



**UNIVERSIDADE FEDERAL DE ITAJUBÁ
INSTITUTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
MECÂNICA**

Guilherme Augusto Vilas Boas Vasconcelos

Otimização robusta no processo de
fresamento de topo do aço inoxidável duplex
UNS S32205 por meio de aprendizagem de
máquina

Itajubá/MG

2025

UNIVERSIDADE FEDERAL DE ITAJUBÁ
INSTITUTO DE ENGENHARIA MECÂNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
MECÂNICA

Guilherme Augusto Vilas Boas Vasconcelos

Otimização robusta no processo de
fresamento de topo do aço inoxidável duplex
UNS S32205 por meio de aprendizagem de
máquina

Tese submetida ao Programa de Pós-Graduação em Engenharia Mecânica como parte dos requisitos para obtenção do título de Doutor em Engenharia Mecânica.

Área de Concentração: Projeto, Materiais e Processos.

Orientadora: Prof^a. Dr^a. Mirian de Lourdes Noronha Motta Melo

Coorientador: Prof. Dr. Matheus Brendon Francisco

Itajubá/MG

2025

*Dedico esta tese primeiramente a Deus,
à minha esposa, Rayssa Simone Moraes de Vasconcelos,
às minhas filhas, Mariah Moraes de Vasconcelos e Maria Luísa Moraes de Vasconcelos,
e aos meus pais, Carlos Rogério de Vasconcelos e Helenice Ribeiro da Silva Vasconcelos.*

AGRADECIMENTOS

Primeiramente, agradeço a Deus, cuja infinita bondade e sabedoria iluminaram meu caminho, proporcionando-me força e resiliência para superar cada desafio. Sua presença constante foi um verdadeiro farol em minha jornada.

À minha amada esposa, Rayssa Simone Moraes de Vasconcelos, expresse minha mais profunda gratidão por ser meu alicerce, minha parceira incansável e uma inspiração constante. Seu amor incondicional, apoio firme e fé inabalável em mim foram fundamentais para que eu enfrentasse cada desafio com coragem. Agradeço, de todo o coração, pelo maior presente que a vida — por meio de você — me concedeu: nossas filhas, Mariah e Maria Luísa, que enchem meus dias de alegria, renovam minha esperança e dão verdadeiro sentido à minha existência.

Aos meus pais, Carlos Rogério de Vasconcelos e Helenice Ribeiro da Silva Vasconcelos, minha eterna gratidão por sua dedicação, amor e apoio inabalável. Vocês me ensinaram os valores que moldaram quem sou hoje, e sem vocês, esta conquista não seria possível.

Uma homenagem especial aos meus avós, João Ribeiro da Silva e Maria Aparecida Vilas Boas Silva, que também foram meus pais e cujas memórias viverão eternamente em meu coração. A sabedoria, amor e sacrifícios de vocês foram fundamentais na formação do meu caráter e na construção dos meus sonhos.

À minha família, que sempre esteve ao meu lado, me apoiando, me ensinando e orando por mim, meu mais profundo agradecimento.

À minha orientadora, Prof. Dra. Mirian de Lourdes Noronha Motta Melo, sou imensamente grato pela orientação, incentivo e pelos valiosos ensinamentos ao longo deste processo. A confiança depositada em mim e sua disponibilidade constante foram essenciais para meu desenvolvimento.

Ao meu coorientador, Prof. Dr. Matheus Brendon Francisco, agradeço pela colaboração e apoio imprescindíveis na realização deste trabalho. Sua experiência e conhecimento foram cruciais para meu crescimento acadêmico e profissional. Sou eternamente grato por sua dedicação e por me impulsionar a ser uma versão melhor de mim mesmo.

Aos amigos que fiz ao longo desta trajetória, em especial ao Prof. Dr. Carlos Henrique de Oliveira, ao Dr. Luiz Gustavo Paes, ao Dr. Elioenai Levi Barbedo, ao Claudemiro Teodoro e ao Thiago Gonçalves, registro minha mais sincera gratidão pela amizade e pelo apoio incondicional. Vocês tornaram essa jornada mais leve, significativa e repleta de momentos inesquecíveis.

A todos os meus amigos, que sempre me incentivaram a buscar o novo e explorar novos horizontes, meu sincero agradecimento. Vocês desempenharam um papel crucial em minha trajetória, aliviando o peso das cobranças diárias com boas risadas e lembranças marcantes. A amizade de cada um de vocês foi uma fonte de alegria e motivação, e sou

grato por cada momento que construímos juntos.

À RCS Usinagem de Precisão e Manutenção Eireli, expresso minha sincera gratidão pelo apoio, compreensão e incentivo que me foram oferecidos ao longo do desenvolvimento deste trabalho. Reconheço que, em diversas ocasiões, precisei abdicar de minhas responsabilidades profissionais para me dedicar a esta pesquisa. A flexibilidade e a assistência proporcionadas pela empresa foram fundamentais para que eu pudesse conciliar essas demandas e alcançar este objetivo acadêmico. Agradeço pela confiança depositada em mim e pelo ambiente de trabalho colaborativo, que sempre incentivou meu crescimento pessoal e profissional.

Aos técnicos do laboratório NOMATI (Núcleo de Otimização da Manufatura e Tecnologia da Inovação), José Veríssimo Ribeiro de Toledo e Emerson Barsottini, meu reconhecimento pelo suporte e dedicação.

Agradeço de maneira especial à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG) por acreditarem, incentivarem e impulsionarem a pesquisa no Brasil. Seu compromisso com o desenvolvimento científico é fundamental para o progresso e a inovação em nosso país.

Agradeço também à UNIFEI pelo programa de pós-graduação em Engenharia Mecânica, que abriu as portas para o desenvolvimento deste projeto e possibilitou a realização de mais esta pesquisa. Sou profundamente grato a essa instituição pelo compromisso com a formação de profissionais qualificados e pela promoção do avanço científico e tecnológico em nosso país.

*"Acredito que a única coragem que alguém precisa na vida é a coragem de seguir os
próprios sonhos."
(Oprah Winfrey)*

RESUMO

VASCONCELOS, G. A. V B **Otimização multiobjetivo no fresamento de topo do aço inoxidável duplex UNS S32205 por meio de aprendizado de máquina.** 2025. 157 p. Tese (Doutorado em Engenharia Mecânica) - Universidade Federal de Itajubá, *campus* sede, 2025.

A crescente busca por eficiência energética e redução de custos em processos de manufatura tem impulsionado a necessidade de otimização em operações como o fresamento de topo, sobretudo na usinagem de materiais complexos, como o aço inoxidável duplex UNS S32205. Esse material, embora apresente excelente resistência mecânica e à corrosão, possui baixa usinabilidade devido à sua tendência ao encruamento e à baixa condutividade térmica. No fresamento de topo desse aço, a definição precisa dos parâmetros de corte torna-se ainda mais desafiadora devido à presença de variáveis de ruído inerentes ao processo. Diante dessa complexidade, a aplicação de modelos de aprendizado de máquina desponta como uma abordagem promissora, desde que aliada a técnicas adequadas para a construção de modelos robustos, isto é, capazes de manter alto desempenho preditivo mesmo diante de ruídos. Esta tese tem como objetivo desenvolver e validar modelos de aprendizado de máquina para a previsão da rugosidade superficial (R_a) no fresamento de topo do aço inoxidável duplex UNS S32205, considerando simultaneamente variáveis de controle e variáveis de ruído. Os ensaios foram conduzidos com base em um planejamento composto central, combinando as variáveis de entrada (velocidade de corte, avanço por dente, largura fresada e profundidade de corte) com as variáveis de ruído (desgaste do flanco da ferramenta, vazão de fluido e comprimento em balanço). Foram aplicados o conceito de projeto de parâmetro robusto, a metodologia de superfície de resposta e técnicas de aprendizado de máquina. Os modelos utilizados incluíram Máquinas de Vetores de Suporte (SVM), Árvores de Decisão (DTR), Florestas Aleatórias (RF) e Redes Neurais Artificiais (RNA). As métricas de avaliação de desempenho abrangeram RMSE, MAE, MSE e validação cruzada por R^2 médio. Os modelos de RNA apresentaram os melhores desempenhos, com destaque para a arquitetura 7-20-14-1, que obteve R^2 de 0,92, RMSE de 0,06 e R^2 médio de 0,90 na previsão da rugosidade superficial. O modelo de RNA foi então utilizado como função objetivo em um processo de otimização conduzido pelo algoritmo de enxame de partículas (PSO), com o intuito de identificar os parâmetros de corte que minimizam a rugosidade. Os experimentos de confirmação, realizados por meio do arranjo L9 de Taguchi, confirmaram os resultados obtidos, evidenciando que o modelo de aprendizado de máquina selecionado foi eficaz para simular e otimizar o comportamento real do processo.

Palavras-chaves: Inteligência Artificial, Rugosidade Superficial, Indústria 4.0, Redes neurais artificiais, PSO

ABSTRACT

The growing demand for energy efficiency and cost reduction in manufacturing processes has driven the need for optimization in operations such as end milling, especially when machining complex materials like duplex stainless steel UNS S32205. Although this material exhibits excellent mechanical strength and corrosion resistance, it has low machinability due to its tendency to work harden and its low thermal conductivity—factors that compromise process stability and directly affect surface finish quality. In the end milling of this steel, the precise definition of cutting parameters becomes even more challenging due to the presence of noise variables inherent to the process. Given this complexity, the application of machine learning models emerges as a promising approach, provided it is combined with appropriate techniques to construct robust models, that is, models capable of maintaining high predictive performance even in the presence of noise. This thesis aims to develop and validate machine learning models for predicting surface roughness (R_a) in the end milling of duplex stainless steel UNS S32205, simultaneously considering control variables and noise variables. The experiments were conducted based on a central composite design, combining the input variables (cutting speed, feed per tooth, width of cut, and depth of cut) with noise variables (tool flank wear, fluid flow rate, and tool overhang). The study applied the concept of robust parameter design, response surface methodology, and machine learning techniques. The models used included Support Vector Machines (SVM), Decision Tree Regressors (DTR), Random Forests (RF), and Artificial Neural Networks (ANN). Performance evaluation metrics included RMSE, MAE, MSE, and cross-validation using average R^2 . The ANN models showed the best performance, with the 7-20-14-1 architecture standing out, achieving an R^2 of 0.92, RMSE of 0.06, and average R^2 of 0.90 in surface roughness prediction. The ANN model was then used as the objective function in an optimization process conducted using the Particle Swarm Optimization (PSO) algorithm, aiming to identify cutting parameters that minimize roughness. Confirmation experiments, performed using a Taguchi L9 array, validated the obtained results, demonstrating that the selected machine learning model was effective in simulating and optimizing the real behavior of the process.

Key-words: Artificial Intelligence, Surface Roughness, Industry 4.0, Artificial Neural Networks, PSO

LISTA DE FIGURAS

Figura 1 – Fresamento frontal, Periférico e Tangencial	24
Figura 2 – Tipos de fresamento: (a) faceamento; (b) de cantos a 90°; (c) de topo; (d) de bordas; (e) de cavidades (f) de perfis	25
Figura 3 – Tipos Fresas	27
Figura 4 – Microestrutura do aço inoxidável duplex	29
Figura 5 – Microestrutura do aço inoxidável duplex	30
Figura 6 – Perfil de rugosidade superficial R_a	34
Figura 7 – Representação do parâmetro R_t (rugosidade total)	35
Figura 8 – Algoritmos de aprendizagem de máquina utilizados nesta tese	37
Figura 9 – Máquina de Vetores de Suporte - Margens Rígidas	38
Figura 10 – Máquina de Vetores de Suporte - Margens Suave	39
Figura 11 – Função de Perda ε -insensitiva	40
Figura 12 – Árvore de Decisão - CART	42
Figura 13 – Modelo Hipotético de Construção de uma Árvore de Regressão: (a) Matriz de Dados, (b) Estrutura da Árvore, e (c, d) Partições Resultantes	44
Figura 14 – Algoritmo de Floresta Aleatória	46
Figura 15 – modelo de neurônio didático	48
Figura 16 – Modelo de neurônio de McCulloch-Pitts	48
Figura 17 – Função degrau	49
Figura 18 – Função degrau (bipolar)	50
Figura 19 – Função Rampa/ Linear	50
Figura 20 – Função sigmoide	51
Figura 21 – Função tangente hiperbólica	51
Figura 22 – Diagrama da arquitetura de uma rede neural perceptron multicamadas	53
Figura 23 – Validação k-Dobras	57
Figura 24 – Superfícies de resposta: (a) modelo linear; (b) modelo com curvatura	65
Figura 25 – Planejamento composto central para k=3	67
Figura 26 – Planejamento composto central - CCC, CCI, CCF	68
Figura 27 – Deslocamento de partículas no PSO	75
Figura 28 – Fluxograma geral da metodologia adotada	79
Figura 29 – Centro de Usinagem Vertical ROMI D 600	85
Figura 30 – Porta Ferramentas: a) Suporte montado; b) Sistema de fixação dos insertos	86
Figura 31 – Inserto de metal duro R390-11T308M-MM 2030	87
Figura 32 – Material: a)Aço Inoxidável Duplex UNS S32205; b)Detalhamento dimensional	88

Figura 33 – Microscópio estereoscópico utilizado na medição do desgaste de flanco .	90
Figura 34 – Controle da vazão: a)Sem fluido; b)Média vazão; c) Máxima vazão . . .	91
Figura 35 – Controle do balanço: a)Chave; b)Ferramenta de corte; c) Paquímetro .	91
Figura 36 – Equipamentos de medição da rugosidade	92
Figura 37 – Sistema de Medição de Rugosidade	92
Figura 38 – Análise de <i>Outliers</i> - Rugosidade R_a	98
Figura 39 – Correlação de Pearson R_a	99
Figura 40 – Curvas de perdas e validação para diferentes arquiteturas de redes neu- rais	103
Figura 41 – Previsões do modelo a) DTR, b) RF, c) SVM para R_a	105
Figura 42 – Previsões do modelo RNA - R_a	107
Figura 43 – Teste Shapiro Wilk - SVM - DTR - RF	111
Figura 44 – Teste Shapiro Wilk - RNA	112
Figura 45 – Comparação dos efeitos principais	123
Figura 46 – Comparação dos efeitos das interações	125
Figura 47 – Superfícies de resposta $v_c \times f_z$ - a) Real , b) ML	127
Figura 48 – Superfícies de resposta $v_c \times v_b$ - a) Real , b) ML	128
Figura 49 – Superfícies de resposta $f_z \times v_b$ - a) Real , b) ML	129
Figura 50 – Artigo 1	138
Figura 51 – Artigo 2	139
Figura 52 – Artigo 3	140
Figura 53 – Artigo 4	141
Figura 54 – Artigo 5	142
Figura 55 – Certificado de Registro de Programa de Computador	143

LISTA DE TABELAS

Tabela 1 – Comprimento de amostragem (“ <i>cut – off</i> ”)	35
Tabela 2 – Tipos de Kernel e suas respectivas funções e parâmetros.	41
Tabela 3 – Resumo das particularidades dos modelos utilizados	63
Tabela 4 – Composição química do Aço Inoxidável Duplex UNS S32205	88
Tabela 5 – Níveis para as variáveis controláveis	89
Tabela 6 – Níveis para as variáveis de ruído	89
Tabela 7 – Planejamento Experimental - Base de Dados	93
Tabela 8 – Resumo das colunas do DataFrame	97
Tabela 9 – Hiperparâmetros dos modelos - R_a	101
Tabela 10 – Previsões dos modelos SVM, DTR, RF	104
Tabela 11 – Previsões dos modelos de rede neural	106
Tabela 12 – Resultados das métricas para diferentes configurações de modelos para R_a	109
Tabela 13 – Resultados do teste de Shapiro-Wilk para os modelos	110
Tabela 14 – Novo Planejamento Experimental	113
Tabela 15 – Teste T comparando dados reais e previsões geradas pelo modelo de IA.	119
Tabela 16 – Coeficientes codificados e seus efeitos na rugosidade R_a usando-se RNA	120
Tabela 17 – Coeficientes codificados e seus efeitos na rugosidade R_a usando-se os dados reais	121
Tabela 18 – Parâmetros utilizados nas simulações com o algoritmo PSO	130
Tabela 19 – Resultados da otimização com PSO	130
Tabela 20 – Matriz experimental Taguchi L9	132
Tabela 21 – Teste de Hipotese <i>t- Student</i>	133
Tabela 22 – Análise de Variância - Experimentos de Confirmação	133

