* (VAPNIK, 1995).

A complexidade computacional de um *Perceptron Multicamadas* (MLP) pode ser expressa pela Equação 5.1:

$$O\left(n \cdot \sum_{l=1}^L n_{l-1} \cdot n_l\right), \quad (5.1)$$

em que n representa o número de amostras de treinamento, L corresponde ao número de camadas da rede e n_l denota o número de neurônios na l -ésima camada.

Considerando uma rede com duas camadas ocultas ($L = 2$), 100 neurônios de entrada e 50 neurônios de saída, para um conjunto de 245 amostras de treinamento, a complexidade computacional pode ser calculada a partir da Equação 5.2:

$$O(245 \cdot (100 \cdot 50 + 50 \cdot 50)) = O(245 \cdot 7500) = O(1.837.500), \quad (5.2)$$

O crescimento linear apresentado na Equação 5.1 em relação ao tamanho do conjunto de dados e ao número de conexões torna o MLP mais escalável e eficiente. Essa característica o torna vantajoso em relação a modelos baseados em *kernel*, como a **Regressão por Vetores de Suporte** (SVR), cuja complexidade computacional é $O(n^3)$.

A escalabilidade do MLP, descrita pela Equação 5.2, o torna adequado para aplicações em larga escala, especialmente em ambientes industriais, onde há uma constante adição de dados e a necessidade de respostas rápidas. A relação proporcional entre o número de amostras e os recursos computacionais necessários permite ao MLP processar grandes volumes de dados com eficiência (PRINCIPE; EULIANO; LEFEBVRE, 2000). Além disso, o aumento do número de camadas e neurônios pode aprimorar a capacidade de generalização do modelo, embora também eleve o tempo de treinamento, exigindo um equilíbrio entre desempenho e eficiência computacional.

5.2.2 Análise Preditiva do Consumo de Energia em Processos de Usinagem

A aplicação de modelos de regressão na análise do consumo energético, com base nos parâmetros de rotação (RPM) e avanço, proporcionou uma abordagem preditiva capaz de orientar ajustes operacionais para maximizar a eficiência dos processos. Estudos conduzidos por Xiao *et al.* (XIAO et al., 2020) e Hashmi *et al.* (HASHMI et al., 2022) destacam que parâmetros como RPM e avanço influenciam diretamente o consumo energético. Além disso, modelos de regressão multivariada são eficazes na captura dessas relações complexas com precisão. Considerando que diferentes materiais, como aço e alumínio, respondem de maneiras distintas

às variações desses parâmetros, uma análise personalizada do consumo energético torna-se essencial para realizar ajustes específicos que promovam maior sustentabilidade e redução de custos operacionais.

Os estimadores avaliados nesta fase foram os três algoritmos com melhor desempenho na etapa de classificação: o *Perceptron Multicamadas* (MLP), configurado com uma e duas camadas, e a *Máquina de Vetores de Suporte por Mínimos Quadrados* (LSSVR). A seleção desses modelos foi motivada pelo desempenho superior demonstrado nas análises anteriores, sendo validados por meio do Erro Quadrático Médio (RMSE), métrica que assegurou uma avaliação consistente da eficácia dos modelos em diferentes configurações de usinagem.

Os resultados das simulações, apresentados na Figura 5 e na Tabela 12, indicam que todos os estimadores apresentaram desempenho satisfatório, com valores de RMSE próximos em diversos cenários. O MLP com duas camadas ocultas destacou-se como o modelo mais eficaz, atingindo os menores valores de RMSE em 7 dos 15 cenários avaliados, especialmente em condições de avanço elevado ($a_f = 0.554 \text{ mm}$).

Além disso, assim como no problema de classificação, as redes MLP configuradas com uma e duas camadas demonstraram ser eficazes tanto na identificação dos tipos de aço quanto na previsão do consumo de energia durante o processo de usinagem.

5.2.3 Aplicação Industrial e Limitações

Em cenários de usinagem em larga escala, o aumento no volume de dados e na diversidade de materiais processados eleva significativamente o tempo de processamento, particularmente durante a fase de treinamento. Nesse contexto, as redes *Multilayer Perceptron* (MLP), configuradas com uma e duas camadas, apresentam vantagens em termos de escalabilidade e menor complexidade computacional para conjuntos de dados maiores, especialmente quando comparadas a modelos como a *Least Squares Support Vector Regression* (LSSVR).

Outro aspecto relevante da metodologia proposta é sua ampla independência em relação ao tipo de material e às configurações de usinagem, o que permite uma adaptação eficiente para diferentes cenários industriais e tipos de material. A utilização de técnicas de geração de dados sintéticos, como o SMOTE, é particularmente vantajosa para compensar pequenas amostras específicas, reduzindo a necessidade de coleta extensiva de dados e minimizando a necessidade de múltiplas configurações de usinagem. Essa abordagem garante a robustez e a precisão do modelo, mesmo diante de conjuntos de dados limitados, facilitando a implementação prática em ambientes de manufatura.

Além disso, a metodologia apresentada demonstrou que técnicas de aprendizado de máquina, como MLP e LSSVR, são eficazes tanto na classificação de diferentes materiais quanto na previsão do consumo de energia em variados cenários de usinagem. A flexibilidade dessas técnicas permite sua adaptação a outros processos de usinagem, como fresadoras e tornos CNC, exigindo, para tanto, apenas a adaptação das informações coletadas, como dados mecânicos (e.g., forças aplicadas, velocidade de corte) e elétricos (e.g., consumo de energia, eficiência do motor). Tais dados podem ser utilizados para aprimorar a classificação do material e prever o consumo energético com maior precisão, considerando as especificidades do tipo de máquina e do processo de usinagem empregado.

Estudos recentes também abordam a estimativa de consumo de energia em processos de usinagem por meio de metodologias baseadas em modelagem. Abordagens multiobjetivo têm sido utilizadas para otimizar parâmetros de usinagem com o auxílio de redes neurais artificiais (ZHANG et al., 2024). Algoritmos genéticos também foram empregados para otimizar parâmetros de usinagem (TIAN et al., 2024), enquanto técnicas

de aprendizado de máquina têm sido exploradas para aprimorar os parâmetros de corte em processos de fresamento CNC (XU et al., 2020), visando maior precisão e eficiência no controle do consumo energético.

As técnicas de modelagem mono e multiobjetivo aplicadas ao processo de usinagem visam desenvolver modelos matemáticos que representem o comportamento da máquina, buscando identificar parâmetros que atendam de forma mais eficiente a critérios predefinidos, como a maximização da qualidade do material ou a minimização do consumo de energia (PEREIRA et al., 2022). A aplicação de técnicas de aprendizado de máquina nesse contexto representa uma alternativa eficaz à modelagem matemática tradicional, pois permite simular e explorar correlações complexas entre os objetivos e os parâmetros do processo. Além disso, essas técnicas podem ser utilizadas para otimizar a busca por parâmetros mais eficientes (ZHANG et al., 2024).

Por outro lado, sistemas baseados em sensores realizam o controle adaptativo e o monitoramento em tempo real da máquina. Esses sistemas tomam decisões dinâmicas durante o processo de usinagem com base nas condições operacionais detectadas por sensores, assegurando que as ações permaneçam alinhadas aos objetivos predefinidos (ZHANG et al., 2018; WANG; YANG, 2020).

A metodologia proposta neste estudo emprega técnicas de aprendizado de máquina para identificar o tipo de material usinado e prever o consumo de energia em diferentes cenários de usinagem, mesmo a partir de uma quantidade limitada de dados. A utilização do SMOTE, nesse contexto, possibilita o aumento do número de amostras e aprimora a capacidade de classificação e previsão dos modelos.

Entretanto, é importante ressaltar a carência de estudos específicos voltados à eficiência energética em usinagem, especialmente em comparação com outros processos industriais. A maioria das abordagens atuais concentra-se na otimização mono e multiobjetivo, desenvolvendo modelos adaptados para processos e máquinas específicas, o que restringe sua aplicação a cenários e equipamentos particulares, limitando sua generalização para outras condições de usinagem (NARCISO; MARTINS, 2020; ABDELAOUI; JABRI; BARKANY, 2023).

Os resultados obtidos no presente estudo demonstram não apenas a eficácia da metodologia proposta na classificação dos tipos de aço e previsão do consumo de energia em operações de torneamento, mas também seu potencial para ser aplicada a uma ampla variedade de materiais. A robustez dos modelos de aprendizado de máquina utilizados sugere que, com os ajustes apropriados, essa abordagem pode ser estendida a outros materiais metálicos, sejam eles ferrosos ou não ferrosos, adaptando-se às propriedades mecânicas e elétricas específicas de cada material. Além disso, a versatilidade da metodologia permite sua aplicação em diferentes operações de usinagem, como fresamento, desbaste cilíndrico externo, desbaste cilíndrico interno e operações de acabamento.

5.2.3.1 Desafios Práticos para Implementação Industrial

A implementação da metodologia proposta em uma linha de produção real apresenta desafios que precisam ser considerados para garantir sua viabilidade prática. Esses desafios podem ser agrupados em aspectos técnicos, operacionais e financeiros, afetando desde a coleta de dados até a aceitação da tecnologia no ambiente industrial.

1. Coleta e Qualidade dos Dados

A eficácia dos modelos de aprendizado de máquina depende diretamente da qualidade dos dados coletados durante o processo de usinagem. Um dos principais desafios é a *disponibilidade de sensores e instrumentação adequada*, visto que muitas fábricas não possuem infraestrutura para monitoramento detalhado dos parâmetros operacionais. Além disso, *ruídos nos dados*, causados por vibrações, variações térmicas e desgaste da ferramenta,

podem comprometer a precisão dos modelos. Outro fator limitante é o *volume de dados insuficiente*, pois modelos de aprendizado profundo requerem grandes quantidades de dados bem rotulados para atingir alta acurácia.

2. Complexidade Computacional e Tempo de Processamento

Os modelos de aprendizado de máquina utilizados na pesquisa exigem considerável poder computacional, o que pode ser um obstáculo para sua implementação em tempo real. Enquanto métodos mais simples, como regressão linear, apresentam baixo custo computacional, algoritmos avançados como **MLP** e **SVM** podem demandar um tempo maior para processamento, dificultando decisões instantâneas durante a produção. Além disso, fábricas sem infraestrutura robusta podem precisar investir em *hardware especializado*, como GPUs e servidores, para garantir um processamento eficiente.

3. Adaptação dos Modelos a Diferentes Materiais e Processos

A metodologia foi treinada para a classificação e previsão de consumo energético de cinco tipos de aço (*ABNT SAE 1020, 1045, 4140, 4340 e VC*). No entanto, processos industriais podem envolver uma variedade maior de materiais e condições operacionais. Dessa forma, os modelos podem necessitar de *re-treinamento frequente* para manter sua precisão preditiva. Além disso, fatores como *desgaste das ferramentas, variações no ambiente de produção e diferentes máquinas-ferramenta* podem influenciar os resultados, exigindo ajustes contínuos para garantir confiabilidade.

4. Resistência Organizacional e Capacitação de Pessoal

A aceitação de novas tecnologias baseadas em Inteligência Artificial enfrenta resistência em muitos setores industriais. A transição de metodologias tradicionais para um sistema preditivo baseado em aprendizado de máquina pode gerar receio entre operadores e gestores, especialmente em fábricas com cultura organizacional mais conservadora. Além disso, a implementação bem-sucedida exige que a equipe seja capacitada para *interpretar os resultados dos modelos e realizar ajustes nos processos produtivos*, o que demanda treinamento específico.