LISTA DE ABREVIATURAS E SIGLAS

<i>CUT-OFF</i>	Comprimento de onda do filtro
AlCrN	Classe de revestimentos avançados - Alumínio-Cromo-Nitreto
ASS	<i>Austenitic Stainless Steel</i> - Aço inoxidável Austenítico)
CCC	Cúbica de corpo centrado
CCD	<i>Central Composite Design</i> - (Planejamento composto central)
CFC	Cúbica de face centrada
CNC	Comando Numérico Computadorizado
DSS	<i>Duplex Stainless Steel</i> - (Aço inoxidável duplex)
DTR	<i>Decision Tree Regression</i> - (Árvore de decisão)
FSS	<i>Ferritic Stainless Steel</i> - (Aço inoxidável Ferrítico)
IA	Inteligência Artificial
IEPG	Instituto de Engenharia de Produção e Gestão
LMAUT	Laboratório de Manufatura e Automação
MAE	<i>Mean Absolute Error</i> - (Erro Médio Absoluto)
ML	<i>Machine learning</i> - (Aprendizagem de máquina)
MLP	<i>Multilayer Perceptron</i> - (Perceptron Multi camadas)
MSE	<i>Mean Square Error</i> - (Erro Quadrático Médio)
NOMATI	Núcleo de Otimização da Manufatura e Tecnologia da Inovação
PREN	<i>Pitting Resistance Equivalent Number</i> - (Número equivalente de resistência por pite)
RF	<i>Random Forest</i> - (Floresta Aleatória)
RMSE	<i>Root Mean Square Error</i> - (Raiz do Erro Quadrático Médio)
RNA	<i>Artificial neural networks</i> - (Redes neurais artificiais)
RPD	<i>Robust Parameter Design</i> - (Projeto de parâmetro robusto)
SVM	<i>Support Vector Machine</i> - (Máquina de vetores de suporte)
TiAlN	Classe de revestimentos avançados - Titânio-Alumínio-Nitreto
TiAlSiN	Classe de revestimentos avançados - Titânio-Alumínio-Silício-Nitreto
UNIFEI	Universidade Federal de Itajubá
UNS S32205	<i>Unified Numbering System</i>
ZTA	Zona termicamente afetada

LISTA DE SÍMBOLOS

2^k	Número de pontos fatoriais
$2k$	Número de pontos axiais
C	Termo de regularização
CV	Processo de validação cruzada
C_r	Cromo
D	Conjunto variáveis independentes, $i = 1, \dots, k$
F_e	Ferrítica
J	Números de regiões
L	Função Lagrangeana
M_o	Molibdênio
N	Tamanho da amostra
N	Nitrogênio
N_i	Níquel
Q	Vazão de fluído
R^2	Coefficiente de Determinação
R_a	Rugosidade superficial
R_t	Rugosidade superficial total
Y	Variavel de resposta
α	Alfa
α_i	Multiplicador de Lagrange
α_i^*	Multiplicador de Lagrange
\bar{y}_i	Média dos valores reais para a resposta y
β	Inclinação da curva sigmoide
β_i	Coefficientes de regressão, $i = 1, \dots, k$
η_i	Multiplicador de Lagrange
η_i^*	Multiplicador de Lagrange
γ	Gama
γ_j	Constante em cada região, $j=1, \dots, J$
\hat{y}_i	Valores previstos para a resposta y
\mathbb{R}	Números Reais
ρ	Raio da região experimental CCD
ε	Função perda
a_e	Largura fresada
a_p	Profundidade de corte
f	Avanço

f_z	Avanço por dente
$g(\cdot)$	Função ativação
k	Número de dobras
$k(x_i, x_j)$	<i>Kernel</i>
l_e	comprimento de amostragem
l_m	comprimento de avaliação
lt_0	Comprimento em balanço
n_c	Número de pontos centrais
s	Valor da variável na divisão
t_1	Nós de ligação
v_b	Desgaste de flanco
v_c	Velocidade de corte
v_f	Velocidade de avanço
w_{i1}	Pesos sinápticos das redes neurais
y	Resposta de interesse
z	Variáveis incontroláveis - ruído
k	Números de variáveis independentes

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Contexto da Pesquisa	17
1.2	Objetivos	20
1.3	Objetivos específicos	20
1.4	Contribuição Científica	21
1.5	Delimitações da pesquisa	22
2	REVISÃO DA LITERATURA	23
2.1	Fresamento	23
2.2	Aços Inoxidáveis Duplex	27
2.3	Usinabilidade	29
2.4	Qualidade da Superfície	33
2.5	Aprendizagem de Máquina	35
2.5.1	Máquina de vetores de suporte	37
2.5.2	Árvore de Decisão	41
2.5.3	Florestas Aleatórias	44
2.5.4	Redes Neurais Artificiais	47
2.5.4.1	O neurônio	47
2.5.4.2	Função de Ativação	49
2.5.4.3	Arquiteturas de Redes	51
2.5.4.4	Rede Perceptron de Múltiplas Camadas	52
2.5.4.5	Treinamento de uma Rede neural	53
2.5.4.6	Algoritmo de Retro Propagação	54
2.5.5	Generalização	56
2.5.6	Validação Cruzada via k-dobras	56
2.5.7	Métricas de Avaliação	57
2.5.8	Desenvolvimento de Modelos de Aprendizagem de máquina	59
2.5.8.1	Coleta de Dados	59
2.5.8.2	Separação Treino e Teste	59
2.5.8.3	Configuração dos hiperparâmetros	59
2.5.8.4	Treinamento	60
2.5.8.5	Teste e Validação	60
2.6	Metodologia de Superfície de Resposta	63
2.6.1	Projeto de Parâmetro Robusto	68
2.6.2	Arranjo Combinado	70

2.6.3	Otimização por Enxame de Partículas (PSO)	74
3	METODOLOGIA	78
3.1	Equipamentos e Materiais	84
3.2	Procedimento Experimental	89
3.3	Criação da Base de Dados	92
4	RESULTADOS E DISCUSSÃO	96
4.1	Análise Exploratória	96
4.1.1	Limpeza dos Dados	96
4.1.2	Análise de Outliers	97
4.1.3	Análise de Correlação	98
4.1.4	Pré Processamento	99
4.2	Criação dos Modelos - Rugosidade Superficial	100
4.2.1	Treinamento dos modelos	100
4.2.2	Previsão dos modelos	104
4.2.3	Métricas	108
4.2.4	Teste de Normalidade	110
4.3	Análise Comparativa	113
4.3.1	Nova Base de dados	113
4.3.2	Desenvolvimento dos modelos matemáticos	119
4.3.3	Análise dos efeitos principais	122
4.3.4	Análise dos efeitos das interações	124
4.3.5	Otimização PSO	129
5	EXPERIMENTOS DE CONFIRMAÇÃO	132
6	CONCLUSÃO	136
7	PUBLICAÇÕES	138
	REFERÊNCIAS	144

1 INTRODUÇÃO

1.1 Contexto da Pesquisa

A usinagem é um dos processos de fabricação mais importantes, amplamente utilizada em indústrias que exigem alta precisão, como os setores aeroespacial, automobilístico, petroquímico, químico e alimentício. Durante muitos anos, a usinagem convencional predominou nessas áreas, utilizando máquinas-ferramenta operadas manualmente, onde a qualidade, a precisão e o controle do processo dependiam quase exclusivamente da habilidade do operador. Essa abordagem, no entanto, apresentava diversas ineficiências, como altos custos de produção, qualidade inconsistente dos produtos e subutilização dos inserts de corte, resultado da exploração inadequada dos parâmetros de corte (XIAO et al., 2021).

Com o avanço da tecnologia, o uso de máquinas CNC (Comando Numérico Computadorizado) cresceu significativamente, revolucionando o setor de manufatura. Essas máquinas permitem um controle mais preciso dos parâmetros de corte, como velocidade e avanço, além de oferecer uma produção mais automatizada e eficiente (SQUEO; FRIGERIO; MATTA, 2019). Comparadas às máquinas tradicionais, as CNC são mais rápidas, confiáveis e capazes de executar operações complexas com maior repetibilidade e precisão. O aumento do uso dessas máquinas é evidente; por exemplo, na China, o consumo de centros de usinagem CNC cresceu de pouco mais de 2.000 unidades em 2001 para quase 60.000 máquinas em 2019 (LI et al., 2019). Esse crescimento ressalta a importância das máquinas CNC na produção moderna, onde a busca por eficiência energética e redução de custos é crucial.

A usinagem CNC é um processo multifacetado em que diversos fatores — como o tipo de material, os parâmetros de corte, a escolha da ferramenta e o controle da qualidade — influenciam o resultado final em termos de custo, tempo, qualidade e produtividade. Compreender esses aspectos é essencial para otimizar as operações e assegurar uma gestão eficiente dos recursos. Dentre as operações de usinagem CNC, o fresamento de topo destaca-se como uma das mais versáteis e importantes, sendo amplamente utilizado para criar superfícies planas ou complexas em peças de diferentes materiais (MALI; GUPTA; RAMKUMAR, 2021). Além disso, o fresamento de topo combina alta precisão com eficiente remoção de material, sendo aplicado nas indústrias aeroespacial (CIECIELAĞ; ZALESKI, 2022), automotiva (LI et al., 2022), na fabricação de moldes (BINALI et al., 2023) e nas indústrias petroquímicas (GUIMARÃES et al., 2024).

O material a ser usinado desempenha um papel crucial na eficiência do processo de fresamento. Materiais de alto desempenho, como o aço inoxidável duplex utilizado nesta

tese, são valorizados por sua resistência e durabilidade, mas apresentam um custo significativamente maior em comparação a aços mais macios (PENG; LI, 2024). A usinabilidade do material também impacta diretamente o tempo de usinagem, pois materiais mais duros aumentam o desgaste das ferramentas. Isso leva à necessidade de reduzir os níveis dos parâmetros de corte, prolongando o tempo de usinagem e resultando em custos operacionais mais elevados (OLIVEIRA et al., 2022; VASCONCELOS, 2022).

A usinabilidade do aço inoxidável duplex no fresamento de topo é especialmente desafiadora devido à sua baixa condutividade térmica e ao alto encruamento, fatores que intensificam o desgaste das ferramentas de corte (MARQUES et al., 2023). Esses aspectos aumentam significativamente os custos operacionais, pois exigem trocas mais frequentes dos insertos de corte e um uso intensivo de fluido de corte, tornando o processo mais oneroso. Embora os fluidos de corte contribuam para a produtividade das operações, prolonguem a vida útil da ferramenta e melhorem a qualidade da peça, eles podem elevar o custo de manufatura em aproximadamente 18% a 20% (PRAKASH; ARUN; SACHIN, 2023). Ademais, os impactos ambientais têm gerado grande preocupação, pois o descarte inadequado de fluidos de corte, além de ser oneroso e sujeito a regulamentações rígidas, pode causar sérios problemas ambientais, como a poluição da água e do solo (KHANNA et al., 2021).

O desgaste acelerado das ferramentas também impacta o tempo de operação, prolongando o ciclo de usinagem e, conseqüentemente, elevando o custo por peça (PENG; LI, 2024). Nesse contexto, a definição precisa dos parâmetros de corte controláveis, como velocidade de corte v_c , avanço por dente f_z , profundidade de corte a_p e largura fresada a_e , é fundamental para otimizar o processo. Além disso, é essencial considerar a influência de variáveis incontroláveis, como o desgaste de flanco v_b e a vazão de fluido Q , que afetam significativamente a estabilidade e a qualidade da usinagem. Portanto, estabelecer condições de corte adequadas é essencial para manter a competitividade, assegurando a qualidade e a durabilidade das peças produzidas.

Nos últimos anos, o uso de modelos de aprendizado de máquina (ML) na usinagem tem ganhado destaque, especialmente para previsão de respostas e o controle de parâmetros no fresamento de topo (MONGAN et al., 2023). Esses modelos utilizam dados do processo para aprender padrões complexos e prever o comportamento do sistema sob diferentes condições de operação, o que permite uma abordagem mais eficiente e econômica. Em vez de depender de experimentação intensiva, o ML possibilita a identificação de parâmetros de corte adequados para otimizar o desempenho do processo, reduzindo significativamente o tempo e os custos, além de promover maior eficiência energética e sustentabilidade.

A literatura recente apresenta uma ampla gama de aplicações de aprendizado de máquina no contexto de usinagem, com foco na otimização e previsibilidade do desempenho no fresamento. Por exemplo, um estudo aplicou redes neurais convolucionais para prever o desgaste da ferramenta no fresamento de face do Inconel 718, considerando variáveis

como velocidade de corte (v_c), avanço por dente (f_z) e profundidade de corte (a_p). Os resultados demonstraram que o modelo alcançou uma precisão de 96,2% na previsão dos valores de desgaste da ferramenta (WU et al., 2019).

Outro trabalho investigou o uso de aprendizado de máquina para prever automaticamente o desvio de planicidade no fresamento de topo do aço 1045. Diferentes modelos foram testados, como Perceptrons Multicamadas, Redes de Funções de Base Radial, Árvores de Decisão e Random Forest. As variáveis utilizadas incluíram velocidade de corte (v_c), avanço por dente (f_z), profundidade de corte (a_p), comprimento da peça e tempo de usinagem. Entre os modelos, o Random Forest apresentou o melhor desempenho, mostrando a eficácia na aprendizagem com os dados experimentais (BUSTILLO et al., 2021).

Em outra pesquisa, foram conduzidos experimentos e otimização do fresamento de topo no aço maraging 350, uma liga de ferro-níquel de alta resistência e tenacidade. A partir de variáveis como velocidade de corte (v_c), avanço por dente (f_z) e profundidade de corte (a_p), cinco modelos de aprendizado de máquina – SVM, KNN, rede neural artificial (ANN), Random Forest e XGBoost – foram treinados e testados. O modelo XGBoost se destacou, atingindo uma precisão de 98% em conjuntos de dados pequenos (ABBAS et al., 2021).

Outro estudo investigou a aplicação de regressão dos vetores de suporte (SVR) no fresamento de topo do aço inoxidável SS316, com foco em diferentes condições de resfriamento: seco, úmido e criogênico. Utilizando a metodologia de superfície de resposta (RSM), o estudo construiu um modelo que relaciona as variáveis independentes (velocidade de corte, avanço por dente e profundidade de corte) à rugosidade superficial. Os resultados mostraram que o modelo SVR foi eficaz em compreender o impacto dos parâmetros do processo na rugosidade, oferecendo previsões precisas (KARTHIK et al., 2021).

Outra pesquisa explorou o uso de regressão de crista do kernel gaussiano para prever o desgaste de flanco no fresamento de topo do Inconel 718, com variáveis de entrada como velocidade de corte (v_c), avanço por dente (f_z), profundidade de corte (a_p) e largura fresada (a_e). O modelo alcançou um coeficiente de determinação (R^2) de 0,93, indicando alta precisão (BANDA et al., 2023).

Estudos adicionais exploram a previsão da rugosidade superficial e o monitoramento das condições de ferramentas no fresamento. Por exemplo, Wu et al. (2022) desenvolveu modelos para prever a rugosidade no fresamento de topo do aço S45C, enquanto Kaliyannan et al. (2024) aplicaram aprendizado profundo e aprendizado por reforço para monitorar as condições das ferramentas. No estudo de Mohanraj et al. (2024), foram desenvolvidos modelos de floresta aleatória voltados para a previsão de falhas em fresas durante o fresamento de topo. Já Aslan (2024) aplicaram modelos de aprendizado de máquina para realizar uma análise de usinabilidade, comparando diversos meios de resfriamento e lubrificação na fresagem do aço Hardox 400. Em outro estudo, Danish et al. (2024) investigaram modelos de aprendizado de máquina para prever e classificar o

desgaste de ferramentas no fresamento sustentável do aço inoxidável 316.

O uso de modelos de aprendizado de máquina em processos de fresamento de topo tem crescido significativamente, impulsionado pela busca por maior precisão e eficiência na previsão dos níveis das variáveis do processo. No entanto, uma lacuna importante ainda persiste na literatura: a maioria dos modelos de aprendizado de máquina desenvolvidos para o fresamento de topo considera apenas variáveis controláveis, negligenciando as variáveis incontroláveis ou ruídos inerentes ao processo, como desgaste de ferramenta e variações na vazão de fluido. Essa limitação pode levar à construção de modelos que apresentam boas métricas de desempenho em dados controlados, mas que não conseguem representar com precisão as condições reais e variáveis encontradas em ambientes industriais. Dessa forma, a capacidade preditiva e a aplicabilidade prática desses modelos ficam comprometidas.

Preencher essa lacuna é fundamental para o avanço da modelagem robusta no fresamento, pois a inclusão das variáveis incontroláveis permite desenvolver modelos que simulam de forma mais realista o comportamento do processo, tornando-os mais confiáveis para a tomada de decisão. Além disso, na literatura atual, são escassos os trabalhos que integrem diretamente esses modelos robustos de aprendizado de máquina com técnicas de otimização para a melhoria dos parâmetros de corte.

Neste contexto, esta tese propõe o desenvolvimento de modelos que considerem simultaneamente as variáveis controláveis e incontroláveis, buscando refletir as condições reais do fresamento de topo do aço inoxidável duplex UNS S32205. Para encontrar o ponto ótimo de operação que minimize a rugosidade superficial R_a , será aplicado o algoritmo Particle Swarm Optimization (PSO), utilizando como função objetivo um modelo preditivo baseado em aprendizado de máquina. Essa abordagem integrada visa não apenas aumentar a precisão das previsões, mas também promover melhorias tangíveis no desempenho do processo, contribuindo para a eficácia da aplicação dessas tecnologias em ambientes industriais.

1.2 Objetivos

O presente trabalho tem como objetivo principal a otimização do processo de fresamento de topo do aço inoxidável duplex UNS S32205 (*Unified Numbering System*), por meio do desenvolvimento de modelos de aprendizagem de máquina para previsão da rugosidade superficial - R_a , considerando tanto variáveis controláveis quanto incontroláveis do processo.

1.3 Objetivos específicos

Dentre os objetivos específicos desta investigação, destacam-se:

1. Desenvolver modelos preditivos para a rugosidade superficial (R_a), utilizando diferentes técnicas de aprendizado de máquina, como SVM (*Support Vector Machine* - (Máquina de vetores de suporte)), DTR (*Decision Tree Regression* - (Árvore de decisão)), RF (*Random Forest* - (Floresta Aleatória)) e RNA (*Artificial neural networks* - (Redes neurais artificiais));
2. Avaliar as métricas de desempenho dos modelos e selecionar aquele que apresentar o menor RMSE (*Root Mean Square Error* - (Raiz do Erro Quadrático Médio)), o maior coeficiente de determinação (R^2) e o maior valor médio de R^2 ;
3. Modelar a função de regressão obtida a partir do modelo de aprendizado de máquina;
4. Analisar a eficiência do modelo quanto à acurácia de suas previsões;
5. Verificar a capacidade do modelo em identificar a influência dos parâmetros controláveis e incontroláveis sobre a variável resposta;
6. Realizar a otimização do modelo de regressão gerado, com o objetivo de comparar os resultados preditivos com os dados experimentais reais;
7. Avaliar os experimentos de confirmação, com o intuito de validar os resultados obtidos.

1.4 Contribuição Científica

As principais contribuições científicas do presente estudo são:

1. A inclusão dos ruídos inerentes ao processo, juntamente com as variáveis controláveis, no desenvolvimento e treinamento dos modelos de aprendizagem de máquina. Ao considerar tanto os ruídos do processo quanto os parâmetros controláveis, os modelos se tornam mais representativos da realidade industrial, permitindo previsões mais precisas da rugosidade (R_a).
2. Desenvolvimento de modelos de aprendizado de máquina que incorporam as variabilidades e ruídos naturais do processo de usinagem, como desgaste da ferramenta, vazão de fluido e altura em balanço. Esses modelos são capazes de considerar o impacto dessas variáveis incontroláveis sobre as variáveis controláveis, permitindo previsões mais realistas e consistentes da rugosidade superficial. Para a indústria, essa abordagem contribui significativamente para a otimização do processo e para a melhoria da qualidade na produção.
3. Um método eficiente e de baixo custo para simular o processo de fresamento de topo do aço inoxidável duplex, reduzindo a necessidade de testes experimentais caros e demorados.

1.5 Delimitações da pesquisa

Este subcapítulo tem como objetivo esclarecer as condições de contorno desta pesquisa. Em primeiro lugar, este trabalho limita-se à aplicação da metodologia de aprendizado de máquina no processo de fresamento de topo do aço inoxidável duplex UNS S32205, utilizando insertos de metal duro CoroMill R390-11T308M-MM GC 2030 (*SandvikCoromant*), revestidos com dupla camada de nitreto de titânio (TiN) e nitreto de titânio alumínio (TiAlN). A escolha desse material e ferramenta se deve às suas características específicas de usinabilidade, sendo amplamente utilizado em ambientes industriais. Embora a metodologia aplicada possa ser estendida a outros processos de usinagem, este trabalho restringe-se a essa configuração específica.

Quanto ao processo de usinagem, os resultados obtidos são válidos exclusivamente para as condições experimentais avaliadas. A pesquisa foi conduzida dentro de uma região experimental delimitada, e os modelos desenvolvidos não têm a intenção de abranger outras condições ou cenários industriais fora do escopo definido.

Além disso, os modelos avaliados neste estudo foram restritos aos seguintes algoritmos de aprendizado de máquina: Máquinas de vetores de suporte (SVM), árvores de decisão, redes neurais artificiais (MLP) e floresta aleatória. Outros modelos de aprendizado de máquina não foram considerados nesta pesquisa.

2 REVISÃO DA LITERATURA

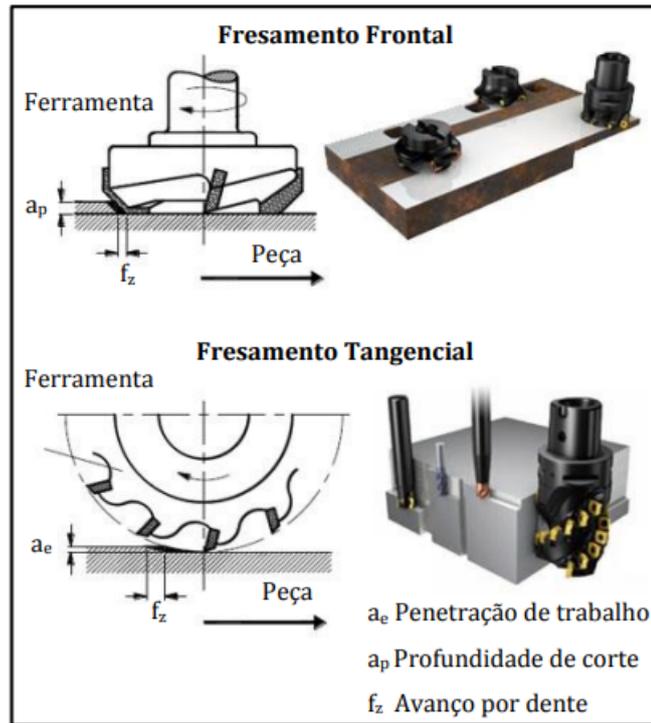
Este capítulo apresenta uma revisão da literatura focada no desenvolvimento do processo de fresamento de topo do aço inoxidável duplex, utilizando técnicas de aprendizagem de máquina. São discutidas as características e propriedades desse material, além de abordar metodologias de inteligência artificial, como a aprendizagem de máquina, validação cruzada, modelos baseados em árvores, máquinas de vetores de suporte e redes neurais artificiais. Além disso, são explorados conceitos relacionados à aplicação da metodologia de superfícies de resposta, o uso do projeto de parâmetro robusto e o conceito de arranjo combinado.

2.1 Fresamento

Compreendemos como operações de usinagem aquelas que, ao conferir forma, dimensões, acabamento à peça, ou uma combinação desses três elementos, resultam na geração de cavacos (FERRARESI; PALLEROSI; RUFFINO, 1970). Ferraresi, Pallerosi e Ruffino (1970) define fresamento como o processo destinado à obtenção de superfícies plana perpendicular ao eixo de rotação da ferramenta. Diniz, Marcondes e Coppini (2014) corrobora dizendo que o processo de fresamento envolve a criação de superfícies planas mediante a eliminação sequencial de material. Isso é alcançado por meio da ação de corte e rotação da ferramenta em torno de seu eixo, combinado com o movimento progressivo da mesa.

As operações de fresamento conforme Figura 1 podem ser classificadas em periférico, tangencial e faceamento de topo (KLOCKE, 2018).

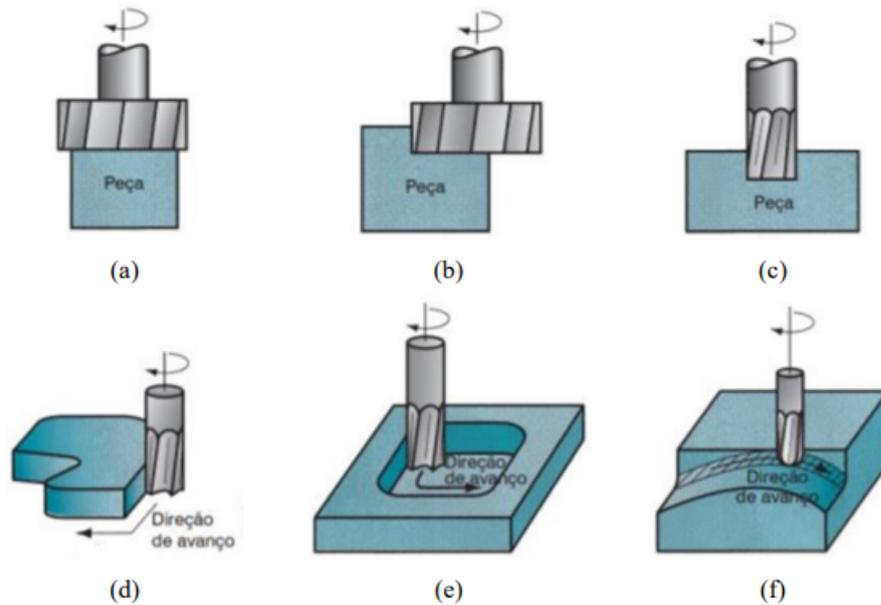
Figura 1 – Fresamento frontal, Periférico e Tangencial



Fonte: Klocke (2018), Sandvik (2017)

De acordo com (GROOVER, 2000), o faceamento convencional (Figura 2.a) envolve um processo em que o diâmetro da fresa é significativamente maior que a espessura da peça, permitindo que a ferramenta cubra a peça por completo. De maneira semelhante, no fresamento de cantos a 90° ou no faceamento parcial (Figura 2.b), a ferramenta cobre apenas uma parte da superfície. No fresamento de topo (Figura 2.c), o diâmetro da fresa é menor que o da peça, resultando na formação de sulcos ou canais. Nesse caso, a superfície usinada é gerada pelas arestas de corte secundárias, que estão dispostas perpendicularmente ao eixo da fresa. No fresamento de bordas (Figura 2.d), o processo ocorre por meio das arestas de corte principais da fresa, que entram em contato com a periferia da peça. O fresamento de cavidades (Figura 2.e) envolve a criação de cavidades ou bolsões em superfícies planas. Por fim, o fresamento de perfis (Figura 2.3f) utiliza uma fresa de ponta esférica que segue uma trajetória curvilínea, côncava ou convexa, cobrindo toda a peça para formar uma estrutura tridimensional na superfície.

Figura 2 – Tipos de fresamento: (a) faceamento; (b) de cantos a 90°; (c) de topo; (d) de bordas; (e) de cavidades (f) de perfis



Fonte: Groover (2000)

O fresamento é amplamente utilizado na indústria devido à sua capacidade de produzir superfícies geométricas complexas, com altas taxas de remoção de material e formas com boa precisão dimensional. Por essas características, esse processo é bastante aplicado no setor metal-mecânico (BHISE; JOGI, 2021). Indústrias, especialmente aquelas voltadas para os segmentos de petróleo e gás, exigem peças fabricadas com elevada precisão e exatidão (POLICENA et al., 2018). A qualidade do acabamento superficial é uma exigência crucial para projetistas e fabricantes, onde um acabamento inadequado pode aumentar o risco de corrosão por pite, comprometendo a durabilidade da peça ou do componente (SAMBEDANA et al., 2019). A escolha do processo de fresamento se justifica pela sua eficiência na remoção rápida de material, garantindo um acabamento de alta qualidade (KUMAR; SARAVANAN; PATNAIK, 2020).

No fresamento de topo (Figura 2.c), objetivo deste trabalho, é necessário definir previamente algumas grandezas para alcançar uma combinação eficaz de parâmetros, garantindo um bom acabamento e alta produtividade. Entre os principais parâmetros de corte estão a velocidade de corte (v_c), a velocidade de avanço (v_f), a rotação (n), o avanço (f), o avanço por dente da fresa (f_z), a profundidade de corte (a_p) e a largura de corte (a_e).

- A velocidade de corte (v_c) refere-se à velocidade instantânea do movimento principal de um ponto específico na aresta de corte em relação à peça, medida em metros por minuto (m/min) (STEMMER, 1993). No fresamento, essa velocidade corresponde à velocidade tangencial resultante da rotação (n) (rpm) da ferramenta com diâmetro

nominal (Φ), conforme descrito na Equação 2.1. (DINIZ; MARCONDES; COPPINI, 2014).

$$vc = \frac{\pi \cdot \Phi \cdot n}{1000} [m/min] \quad (2.1)$$

- O avanço f é a distância percorrida pela ferramenta em cada rotação (mm/volta) ou em cada curso. Para ferramentas com múltiplas arestas de corte, como as fresas, o avanço por dente da fresa (fz) é definido como a distância que cada dente percorre na direção do avanço, correspondente ao intervalo entre duas marcas consecutivas. O avanço é calculado conforme a Equação 2.2, onde z representa o número de dentes (ou arestas de corte) da fresa (MACHADO et al., 2015).

$$f = fz \cdot z [m/volta] \quad (2.2)$$

- A velocidade de avanço v_f refere-se à velocidade instantânea com que um ponto específico da aresta de corte se desloca em relação à peça, medida em milímetros por minuto (mm/min) (STEMMER, 1993). Ela é determinada pelo produto do avanço (f) pela rotação (n), conforme descrito na Equação 2.3. (DINIZ; MARCONDES; COPPINI, 2014).

$$vf = f \cdot n [mm/min] \quad (2.3)$$

- A profundidade de corte (ap) é a medida da penetração da ferramenta na peça, tomada em uma direção perpendicular ao plano de trabalho. Já a largura de corte (ae) refere-se à extensão da penetração da ferramenta em relação à peça, medida no plano de trabalho e perpendicular à direção de avanço (MACHADO et al., 2015).

Para satisfazer as diversas exigências no processo de fresamento, existe uma ampla gama de configurações de fresas disponíveis (SANDVIK, 2017). A Figura 3 mostra alguns exemplos de fresas fabricadas em aço rápido ou metal duro, assim como fresas com insertos intercambiáveis, feitos de metal duro ou cerâmica, acoplados a um suporte de aço que as segura.

Figura 3 – Tipos Fresas



Fonte: :

Adaptado SERRATOOLS (2019)

2.2 Aços Inoxidáveis Duplex

O DSS (*Duplex Stainless Steel* - (Aço inoxidável duplex)) definido pela norma ISO 15156-3 (2020) é uma liga composta por cromo C_r , níquel N_i e molibdênio M_o , derivada da família duplex (S32900), que é predominantemente ferrítica ($F_e - \alpha$). A incorporação de nitrogênio N elevou a proporção de austenita ($F_e - \gamma$) para cerca de 50%, resultando em uma melhora na tenacidade e na resistência à corrosão por cloretos (PHILIP; CHANDRAMOHAN; RAJESH, 2015).

A primeira menção ao aço inoxidável duplex (DSS) remonta a 1927, quando Bain e Griffiths publicaram um artigo descrevendo uma liga com estrutura bifásica de ferrita-austenita. Os primeiros aços inoxidáveis duplex laminados foram fabricados na Suécia em 1930 e aplicados na indústria de papel sulfite, com o objetivo de mitigar problemas de corrosão intergranular que afetavam os aços austeníticos de alto carbono da época (MORELO, 2014). No mesmo ano, na Finlândia, houve a produção de peças em DSS por fundição, e, em 1936, a França obteve a primeira patente relacionada ao DSS. Essa primeira geração de DSS foi amplamente empregada durante a Segunda Guerra Mundial e em diversas aplicações industriais, como tanques de armazenamento, trocadores de calor e bombas centrífugas (IMOA, 2012).

Os aços inoxidáveis duplex (DSS) da primeira geração demonstraram um desempenho satisfatório nas aplicações mencionadas anteriormente. Contudo, a ZTA (Zona termicamente afetada) nas juntas soldadas exibia tenacidade reduzida devido ao excesso de ferrita e apresentava resistência à corrosão bem abaixo da do material base (ALVAREZ-ARMAS, 2008). No final dos anos 1960, o avanço na tecnologia de fabricação de aços e o processo de descarburização com oxigênio e argônio permitiram, entre outras melhorias, a inclusão de nitrogênio na composição dos DSS. Essa inovação resultou em uma ZTA com maior tenacidade e resistência à corrosão, mais próxima das características do metal base. Além disso, a adição de nitrogênio contribuiu para uma melhor estabilidade da fase ($F_e - \gamma$) e

reduziu a formação de fases intermetálicas prejudiciais (IMOA, 2012).