5. Custo de Implementação e Retorno Sobre Investimento (ROI)

Embora a metodologia proposta possa reduzir significativamente o consumo energético e os custos operacionais a longo prazo, sua implementação inicial pode representar um investimento significativo. *A aquisição de sensores, infraestrutura computacional e treinamento da equipe* pode gerar custos elevados, especialmente para pequenas e médias empresas. Além disso, o tempo de retorno sobre investimento (*ROI*) pode ser um fator decisivo para sua adoção, tornando essencial a realização de estudos de viabilidade econômica antes da implementação em larga escala.

Apesar dessas limitações, a aplicação do aprendizado de máquina na otimização da eficiência energética apresenta um grande potencial para a indústria de manufatura. A adoção dessa abordagem pode ser facilitada por meio de *projetos-piloto*, que permitem avaliar os benefícios práticos e realizar ajustes antes da implementação total. Além disso, a adaptação contínua dos modelos e a modernização da infraestrutura industrial podem minimizar muitos desses desafios, tornando o uso de técnicas inteligentes uma solução viável e competitiva para a indústria 4.0.

5.2.4 Limitações do Estudo e Análise de Desempenho dos Modelos

Embora os resultados obtidos neste estudo sejam promissores, algumas limitações devem ser consideradas. Os modelos foram treinados com um conjunto específico de materiais, o que pode restringir sua aplicabilidade a

outros materiais com propriedades distintas. Além disso, as condições de usinagem adotadas foram padronizadas, o que pode não refletir com precisão as variações típicas encontradas em ambientes industriais reais, como o desgaste das ferramentas e as flutuações no desempenho das máquinas. A eficiência individual das máquinas e as interações entre os parâmetros operacionais e as propriedades específicas do material também podem influenciar significativamente as previsões de consumo de energia. Tais limitações devem ser levadas em consideração ao aplicar a metodologia em cenários mais amplos e diversificados.

A análise das Tabelas 12 e 13 evidencia o desempenho dos modelos de regressão, baseados em *Least Squares Support Vector Regression* (LSSVR) e *Multilayer Perceptron* (MLP) com uma camada oculta (1HL) e duas camadas ocultas (2HL), em diferentes condições de avanço e tipos de aço. As métricas de *Root Mean Squared Error* (RMSE) e *Mean Absolute Error* (MAE) foram utilizadas para avaliar a precisão das previsões realizadas pelos modelos nos conjuntos de treino e teste. De modo geral, os menores valores de RMSE e MAE indicam um desempenho superior na previsão.

As métricas **RMSE** e **MAE** desempenham um papel crucial na análise do desempenho dos modelos. O *Root Mean Squared Error* (RMSE) foi escolhido para capturar os grandes desvios de previsão, penalizando fortemente os erros maiores. Isso foi particularmente importante para identificar casos em que os modelos apresentaram falhas significativas, como no caso do **LSSVR**, que mostrou um bom desempenho no conjunto de treinamento, mas um erro elevado no conjunto de teste. Assim, o **RMSE** ajudou a detectar problemas de *overfitting*, onde o modelo estava ajustado excessivamente aos dados de treinamento, comprometendo sua capacidade de generalização.

O **MAE**, por outro lado, forneceu uma visão mais equilibrada do desempenho dos modelos, pois não penaliza os erros grandes de forma tão acentuada como o **RMSE**. Essa métrica foi útil para avaliar a consistência dos modelos em termos de erro médio, considerando tanto as pequenas quanto as grandes previsões erradas. O uso conjunto de **RMSE** e **MAE** permitiu uma análise robusta da capacidade de previsão dos modelos em diferentes cenários de usinagem, proporcionando uma visão detalhada tanto dos erros médios quanto das grandes discrepâncias, que são cruciais para otimizar o consumo de energia no processo de usinagem.

A análise dos resultados revela que o modelo LSSVR geralmente apresenta os menores valores de RMSE e MAE no conjunto de treino, indicando um bom ajuste aos dados de treinamento. No entanto, em diversos casos de teste, especialmente para os aços 4140/320 e 4340/116, observam-se aumentos significativos nos erros, o que sugere a ocorrência de *overfitting*.

Por outro lado, o modelo MLP-1HL apresenta um desempenho consistente em ambos os conjuntos de treino e teste, com uma diferença menos acentuada entre os erros, indicando uma maior capacidade de generalização em comparação com o LSSVR. No entanto, em situações específicas, como para o aço 1045/116, ainda são observados aumentos significativos de erro no teste, revelando desafios no ajuste do modelo às propriedades peculiares desse material.

O modelo MLP-2HL apresentou resultados intermediários entre os dois modelos anteriores, com uma redução visível dos erros em diferentes classes de aço, como 1020/320 e 4140/554. Isso sugere que o aumento na complexidade do modelo, proporcionado pelas camadas adicionais, pode ter contribuído para melhorar o desempenho preditivo em condições que apresentam maior variação nos dados.

Com base nas métricas de RMSE e MAE, as seguintes conclusões podem ser extraídas:

- O modelo **LSSVR** apresentou o melhor desempenho no conjunto de treino, com os menores valores

médios de erro. Entretanto, sua capacidade de generalização no conjunto de teste foi inferior, evidenciada por aumentos expressivos de erro em algumas classes.

- O modelo **MLP-1HL** apresentou um desempenho mais equilibrado, com diferenças menores entre os conjuntos de treino e teste, demonstrando-se mais robusto e menos suscetível ao fenômeno de *overfitting*.
- O modelo **MLP-2HL** exibiu uma melhora geral em relação ao MLP-1HL, especialmente em cenários com maior variação nos dados. Contudo, em alguns casos, os erros ainda foram mais elevados do que os observados para o LSSVR no conjunto de treino.

De forma geral, o modelo **MLP-1HL** foi o que melhor equilibrou precisão e capacidade de generalização, sendo a alternativa mais apropriada para cenários que exigem um desempenho consistente entre os conjuntos de treino e teste. Embora o modelo **LSSVR** tenha se destacado nos dados de treino, sua tendência ao *overfitting* compromete sua confiabilidade em aplicações industriais reais.

O modelo **MLP-2HL**, por sua vez, demonstrou ser uma alternativa promissora para cenários de maior complexidade, embora ainda requeira ajustes mais refinados nos hiperparâmetros para melhorar sua consistência em todas as classes de materiais testados.

Esses resultados evidenciam a importância de se avaliar os modelos não apenas pelo desempenho no conjunto de treino, mas também pela capacidade de generalização frente a novos dados. Em aplicações industriais, onde as variações operacionais são inevitáveis, o modelo **MLP-1HL** apresenta um equilíbrio mais vantajoso entre robustez e precisão. Futuros estudos podem explorar estratégias de ajuste de hiperparâmetros, além de técnicas como a *regularização* e a *validação cruzada* (*cross-validation*), a fim de mitigar os efeitos de *overfitting* observados no modelo **LSSVR** e otimizar o desempenho dos modelos de redes neurais profundas.

Tabela 12 – RMSE de Regressão para Diferentes Métodos e Configurações de Treino e Teste

Aço/Avanço	LSSVR		MLP 1 Hidden Layer		MLP 2 Hidden Layer	
	Treino	Teste	Treino	Teste	Treino	Teste
1020/116	2,37E-04	1,30E-03	8,58E-04	9,38E-04	9,18E-04	1,27E-03
1020/320	8,99E-05	1,40E-03	3,89E-04	3,95E-04	2,28E-04	4,32E-04
1020/554	7,77E-05	5,09E-04	2,02E-04	4,69E-04	2,09E-04	2,75E-04
1045/116	9,54E-04	8,43E-04	6,51E-04	1,33E-03	8,25E-04	1,65E-03
1045/320	3,81E-04	5,20E-04	1,21E-04	7,71E-04	1,50E-04	5,40E-04
1045/554	1,26E-04	7,25E-05	2,31E-04	2,52E-04	2,24E-04	1,95E-04
4140/116	4,98E-04	9,43E-04	9,16E-04	1,44E-03	2,76E-04	3,48E-04
4140/320	5,91E-04	4,10E-03	2,47E-04	3,35E-04	7,70E-04	1,36E-03
4140/554	2,28E-04	4,55E-04	2,17E-04	2,73E-04	2,19E-04	2,40E-04
4340/116	1,10E-03	1,80E-03	9,29E-04	1,23E-03	8,97E-04	1,20E-03
4340/320	4,06E-04	5,08E-04	2,65E-04	3,33E-04	2,53E-04	2,85E-04
4340/554	2,01E-04	5,23E-04	2,14E-04	2,07E-04	2,18E-04	2,31E-04
VC/116	7,73E-04	6,87E-04	8,81E-04	4,65E-04	9,36E-04	4,76E-04
VC/320	3,37E-04	1,20E-03	3,52E-04	2,36E-04	2,73E-04	7,41E-05
VC/554	1,53E-04	1,47E-04	2,43E-04	3,95E-04	1,62E-04	3,98E-04

Fonte: Elaborado pelo autor.

Tabela 13 – MAE de Regressão para Diferentes Métodos e Configurações de Treino e Teste

Aço/Avanço	LSSVR		MLP 1 Hidden Layer		MLP 2 Hidden Layer	
	Treino	Teste	Treino	Teste	Treino	Teste
1020/116	1.89E-04	1.04E-03	6.85E-04	7.49E-04	7.33E-04	1.01E-03
1020/320	7.17E-05	1.12E-03	3.10E-04	3.15E-04	1.82E-04	3.45E-04
1020/554	6.20E-05	4.06E-04	1.61E-04	3.74E-04	1.67E-04	2.19E-04
1045/116	7.61E-04	6.73E-04	5.20E-04	1.06E-03	6.58E-04	1.32E-03
1045/320	3.04E-04	4.15E-04	9.68E-05	6.15E-04	1.20E-04	4.31E-04
1045/554	1.01E-04	5.79E-05	1.84E-04	2.01E-04	1.79E-04	1.56E-04
4140/116	3.97E-04	7.53E-04	7.31E-04	1.15E-03	2.20E-04	2.78E-04
4140/320	4.72E-04	3.27E-03	1.97E-04	2.67E-04	6.15E-04	1.09E-03
4140/554	1.82E-04	3.63E-04	1.73E-04	2.18E-04	1.75E-04	1.92E-04
4340/116	8.78E-04	1.44E-03	7.41E-04	9.81E-04	7.16E-04	9.58E-04
4340/320	3.24E-04	4.05E-04	2.12E-04	2.66E-04	2.02E-04	2.27E-04
4340/554	1.60E-04	4.17E-04	1.71E-04	1.65E-04	1.74E-04	1.84E-04
VC/116	6.17E-04	5.49E-04	7.03E-04	3.71E-04	7.47E-04	3.80E-04
VC/320	2.69E-04	9.58E-04	2.81E-04	1.88E-04	2.18E-04	5.91E-05
VC/554	1.22E-04	1.17E-04	1.94E-04	3.15E-04	1.29E-04	3.18E-04

Fonte: Elaborado pelo autor.

5.3 Critérios para Avaliação de Modelos

A escolha das métricas de avaliação é essencial para compreender diferentes aspectos do desempenho dos modelos de regressão e classificação utilizados neste estudo. Para os modelos de regressão, as métricas *Root Mean Squared Error* (RMSE) e *Mean Absolute Error* (MAE) foram adotadas, permitindo quantificar o erro médio das previsões sob diferentes perspectivas. Já no contexto da classificação, foram empregadas métricas como precisão (*Accuracy*), *Positive Predictive Value* (PPV), Sensibilidade (*Recall*) e *F-Score*, possibilitando uma análise detalhada da performance preditiva em distintos cenários.