No final dos anos 1970, a segunda geração do aço inoxidável duplex (DSS) foi impulsionada pela adição de nitrogênio, o que ampliou sua expansão comercial. Na época, houve uma crescente demanda por materiais com alta resistência mecânica e boa resistência à corrosão por cloretos, com o objetivo de serem empregados em plataformas de petróleo e gás no Mar do Norte. Durante esse período, a liga de DSS mais utilizada foi a 2205. Devido à alta resistência desse material, foi possível reduzir significativamente a espessura dos componentes, oferecendo vantagens consideráveis para sua aplicação (IMOA, 2012).

Em meados da década de 1990, a utilização dos aços inoxidáveis duplex (DSS) aumentou principalmente devido ao seu custo mais baixo em comparação com os aços inoxidáveis austeníticos ASS (*Austenitic Stainless Steel* - Aço inoxidável Austenítico), uma vez que sua composição contém menos (N_i) (SNIS; OLSSON, 2008). Em seu estado recozido, os DSS apresentam maior resistência do que os ASS e os aços inoxidáveis FSS (*Ferritic Stainless Steel* - (Aço inoxidável Ferrítico)). No entanto, é possível aumentar sua resistência mecânica por meio de tratamento térmico. Além disso, a resistência à corrosão galvânica e à corrosão por pite pode ser melhorada com a adição de molibdênio (Mo) à sua composição química (LIMA, 2019).

A corrosão por pites, ou simplesmente pite, é um tipo altamente localizado de corrosão que afeta principalmente a superfície de metais inoxidáveis, especialmente na presença de cloretos (SEDRIKS, 1996). Esse processo inicia-se em pequenos pontos da superfície do metal, onde ocorrem reações eletroquímicas localizadas que resultam na formação de pequenos "poços" ou "furos" na superfície. Esses pites são profundos e estreitos, resultantes de descontinuidades provocadas pelo contato do metal com ambientes agressivos, como soluções salinas (CARVALHO, 2024). O pite é um dos tipos mais destrutivos de corrosão porque pode causar perfuração do metal e se propaga rapidamente devido ao aumento local da acidez. A resistência à corrosão por pites é influenciada pela presença de elementos de liga como cromo (Cr), molibdênio (Mo) e nitrogênio (N); quanto maior o teor desses elementos, melhor a resistência do aço à corrosão por pites (CANIÇALI, 2022).

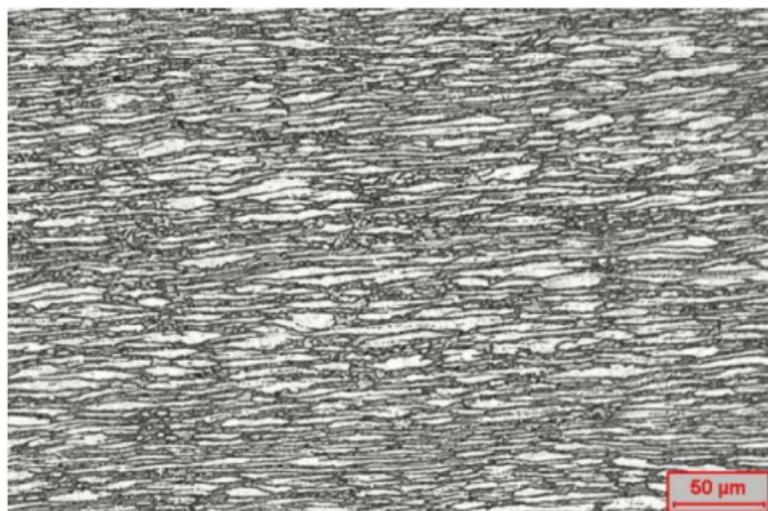
A expressão que permite comparar de maneira geral a resistência ao pite em diferentes aços inoxidáveis é conhecida como PREN (*Pitting Resistance Equivalent Number* - (Número equivalente de resistência por pite)). O PREN pode ser calculado pela Equação 2.4.

$$PREN = \%Cr + 3,3(\%Mo + 0,5\%W) + 16\%N \quad (2.4)$$

Para que os DSS se enquadrem como aços inoxidáveis duplex precisam ter um valor de PREN superior a 20. IMOA (2014) relaciona cinco tipos de DSS: *lean duplex* (PREN = 21-27), *lean duplex* com Mo (PREN = 27-34), *standard duplex* (PREN = 34-38), *super duplex* (PREN = 38-43) e hiper duplex (PREN = 49-53) (IMOA, 2012).

O UNS S32205 apresenta uma microestrutura bifásica, composta por fases austenítica CFC (Cúbica de face centrada) e ferrítica CCC (Cúbica de corpo centrado). Sua composição química típica inclui 22% C_r , 5% N_i e 3% M_o , além de uma pequena adição de nitrogênio (N). A Figura apresenta as fases do aço inoxidável duplex 4.

Figura 4 – Microestrutura do aço inoxidável duplex



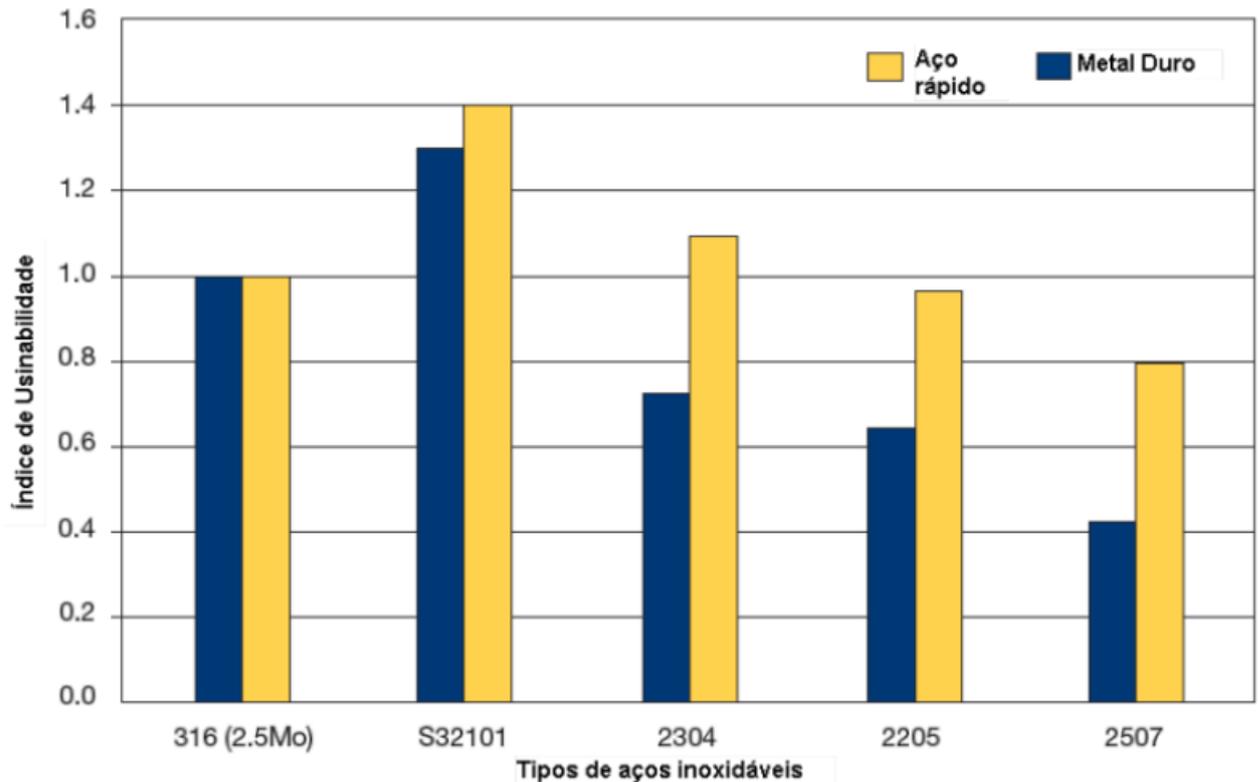
Fonte: Silva, Batista e Batista (2017)

Na representação, as fases em preto correspondem à ferrita, enquanto as em branco indicam a presença de austenita, justificando o termo "Duplex" (GUNN, 1997). De acordo com Siow, Song e Qiu (2001), a presença da austenita confere ao material características como ductilidade, tenacidade e soldabilidade, enquanto a ferrita contribui para uma elevada resistência à corrosão sob tensão.

2.3 Usinabilidade

Devido à ampla gama de aços inoxidáveis disponíveis, uma caracterização simplificada de sua usinabilidade pode ser imprecisa. Usinabilidade é definida por como sendo a capacidade de um material de ser cortado, moldado ou usinado com eficiência e qualidade durante o processo de usinagem. A usinabilidade dos aços inoxidáveis varia significativamente, indo desde baixa até muito alta, dependendo da liga específica escolhida (DINIZ; MARCONDES; COPPINI, 2014). A Figura 5 apresenta o gráfico de colunas comparando a usinabilidade dos diferentes DSS (2101, 2304, 2205 e 2507), com o ASS 316, aplicando ferramentas de aço-rápido e metal-duro.

Figura 5 – Microestrutura do aço inoxidável duplex



Fonte: Adaptado de IMO A (2012)

Usinar aços inoxidáveis duplex geralmente apresenta um desafio considerável devido aos elevados teores de molibdênio (M_o), nitrogênio e ao baixo teor de carbono (C) ((JEBARAJ et al., 2017; SANTOS et al., 2021)). Entre os fatores que justificam a baixa usinabilidade estão a alta resistência, a alta tenacidade, a baixa condutividade térmica, a presença de pequenas inclusões não metálicas e o alto grau de encruamento.

O encruamento é mais pronunciado nas camadas superficiais do que nas camadas internas, devido ao maior grau de deformação nas regiões próximas à superfície usinada. O endurecimento por deformação aumenta com o avanço de corte. Em contraste, a influência da velocidade de corte é menor, pois, embora um aumento na velocidade de cisalhamento eleve a taxa de deformação, isso também eleva a temperatura na zona de corte (MOHAMMADI; AMIRABADI, 2022). A formação de arestas postigas de corte, associada à alta ductilidade do material, geralmente resulta em um acabamento superficial de baixa qualidade, discrepâncias dimensionais e desgaste acelerado da ferramenta (KROLCZYK et al., 2014; PARO; HÄNNINEN; KAUPPINEN, 2001).

A estrutura bifásica (ferrita-austenita) dos aços inoxidáveis duplex (DSS) tende a induzir vibrações durante o processo de corte, o que agrava a dificuldade em alcançar uma rugosidade superficial de alta qualidade e uma vida útil prolongada da ferramenta (KOYEE et al., 2014). A ferrita ($Fe-\alpha$) e a austenita ($F_e - \gamma$) estão distribuídas de forma aleatória; dessa forma, a ferramenta alterna entre cortar grãos macios ($F_e - \alpha$) e grãos

duros ($F_e - \gamma$), o que pode provocar vibrações regenerativas (autoexcitadas ou chatter) durante o corte (KOYEE et al., 2014). Cada fase possui propriedades distintas e contribui de maneira diferenciada para a formação de cavacos e a remoção de material durante o corte (GOWTHAMAN; JEYAKUMAR; SARAVANAN, 2020). Em aços com teores de carbono inferiores a 0,06%, a ferrita apresenta uma dureza em torno de 90 HB, enquanto a dureza da austenita varia de 85 a 170 HB (STÅHL et al., 2012)

Segundo Martinho et al. (2019), o aço inoxidável austenítico (ASS) apresenta uma condutividade térmica inferior quando comparado ao aço carbono, o que pode influenciar diretamente no comportamento térmico durante processos de usinagem. Além disso, conforme dados da IMOA (2012), o aço ASS do tipo UNS S32205 possui propriedades mecânicas inferiores ao duplex, com limite de escoamento e resistência à tração geralmente menores. Especificamente, em temperatura ambiente e na condição recozido solubilizado, o limite de escoamento dos aços ASS convencionais é menos da metade do observado em aços inoxidáveis duplex. Essas características indicam que, embora o ASS ofereça boa resistência à corrosão e usinabilidade, suas propriedades térmicas e mecânicas impõem limitações em certas aplicações industriais.

Devido à sua maior dureza e à rápida taxa de endurecimento por deformação, os aços inoxidáveis duplex tendem a diminuir a vida útil da ferramenta durante as operações de usinagem ou requerem períodos de usinagem mais prolongados quando comparados aos tipos padrão austeníticos (IMOA, 2012). Por esse motivo, a manufatura de componentes em aço inoxidável duplex representa um considerável desafio para a indústria metal-mecânica, especialmente quando o método de usinagem utilizado é o fresamento (AMARO; FERREIRA; SIMÕES, 2020). Nesse contexto, vários estudos dedicados ao processo de fresamento dos aços inoxidáveis duplex têm sido divulgados. Em geral, esses estudos visam melhorar a qualidade e aumentar a produtividade, metas desafiadoras devido à sua baixa usinabilidade.

Policena et al. (2018) examinaram o impacto do avanço por dente, da profundidade e da velocidade de corte nas rugosidades R_a e R_z durante o processo de fresamento do aço inoxidável duplex UNS S32205. Constataram que o avanço representou a variável mais notável para ambas as rugosidades. Os pesquisadores notaram que níveis inferiores de configuração para o avanço e a profundidade de corte resultaram na minimização dos valores de R_a e R_z .

Selvaraj e Chandrasekar (2018) investigaram a influência da velocidade de corte e avanço por dente, durante o fresamento do aço inoxidável duplex e super duplex, sobre a rugosidade e força de corte. Os autores concluíram que a variável mais influente em ambas as respostas foi o avanço por dente.

Selvaraj, Chandramohan e Rajesh (2019) realizaram a otimização dos parâmetros de corte durante o fresamento do aço inoxidável duplex UNS S31803, com o objetivo de reduzir a rugosidade, a força de corte e o desgaste do flanco da ferramenta. A conclusão

dos autores foi que o avanço por dente exerceu a maior influência sobre a rugosidade e a força de corte, ao passo que a velocidade foi a variável mais significativa no desgaste da ferramenta.

Grguraš, Kern e Pušavec (2019) estudaram o desempenho de corte de ferramentas de fresamento sólido de cerâmica e metal duro na usinagem da liga à base de níquel Inconel 718 e do aço inoxidável 316L. Os resultados indicam que as ferramentas de fresamento de cerâmica aumentam a taxa de remoção de material e a produtividade. No entanto, a eficiência global das ferramentas cerâmicas ainda pode ser economicamente questionável.

Oliveira et al. (2020) examinaram o impacto da velocidade de corte, avanço por dente, profundidade de corte e largura fresada nos fatores rotacionados F_1 (que englobam as rugosidades R_a , R_q , R_t e R_y) e F_2 (associados à potência de corte e eficiência) durante o processo de fresamento do aço inoxidável duplex UNS S32205. A conclusão dos autores foi que o avanço por dente se mostrou como o parâmetro mais significativo para o fator F_1 , enquanto a velocidade de corte teve maior influência sobre o fator F_2 .

Amaro, Ferreira e Simões (2020) estudaram a influência da estratégia de fresamento por corte na usinabilidade dessas ligas, comparando percursos convencionais e trocoidais, fresados com uma ferramenta que possui pastilhas intercambiáveis revestidas com AlTiN. Os autores concluíram que para ambas as estratégias, os resultados mostraram que o dano à aresta da ferramenta é caracterizado pelo desenvolvimento progressivo de um desgaste de flanco, seguido de fenômeno de lascamento, que geralmente aparece primeiro localizado na região da aresta de corte onde termina o contato com o cavaco.

Abbas et al. (2021) avaliaram o efeito da velocidade de corte, do avanço e do resfriamento na qualidade da superfície e no consumo de energia no acabamento de fresamento de topo de aço inoxidável duplex. Os autores concluíram que com maiores velocidades de corte e com o resfriamento houve uma redução da energia de corte, melhora na qualidade da superfície e maior produtividade.

Yasir et al. (2021) realizaram uma investigação sobre a velocidade de corte e avanço na qualidade da superfície e na micro dureza do fresamento de topo de precisão em aço inoxidável. A melhor qualidade superficial foi observada para velocidades de corte maiores e avanços menores. A microdureza foi aumentada com o aumento da velocidade de corte. Por fim os resultados indicaram que amostras com maior rugosidade superficial eram mais propensas à fissuração por corrosão sob tensão.

Silva et al. (2022) estudaram o comportamento do desgaste das ferramentas revestidas ao fresar o aço inoxidável duplex S32101. Os autores concluíram que os revestimentos de TiAlSiN (Classe de revestimentos avançados - Titânio-Alumínio-Silício-Nitreto) depositados nas ferramentas de metal duro apresentaram melhor desempenho ao desgaste do que as ferramentas revestidas com TiAlN (Classe de revestimentos avançados - Titânio-Alumínio-Nitreto) nas mesmas condições de fresamento lubrificado, proporcionando também um melhor acabamento superficial. Os revestimentos TiAlSiN podem

acomodar valores de avanço mais elevados e distâncias de corte maiores, apresentando menor desgaste do revestimento e melhor qualidade superficial da peça.