A Tabela 13 apresenta os valores de MAE obtidos para os modelos LSSVR, MLP-1HL e MLP-2HL, considerando diferentes configurações de avanço e tipos de aço. Esses resultados foram obtidos nos conjuntos de treino e teste, permitindo uma avaliação mais abrangente sobre a capacidade de generalização de cada modelo.

Os resultados indicam que o modelo LSSVR apresentou os menores valores de MAE no conjunto de treino, sugerindo um ajuste preciso aos dados de treinamento. No entanto, quando testado em novos dados, os erros aumentaram significativamente, especialmente para certos tipos de aço, como o 4140/320. Esse comportamento sugere um possível *overfitting*, ou seja, um modelo que se ajusta excessivamente aos padrões do conjunto de treino, mas apresenta dificuldades ao generalizar para novos dados.

Por outro lado, os modelos de rede neural, MLP-1HL e MLP-2HL, demonstraram um desempenho mais equilibrado entre treino e teste, o que indica uma maior capacidade de generalização. O modelo MLP-2HL, em particular, apresentou menor erro absoluto médio em cenários com maior variabilidade nos dados, reforçando sua robustez para diferentes condições operacionais.

A comparação entre MAE e RMSE reforça a importância de utilizar ambas as métricas na avaliação dos modelos de regressão. Como o RMSE penaliza erros extremos de forma mais severa, ele se torna mais adequado para cenários onde grandes desvios impactam diretamente a qualidade da previsão. Em contrapartida, o




Figura 5 – Desempenho dos estimadores no problema de aproximação de função com as amostras de teste para os aços 1020 (Fig. 5a), 1045 (Fig. 5b), 4140 (Fig. 5c), 4340 (Fig. 5d) e VC (Fig. 5e), respectivamente.

Fonte: Elaborado pelo autor.

MAE oferece uma visão mais estável e menos influenciada por valores discrepantes, sendo útil para avaliar a tendência geral do erro. Modelos que indicaram sinais de *overfitting* no RMSE, como o LSSVR, mantiveram esse padrão no MAE, embora com diferenças menos acentuadas entre treino e teste.

No contexto da classificação, a métrica de precisão (*Accuracy*) fornece uma visão geral do desempenho do modelo, mas pode ser insuficiente quando há desbalanceamento de classes. O PPV, por sua vez, permite avaliar a confiabilidade das previsões positivas, enquanto a Sensibilidade mede a capacidade do modelo de identificar corretamente todos os elementos de uma determinada classe. O *F-Score* combina esses dois aspectos, trazendo um equilíbrio necessário para cenários onde tanto falsos positivos quanto falsos negativos possuem impacto significativo.

A escolha dessas métricas foi guiada pela necessidade de capturar as nuances do desempenho dos modelos em diferentes contextos. Em aplicações industriais, como a otimização da eficiência energética na usinagem, garantir a precisão preditiva e minimizar desvios operacionais são fatores críticos para o sucesso da implementação. Dessa forma, o uso combinado de MAE e RMSE na regressão, aliado à análise detalhada das métricas de classificação, proporciona uma avaliação mais completa da eficácia dos modelos.

Para futuras pesquisas, recomenda-se explorar a utilização dessas métricas como critérios de otimização no treinamento dos modelos, visando alcançar um equilíbrio ideal entre robustez e precisão preditiva. Esse enfoque pode ser particularmente útil para lidar com variações operacionais em ambientes industriais, onde a adaptabilidade e a confiabilidade dos modelos desempenham um papel crucial na melhoria contínua dos processos de usinagem.

6 Conclusão

Este estudo teve como objetivo desenvolver uma abordagem inovadora baseada em aprendizado de máquina para a classificação de diferentes tipos de aço em processos de usinagem, utilizando dados coletados durante operações de torneamento. Além da identificação automatizada dos materiais usinados, a metodologia proposta incorporou técnicas de regressão para prever o consumo energético sob distintas condições operacionais, contribuindo para maior eficiência produtiva e redução de custos.

Diferentemente das pesquisas anteriores, que tratam separadamente a classificação de materiais e a modelagem de variáveis operacionais, este estudo integrou ambas as abordagens em um modelo unificado. A regressão permitiu estimar com precisão o consumo energético com base em variáveis mecânicas e elétricas do processo, enquanto a classificação possibilitou a identificação dos diferentes tipos de aço.

Essa combinação resultou em um controle mais preciso do processo, possibilitando ajustes dinâmicos para minimizar desperdícios e maximizar a eficiência. No contexto da Indústria 4.0, onde automação e Inteligência Artificial desempenham um papel essencial na otimização dos processos produtivos e na sustentabilidade industrial, essa abordagem representa um avanço significativo.

Os modelos foram avaliados por meio de experimentos rigorosos, garantindo que seu desempenho fosse analisado em condições realistas. Na tarefa de classificação, o *Perceptron Multicamadas* (MLP) demonstrou maior precisão, atingindo acurácia média de 94,64% e 95,52% para as versões com uma e duas camadas ocultas, respectivamente. Além disso, métricas como Valor Preditivo Positivo (PPV), sensibilidade e *F1-score* confirmaram a capacidade do modelo de capturar padrões complexos nos dados e se adaptar a diferentes condições operacionais. Já na regressão para previsão do consumo energético, os modelos MLP novamente se destacaram, obtendo os menores valores de *Root Mean Squared Error* (RMSE) em sete dos quinze cenários testados. Além disso, superaram a Regressão por Vetores de Suporte com Mínimos Quadrados (LSSVR) em doze dos quinze cenários, demonstrando maior precisão na modelagem do consumo de energia.

A seleção de atributos desempenhou um papel essencial na melhoria do desempenho dos modelos, permitindo a eliminação de variáveis irrelevantes ou redundantes. A análise de correlação indicou que os atributos tempo (t), avanço por rotação (a_f) e energia de corte (E_c) não contribuíam significativamente para a classificação dos tipos de aço e poderiam ser removidos sem prejuízo ao desempenho da maioria dos classificadores. Essa exclusão levou a um aumento expressivo da acurácia média dos modelos MLP, SVM e LSSVM, evidenciando que a escolha criteriosa dos atributos pode maximizar o desempenho dos algoritmos sem comprometer sua capacidade preditiva. No entanto, essa redução dimensional impactou negativamente os modelos OLS e *Naive Bayes Gaussiano*, demonstrando que a eliminação de variáveis deve considerar as especificidades de cada classificador.

A técnica de sobreamostragem sintética SMOTE foi aplicada para mitigar problemas de desbalanceamento no conjunto de dados, garantindo uma distribuição mais equitativa entre as classes e melhorando a capacidade dos modelos de identificar padrões distintos nos diferentes tipos de aço. Esse processo mostrou-se essencial para aprimorar a qualidade do aprendizado, permitindo que os modelos reconhecessem padrões de consumo energético de forma mais eficiente.

Apesar dos avanços alcançados, desafios ainda precisam ser superados para a implementação da metodologia

em um ambiente industrial real. Fatores como desgaste de ferramentas, variações no fornecimento de energia e oscilações nos parâmetros de corte podem impactar a precisão dos modelos ao longo do tempo. Assim, recomenda-se a realização de testes adicionais sob diferentes condições operacionais, garantindo a robustez dos modelos e sua capacidade de adaptação a cenários dinâmicos.

Futuras investigações podem explorar a adaptação da metodologia para uma gama mais ampla de materiais e processos de usinagem, incluindo fresamento e acabamento. A integração do aprendizado de máquina com sensores inteligentes possibilitaria a coleta contínua de variáveis operacionais, como vibração, temperatura e desgaste da ferramenta, permitindo ajustes automáticos dos parâmetros da máquina em tempo real. Essa adaptação não apenas aumentaria a eficiência energética do processo, mas também minimizaria falhas operacionais e reduziria custos.

Além disso, a incorporação de técnicas avançadas de otimização, como algoritmos genéticos e otimização por enxame de partículas, pode elevar ainda mais a eficácia dos modelos preditivos. Essas técnicas podem ser aplicadas na determinação automática dos parâmetros operacionais ideais, resultando em um controle mais preciso do consumo energético e no aumento da produtividade. A validação prática da metodologia em um ambiente industrial representa um passo essencial para consolidar o aprendizado de máquina como uma solução viável na otimização da usinagem. A implementação em uma linha de produção permitiria avaliar a robustez dos modelos diante de variações operacionais, como desgaste da ferramenta, mudanças na matéria-prima e flutuações nos parâmetros de corte.

A integração com sistemas de monitoramento industrial, como *Supervisory Control and Data Acquisition* (SCADA) e *Programmable Logic Controllers* (PLCs), poderia viabilizar a automação da tomada de decisões baseada nos modelos desenvolvidos. Essa automação reduziria a necessidade de intervenção manual e aumentaria a eficiência operacional, promovendo um controle mais inteligente sobre os processos produtivos e garantindo um fluxo de trabalho mais sustentável.

Os resultados obtidos demonstram que a abordagem integrada de classificação e regressão proposta neste estudo representa uma inovação significativa no contexto da usinagem. A inexistência de trabalhos anteriores que combinem essas duas técnicas simultaneamente reforça a relevância desta pesquisa. A classificação permitiu identificar automaticamente os materiais envolvidos na usinagem, enquanto a regressão viabilizou a previsão do consumo energético, possibilitando ajustes dinâmicos no processo. Essa metodologia amplia as possibilidades de otimização na manufatura industrial, fornecendo um modelo mais abrangente e eficiente para o controle inteligente de processos de usinagem.

Por fim, a combinação do aprendizado de máquina com sistemas inteligentes de monitoramento pode transformar significativamente a manufatura moderna. A adoção de modelos preditivos robustos pode proporcionar maior precisão, redução de desperdícios e economia de recursos, alinhando-se às diretrizes da Indústria 4.0. Espera-se que os avanços alcançados neste estudo contribuam para o desenvolvimento de processos industriais mais eficientes, sustentáveis e tecnologicamente avançados, consolidando a aplicação de Inteligência Artificial como um diferencial competitivo na manufatura.

Referências

- ABDELAOUI, F. Z. E.; JABRI, A.; BARKANY, A. E. Optimization techniques for energy efficiency in machining processes—a review. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 125, n. 7, p. 2967–3001, 2023. Disponível em: <<https://doi.org/10.1007/s00170-023-10927-y>>. Acesso em: 17 ago. 2024. Citado 7 vezes nas páginas 21, 22, 23, 31, 32, 37 e 74.
- ABU-MAHFOUZ, I. et al. Surface roughness prediction as a classification problem using support vector machine. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 92, p. 803–815, 2017. Disponível em: <<https://doi.org/10.1007/s00170-017-0165-9>>. Acesso em: 9 fev. 2025. Citado na página 23.
- ALMEIDA, F. A. et al. A weighted mean square error approach to the robust optimization of the surface roughness in an aisi 12l14 free-machining steel-turning process. *Journal of Mechanical Engineering*, v. 64, n. 3, p. 147–156, 2018. Citado 2 vezes nas páginas 26 e 29.
- ALSAWALQAH, H. et al. Hybrid smote-ensemble approach for software defect prediction. In: *COMPUTER SCIENCE ON-LINE CONFERENCE, 6., 2017, Cham. Proceedings*. Cham: Springer International Publishing, 2017. (Software Engineering Trends and Techniques in Intelligent Systems: Proceedings of the 6th Computer Science On-line Conference 2017 (CSOC2017), Vol 3), p. 355–366. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-319-57141-6_39>. Acesso em: 17 ago. 2024. Citado na página 45.
- APOSTOLOS, F. et al. Energy efficiency of manufacturing processes: a critical review. *Procedia CIRP*, Elsevier, Amsterdã, Países Baixos, v. 7, p. 628–633, 2013. Disponível em: <<https://doi.org/10.1016/j.procir.2013.06.044>>. Acesso em: 11 nov. 2024. Citado na página 14.
- ARRIAZA, O. V. et al. Trade-off analysis between machining time and energy consumption in impeller nc machining. *Robotics and Computer-Integrated Manufacturing*, Elsevier, v. 43, p. 164–170, 2017. Disponível em: <<https://doi.org/10.1016/j.rcim.2015.09.014>>. Acesso em: 15 fev. 2024. Citado 2 vezes nas páginas 15 e 54.
- BAPTISTA, A. L. d. B. Aspectos metalúrgicos na avaliação da usinabilidade de aços. *Rem: Revista Escola de Minas*, Ouro Preto, v. 55, n. 2, p. 67–72, apr 2002. Disponível em: <<https://doi.org/10.1590/S0370-44672002000200006>>. Acesso em: 26 mai. 2024. Citado na página 33.
- BAYES, T. An essay towards solving a problem in the doctrine of chances. *Philosophical Transactions of the Royal Society of London*, London, United Kingdom, v. 53, p. 370–418, 1763. Disponível em: <<https://doi.org/10.1098/rstl.1763.0053>>. Acesso em: 03 out. 2024. Citado 3 vezes nas páginas 29, 50 e 53.
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. Berlin, Heidelberg: Springer-Verlag, 2006. (Information Science and Statistics). ISBN 978-0387310732. Citado 3 vezes nas páginas 50, 54 e 55.
- BORBA, H. H. P. d. S.; ALBUQUERQUE, W. L. L. d. Tendências e desafios da implementação da inteligência artificial nas empresas. *Revista Ciências Humanas*, v. 28, n. 133, 2024. Acesso em: 20 fev. 2025. Disponível em: <<https://revistaft.com.br/tendencias-e-desafios-da-implementacao-da-inteligencia-artificial-nas-empresas/>>. Citado 2 vezes nas páginas 22 e 31.
- BROCKWAY, P. E. et al. Energy efficiency and economy-wide rebound effects: A review of the evidence and its implications. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 141, p. 110781, 2021. Disponível em: <<https://doi.org/10.1016/j.rser.2021.110781>>. Acesso em: 17 fev. 2024. Citado 2 vezes nas páginas 14 e 15.
- BROWNLEE, J. *A Gentle Introduction to k-Fold Cross-Validation*. 2019. Acesso em: 23 fev. 2025. Disponível em: <<https://machinelearningmastery.com/k-fold-cross-validation/>>. Citado na página 61.
- CAETANO, R. G. D. *Influência dos parâmetros de corte na eficiência energética em processos de usinagem por torneamento*. Dissertação (Mestrado) — Federal Institute of Science and Technology of Ceará (IFCE), Maracanaú, Ceará, August 2019. Citado na página 38.

- CALi, M. et al. An accurate roughness prediction in milling processes through analytical evaluation and knn regression approach. *The International Journal of Advanced Manufacturing Technology*, Springer-Verlag London Ltd., Online First, p. 1–20, 2024. Disponível em: <<https://doi.org/10.1007/s00170-024-14526-3>>. Acesso em: 29 jan. 2025. Citado 2 vezes nas páginas 25 e 29.
- CAO, L.; TAY, F. E. Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on Neural Networks*, v. 14, n. 6, p. 1506–1518, 2003. Citado na página 51.
- CASTANHEIRA, N. P. *Métodos quantitativos*. Brasil: Editora Intersaberes, 2013. Citado na página 53.
- CHAI, T.; DRAXLER, R. R. Root mean square error (*RMSE*) or mean absolute error (*MAE*)? – arguments against avoiding rmse in the literature. *Geoscientific Model Development*, v. 7, n. 3, p. 1247–1250, 2014. Citado 2 vezes nas páginas 58 e 59.
- CHAWLA, N. V. Special issue on learning from imbalanced data sets. *SIGKDD Explorations*, v. 6, n. 1, p. 1–6, 2004. Disponível em: <<https://doi.org/10.1145/1007730.1007733>>. Acesso em: 20 fev. 2024. Citado 2 vezes nas páginas 55 e 56.
- CHAWLA, N. V. et al. Smote: synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, v. 16, p. 321–357, 2002. Disponível em: <<https://doi.org/10.1613/jair.953>>. Acesso em: 20 fev. 2024. Citado 3 vezes nas páginas 44, 45 e 62.
- CHEN, J. et al. Predicting surface roughness in turning complex-structured workpieces using vibration-signal-based gaussian process regression. *Sensors*, MDPI, v. 24, p. 2117, 2024. Disponível em: <<https://doi.org/10.3390/s24072117>>. Acesso em: 24 set. 2024. Citado na página 29.
- CHEN, Y. Integrated and intelligent manufacturing: Perspectives and enablers. *Engineering*, Elsevier, v. 3, n. 5, p. 588–595, 2017. Disponível em: <<https://doi.org/10.1016/J.ENG.2017.04.009>>. Acesso em 16 ago. 2024. Citado 2 vezes nas páginas 21 e 23.
- CHENG, J. et al. Adaptive ccr-elm with variable-length brain storm optimization algorithm for class-imbalance learning. *Natural Computing*, Springer, v. 20, p. 11–22, 2021. Disponível em: <<https://doi.org/10.1007/s11047-019-09735>>. Acesso em: 23 fev. 2024. Citado na página 45.
- CHENG, M. et al. Prediction and evaluation of surface roughness with hybrid kernel extreme learning machine and monitored tool wear. *Journal of Manufacturing Processes*, Elsevier, v. 84, p. 1541–1556, 2022. Disponível em: <<https://doi.org/10.1016/j.jmapro.2022.10.072>>. Acesso em: 29 jan. 2025. Citado na página 24.
- CHUANG, C.-C.; LEE, Z.-J. Hybrid robust support vector machines for regression with outliers. *Applied Soft Computing*, Elsevier, v. 11, n. 1, p. 64–72, 2011. Citado na página 37.
- CHUANG, C.-C. et al. Robust support vector regression networks for function approximation with outliers. *Neural Networks, IEEE Transactions on*, IEEE, v. 13, n. 6, p. 1322–1330, 2002. Citado na página 37.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, v. 20, p. 273–297, 1995. Disponível em: <https://ise.ncsu.edu/wp-content/uploads/sites/9/2022/08/Cortes-Vapnik1995_Article_Support-vectorNetworks.pdf>. Acesso em: 20 fev. 2024. Citado 2 vezes nas páginas 29 e 54.
- COSTA, D. M. D.; BELINATO, G.; FERREIRA, J. C. de O. Relação entre custo de energia e modalidade tarifária em um processo de usinagem de aço endurecido com ferramenta com geometria wiper usando metodologia de superfície de resposta. In: *Anais do XXXVII Encontro Nacional de Engenharia de Produção*. Joinville, Brasil: [s.n.], 2017. Acessado em: 5 mar. 2025. Disponível em: <https://www.abepro.org.br/biblioteca/TN_WPG_228_331_29887.pdf>. Citado na página 16.
- COVER, T.; HART, P. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, IEEE, v. 13, n. 1, p. 21–27, 1967. Disponível em: <<https://ieeexplore.ieee.org/document/1053964>>. Acesso em: 07 ago. 2024. Citado 2 vezes nas páginas 50 e 52.

- DALE, A. I. Thomas bayes, an essay towards solving a problem in the doctrine of chances (1764). In: GRATTAN-GUINNESS, I. (Ed.). *Landmark Writings in Western Mathematics 1640-1940*. Amsterdã, Países Baixos: Elsevier, 2005. p. 199–207. Citado na página 53.
- DATA CAMP. *O que é uma matriz de confusão no aprendizado de máquina*. 2025. Acesso em: 3 mar. 2025. Disponível em: <<https://www.datacamp.com/pt/tutorial/what-is-a-confusion-matrix-in-machine-learning>>. Citado na página 57.
- DAVIS, J.; GOADRICH, M. The relationship between precision-recall and roc curves. In: *Proceedings of the 23rd International Conference on Machine Learning (ICML)*. Pittsburgh, PA, United States: ACM, 2006. p. 233–240. Disponível em: <<https://doi.org/10.1145/1143844.1143874>>. Acesso em: 21 fev. 2024. Citado na página 55.
- DENG, S.; YEH, T.-H. Using least squares support vector machines for the airframe structures manufacturing cost estimation. *International Journal of Production Economics*, Elsevier, v. 131, n. 2, p. 701–708, 2011. Disponível em: <<https://doi.org/10.1016/j.ijpe.2011.02.019>>. Acesso em: 25 jan. 2025. Citado na página 23.
- DENKANA, B. et al. Energy efficient machine tools. *CIRP Annals*, v. 69, n. 2, p. 646–667, 2020. Disponível em: <<https://doi.org/10.1016/j.cirp.2020.05.008>>. Acesso em: 23 set. 2024. Citado na página 16.
- DOMINGOS, P.; PAZZANI, M. On the optimality of the simple bayesian classifier under zero-one loss. In: *Machine Learning*. [s.n.], 1997. v. 29, p. 103–130. Acesso em: 01 mar. 2025. Disponível em: <<https://doi.org/10.1023/A:1007413511361>>. Citado na página 50.
- DORIGO, M.; BIRATTARI, M.; STUTZLE, T. Ant colony optimization. *IEEE Computational Intelligence Magazine*, IEEE, v. 1, n. 4, p. 28–39, 2006. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4129846>>. Acesso em: 23 set. 2024. Citado 2 vezes nas páginas 24 e 30.
- DRAPER, N. R.; SMITH, H. *Applied Regression Analysis*. 3. ed. New York, USA: John Wiley Sons, 1998. Citado na página 50.
- DRUCKER, H. et al. Support vector regression machines. *Advances in Neural Information Processing Systems*, v. 9, p. 155–161, 1997. Citado na página 51.
- DUARTE, L. M. et al. A novel approach based on pattern recognition techniques to evaluate magnetic properties of a non-grain oriented electrical steel in the secondary recrystallization process. *Measurement*, Elsevier, v. 167, p. 108135, 2021. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.108135>>. Acesso em: 22 fev. 2024. Citado na página 45.
- DUBOIS, D. J. *Fuzzy Sets and Systems: Theory and Applications*. New York: Academic Press, 1980. v. 144. Citado na página 30.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern Classification*. 2nd. ed. New York, USA: John Wiley & Sons, 2001. Citado na página 52.
- DUFRENOIS, F.; COLLIEZ, J.; HAMAD, D. Weighted support vector regression for robust single model estimation: application to motion segmentation in image sequences. In: *IEEE. Neural Networks, 2007. IJCNN 2007. International Joint Conference on*. Orlando, FL, USA, 2007. p. 586–591. Citado na página 37.
- EL-HOFY, H. *Fundamentals of Machining Processes: Conventional and Nonconventional Processes*. 3. ed. Boca Raton: CRC Press, 2018. 602 p. ISBN 9780429443329. Citado 3 vezes nas páginas 32, 33 e 37.
- FAHLE, S.; PRINZ, C.; KUHLENKÖTTER, B. Systematic review on machine learning (ml) methods for manufacturing processes – identifying artificial intelligence (ai) methods for field application. *Procedia CIRP*, v. 93, p. 413–418, 2020. Disponível em: <<https://doi.org/10.1016/j.procir.2020.04.109>>. Acesso em: 3 mar. 2024. Citado na página 16.
- FENG, C. et al. Feature-based optimization method integrating sequencing and cutting parameters for minimizing energy consumption of cnc machine tools. *The International Journal of Advanced Manufacturing Technology*, v. 121, n. 1, p. 503–515, 2022. Disponível em: <<https://link.springer.com/article/10.1007/s00170-022-09340-8>>. Acesso em: 16 ago. 2024. Citado 2 vezes nas páginas 24 e 30.