Sousa et al. (2022) investigaram o desempenho de quatro ferramentas de fresamento com diferentes geometrias e revestimentos (*TiAlN*, *AlCrN* (Classe de revestimentos avançados - Alumínio-Cromo-Nitreto), *TiAlSiN*) em operações de usinagem de *ASS*. As ferramentas diferiam no número de canais, sendo uma com dois canais (T1) e as demais com quatro (T2, T3 e T4), e nos tipos de revestimento aplicados. Os resultados mostraram que as ferramentas T1 (dois canais, *AlCrN*) e T2 (*TiAlN*) não se adequaram bem às condições de usinagem mais exigentes, sofrendo desgaste severo, especialmente sob avanço elevado. As ferramentas T3 (quatro canais, *AlCrN*) e T4 (*TiAlSiN*) apresentaram os melhores resultados, com T4 superando as demais em termos de resistência ao desgaste de flanco e qualidade da superfície usinada, sobretudo nas condições de teste com avanço de 75% e 100%

Janardhan, Chandrappa e Suresh (2023) estudaram o fresamento em alta velocidade de aço inoxidável super duplex e para investigar o efeito dos parâmetros de corte na rugosidade superficial. Os resultados mostram que uma velocidade de corte mais alta resultou em forças de corte mais baixas, mas uma taxa de avanço mais alta resultou em forças de corte mais altas. Os pesquisadores demonstraram que aumentar as forças de usinagem também aumenta a profundidade de corte. Verificou-se que velocidades de corte mais altas resultam em valores reduzidos de rugosidade superficial durante a usinagem de aço super duplex.

Toledo et al. (2023) realizaram um estudo na abordagem de otimização evolutiva robusta multiobjetivo aplicada ao processo de fresamento helicoidal multivariado de aço super duplex para avaliar a força de corte, a rugosidade e a cilindridade. Para o estudo, foram considerados os parâmetros pertinentes ao processo e os ruídos. Os ruídos considerados foram o balanço da ferramenta, a vazão de fluido e a profundidade do furo. Os resultados mostraram que é possível otimizar o viés e a variância do processo utilizando o erro quadrático médio e o algoritmo evolutivo multiobjetivo AGE-MOEA obteve o melhor desempenho considerando o hipervolume. Algumas soluções com alto trade-off foram selecionadas através de pseudopesos para auxiliar a tomada de decisão.

2.4 Qualidade da Superfície

A rugosidade superficial é um fator crucial na avaliação da qualidade de peças usinadas, afetando diretamente sua funcionalidade, desempenho e durabilidade. Originada pelas características inerentes ao processo de usinagem, como a interação entre a peça e a ferramenta de corte, a rugosidade é composta por um padrão de irregularidades que podem ser cíclicas ou apresentar uma textura específica. Essas irregularidades são influenciadas por diversos fatores, incluindo os materiais da peça e da ferramenta, a geometria da

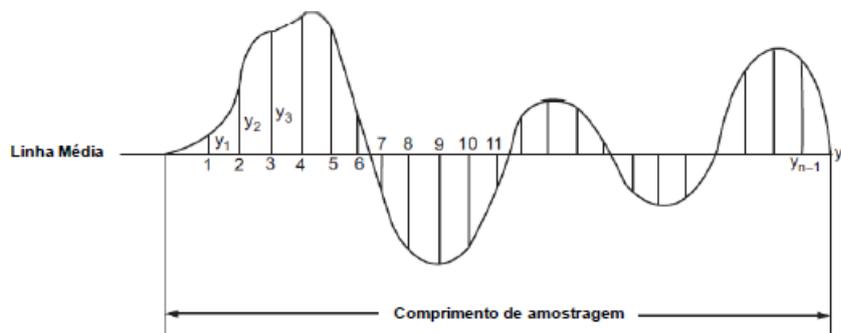
peça, os parâmetros de corte e as condições do processo de usinagem (AMORIM, 2002; PETROPOULOS; PANDAZARAS; DAVIM, 2010; QIN et al., 2014)

A análise da rugosidade é realizada por meio de parâmetros específicos, dos quais os mais relevantes são a rugosidade média R_a e a rugosidade total R_t , que quantificam as variações superficiais. Segundo Agostinho, Rodrigues e Lirani (2004) e Machado et al. (2015), o parâmetro R_a é calculado pela média aritmética dos valores absolutos das variações do perfil efetivo conforme Equação 2.5.

$$R_a = \frac{(y_1 + y_2 + \dots + y_7 + y_8 \dots + y_{n-1} + y_n)}{n} = \frac{\sum_{i=1}^n |y_i|}{n} \quad (2.5)$$

Segundo Smith (2002), a rugosidade R_a foi adotada para especificações de usinagem por ser um parâmetro mais fácil de determinar graficamente, a partir do registro de um perfil. Por esse motivo, foi adotado, antes mesmo do desenvolvimento de instrumentos de medição automática, para medir a textura de superfície. Um perfil típico resultante para a rugosidade R_a após o processo de usinagem poder ser observada conforme Figura 6.

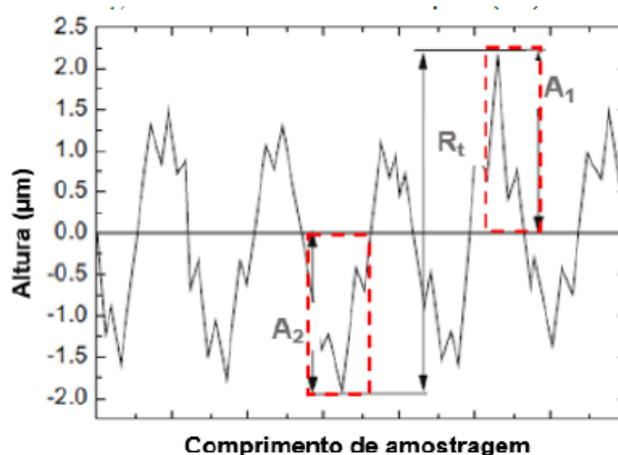
Figura 6 – Perfil de rugosidade superficial R_a



Fonte: :

Adaptado Patil (2018)

Já a rugosidade R_t é a distância vertical entre o pico mais alto e o vale mais profundo em um comprimento de amostra, conforme Figura 7. A integridade da superfície usinada engloba não só aspectos visíveis como topografia e textura, mas também características internas, como modificações metalúrgicas e tensões residuais, que podem influenciar o desempenho da peça em suas aplicações finais (GRZESIK, 2017).

Figura 7 – Representação do parâmetro R_t (rugosidade total)

Fonte: :

Adaptado Quinten (2019)

O controle e a medição da rugosidade são essenciais para garantir a adequação das peças às suas funções específicas, impactando a resistência ao desgaste, os custos de produção e a resistência à fadiga (GADELMAWLA et al., 2002; MIKOLAJCZYK, 2014). Equipamentos especializados, como rugosímetros, são empregados seguindo normas técnicas rigorosas que orientam sobre os procedimentos adequados de medição, incluindo o *CUT-OFF* (Comprimento de onda do filtro) para diferenciar entre perfis de rugosidade (ABNT, 2002).

Grous (2013) desenvolveu uma tabela experimental baseada nas diretrizes da *DIN 4766* e nas especificações da *Mitutoyo*[®], estabelecendo uma correlação entre o comprimento de amostragem l_e e o comprimento de avaliação l_m com base nos parâmetros de rugosidade R_a e R_z . Os detalhes são apresentados na Tabela 1.

Tabela 1 – Comprimento de amostragem (“cut – off”)

R_a	R_z	Comprimento de amostragem l_E	Comprimento de avaliação l_m
$0,006 < R_a > 0,02$	$0,025 < R_z > 0,1$	0,08	0,4
$0,02 < R_a > 0,1$	$0,1 < R_z > 0,5$	0,25	1,25
$0,1 < R_a > 2$	$0,5 < R_z > 10$	0,8	4
$2 < R_a > 10$	$10 < R_z > 50$	2,5	12,5
$10 < R_a > 80$	$50 < R_z > 200$	8	40

Fonte: Grous (2013)

2.5 Aprendizagem de Máquina

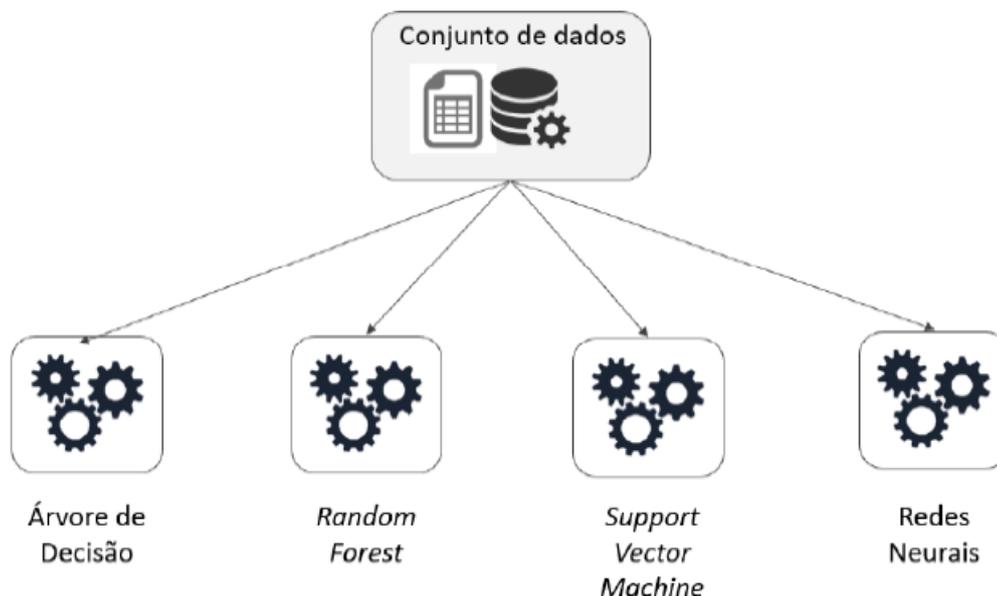
O objetivo principal da IA (Inteligência Artificial) é fornecer um conjunto de algoritmos e técnicas que possam resolver automaticamente e de forma eficiente problemas

que os humanos realizam intuitivamente (BEAM; KOHANE, 2018). O aprendizado de máquina é um campo do aprendizado computacional dentro da IA que busca a detecção automatizada de padrões significativos em dados e a solução de problemas que são impossíveis ou impraticáveis de serem representados por algoritmos explícitos (SHALEV-SHWARTZ; BEN-DAVID, 2014). Enquanto a IA abrange um conjunto grande e diverso de trabalhos relacionados ao raciocínio automático de máquinas (conhecimento, inferência, planejamento), o subcampo do ML (*Machine learning* - (Aprendizagem de máquina)) tende a ser especificamente interessado no reconhecimento de padrões e no aprendizado a partir de dados (JORDAN; MITCHELL, 2015).

Basicamente, o problema de aprendizado pode ser definido de acordo com sua saída como: (i) problemas de classificação, nos quais a saída assume valores discretos que representam categorias; e (ii) problemas de regressão, nos quais a saída é um valor real e sua relação com a entrada é dada por uma função. Essencialmente, existem três características nas quais o ML tem alcançado resultados bem-sucedidos: (1) existe um padrão; (2) não é possível (ou viável) representá-lo matematicamente; (3) existem dados que relacionam variáveis (MAIOR, 2020).

A aplicação mais bem-sucedida do ML é, definitivamente, observada em problemas supervisionados. Modelos de ML encontram relações entre entradas e saídas, o que permite seu uso em contextos como mineração de dados, reconhecimento de padrões e problemas de previsão, por exemplo. Esses contextos são particularmente interessantes porque é possível trabalhar com pequenos e grandes conjuntos de dados e a tarefa de pré-processamento, preparação de dados e/ou previsão pode ser realizada por vários modelos de ML (VOYANT et al., 2017). Existem diversos tipos de algoritmos de regressão. A Figura 8 mostra quais algoritmos foram utilizados nesta tese.

Figura 8 – Algoritmos de aprendizagem de máquina utilizados nesta tese



Fonte: Adaptado Géron (2022)

A seguir, será apresentado um breve resumo de cada algoritmo de regressão utilizado nesta tese. O objetivo é fornecer uma visão geral de cada algoritmo, enquanto descrições mais detalhadas estão além do escopo desta tese e podem ser consultadas nas referências recomendadas. Para manter a padronização, alguns dos algoritmos são referenciados no texto em inglês.

2.5.1 Máquina de vetores de suporte

Drucker et al. (1996) propuseram as máquinas de vetores de suporte para regressão (SVR - *Support Vector Regression*), um método que confirma os conceitos da teoria de aprendizado estatístico de (VAPNIK, 1999). De acordo Wang (2005), a Máquina de Vetores de Suporte é um método de aprendizado supervisionado que tem como objetivo criar uma função de mapeamento entre um vetor de entrada \mathbf{x} e um escalar de saída y com base no conjunto de dados de treinamento $D = [(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N)]$, $i = 1, \dots, N$. Supondo um contexto em que a variável resposta Y é contínua, $\mathbf{y} \in \mathbb{R}$ e as observações formam o vetor de variáveis explicativas, os modelos de vetores de suporte para regressão (DRUCKER et al., 1996) foram propostos como uma versão generalizada das máquinas de vetores de suporte. Da mesma forma, o método herda propriedades importantes da versão de classificação, uma vez que está baseado em vetores de suporte e nas funções do kernel para lidar com cenários em que os dados não possuem comportamento linear.

Seja um modelo linear, segundo a Equação 2.6:

$$f(\mathbf{x}_i) = \mathbf{w} \cdot \mathbf{x} + b \quad (2.6)$$

Onde $f(\mathbf{x}_i)$ é determinado a partir da minimização da norma:

$$\frac{\|\mathbf{w}\|^2}{2} = \frac{\mathbf{w} \cdot \mathbf{w}}{2} \quad (2.7)$$

sujeito às condições:

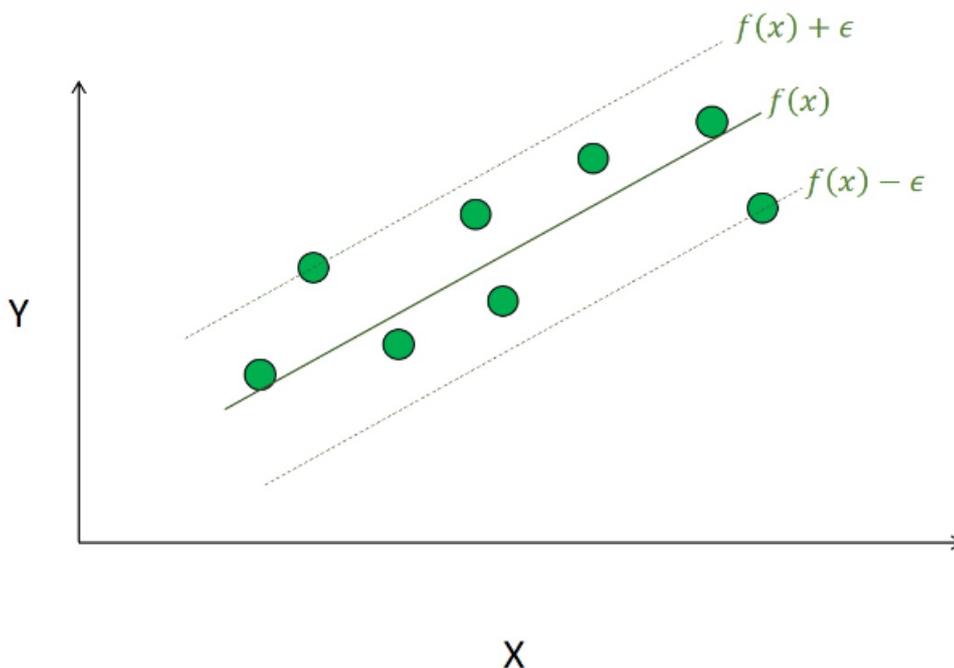
$$|y_i - f(\mathbf{x}_i)| \leq \varepsilon, \forall i = 1, \dots, n \quad (2.8)$$

Tais condições advêm do uso da função de perda ε -insensitiva. A função de perda ε -insensitiva utilizada no SVR é representada por $\varepsilon_i = |y_i - \hat{y}_i| - \varepsilon$, por meio da restrição apresentada na Equação 2.9.

$$L = \begin{cases} 0, & \text{se } |y_i - \hat{y}_i| < \varepsilon \\ |y_i - \hat{y}_i| - \varepsilon, & \text{caso contrário} \end{cases} \quad (2.9)$$

O SVM para regressão busca analisar o comportamento dos dados dentro de um hipertubo. Um hipertubo é uma construção que, em um espaço multidimensional, separa duas classes de dados. A Figura 9 ilustra o comportamento dos dados em um SVR com margens rígidas, onde todos os dados estão contidos dentro do hipertubo. A Equação 2.9, conhecida como ε -insensitiva, indica que o problema de otimização da Equação 2.7 se restringe a resíduos absolutos inferiores a ε , permitindo que alguns pontos não satisfaçam essa restrição (ARA RAYDONAL OSPINA, 2023).