- FERIOTTI, M. A. et al. Melhoria do processo de fresamento de dentes de engrenagem: estudo de caso em uma pequena empresa. *Brazilian Journal of Production Engineering*, v. 9, n. 2, p. 127–142, 2023. Acesso em: 22 fev. 2025. Disponível em: <<https://periodicos.ufes.br/bjpe/article/view/39929>>. Citado na página 21.
- FERNANDEZ, A. et al. *Learning from Imbalanced Data Sets*. Cham, Switzerland: Springer, 2018. Citado 3 vezes nas páginas 16, 46 e 55.
- FERNÁNDEZ, A. et al. A review on big data learning in feature selection. *Information Fusion*, v. 23, p. 1–24, 2014. Citado na página 51.
- FILHO, M. L. O. *A utilização da regressão linear como ferramenta estratégica para a projeção dos custos de produção*. Brasil: [s.n.], 2014. Acesso em: 2 mar. 2025. Disponível em: <<https://anaiscbc.abcustos.org.br/anais/article/view/2762>>. Citado na página 53.
- FINGERHUT, F. et al. Data-driven usage profiling and anomaly detection in support of sustainable machining processes. In: *2022 IEEE International Conference on Data Mining Workshops (ICDMW)*. Orlando, FL, United States: IEEE, 2022. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=10031154>>. Acesso em: 23 set. 2024. Citado na página 69.
- FIX, E. *Discriminatory Analysis: Nonparametric Discrimination, Consistency Properties*. Randolph Field, Texas: [s.n.], 1985. v. 1. Citado 2 vezes nas páginas 29 e 49.
- FLETCHER, R. *Practical Methods of Optimization*. Chichester, United Kingdom: John Wiley & Sons, 2013. Citado na página 50.
- GARCÍA, V.; MOLLINEDA, R. A.; SÁNCHEZ, J. S. On the k-nn performance in a challenging scenario of imbalance and overlapping. *Pattern Analysis and Applications*, Springer, London, UK, v. 11, n. 3-4, p. 269–280, 2008. Acesso em: 02 mar. 2025. Disponível em: <<https://link.springer.com/article/10.1007/s10044-007-0087-5>>. Citado na página 52.
- GENG, D.; EVANS, S.; KISHITA, Y. The identification and classification of energy waste for efficient energy supervision in manufacturing factories. *Renewable and Sustainable Energy Reviews*, v. 182, p. 113409, 2023. Disponível em: <<https://doi.org/10.1016/j.rser.2023.113409>>. Acesso em: 04 mar. 2024. Citado na página 16.
- GHORBANIOSKALAEI, E. et al. On the use of agile optimization for efficient energy consumption in smart cities' transportation and mobility. *Future Transportation*, v. 2, n. 4, p. 868–885, 2022. Disponível em: <<https://doi.org/10.3390/futuretransp2040048>>. Acesso em: 24 set. 2024. Citado na página 15.
- GONG, C.; GU, L. A novel smote-based classification approach to online data imbalance problem. *Mathematical Problems in Engineering*, Nova Iorque, EUA, 2016. Disponível em: <<https://doi.org/10.1155/2016/5685970>>. Acesso em: 03 out. 2024. Citado na página 45.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. Disponível em: <<https://www.deeplearningbook.org>>. Citado 3 vezes nas páginas 43, 48 e 49.
- GOODFELLOW, I. et al. Generative adversarial networks. In: *Advances in Neural Information Processing Systems (NeurIPS)*. Montreal, Canadá: [s.n.], 2014. v. 27. Acesso em: 28 fev. 2025. Disponível em: <<https://proceedings.neurips.cc/paper/2014/file/5ca3e9b122f61f8f06494c97b1afccf3-Paper.pdf>>. Citado 2 vezes nas páginas 45 e 46.
- GREENE, W. H. *Econometric Analysis*. 8. ed. Nova Iorque, EUA: Pearson, 2018. Citado na página 53.
- GROOVER, M. P. *Introduction to Manufacturing Processes*. Hoboken, NJ, United States: Wiley, 2012. 720 p. ISBN 9781118213629. Citado 3 vezes nas páginas 32, 33 e 36.
- GROOVER, M. P. *Fundamentals of Modern Manufacturing: Materials, Processes, and Systems*. 7. ed. Hoboken, NJ, United States: Wiley, 2019. ISBN 978-1119475219. Citado 4 vezes nas páginas 21, 32, 33 e 37.

- GUPTA, M. K. et al. Comparison of tool wear, surface morphology, specific cutting energy and cutting temperature in machining of titanium alloys under hybrid and green cooling strategies. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 2023. Disponível em: <<https://doi.org/10.1007/s40684-023-00512-9>>. Acesso em: 05 mar. 2024. Citado na página 33.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 2. ed. Sebastopol, CA, USA: O'Reilly Media, 2019. Disponível em: <<https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/>>. Citado na página 48.
- HAN, S. et al. Classification and regression models of audio and vibration signals for machine state monitoring in precision machining systems. *Journal of Manufacturing Systems*, Amsterdam, Netherlands, v. 61, p. 45–53, 2021. Disponível em: <<https://doi.org/10.1016/j.jmsy.2021.08.004>>. Acesso em: 15 abr. 2024. Citado na página 69.
- HARIK, R.; WUEST, T. *Introduction to Advanced Manufacturing*. Hoboken, NJ, United States: Wiley, 2019. 46 p. ISBN 9781119998128. Citado 2 vezes nas páginas 32 e 37.
- HASHMI, A. W. et al. Artificial intelligence techniques for implementation of intelligent machining. *Materials Today: Proceedings*, Amsterdam, Netherlands, v. 56, p. 1947–1955, 2022. Disponível em: <<https://doi.org/10.1016/j.matpr.2021.11.277>>. Acesso em: 17 ago. 2024. Citado 3 vezes nas páginas 23, 29 e 72.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2. ed. New York, United States: Springer, 2009. Citado 3 vezes nas páginas 50, 52 e 54.
- HAWKINS, D. M. *Identification of Outliers*. Dordrecht: Springer, 1980. Citado na página 58.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Upper Saddle River, NJ, United States: Prentice Hall PTR, 1998. Citado 3 vezes nas páginas 21, 27 e 29.
- HE, H. et al. Adasyn: Adaptive synthetic sampling approach for imbalanced learning. In: *Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN)*. Hong Kong, China: [s.n.], 2008. p. 1322–1328. Acesso em: 28 fev. 2025. Disponível em: <<https://ieeexplore.ieee.org/document/4633969>>. Citado na página 45.
- HE, H.; GARCIA, E. A. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, Piscataway, NJ, United States, v. 21, n. 9, p. 1263–1284, 2009. Disponível em: <<https://doi.org/10.1109/TKDE.2008.239>>. Acesso em: 24 set. 2024. Citado 3 vezes nas páginas 54, 55 e 56.
- HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor, MI, United States: University of Michigan Press, 1975. Reviewed by J.R. Sampson. Citado 2 vezes nas páginas 24 e 30.
- HOU, W. et al. Deep features based on a dcnn model for classifying imbalanced weld flaw types. *Measurement*, Elsevier, Amsterdam, Netherlands, v. 131, p. 482–489, 2019. Disponível em: <<https://doi.org/10.1016/j.measurement.2018.09.011>>. Acesso em: 04 abr. 2024. Citado na página 45.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: *Proceedings of the 2004 IEEE International Joint Conference on Neural Networks (IJCNN)*. Budapest, Hungary: IEEE, 2004. v. 2, p. 985–990. Data da conferência: 25-29 jul. 2004. Adicionado ao IEEE Xplore em: 17 jan. 2005. Print ISBN: 0-7803-8359-1. Print ISSN: 1098-7576. Disponível em: <<https://doi.org/10.1109/IJCNN.2004.1380068>>. Acesso em: 04 abr. 2024. Citado na página 52.
- HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: Theory and applications. *Neurocomputing*, v. 70, n. 1-3, p. 489–501, 2006. Disponível em: <<https://doi.org/10.1016/j.neucom.2005.12.126>>. Acesso em: 29 jan. 2025. Citado 4 vezes nas páginas 24, 29, 49 e 52.
- HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, v. 22, n. 4, p. 679–688, 2006. Citado na página 58.

- IBM. *O que é uma matriz de confusão?* 2025. Acesso em: 3 mar. 2025. Disponível em: <<https://www.ibm.com/br-pt/topics/confusion-matrix>>. Citado na página 57.
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). *Emissions Trends and Drivers*. Cambridge, United Kingdom: Cambridge University Press, 2023. 215–294 p. Disponível em: <<https://keneamazon.net/Documents/Publications/Virtual-Library/Impacto/157.pdf>>. Acesso em: 18 ago. 2024. Citado na página 16.
- INTERNATIONAL ENERGY AGENCY. *Energy System Industry*. 2022. Disponível em: <<https://www.iea.org/energy-system/industry>>. Acesso em: 05 nov. 2023. Citado na página 15.
- INTERNATIONAL ENERGY AGENCY. *World Energy Outlook 2023*. 2023. Disponível em: <<https://www.iea.org/reports/world-energy-outlook-2023>>. Acesso em: 18 ago. 2024. Citado na página 14.
- ISHAQ, A. et al. Improving the prediction of heart failure patients' survival using smote and effective data mining techniques. *IEEE Access*, IEEE, Piscataway, NJ, United States, v. 9, p. 39707–39716, 2021. Disponível em: <<https://doi.org/10.1109/ACCESS.2021.3064084>>. Acesso em: 07 abr. 2024. Citado na página 45.
- JAIN, V. K. *Advanced Machining Processes*. Boca Raton, FL, United States: CRC Press, 2022. 600 p. ISBN 9781482211108. Citado na página 33.
- JANG, J.-S. R. Anfis: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, v. 23, n. 3, p. 665–685, 1993. Citado na página 26.
- JIA, S. et al. Multi-objective optimization of cnc turning process parameters considering transient-steady state energy consumption. *Sustainability*, MDPI, Basel, Switzerland, v. 13, n. 24, p. 13803, 2021. Disponível em: <<https://doi.org/10.3390/su132413803>>. Acesso em: 05 mar. 2024. Citado na página 14.
- JIANG, X.; LI, S. Bas: Beetle antennae search algorithm for optimization problems. *arXiv preprint arXiv:1710.10724*, Ithaca, NY, United States, 2017. Disponível em: <<https://arxiv.labs.arxiv.org/html/1710.10724>>. Acesso em: 24 set. 2024. Disponível em: <<https://arxiv.labs.arxiv.org/html/1710.10724>>. Citado 2 vezes nas páginas 25 e 30.
- JIMÉNEZ, J. C. et al. Energy consumption analysis of machining centers using bayesian analysis and genetic optimization. *arXiv preprint arXiv:2207.05243*, 2022. Disponível em: <<https://arxiv.org/abs/2207.05243>>. Citado 2 vezes nas páginas 14 e 16.
- JINDAL, A. et al. Decision tree and svm-based data analytics for theft detection in smart grid. *IEEE Transactions on Industrial Informatics*, IEEE, v. 12, n. 3, p. 1005–1016, 2016. Acessado em: 22 de fevereiro de 2025. Disponível em: <<https://ieeexplore.ieee.org/document/7307138>>. Citado na página 29.
- JOACHIMS, T. Text categorization with support vector machines: Learning with many relevant features. *European Conference on Machine Learning (ECML)*, p. 137–142, 1998. Citado na página 51.
- JONES, M.; FERREIRA, P. Vibration analysis for material classification in turning processes. *International Journal of Precision Engineering and Manufacturing*, New York, USA, v. 21, p. 305–319, 2020. Disponível em: <<https://doi.org/10.1007/s12541-020-00123-5>>. Citado 2 vezes nas páginas 69 e 70.
- KALPAKJIAN, S.; SCHMID, S. *Manufacturing Engineering and Technology*. Boston, MA, United States: Pearson Education, 2021. 1313 p. Formato: Livro digital. Disponível em: <<https://www.pearson.com>>. Acesso em: 24 out. 2024. ISBN 9781292422299. Citado 3 vezes nas páginas 21, 32 e 36.
- KAUFMAN, S. et al. Leakage in data mining: Formulation, detection, and avoidance. *ACM Transactions on Knowledge Discovery from Data*, v. 6, n. 4, p. 1–21, 2012. Disponível em: <<https://dl.acm.org/doi/10.1145/2382577.2382579>>. Citado na página 44.
- KIM, D.-H. et al. Smart machining process using machine learning: A review and perspective on machining industry. *International Journal of Precision Engineering and Manufacturing-Green Technology*, Seoul, South Korea, v. 5, p. 555–568, 2018. Disponível em: <<https://link.springer.com/article/10.1007/s40684-018-0057-y>>. Acesso em: 12 abr. 2024. Citado 3 vezes nas páginas 23, 29 e 31.