Figura 9 – Máquina de Vetores de Suporte - Margens Rígidas



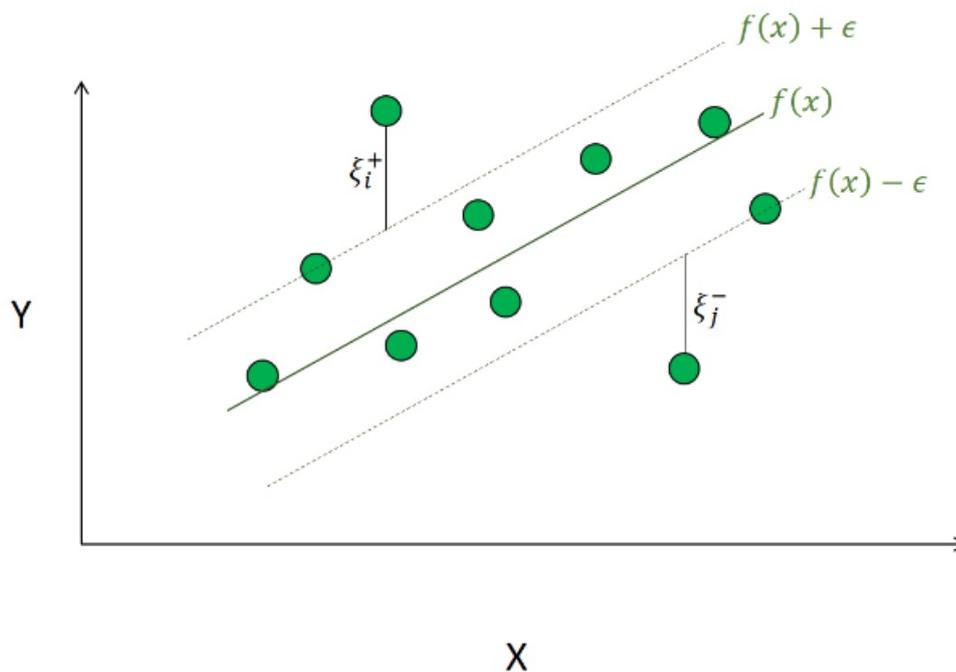
Fonte: Adaptado Ara Raydonal Ospina (2023)

Entretanto, visando obter um método mais flexível, é possível introduzir variáveis de folga ε_i e ε_i^* para cada ponto. O objetivo agora é minimizar a Equação 2.10.

$$\begin{aligned} \text{Min} &= \left\{ \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^N (\xi_i + \xi_i^*) \right\} \\ \text{s.t.:} &= \begin{cases} y_i - [\mathbf{x}_i^T \mathbf{w} + b] \leq \varepsilon + \xi_i \\ [\mathbf{x}_i^T \mathbf{w} + b] - y_i \leq \varepsilon + \xi_i^* \end{cases} \end{aligned} \quad (2.10)$$

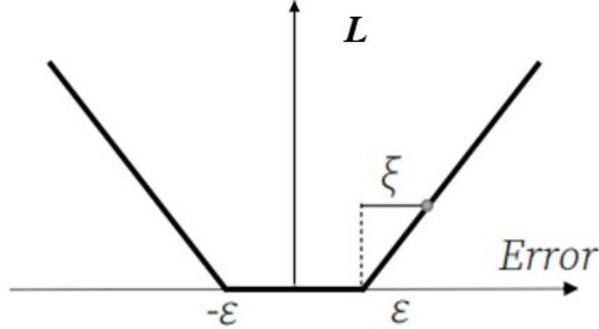
Sendo $\xi_i, \xi_i^* \geq 0$ para todo $i = 1, \dots, n$ e $C > 0$, onde C é uma constante que controla a penalidade aplicada às observações que se encontram fora da margem ε . A Figura 10 ilustra o comportamento dos dados em um SVR com margens suaves. Nesse caso, é possível que alguns pontos extrapolem o hipertubo. Essa flexibilidade é introduzida, em parte, para evitar o *overfitting* (ARA RAYDONAL OSPINA, 2023).

Figura 10 – Máquina de Vetores de Suporte - Margens Suave



Fonte: Adaptado Ara Raydonal Ospina (2023)

A função de perda L desconsidera os erros inferiores a ε , tratando-os como nulos. A Figura 11 ilustra o comportamento dessa função de perda.

Figura 11 – Função de Perda ε -insensitiva

Fonte: Adaptado Tito (2024)

Para simplificar a resolução da Equação 2.10, é conveniente considerar a formulação dual. Essa abordagem não apenas facilita a resolução, mas também possibilita a extensão da regressão de vetor de suporte para problemas não lineares. Antes disso, no entanto, é essencial introduzir a formulação lagrangiana para o problema de regressão do vetor de suporte primal, conforme indicado na Equação 2.11. Neste contexto, os multiplicadores de Lagrange α_i , α_i^* , η_i , e η_i^* , que devem ser não-negativos, desempenham um papel crucial (VAPNIK, 1999); (DRUCKER et al., 1996).

$$L = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^N (\xi_i + \xi_i^*) - \sum_{i=1}^N \alpha_i (\varepsilon + \xi_i - y_i + \mathbf{x}_i^T \mathbf{w} + b) - \sum_{i=1}^N \alpha_i^* (\varepsilon + \xi_i^* - \mathbf{x}_i^T \mathbf{w} - b + y_i) - \sum_{i=1}^N (\eta_i \xi_i + \eta_i^* \xi_i^*) \quad (2.11)$$

Derivando a função Lagrangiana em relação às variáveis do problema primal (\mathbf{w} , b , ξ_i e ξ_i^*) e igualando-as a zero, obtêm-se as condições de otimização de primeira ordem, conforme descrito por (SMOLA; SCHÖLKOPF, 2004).

$$\frac{\partial L}{\partial b} = \sum_{i=1}^N (\alpha_i + \alpha_i^*) = 0 \quad (2.12)$$

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N (\alpha_i + \alpha_i^*) \mathbf{x}_i = 0 \quad (2.13)$$

$$\frac{\partial L}{\partial \xi_i} = C - \alpha_i - \eta_i = 0 \quad (2.14)$$

$$\frac{\partial L}{\partial \xi_i^*} = C - \alpha_i^* - \eta_i^* = 0 \quad (2.15)$$

Ao substituir os resultados das derivadas da função lagrangeana na Equação 2.10, chega-se à formulação dual do problema de SVR, conforme apresentado na Equação 2.16 (VAPNIK, 1999); (DRUCKER et al., 1996).

$$\begin{aligned} \text{Max} = & \left\{ -\frac{1}{2} \sum_{i,j}^N (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \mathbf{x}_i \mathbf{x}_j - \varepsilon \sum_{i=1}^N (\alpha_i - \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \right\} \\ \text{s.t.:} = & \begin{cases} \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i \alpha_i^* \in [0, C] \end{cases} \end{aligned} \quad (2.16)$$

Nesta formulação dual, o vetor \mathbf{w} é reescrito como uma combinação linear das observações de treinamento, $\mathbf{x}_i \mathbf{x}_j$. As variáveis η_i e η_i^* foram eliminadas ao serem expressas em termos de C , α_i e α_i^* . Dessa forma, \mathbf{w} é dado por $\mathbf{w} = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \mathbf{x}_i$. Conseqüentemente, na regressão de vetor de suporte, o modelo inicial apresentado na Equação 2.6 pode ser reescrito como uma combinação linear dos dados de treinamento, conforme a Equação 2.17. No entanto, o modelo inclui apenas os vetores de suporte, ou seja, \mathbf{x}_i tal que $\alpha_i > 0$ ou $\alpha_i^* > 0$, para $i = 1, \dots, N$. O SVR aumenta a dimensionalidade no espaço vetorial de suporte, em vez de no espaço dos preditores (VAPNIK, 1999).

$$\hat{y} = \sum_{i=1}^N (\alpha_i - \alpha_i^*) k(\mathbf{x}_i, \mathbf{x}) + b \quad (2.17)$$

O modelo SVR depende apenas do produto escalar dos dados de treinamento, x_i . Para aproximar as funções complexas, o produto escalar x_i, x_j pode ser atribuído por um kernel, $k(x_i, x_j)$. Alguns dos Kernels mais utilizados na prática são os polinomiais, gaussianos e os sigmoidais, listados na Tabela 2. Cada um desses parâmetros deve ser especificado pelo usuário e estão listados na tabela correspondente. Em particular, o kernel sigmoidal satisfaz as condições de mercer apenas para certos valores de γ e κ . Além disso, os kernels polinomiais com $d = 1$ são classificados como lineares (CHANG, 2001).

Tabela 2 – Tipos de Kernel e suas respectivas funções e parâmetros.

Tipo de Kernel	Função $K(\mathbf{x}_i, \mathbf{x}_j)$	Parâmetros
Polinomial	$(\delta(\mathbf{x}_i \cdot \mathbf{x}_j) + \kappa)^d$	δ, κ e d
Gaussiano	$\exp(-\sigma \ \mathbf{x}_i - \mathbf{x}_j\ ^2)$	σ
Sigmoidal	$\tanh(\delta(\mathbf{x}_i \cdot \mathbf{x}_j) + \kappa)$	δ e κ

Fonte: Chang (2001)

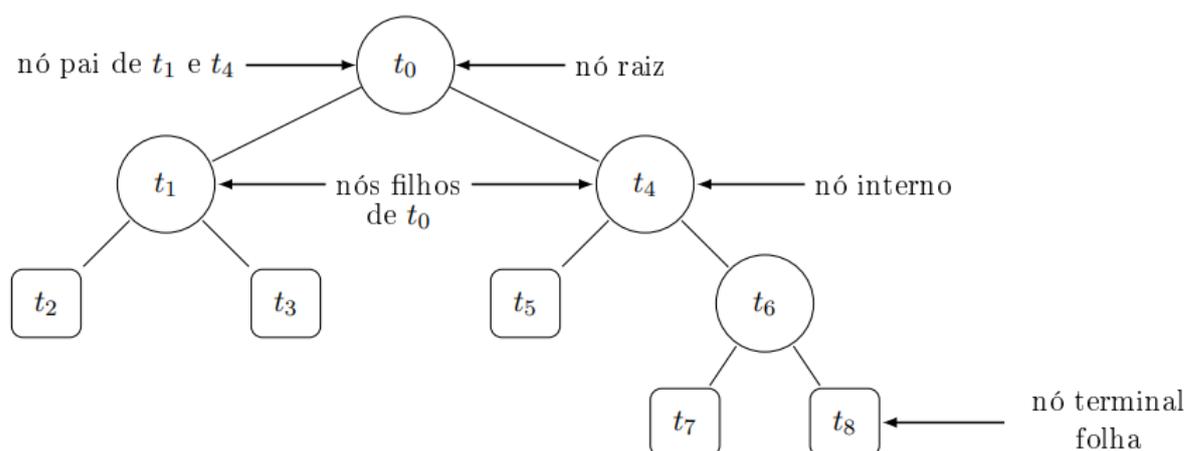
2.5.2 Árvore de Decisão

Os métodos baseados em árvore são amplamente reconhecidos por sua simplicidade e facilidade de interpretação. A abordagem das Árvores de Classificação e Regressão

(CART - *Classification and Regression Trees*) ou Árvores de Decisão - (*Decision Tree Regression*) foi inicialmente proposta por (BREIMAN et al., 1984), que apresentaram de forma integrada a metodologia completa para a construção dessas árvores. Esse método consiste na segmentação do espaço preditivo em diversas regiões retangulares simples, onde as previsões são realizadas com base na média ou em outra medida estatística das observações de treinamento contidas nessas regiões. A técnica é conhecida como árvore de decisão devido à forma como as regras utilizadas para dividir o espaço preditivo podem ser representadas graficamente em um diagrama no formato de árvore (JAMES et al., 2013).

No estudo de Breiman et al. (1984), são estabelecidas definições fundamentais para a construção de uma árvore. A árvore é definida como um grafo $G = (V, E)$, onde quaisquer dois vértices (nós) estão conectados por um único caminho. Uma árvore enraizada é aquela em que um dos nós é designado como raiz, e a partir desse nó a estrutura é direcionada. Os nós "pais" e "filhos" são conectados por arestas que unem dois nós, t_1 e t_2 se t_1 e t_2 estão conectados, t_1 é o pai de t_2 , e t_2 é o filho de t_1 . Em uma árvore enraizada, os nós são classificados como internos ou terminais: um nó interno possui um ou mais filhos, enquanto um nó terminal, ou folha, não possui descendentes. Uma árvore binária é uma árvore enraizada em que todos os nós internos têm exatamente dois filhos. A Figura 12 esquematiza as definições apresentadas.

Figura 12 – Árvore de Decisão - CART



Fonte: Adaptado Souza (2021)

Assim como o algoritmo SVM, as árvores de decisão (CART) podem produzir saídas contínuas ou discretas. Saídas discretas referem-se a um conjunto finito de valores distintos, que podem ser categóricos ou inteiros, sem permitir valores intermediários. Em contrapartida, as saídas contínuas podem assumir qualquer valor dentro de um intervalo, incluindo números fracionários ou reais (SOUZA, 2021).

Considerando k variáveis de entrada e uma resposta, representadas como (\mathbf{x}_1, y) onde $\mathbf{x}_1 = (x_{i1}, x_{i1}, \dots, x_{iK})$ para $i = 1, \dots, N$, o algoritmo CART para regressão deve, em cada ite-

ração, definir qual variável e nível usar para particionar o espaço dos preditores. Supondo J regiões R_1, R_2, \dots, R_J , a resposta em cada região é uma constante γ_j para $j = 1, \dots, J$. Portanto, o modelo de árvore de regressão pode ser descrito pela Equação 2.18, $\theta = \{R_j, \gamma_j\}$, onde $I(\mathbf{x} \in R_j)$ é uma função indicadora que assume o valor 1 se x pertence a R_j e 0 caso contrário. Para minimizar a soma dos quadrados, o melhor valor para γ_j é a média dos valores y_i pertencentes a R_j , ou seja, $\hat{\gamma}_j = \bar{y}_i$, para $x_i \in R_j$ (HASTIE, 2009).

$$f(\mathbf{x}) = T(\mathbf{x}, \theta) = \sum_{j=1}^N \gamma_j I(\mathbf{x} \in R_j) \quad (2.18)$$

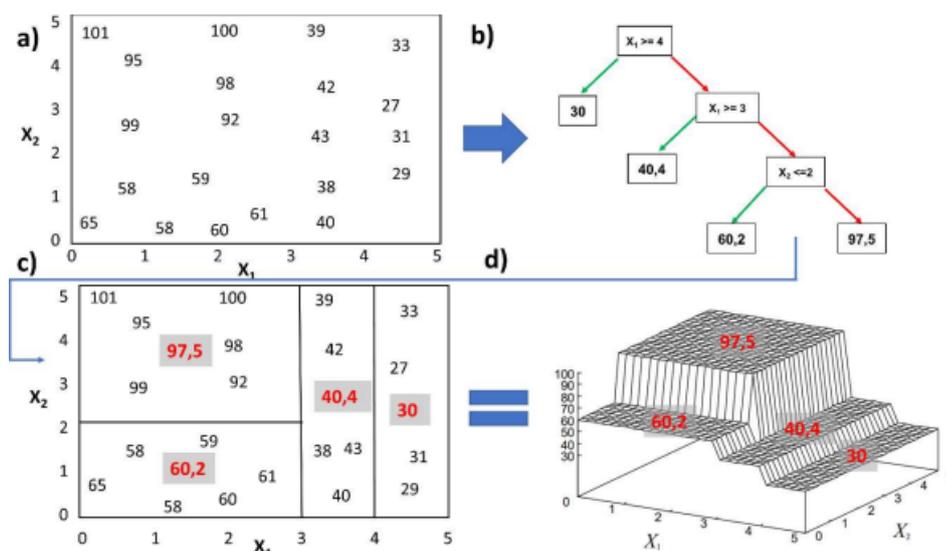
Considerando todos os dados de treinamento, os semi-planos são definidos selecionando uma variável de decisão x_k , onde $k = 1, \dots, k$ e um ponto de divisão s . Dessa forma, os conjuntos $R_1(k, s)$ e $R_2(k, s)$ são definidos como $R_1(k, s) = \{\mathbf{x} \mid x_k \leq s\}$ e $R_2(k, s) = \{\mathbf{x} \mid x_k > s\}$, respectivamente. O algoritmo CART, então, identifica a variável k e o valor s que melhor realizam o particionamento ao resolver o problema da Equação 2.19:

$$\min_{k,s} \left[\min_{\gamma_1} \sum_{x_i \in R_1(k,s)} (y_i - \gamma_1)^2 + \min_{\gamma_2} \sum_{x_i \in R_2(k,s)} (y_i - \gamma_2)^2 \right] \quad (2.19)$$

Para cada variável, o valor de divisão s é o determinado ao examinar todos os preditores, a fim de identificar o melhor par de (k, s) (HASTIE, 2009).

A Figura 13 apresenta um exemplo de modelo de árvore de regressão, onde a variável y é modelada em função das variáveis x_1 e x_2 . A matriz $\mathbf{X}_{21,2}$, que inclui os dados das variáveis x_1 e x_2 , assim como seus valores correspondentes de y , é mostrada na Figura 13a. A árvore de regressão gerada a partir desses dados é exibida na Figura 13b, onde o valor previsto em cada nó terminal (folha) corresponde à média dos valores das amostras presentes nesse nó. As divisões feitas pela árvore de regressão são representadas de duas formas diferentes nas Figuras 13c e 13d.

Figura 13 – Modelo Hipotético de Construção de uma Árvore de Regressão: (a) Matriz de Dados, (b) Estrutura da Árvore, e (c, d) Partições Resultantes



Fonte: Adaptado Santana (2020)

A metodologia CART aplica uma abordagem de divisão binária recursiva, que é realizada de forma hierárquica e otimizada localmente. A abordagem hierárquica (*top-down*) inicia-se no nó raiz, que contém todas as observações, e prossegue particionando os nós de acordo com um critério de minimização do erro. Essa estratégia é descrita como otimizada localmente (gananciosa), pois em cada passo se busca a divisão que minimiza o erro de previsão em relação a um critério específico. O processo é recursivo, pois a mesma lógica é aplicada a cada novo nó gerado (SOUZA, 2021).

2.5.3 Florestas Aleatórias

Breiman et al. (1984) destaca que o método CART pode gerar árvores de decisão instáveis. A complexidade nas relações entre as variáveis preditoras \mathbf{x} e a variável resposta y aumenta quando se consideram as interações entre as variáveis preditoras. É possível que diferentes grupos de variáveis forneçam informações semelhantes ou quase equivalentes sobre a variável resposta, resultando em reduções quase idênticas na impureza em um nó específico. Devido à presença inevitável de ruído nos dados, a escolha das divisões pode ocorrer quase ao acaso, fazendo com que divisões semelhantes na impureza levem à criação de árvores com estruturas muito distintas.

Breiman et al. (1984) define um procedimento como instável quando pequenas alterações no conjunto de dados resultam em grandes variações no erro de predição. Esse conceito é evidente em árvores de regressão, onde o erro de predição está relacionado à minimização da soma dos quadrados.

Para reduzir a instabilidade, Breiman et al. (1984) recomenda o uso do *bagging*, uma técnica cujo nome vem de "*bootstrap aggregating*", para melhorar o desempenho do CART. O *bootstrap*, conforme descrito por Tibshirani e Efron (1993), envolve a criação de várias amostras com reposição a partir de um conjunto de dados, o que permite inferências estatísticas. No contexto do *bagging*, várias árvores CART são construídas a partir de diferentes amostras *bootstrap*, e a predição final é obtida pela média das predições de todas as árvores para um mesmo dado de entrada.

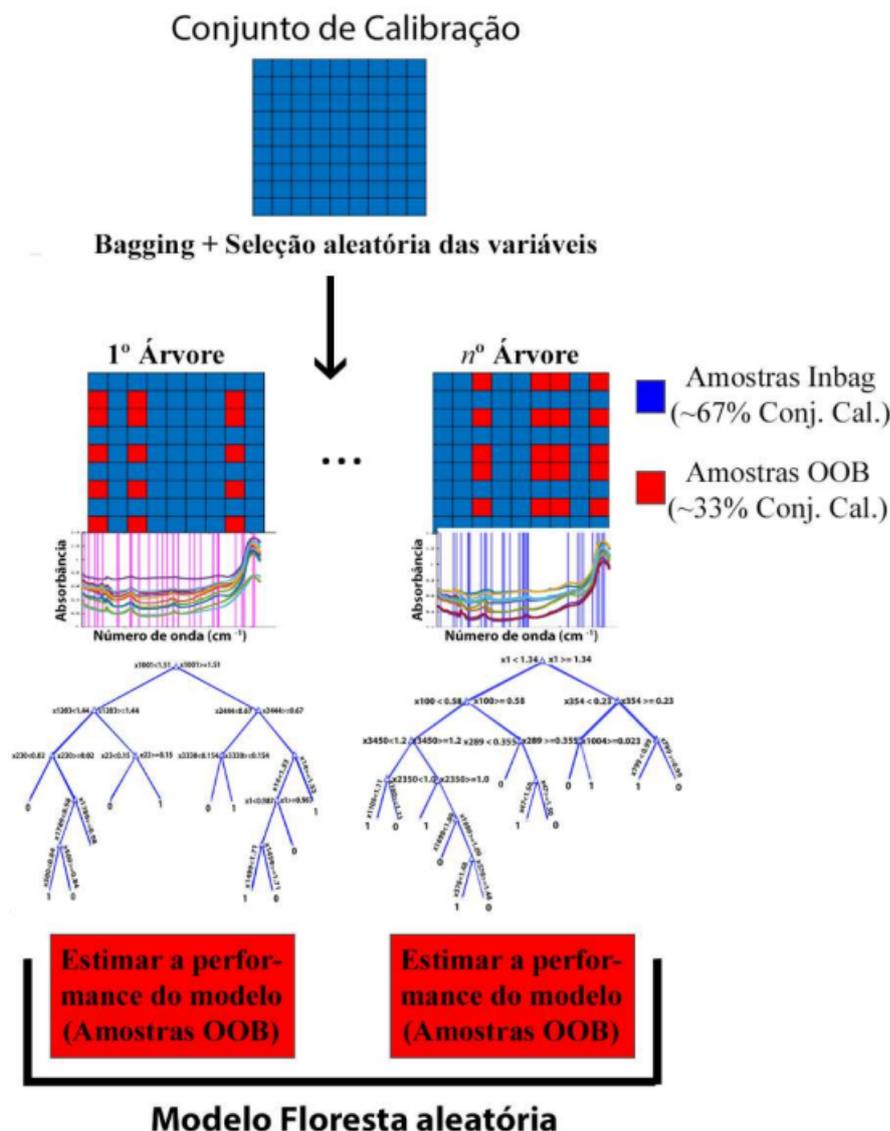
O *bagging* é uma das abordagens mais simples dentro das técnicas de ensemble. Estudos subsequentes, como os de (BREIMAN, 2001) e outros autores citados por Louppe (2014), expandiram essa ideia para incluir não apenas a seleção aleatória de amostras *bootstrap*, mas também a seleção aleatória de subconjuntos das variáveis preditoras ao construir os nós de cada árvore. Esse método, quando aplicado às árvores de decisão CART, é conhecido como random forest. As random forests mostram um desempenho significativamente superior ao de uma única árvore CART ou ao *bagging* (SOUZA, 2021).

Nesse método, diferentes conjuntos de dados de treinamento são gerados B vezes usando o método *bootstrap*. Para cada amostra *bootstrap* b , é estimada uma árvore de decisão $\hat{f}^{*b}(\mathbf{x})$, onde b varia de 1 a B . A predição final é calculada pela média das predições de todas as árvores para um dado de entrada específico, conforme mostrado na Equação 2.20 (SOUZA, 2021; JAMES et al., 2013).

$$\hat{f}_{\text{bag}}(\mathbf{x}) = \frac{1}{B} \sum_{b=1}^B \hat{f}^{*b}(\mathbf{x}) \quad (2.20)$$

Após a geração das árvores a partir das amostras *bootstrap*, o conjunto de árvores de decisão é organizado como $\{T1(\theta_1), T2(\theta_2) \dots TB(\theta_B)\}$, onde T_i representa cada árvore e θ_i são as amostras *bootstrap* com reposição, de dimensões $q \times mtry$, sendo q aproximadamente $0,67 \times n$. Esse arranjo proporciona uma representação eficiente e organizada da floresta aleatória, aumentando a robustez e a capacidade de generalização do modelo. Um exemplo genérico de uma floresta aleatória aplicada a um problema de classificação pode ser visto na Figura 14.

Figura 14 – Algoritmo de Floresta Aleatória



Fonte: Adaptado Santana (2020)

O método de aprendizado de máquina baseado em floresta aleatória apresenta diversas vantagens. Entre essas vantagens estão a capacidade de lidar com classes desbalanceadas, a flexibilidade para utilizar a matriz \mathbf{X} mesmo com dados ausentes e a habilidade para manejar sistemas não lineares e variáveis que não seguem distribuições normais (AFANADOR et al., 2016). A Floresta Aleatória (RF - Random Forest) é uma técnica moderna que busca melhorar os resultados do *bagging* ao reduzir a correlação entre as árvores geradas a partir das amostras de bootstrap.

Esse modelo, baseado em árvores de decisão, é eficaz em lidar com conjuntos de dados de alta dimensão e com a presença de multicolinearidade (BELGIU; DRĂGUȚ, 2016). Proposta por Breiman (2001), a Floresta Aleatória gera B árvores de decisão a partir de amostras *bootstrap*. A inovação está no fato de que, durante a construção de cada árvore, para cada divisão, é selecionada aleatoriamente uma amostra de m preditores,

onde m é menor que o número total de preditores k . Esse método visa minimizar o efeito da multicolinearidade e evitar o favorecimento excessivo de certos preditores. Em regressão, é recomendável usar $m = k/3$ preditores para cada divisão binária recursiva (HASTIE, 2009). Além disso, a combinação de técnicas de aleatorização e o uso de um grande número de árvores ajudam a minimizar o impacto de ruídos e dados anômalos (BREIMAN, 2001; BIN et al., 2016). Contudo, é importante sempre verificar a presença de amostras anômalas. O método também facilita a análise da importância das variáveis, a visualização da similaridade entre amostras e o cálculo de medidas de anomalia através da matriz de proximidade (BIN et al., 2016).

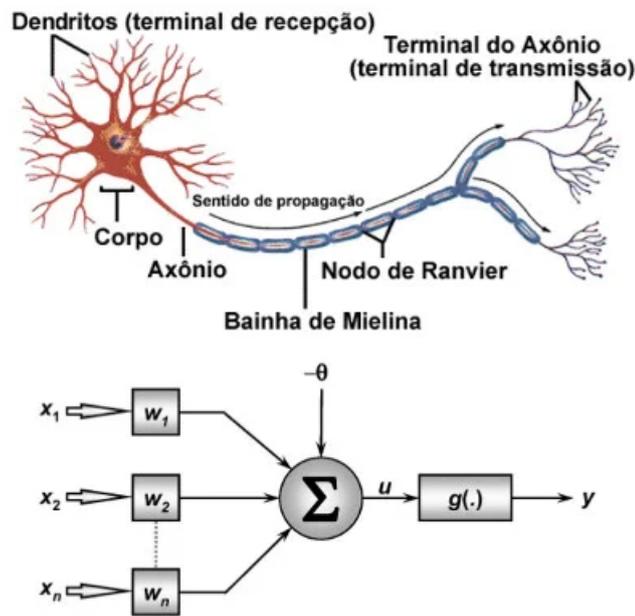
2.5.4 Redes Neurais Artificiais

No final da década de 1980, a área de Redes Neurais Artificiais (RNA), também conhecida como sistemas de processamento paralelo e distribuído, experimentou um renascimento significativo. Essa abordagem computacional é notável por seu funcionamento que, em certa medida, imita a estrutura do cérebro humano. Diferentemente da computação algorítmica convencional, as Redes Neurais não se baseiam em regras ou programas específicos, oferecendo uma alternativa inovadora ao processar informações de forma similar aos neurônios (BRAGA; LUDERMIR; CARVALHO, 2000). Em essência, uma Rede Neural é um processador distribuído massivamente, composto por unidades de processamento simples que possuem a capacidade natural de armazenar e aplicar conhecimento adquirido por meio da experiência. Dessa maneira, as RNAs se assemelham ao cérebro humano em dois aspectos principais: primeiro, pelo conhecimento adquirido através de um processo de aprendizagem; segundo, pelas conexões entre os neurônios (pesos sinápticos), que são responsáveis por armazenar esse conhecimento (HAYKIN, 2001)

2.5.4.1 O neurônio

O neurônio é composto por quatro partes principais: os dendritos, as sinapses, o corpo celular e o axônio, conforme Figura 15. Os dendritos são extensões ramificadas que servem como os receptores de sinais elétricos; as sinapses são os locais de contato entre neurônios, onde neurotransmissores são transferidos do axônio de um neurônio para os dendritos de outro; o corpo celular, ou soma, é a região onde ocorre o processamento e a soma das energias recebidas; e o axônio é a estrutura que conduz os impulsos nervosos para outros neurônios ou músculos. Quando a soma das energias no corpo celular supera um determinado limiar, o axônio emite um impulso elétrico, conhecido como potencial de ação, que desencadeia o disparo do neurônio. As sinapses podem atuar de forma excitatória, facilitando a transmissão do potencial de ação, ou de forma inibitória, dificultando essa passagem (ALBUQUERQUE, 2023).

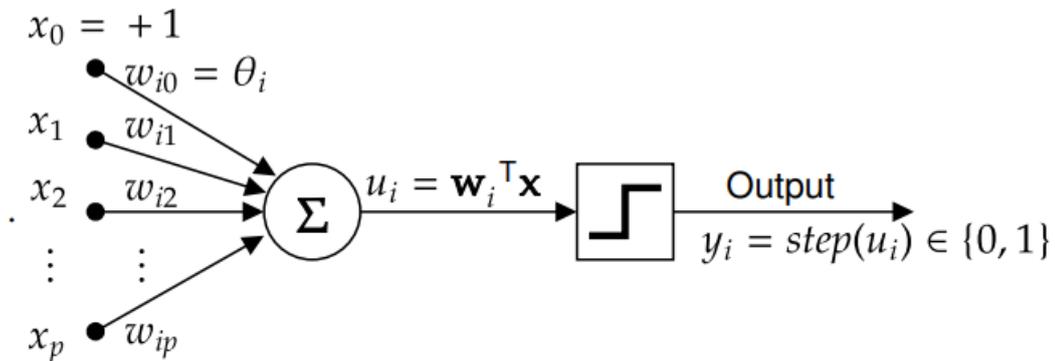
Figura 15 – modelo de neurônio didático



Fonte: Adaptado Haykin (2001)

McCulloch e Pitts (1943) propôs um modelo matemático do neurônio, conforme ilustrado na Figura 16.

Figura 16 – Modelo de neurônio de McCulloch-Pitts



Fonte: Adaptado Albuquerque (2023)

Esse modelo continua sendo um dos blocos fundamentais nos algoritmos de redes neurais. A seguir, detalhamos a modelagem do processamento de informações em um neurônio. As entradas x_1, x_2, \dots, x_p , com $x_j \in \mathbb{R}$, são ponderadas por pesos sinápticos $w_{i1}, w_{i2}, \dots, w_{ip}$, onde $w_{jp} \in \mathbb{R}$, que podem ser positivos (excitatórios) ou negativos (inibitórios), e são somadas ao limiar $\theta_i \in \mathbb{R}$. Formalmente, essa operação é conhecida como a ativação do neurônio i -ésimo, conforme Equação 2.21:

$$u_i = \sum_{j=1}^p w_{ij}x_j + \theta_i = \sum_{j=0}^p w_{ij}x_j \quad (2.21)$$

Ao incluir o limiar θ_i no segundo somatório, definimos $w_{i0} = \theta_i$ e $x_0 = +1$. Essa forma alternativa de expressar a ativação u_i nos permite interpretá-la como o produto escalar $u_i = \mathbf{w}_i^T \mathbf{x}$ entre o vetor de pesos $\mathbf{w}_i \in \mathbb{R}^{p+1}$ e o vetor de entrada $\mathbf{x} \in \mathbb{R}^{p+1}$. Para essa abordagem, os vetores \mathbf{x} e \mathbf{w}_i devem ser definidos, respectivamente, como $\mathbf{x} = [x_0, x_1, x_2, \dots, x_p]^T$ e $\mathbf{w}_i = [w_{i0}, w_{i1}, w_{i2}, \dots, w_{ip}]^T$. Finalmente, a função ativação $g(\cdot)$ que processa o conjunto de entradas recebidas e o transforma em estado de ativação é aplicado a u_i para produzir a saída i ésimo neurônio, como mostrado na Equação 2.22:

$$y_i = g(u_i) = g(\mathbf{w}_i^T \mathbf{x}) = g\left(\sum_{j=1}^p x_j w_j + \theta_i\right) \quad (2.22)$$

Onde:

$$g(u_i) = \begin{cases} 1 & , \text{se } u_i > 0 \\ 0 & , \text{caso contrário} \end{cases}$$

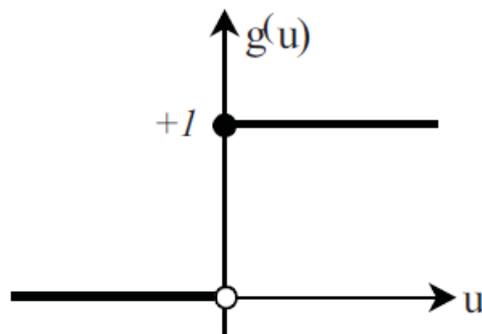
2.5.4.2 Função de Ativação

Existem vários tipos de funções de ativação que podem ser aplicadas em um neurônio, destacando-se entre elas a função linear, função degrau, função degrau (bipolar), função limiar, função sigmoide e função tangente hiperbólica (BRAGA; LUDERMIR; CARVALHO, 2000; HAYKIN, 2001; CÂMARA, 2020).