- KNIGHT, W. A.; BOOTHROYD, G. *Fundamentals of Metal Machining and Machine Tools*. Boca Raton, FL, United States: Taylor & Francis, 2019. 602 p. Formato: Livro digital. Disponível em: <<https://www.taylorandfrancis.com>>. Acesso em: 12 abr. 2024. ISBN 9781420056303. Citado 2 vezes nas páginas 32 e 37.
- KOMOTO, H.; HERRERA, G.; HERWAN, J. An evolvable model of machine tool behavior applied to energy usage prediction. *CIRP Annals*, Amsterdam, Netherlands, v. 69, n. 1, p. 129–132, 2020. Disponível em: <<https://doi.org/10.1016/j.cirp.2020.04.082>>. Acesso em: 24 set. 2024. Citado 2 vezes nas páginas 25 e 29.
- KUHN, M.; JOHNSON, K. *Applied Predictive Modeling*. New York, NY, United States: Springer, 2013. ISBN 978-1461468486. Citado na página 54.
- KUMAR, P.; JAIN, N. K. Surface roughness prediction in micro-plasma transferred arc metal additive manufacturing process using k-nearest neighbors algorithm. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 119, n. 5, p. 2985–2997, 2022. Disponível em: <<https://doi.org/10.1007/s00170-021-08639-2>>. Acesso em: 28 jan. 2025. Citado 2 vezes nas páginas 26 e 29.
- KUMAR, R.; SINGH, A. Neural network applications in machining processes: A review. *International Journal of Machine Learning*, 2022. Citado na página 25.
- KUMARI, R.; SINGH, J.; GOSAIN, A. Sms: Smote-stacked hybrid model for diagnosis of polycystic ovary syndrome using feature selection method. *Expert Systems with Applications*, Elsevier, Amsterdam, Netherlands, v. 225, p. 120102, 2023. Disponível em: <<https://doi.org/10.1016/j.eswa.2023.120102>>. Acesso em: 24 abr. 2024. Citado na página 45.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado 3 vezes nas páginas 25, 30 e 49.
- LEE, Y. O.; JO, J.; HWANG, J. Application of deep neural network and generative adversarial network to industrial maintenance: A case study of induction motor fault detection. In: IEEE. *2017 IEEE International Conference on Big Data (Big Data)*. Boston, MA, United States: IEEE, 2017. p. 3248–3253. Disponível em: <<https://doi.org/10.1109/BigData.2017.8258298>>. Acesso em: 24 maio. 2024. Citado na página 45.
- LEGENDRE, A.-M. *Nouvelles Méthodes pour la Détermination des Orbites des Comètes*. Paris: Firmin Didot, 1805. Citado 3 vezes nas páginas 29, 50 e 53.
- LI, J. et al. Adaptive swarm balancing algorithms for rare-event prediction in imbalanced healthcare data. *PLOS ONE*, Public Library of Science, San Francisco, CA, United States, v. 12, n. 7, p. e0180830, 2017. Disponível em: <<https://doi.org/10.1371/journal.pone.0180830>>. Acesso em: 12 mai. 2024. Citado na página 45.
- LI, L. et al. The data learning and anomaly detection based on the rudder system testing facility. *Measurement*, Elsevier, Amsterdam, Netherlands, v. 152, p. 107324, 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2019.107324>>. Acesso em: 17 maio 2024. Citado na página 45.
- LIU, R. et al. Synthetic minority image over-sampling technique: How to improve auc for glioblastoma patient survival prediction. In: IEEE. *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. Banff, Canada, 2017. p. 1357–1362. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8122802>>. Acesso em: 18 mai. 2024. Citado na página 45.
- MANYIKA, J.; BUGHIN, J. *As promessas e os desafios da era da inteligência artificial*. 2018. Acesso em: 20 fev. 2025. Disponível em: <<https://www.mckinsey.com/featured-insights/artificial-intelligence/the-promise-and-challenge-of-the-age-of-artificial-intelligence/pt-BR>>. Citado 2 vezes nas páginas 22 e 31.
- MITCHELL, T. M. *Machine Learning*. New York, United States: McGraw-Hill, 1997. ISBN 978-0070428072. Citado na página 54.

- MOLINA, L. M.; TETI, R.; ALVIR, E. M. R. Quality, efficiency and sustainability improvement in machining processes using artificial intelligence. *Procedia CIRP*, Amsterdam, Netherlands, v. 118, p. 501–506, 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212827123003104>>. Acesso em: 17 ago. 2024. Citado 8 vezes nas páginas 22, 23, 24, 25, 27, 29, 30 e 31.
- MOREIRA, L. C. et al. Energy-efficient machining process analysis and optimisation based on bs en24t alloy steel as case studies. *Robotics and Computer-Integrated Manufacturing*, Elsevier, Amsterdam, Netherlands, v. 58, p. 1–12, 2019. Disponível em: <<https://doi.org/10.1016/j.rcim.2019.01.011>>. Acesso em: 24 ago. 2024. Citado na página 15.
- MOREIRA, L. C. et al. Supervision controller for real-time surface quality assurance in cnc machining using artificial intelligence. *Computers & Industrial Engineering*, Amsterdam, Netherlands, v. 127, p. 158–168, 2019. Disponível em: <<https://doi.org/10.1016/j.cie.2018.12.016>>. Acesso em: 20 ago. 2024. Citado na página 30.
- MOTTA, M. P. et al. Machine learning models for surface roughness monitoring in machining operations. *Procedia CIRP*, Amsterdam, Netherlands, v. 108, p. 710–715, 2022. Disponível em: <<https://doi.org/10.1016/j.procir.2022.03.110>>. Acesso em: 21 set. 2024. Citado na página 29.
- MUJA, M.; LOWE, D. G. Scalable nearest neighbor algorithms for high dimensional data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 11, p. 2227–2240, 2014. Acesso em: 2 mar. 2025. Disponível em: <<https://www.cs.ubc.ca/~lowe/papers/14mujaPAMI.pdf>>. Citado na página 53.
- MYPATI, O. et al. A critical review on applications of artificial intelligence in manufacturing. *Artificial Intelligence Review*, Amsterdam, Netherlands, v. 56, n. Suppl 1, p. 661–768, 2023. Disponível em: <<https://doi.org/10.1007/s10462-023-10535-y>>. Acesso em: 17 ago. 2024. Citado 4 vezes nas páginas 23, 25, 29 e 30.
- NARCISO, D. A.; MARTINS, F. G. Application of machine learning tools for energy efficiency in industry: A review. *Energy Reports*, Amsterdam, Netherlands, v. 6, p. 1181–1199, 2020. Disponível em: <<https://doi.org/10.1016/j.egyr.2020.07.007>>. Acesso em: 20 ago. 2024. Citado 2 vezes nas páginas 16 e 74.
- NAWAZ, M. A. et al. Trilemma association of energy consumption, carbon emission, and economic growth of brics and oecd regions: quantile regression estimation. *Environmental Science and Pollution Research*, Heidelberg, Germany, v. 28, p. 16014–16028, 2021. Disponível em: <<https://doi.org/10.1007/s11356-020-11823-8>>. Acesso em: 20 ago. 2024. Citado 2 vezes nas páginas 14 e 15.
- NISHANT, R.; KENNEDY, M.; CORBETT, J. Artificial intelligence for sustainability: Challenges, opportunities, and a research agenda. *International Journal of Information Management*, v. 53, p. 102104, 2020. Disponível em: <<https://doi.org/10.1016/j.ijinfomgt.2020.102104>>. Acesso em: 08 nov. 2024. Citado na página 15.
- ÖZDEMİR, A.; POLAT, K.; ALHUDHAIF, A. Classification of imbalanced hyperspectral images using smote-based deep learning methods. *Expert Systems with Applications*, Elsevier, Amsterdam, Netherlands, v. 178, p. 114986, 2021. Disponível em: <<https://doi.org/10.1016/j.eswa.2021.114986>>. Acesso em: 22 ago. 2024. Citado na página 45.
- PARK, H.-S.; NGUYEN, T.-T.; DANG, X.-P. Multi-objective optimization of turning process of hardened material for energy efficiency. *International Journal of Precision Engineering and Manufacturing*, Seoul, South Korea, v. 17, p. 1623–1631, 2016. Disponível em: <<https://doi.org/10.1007/s12541-016-0188-4>>. Acesso em: 15 ago. 2024. Citado na página 33.
- PAWANR, S.; GARG, G. K.; ROUTRAY, S. Prediction of energy consumption of machine tools using multi-gene genetic programming. *Materials Today: Proceedings*, Amsterdam, Netherlands, v. 58, p. 135–139, 2022. Disponível em: <<https://doi.org/10.1016/j.matpr.2022.01.156>>. Acesso em: 16 ago. 2024. Citado 2 vezes nas páginas 24 e 30.
- PAWAR, S. S.; BERA, T. C.; SANGWAN, K. S. Towards energy efficient milling of variable curved geometries. *Journal of Manufacturing Processes*, Elsevier, Amsterdam, Netherlands, v. 94, p. 497–511, 2023. Disponível em: <<https://doi.org/10.1016/j.jmapro.2023.03.078>>. Acesso em: 20 ago. 2024. Citado na página 30.

- PEARL, J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. San Francisco, United States: Morgan Kaufmann, 1988. Citado na página 29.
- PELEGRINO, D. H. *Estudo do Consumo de Energia Elétrica em Máquinas-Ferramentas*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil, 2018. Acessado em: 5 mar. 2025. Disponível em: <<https://teses.usp.br/teses/disponiveis/18/18156/tde-06082018-112106/publico/DaniloHenriquePelegrinoDEFINITIVO.pdf>>. Citado na página 16.
- PENUMURU, D. P.; MUTHUSWAMY, S.; KARUMBU, P. Identification and classification of materials using machine vision and machine learning in the context of industry 4.0. *Journal of Intelligent Manufacturing*, Springer, London, United Kingdom, v. 31, n. 5, p. 1229–1241, 2020. Disponível em: <<https://doi.org/10.1007/s10845-019-01508-6>>. Acesso em: 19 set. 2024. Citado na página 69.
- PEREIRA, F. R. d. S.; FREITAS, F. N. C. A eficiência energética em processo de usinagem por fresamento: Uma revisão na literatura. *Revista da Associação Brasileira de Engenharia e Ciências Mecânicas*, p. 1–15, 2024. Disponível em: <<https://www.sistema.abcm.org.br/articleFiles/download/37330>>. Acesso em: 03 out. 2024. Citado 2 vezes nas páginas 14 e 16.
- PEREIRA, J. L. J. et al. A review of multi-objective optimization: methods and algorithms in mechanical engineering problems. *Archives of Computational Methods in Engineering*, Cham, Switzerland, v. 29, n. 4, p. 2285–2308, 2022. Disponível em: <<https://doi.org/10.1007/s11831-021-09663-x>>. Acesso em: 17 set. 2024. Citado na página 74.
- PHUYAL, S.; BISTA, D.; BISTA, R. Challenges, opportunities and future directions of smart manufacturing: a state of art review. *Sustainable Futures*, Elsevier, Amsterdam, Netherlands, v. 2, p. 100023, 2020. Disponível em: <<https://doi.org/10.1016/j.sfr.2020.100023>>. Acesso em: 16 ago. 2024. Citado na página 14.
- PIMENOV, D. Y. et al. Artificial intelligence systems for tool condition monitoring in machining: Analysis and critical review. *Journal of Intelligent Manufacturing*, Cham, Switzerland, v. 34, n. 5, p. inserir faixa de páginas aqui, 2022. Disponível em: <<https://doi.org/10.1007/s10845-022-01923-2>>. Acesso em: 12 abr. 2024. Citado na página 29.
- POTHARAJU, S. P.; SREEDEVI, M. An improved prediction of kidney disease using smote. *Indian Journal of Science and Technology*, Chennai, India, v. 9, n. 31, p. 1–7, August 2016. Disponível em: <<https://doi.org/10.17485/ijst/2016/v9i31/95634>>. Acesso em: 14 abr. 2024. Citado na página 45.
- POWERS, D. M. W. Evaluation: From precision, recall and f-measure to roc, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, Adelaide, Australia, v. 2, n. 1, p. 37–63, 2011. Disponível em: <<https://arxiv.org/pdf/2010.16061>>. Acesso em: 20 out. 2024. Citado 2 vezes nas páginas 55 e 56.
- PRASHAR, A. Energy efficiency maturity (eem) assessment framework for energy-intensive smes: Proposal and evaluation. *Journal of Cleaner Production*, Amsterdam, Netherlands, v. 166, p. 1187–1201, 2017. Disponível em: <<https://doi.org/10.1016/j.jclepro.2017.08.161>>. Acesso em: 20 abr. 2024. Citado na página 15.
- PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. *Neural and Adaptive Systems: Fundamentals through Simulations*. Hoboken, NJ, United States: John Wiley & Sons, 2000. Citado 2 vezes nas páginas 51 e 72.
- QUINLAN, J. R. Induction of decision trees. In: *Machine Learning*. Nova York, EUA: Springer, 1986. v. 1, n. 1, p. 81–106. Acessado em: 22 de fevereiro de 2025. Citado na página 30.
- RAGAI, I. et al. Toward smart manufacturing: Analysis and classification of cutting parameters and energy consumption patterns in turning processes. *Journal of Manufacturing Systems*, Amsterdam, Netherlands, v. 64, p. 626–635, 2022. Disponível em: <<https://doi.org/10.1016/j.jmsy.2021.08.004>>. Acesso em: 25 mai. 2024. Citado na página 68.

- RAMENTOL, E. et al. Fuzzy-rough imbalanced learning for the diagnosis of high voltage circuit breaker maintenance: The smote-first-2t algorithm. *Engineering Applications of Artificial Intelligence*, Amsterdam, Netherlands, v. 48, p. 134–139, 2016. Disponível em: <<https://doi.org/10.1016/j.engappai.2015.10.009>>. Acesso em: 23 mai. 2024. Citado na página 45.
- RAMOS, M. *O que é Grid Search em Aprendizado de Máquina?* 2022. Acesso em: 23 fev. 2025. Disponível em: <<https://glossario.maconramos.com/glossario/o-que-e-grid-search-em-aprendizado-de-maquina/>>. Citado na página 61.
- REIS, C. Como a usinagem contribui para a sustentabilidade na indústria. *Revista de Engenharia e Sustentabilidade*, 2025. Acessado em: 04 mar. 2025. Disponível em: <<https://c-reis.ind.br/artigo/como-a-usinagem-contribui-para-a-sustentabilidade-na-industria>>. Citado na página 14.
- RESNER, K.; PINOTTI, M. A. Aplicação de machine learning para previsão da vida de ferramentas de usinagem. In: *Anais do XXV Colóquio de Usinagem*. Brusque, Santa Catarina, Brasil: UNIFEDE, 2023. ISBN 978-65-272-0075-8. Acesso em: 20 fev. 2025. Disponível em: <https://www.researchgate.net/publication/375792719_APLICACAO_DE_MACHINE_LEARNING_PARA_PREVISAO_DA_VIDA_DE_FERRAMENTAS_DE_USINAGEM>. Citado 2 vezes nas páginas 27 e 31.
- RUAN, D. (Ed.). *Fuzzy Logic Foundations and Industrial Applications*. Boston, MA, United States: Springer Science & Business Media, 2012. ISBN 978-1-4613-1441-7. Citado na página 25.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. *Learning Representations by Back-Propagating Errors*. Cambridge, MA, USA: MIT Press, 1986. Acesso em: 01 mar. 2025. Disponível em: <<https://www.nature.com/articles/323533a0>>. Citado na página 49.
- SAITO, T.; REHMSMEIER, M. The precision-recall plot is more informative than the roc plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, San Francisco, CA, United States, v. 10, n. 3, p. e0118432, 2015. Disponível em: <<https://doi.org/10.1371/journal.pone.0118432>>. Acesso em: 27 set. 2024. Citado 3 vezes nas páginas 54, 55 e 56.
- SALONITIS, K.; BALL, P. Energy efficient manufacturing from machine tools to manufacturing systems. *Procedia CIRP*, Elsevier, Amsterdam, Netherlands, v. 7, p. 634–639, 2013. Disponível em: <<https://doi.org/10.1016/j.procir.2013.06.045>>. Acesso em: 18 abr. 2024. Citado na página 15.
- SCHISCHKE, K. *Machine tools and related machinery*. Berlin, Germany: Fraunhofer Institute for Reliability and Microintegration, IZM, 2012. Disponível em: <https://prodextern.energimyndigheten.se/globalassets/energieffektivisering/_jag-ar-saljare-eller-tillverkare/dokument/produkter-med-krav/verktygsmaskiner/eup_lot5_task1_august2012_final.pdf>. Acesso em: 14 abr. 2024. Citado na página 16.
- SHIN, S.-J.; WOO, J.; RACHURI, S. Energy efficiency of milling machining: Component modeling and online optimization of cutting parameters. *Journal of Cleaner Production*, Elsevier, Amsterdam, Netherlands, v. 161, p. 12–29, 2017. Disponível em: <<https://doi.org/10.1016/j.jclepro.2017.05.013>>. Acesso em: 14 abr. 2024. Citado na página 15.
- SIHAG, N.; SANGWAN, K. S.; PUNDIR, S. Development of a structured algorithm to identify the status of a machine tool to improve energy and time efficiencies. *Procedia CIRP*, Amsterdam, Netherlands, v. 69, p. 294–299, 2018. Disponível em: <<https://doi.org/10.1016/j.procir.2017.11.081>>. Acesso em: 24 set. 2024. Citado na página 29.
- SMITH, J.; OLIVEIRA, R. Thermal influence on machining processes and material differentiation. *Journal of Manufacturing Science*, London, UK, v. 59, p. 112–126, 2021. Disponível em: <<https://doi.org/10.1016/j.jms.2021.05.003>>. Citado na página 69.
- SMITI, S.; SOUI, M. Bankruptcy prediction using deep learning approach based on borderline smote. *Information Systems Frontiers*, Springer, New York, United States, v. 22, p. 1067–1083, 2020. Disponível em: <<https://doi.org/10.1007/s10796-020-10031-6>>. Acesso em: 10 mai. 2024. Citado na página 45.

- SMOLA, A.; SCHÖLKOPF, B. A tutorial on support vector regression. *Statistics and Computing*, v. 14, n. 3, p. 199–222, 2004. Citado na página 51.
- SMOLA, A. J.; SCHÖLKOPF, B. *Learning with Kernels*. Berlin, Germany: GMD-Forschungszentrum Informationstechnik, 1998. Citado na página 50.
- SOORI, M.; AREZOO, B.; DASTRES, R. Machine learning and artificial intelligence in cnc machine tools: A review. *Sustainable Manufacturing and Service Economics*, Elsevier, Amsterdam, Netherlands, v. 2, p. 100009, 2023. Disponível em: <<https://doi.org/10.1016/j.smse.2023.100009>>. Acesso em: 16 abr. 2024. Citado 4 vezes nas páginas 21, 22, 23 e 31.
- STOCK, J. H.; WATSON, M. W. *Introduction to Econometrics*. Boston, EUA: Addison Wesley, 2003. Citado na página 53.
- SUGUMARAN, V.; MURALIDHARAN, V.; RAMACHANDRAN, K. I. Feature selection using decision tree and classification through proximal support vector machine for fault diagnostics of roller bearing. *Mechanical Systems and Signal Processing*, Elsevier, v. 21, n. 2, p. 930–942, 2007. Acessado em: 22 de fevereiro de 2025. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327006000043>>. Citado na página 29.
- SUN, J. et al. Class-imbalanced dynamic financial distress prediction based on adaboost-svm ensemble combined with smote and time weighting. *Information Fusion*, Elsevier, Amsterdam, Netherlands, v. 54, p. 128–144, 2020. Disponível em: <<https://doi.org/10.1016/j.inffus.2019.07.006>>. Acesso em: 21 mai. 2024. Citado na página 45.
- SUN, Y.; WONG, A. K. C.; KAMEL, M. S. Classification of imbalanced data: A review. *International Journal of Pattern Recognition and Artificial Intelligence*, World Scientific Publishing, Singapore, v. 23, n. 04, p. 687–719, 2009. Disponível em: <<https://doi.org/10.1142/S0218001409007326>>. Acesso em: 12 abr. 2024. Citado na página 54.
- SUYKENS, J.; VANDEWALLE, J. Recurrent least squares support vector machines. *Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on*, IEEE, v. 47, n. 7, p. 1109–1114, 2000. Citado na página 49.
- SUYKENS, J. A. K.; VANDEWALLE, J. Least squares support vector machine classifiers. *Neural Processing Letters*, Springer, Dordrecht, Netherlands, v. 9, p. 293–300, 1999. Disponível em: <<https://link.springer.com/article/10.1023/A:1018628609742>>. Acesso em: 12 abr. 2024. Citado 3 vezes nas páginas 29, 50 e 51.
- TAY, F. E.; CAO, L. Application of support vector machines in financial time series forecasting. *Omega*, v. 29, n. 4, p. 309–317, 2001. Citado na página 51.
- THARWAT, A. Behavioral analysis of support vector machine classifier with gaussian kernel and imbalanced data. *arXiv preprint arXiv:2007.05042*, 2020. Acesso em: 23 fev. 2025. Disponível em: <<https://arxiv.org/abs/2007.05042>>. Citado na página 62.
- TIAN, S. et al. An energy-efficient scheduling approach for flexible job shop problem in an internet of manufacturing things environment. *IEEE Access*, IEEE, Piscataway, NJ, United States, v. 7, 2019. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8716713>>. Acesso em: 20 ago. 2024. Citado na página 30.
- TIAN, X. et al. Joint optimization of feature sequences and toolpath strategies in multi-feature workpiece machining for minimizing energy consumption and processing time. *Journal of Manufacturing Systems*, Elsevier, Amsterdam, Netherlands, v. 74, p. 869–886, 2024. Disponível em: <<https://doi.org/10.1016/j.jmsy.2024.05.007>>. Acesso em: 20 ago. 2024. Disponível em: <<https://doi.org/10.1016/j.jmsy.2024.05.007>>. Citado na página 73.

- TRIANNI, A.; CAGNO, E.; FARNE, S. Barriers, drivers and decision-making process for industrial energy efficiency: A broad study among manufacturing small and medium-sized enterprises. *Applied Energy*, Elsevier, Amsterdam, Netherlands, v. 162, p. 1537–1551, 2016. Disponível em: <<https://doi.org/10.1016/j.apenergy.2015.02.078>>. Acesso em: 20 ago. 2024. Citado na página 15.
- TUPTUK, N.; HAILES, S. Security of smart manufacturing systems. *Journal of Manufacturing Systems*, Elsevier, Amsterdam, Netherlands, v. 47, p. 93–106, 2018. Disponível em: <<https://doi.org/10.1016/j.jmsy.2018.04.007>>. Acesso em: 20 ago. 2024. Citado na página 14.
- ULTRALYTICS. Tendências de ia para 2025: As inovações a que debes estar atento. *Ultralytics Blog*, 2025. Acesso em: 20 fev. 2025. Disponível em: <<https://www.ultralytics.com/pt/blog/2025-ai-trends-the-innovations-to-look-out-for-this-year>>. Citado 2 vezes nas páginas 27 e 31.
- U.S. Energy Information Administration. *Manufacturing Energy Consumption Survey*. 2018. Office of Energy Consumption and Efficiency Statistics, Washington, D.C., United States. Citado na página 16.
- VAPNIK, V. *The Nature of Statistical Learning Theory*. New York, United States: Springer Science & Business Media, 1995. Citado 2 vezes nas páginas 49 e 72.
- VAPNIK, V. *Statistical Learning Theory*. New York, EUA: Wiley, 1998. Citado na página 51.
- VAPNIK, V. *The Nature of Statistical Learning Theory*. New York, United States: Springer Science & Business Media, 2013. Citado 2 vezes nas páginas 29 e 50.
- VARUN, A. et al. Surface roughness prediction using machine learning algorithms while turning under different lubrication conditions. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. Bristol, United Kingdom, 2021. v. 2070, p. 012243. Disponível em: <<https://iopscience.iop.org/article/10.1088/1742-6596/2070/1/012243/meta>>. Acesso em: 24 set. 2024. Citado na página 29.
- VELLOSO, H. M.; HORA, H. R. M. da. Classificação de falhas de um centro de usinagem: um estudo de caso utilizando árvore de decisão. *Simpósio de Pesquisa Operacional e Logística da Marinha - Publicação Online*, v. 3, n. 1, p. 995–1003, 2020. Acesso em: 22 fev. 2025. Disponível em: <<https://www.proceedings.blucher.com.br/article-details/classificacao-de-falhas-de-um-centro-de-usinagem-um-estudo-de-caso-utilizando-rvore-de-deciso-34487>>. Citado 2 vezes nas páginas 21 e 30.
- WANG, B. et al. Smart manufacturing and intelligent manufacturing: A comparative review. *Engineering*, Elsevier, v. 7, n. 6, p. 738–757, 2021. Disponível em: <<https://doi.org/10.1016/j.eng.2020.07.017>>. Acesso em: 16 ago. 2024. Citado 2 vezes nas páginas 21 e 22.
- WANG, H. et al. An optimization model for energy-efficient machining for sustainable production. *Journal of Cleaner Production*, v. 232, p. 1121–1133, 2019. Disponível em: <<https://doi.org/10.1016/j.jclepro.2019.05.271>>. Acesso em: 20 ago. 2024. Citado na página 30.
- WANG, Q.; LIU, F.; LI, C. An integrated method for assessing the energy efficiency of machining workshop. *Journal of Cleaner Production*, Elsevier, v. 52, p. 122–133, 2013. Disponível em: <<https://doi.org/10.1016/j.jclepro.2013.03.020>>. Acesso em: 20 ago. 2024. Citado na página 15.
- WANG, Q.; YANG, H. Sensor-based recurrence analysis of energy efficiency in machining processes. *IEEE Access*, v. 8, p. 18326–18336, 2020. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8963930>>. Acesso em: 23 abr. 2024. Citado na página 74.
- WEINBERGER, K. Q.; BLITZER, J.; SAUL, L. K. Distance metric learning for large margin nearest neighbor classification. *Journal of Machine Learning Research*, v. 10, p. 207–244, 2009. Acesso em: 2 mar. 2025. Disponível em: <<https://jmlr.org/papers/v10/weinberger09a.html>>. Citado na página 53.
- WIDROW, B.; HOFF, M. E. *Adaptive Switching Circuits*. Stanford, CA, United States, 1960. Citado na página 52.

- WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. *Climate Research*, v. 30, n. 1, p. 79–82, 2005. Citado na página 58.
- WILLMOTT, C. J.; MATSUURA, K. On the use of dimensioned measures of error to evaluate the performance of spatial interpolators. *International Journal of Geographical Information Science*, v. 20, n. 1, p. 89–102, 2006. Citado na página 58.
- WOOLDRIDGE, J. M. *Introductory Econometrics: A Modern Approach*. 7. ed. Boston, EUA: Cengage, 2020. Citado na página 53.
- WU, X.; MENG, S. E-commerce customer churn prediction based on improved smote and adaboost. In: IEEE. *2016 13th International Conference on Service Systems and Service Management (ICSSSM)*. Kunming, China, 2016. p. 1–5. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7538581>>. Acesso em: 23 abr. 2024. Citado na página 45.
- XIAO, Q. et al. Energy efficiency modeling for configuration-dependent machining via machine learning: A comparative study. *IEEE Transactions on Automation Science and Engineering*, IEEE, New York, United States, v. 18, n. 2, p. 717–730, 2020. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8959387>>. Acesso em: 17 ago. 2024. Citado 3 vezes nas páginas 23, 29 e 72.
- XIAO, Y. et al. Optimization of low-carbon and highly efficient turning production equipment selection based on beetle antennae search algorithm (bas). *Processes*, MDPI, Basel, Switzerland, v. 11, p. 911, 2023. Disponível em: <<https://www.mdpi.com/2227-9717/11/3/911>>. Acesso em: 12 abr. 2024. Citado 2 vezes nas páginas 24 e 30.
- XIAO, Y. et al. Energy-saving and efficient equipment selection for machining process based on business compass model. *Processes*, MDPI, Basel, Switzerland, v. 10, n. 9, p. 1846, 2022. Disponível em: <<https://www.mdpi.com/2227-9717/10/9/1846>>. Acesso em: 12 abr. 2024. Citado 2 vezes nas páginas 24 e 30.
- XIAO, Y. et al. Multiobjective optimization of machining center process route: Tradeoffs between energy and cost. *Journal of Cleaner Production*, Elsevier, Amsterdam, Netherlands, v. 280, p. 124171, 2021. Disponível em: <<https://doi.org/10.1016/j.jclepro.2020.124171>>. Acesso em: 12 abr. 2024. Citado 5 vezes nas páginas 23, 24, 27, 30 e 31.
- XU, L. et al. A novel intelligent reasoning system to estimate energy consumption and optimize cutting parameters toward sustainable machining. *Journal of Cleaner Production*, Elsevier, Amsterdam, Netherlands, v. 261, p. 121160, 2020. Disponível em: <<https://doi.org/10.1016/j.jclepro.2020.121160>>. Acesso em: 24 set. 2024. Citado na página 74.
- YOUSSEF, H.; EL-HOFY, H. *Traditional Machining Technology: Machine Tools and Operations*. 2. ed. Boca Raton, United States: CRC Press, 2020. ISBN 9781003055303. Citado 2 vezes nas páginas 32 e 36.
- ZEIN, A. *Transition towards energy efficient machine tools*. Londres, Reino Unido: Springer Science & Business Media, 2012. Citado na página 14.
- ZHANG, D. et al. An ensemble method for unbalanced sentiment classification. In: IEEE. *2015 11th International Conference on Natural Computation (ICNC)*. Zhangjiajie, China, 2015. p. 440–445. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=7378029>>. Acesso em: 24 set. 2024. Citado na página 45.
- ZHANG, H. The optimality of naive bayes. In: *Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference*. Miami, FL, USA: AAAI Press, 2004. p. 562–567. Disponível em: <<https://aaai.org/Library/FLAIRS/2004/flairs04-104.php>>. Acesso em: 03 out. 2024. Citado na página 54.
- ZHANG, X. Y. et al. A multi-sensor based online tool condition monitoring system for milling process. *Procedia CIRP*, Elsevier, Amsterdam, Netherlands, v. 72, p. 1136–1141, 2018. Disponível em: <<https://doi.org/10.1016/j.procir.2018.03.092>>. Acesso em: 24 set. 2024. Citado na página 74.

ZHANG, Y. et al. Multi-objective optimization of machining parameters based on an improved hopfield neural network for step-nc manufacturing. *Journal of Manufacturing Systems*, v. 74, p. 222–232, 2024. Disponível em: <<https://doi.org/10.1016/j.jmsy.2024.03.006>>. Acesso em: 03 out. 2024. Citado 2 vezes nas páginas 73 e 74.

ZHENG, T. et al. Data synthesis using dual discriminator conditional generative adversarial networks for imbalanced fault diagnosis of rolling bearings. *Measurement*, Elsevier, Amsterdam, Netherlands, v. 152, p. 107741, 2020. Disponível em: <<https://doi.org/10.1016/j.measurement.2020.107741>>. Acesso em: 03 out. 2024. Citado na página 45.

ZHONG, R. Y. et al. Intelligent manufacturing in the context of industry 4.0: a review. *Engineering*, Elsevier, v. 3, n. 5, p. 616–630, 2017. Disponível em: <<https://doi.org/10.1016/J.ENG.2017.05.015>>. Acesso em: 16 ago. 2024. Citado 3 vezes nas páginas 21, 27 e 31.