1. Função degrau: Neste tipo de função de ativação, ilustrada na Figura 17, a saída do neurônio será 1 se o nível total de atividade interna for maior ou igual a zero; caso contrário, a saída será 0. Onde:

$$g(u) = \begin{cases} 1 & , \text{se } u \geq 0 \\ 0 & , \text{se } u < 0 \end{cases}$$

Figura 17 – Função degrau

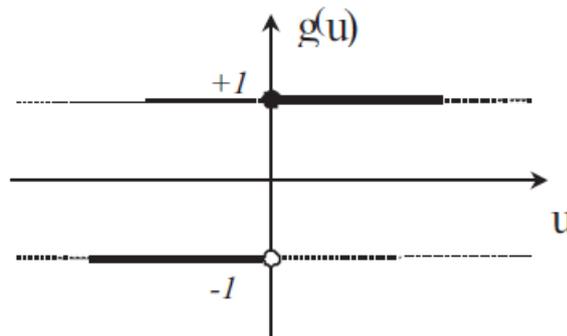


Fonte: Adaptado Tardivo (2024)

2. Função degrau (bipolar): Representada na Figura 18, esta função de ativação permite que a saída do neurônio assuma valores reais negativos ou positivos dentro do intervalo de -1 a +1. Se o nível total de atividade interna for maior ou igual a zero, a saída será 1; caso contrário, será -1. Onde:

$$g(u) = \begin{cases} 1 & , \text{ se } u \geq 0 \\ -1 & , \text{ se } u < 0 \end{cases}$$

Figura 18 – Função degrau (bipolar)

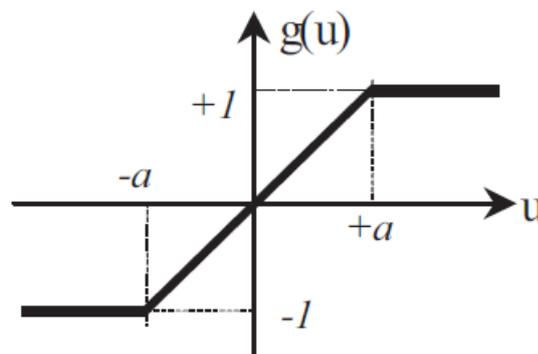


Fonte: Adaptado Tardivo (2024)

3. Função Rampa/ Linear : Na função rampa, mostrada na Figura 19, a saída do neurônio varia linearmente dentro do intervalo de -1 a +1, com valores crescentes ou decrescentes de acordo com o valor de entrada. No intervalo específico definido por -a a +a, a saída corresponde ao valor da função $g(u) = u$

$$g(u) = \begin{cases} 1 & , \text{ se } u \geq a \\ u & , \text{ se } -a < u < a \\ -1 & , \text{ se } u \leq -a \end{cases}$$

Figura 19 – Função Rampa/ Linear

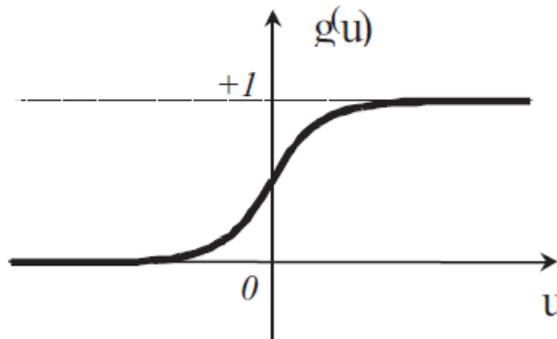


Fonte: Adaptado Tardivo (2024)

4. Função sigmoide: Esta função de ativação, ilustrada na Figura 20, tem como parâmetro β , que define a inclinação (ou ganho) da curva sigmoide. Nesse tipo de função, a saída do neurônio assume valores reais entre 0 e 1.

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (2.23)$$

Figura 20 – Função sigmoide

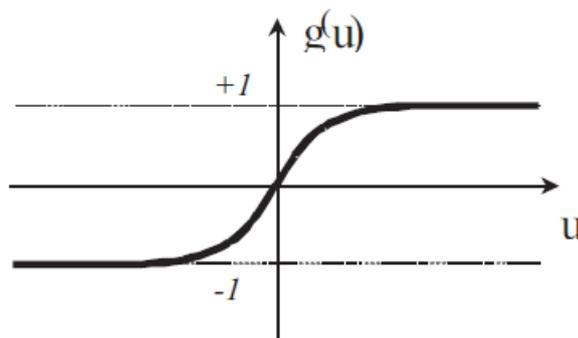


Fonte: Adaptado Tardivo (2024)

5. Função tangente hiperbólica: Como mostrado na Figura 21, a função tangente hiperbólica permite que a saída do neurônio assumira valores reais no intervalo de -1 a 1. Este tipo de ativação utiliza a função $\tanh(u)$, que gera essa variação contínua.

$$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (2.24)$$

Figura 21 – Função tangente hiperbólica



Fonte: Adaptado Tardivo (2024)

2.5.4.3 Arquiteturas de Redes

A arquitetura de uma rede neural refere-se à forma como os neurônios da rede estão organizados. Geralmente, essa arquitetura está associada ao algoritmo utilizado para o treinamento da rede (SILVA, 2009).

Na literatura, há uma ampla variedade de arquiteturas de rede aplicáveis a diversos tipos de problemas, como Perceptron Simples, Perceptron Multicamadas (*MLP*), Redes Neurais Convolucionais (*CNN*), Redes Neurais Recorrentes (*RNN*), Long Short-Term Memory (*LSTM*), Redes Neurais Radiais de Base (*RBF*), Autoencoders, Redes Neurais Generativas Adversárias (*GANs*), e Redes Neurais de Funções de Base Radial (*RBFNN*). Entretanto, neste trabalho, serão abordadas apenas as Redes Perceptron de Múltiplas Camadas, que constituem a arquitetura utilizada no estudo.

Como tudo surge a partir da ideia da arquitetura do perceptron simples, é importante entender a evolução desse conceito. O perceptron simples foi a primeira arquitetura de rede neural artificial, que combinou o modelo de neurônio proposto por McCulloch e Pitts (1943) com uma regra de aprendizado, tornando possível que a rede "aprendesse" a partir de exemplos.

O neurônio individual possui uma modelagem matemática simples, mas, ao serem organizados em camadas, esses neurônios ganham capacidades computacionais poderosas (ALBUQUERQUE, 2023). Isso levou ao rápido desenvolvimento de várias arquiteturas de redes neurais. Durante o processo de aprendizado, o erro – a diferença entre a saída desejada e a saída gerada pela rede – é utilizado para ajustar os pesos e limiares da rede, até que o problema seja solucionado ou o período de treinamento se encerre Albuquerque (2023).

Definindo algumas variáveis que serão utilizadas, o vetor de entrada no instante t é:

$$\mathbf{x}(t) = [x_0(t), x_1(t), x_2(t), \dots, x_p(t)]^T, \mathbf{w}_i(t+1) = \mathbf{w}_i(t) + \eta_{ei}(t)\mathbf{x}(t) \quad (2.25)$$

A Equação que ajusta pesos e limiares, dado o vetor de entrada da Equação 2.25 é:

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) + \eta_{ei}(t)\mathbf{x}(t) \quad (2.26)$$

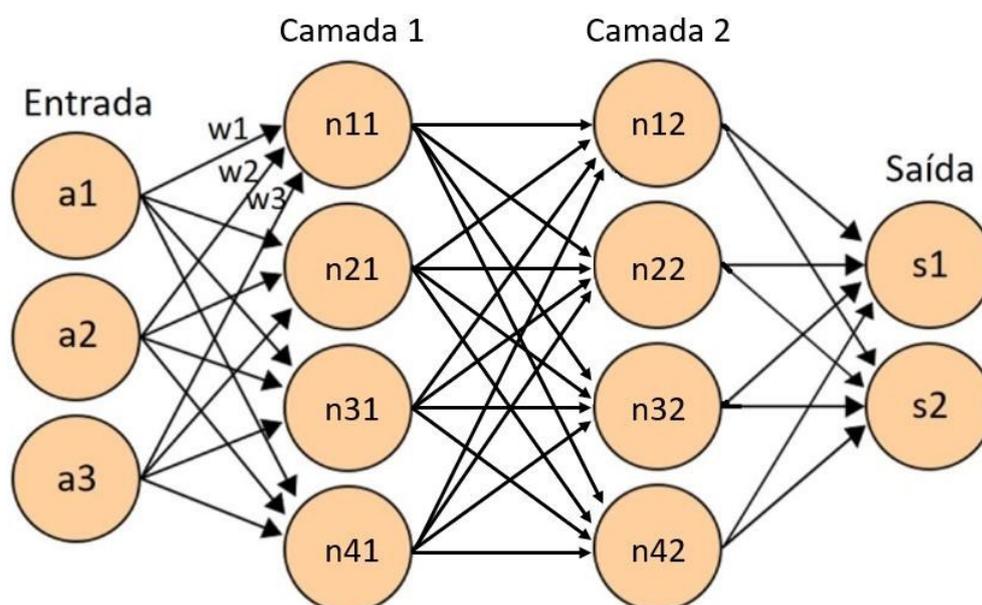
Onde: $\mathbf{w}_i \in \mathbb{R}^{p+1}$ é o vetor peso do i -ésimo neurônio. $\eta \in (0,1)$ representa a taxa de aprendizado. $e_i(t) = d_i(t) - y_i(t)$ é o erro do i -ésimo neurônio no tempo t , $d_i(t)$ é a saída desejada para o i -ésimo neurônio e $y_i(t)$ é a saída gerada por esse neurônio. $\mathbf{x}(t) \in \mathbb{R}^{p+1}$ é o vetor de entrada.

2.5.4.4 Rede Perceptron de Múltiplas Camadas

Conforme descrito na seção anterior, o perceptron é eficiente na resolução de problemas linearmente separáveis. No entanto, em muitos casos práticos, as classes não são linearmente separáveis. Para lidar com essas situações, mais camadas foram adicionadas ao perceptron, permitindo que cada camada processe os dados de forma não linear (HAYKIN, 2001). Esse processamento busca gerar uma representação (ou projeção) que facilite a separação das classes pelos neurônios da camada de saída.

A Rede Perceptron recebe esse nome por ser composta, principalmente, por neurônios com modelos não lineares e por apresentar uma estrutura de neurônios organizados de forma adiante, ou seja, em que o fluxo de informações segue em uma única direção (CÂMARA, 2020). A Figura 22 ilustra o modelo geral de uma rede Perceptron, evidenciando a existência de vetores de entrada e saída. A rede é estruturada em diferentes camadas, incluindo a de entrada, a de saída e uma ou mais camadas ocultas. Nesse contexto, o Perceptron simples possui apenas uma camada intermediária, enquanto o MLP (*Multilayer Perceptron* - (Perceptron Multi camadas)) é caracterizado pela presença de diversas camadas ocultas, nas quais acontece o ajuste dos pesos (CÂMARA, 2020; ALBUQUERQUE, 2023; TARDIVO, 2024).

Figura 22 – Diagrama da arquitetura de uma rede neural perceptron multicamadas



Fonte: (HAYKIN, 2001)

As redes MLP oferecem uma capacidade computacional muito superior quando comparadas às redes que não possuem camadas intermediárias. As camadas ocultas, nesse tipo de rede, atuam como detectores de características, criando uma codificação interna dos dados de entrada que é utilizada para definir a saída da rede. Entretanto, em algumas situações, o uso de duas ou mais camadas ocultas pode otimizar o treinamento da rede. Porém, adicionar muitas camadas ocultas não é recomendado, pois a precisão do erro propagado durante o treinamento diminui a cada camada anterior que ele atravessa (BRAGA; LUDERMIR; CARVALHO, 2000; NIED, 2007).

2.5.4.5 Treinamento de uma Rede neural

A característica essencial de uma rede neural é sua capacidade de aprender a partir de regras definidas previamente e, assim, melhorar seu desempenho ao longo do tempo. Embora o conceito de "aprendizagem" tenha várias interpretações, será adotada aqui uma

definição específica, adaptada ao contexto do treinamento de redes neurais, baseada nos trabalhos de Mendel e McClaren (HAYKIN, 2001).

Hassoun (1995) sugere que o processo de aprendizagem em redes neurais artificiais pode ser visto como um processo de otimização. Segundo Haykin (2001), o objetivo do treinamento de uma rede neural é ajustar gradualmente os pesos sinápticos, conforme uma regra de aprendizado que orienta essas modificações. Esse processo utiliza um conjunto de dados de treinamento, e após a apresentação de todos os exemplos, considera-se que a rede completou uma época de aprendizagem.

Conjuntos de regras bem definidas para a resolução de problemas de aprendizagem são conhecidos como algoritmos de aprendizado ou treinamento (HAYKIN, 2001). Existem diversos algoritmos como vimos no tópico anterior, cada um com diferentes aplicações, vantagens e limitações. O principal ponto de distinção entre eles está na maneira como ajustam os pesos sinápticos dos neurônios, considerando a relação entre a rede neural e o ambiente externo (BELÍCIO; DINIZ; JÚNIOR, 2016; HASSOUN, 1995).

De acordo com (IYODA, 2000), uma estratégia para implementar o aprendizado supervisionado em redes neurais é utilizando procedimentos iterativos de correção de erro. Para isso, seja d_k a saída esperada de um neurônio k e z_k a saída efetiva obtida. A saída z_k é gerada por um vetor de entrada \mathbf{x} , aplicado à rede na qual o neurônio k está inserido, durante a iteração n . O erro para o neurônio k é dado pela diferença entre a saída desejada e a observada, conforme a equação 2.27:

$$e_k(n) = d_k(n) - z_k(n) \quad (2.27)$$

O objetivo desse método de aprendizado é minimizar uma função de custo baseada no erro e_k , de maneira que a saída real dos neurônios se aproxime da saída esperada. Assim, o aprendizado torna-se um problema de otimização quando uma função de custo é estabelecida. Com a utilização de um algoritmo de treinamento que minimiza o erro, um conjunto de dados apropriado e um número adequado de iterações, a rede pode ser treinada para tarefas como classificação de padrões e aproximação de funções (IYODA, 2000; HAYKIN, 2001).

Como mencionado anteriormente, a escolha do algoritmo de treinamento é fundamental, pois é ele que garante que a RNA aproxime corretamente uma função. Vários algoritmos foram desenvolvidos com o objetivo de evitar mínimos locais, melhorar a velocidade do aprendizado e garantir uma boa generalização. Entre eles, destacam-se o *RPROP* (RIEDMILLER; BRAUN, 1993), o *QuikProp* (FAHLMAN et al., 1988) e o mais conhecido, o algoritmo de Retropropagação (*Backpropagation*) (HAYKIN, 2001).

2.5.4.6 Algoritmo de Retro Propagação

O algoritmo de Retropropagação, amplamente utilizado para o treinamento de Redes Neurais Artificiais (RNAs) com múltiplas camadas, baseia-se no princípio de correção de

erro (HAYKIN, 2001). Para sua implementação, três aspectos essenciais da arquitetura da rede devem ser observados. O primeiro refere-se à função de ativação de cada neurônio da RNA, que deve ser não-linear e contínua, com derivada bem definida. Isso é fundamental, pois sem essa característica, não seria possível utilizar o vetor gradiente, que é crucial para ajustar os pesos sinápticos de forma eficiente. O segundo ponto aborda a importância de incorporar uma ou mais camadas de neurônios ocultos em um modelo de Redes Neurais Artificiais (RNA). Essas camadas permitem que a rede adquira a capacidade de aprender tarefas complexas, ao identificar e extrair progressivamente os fatores mais significativos dos vetores de entrada. Por fim, o terceiro aspecto diz respeito à necessidade de que a Rede Neural Artificial (RNA) possua um alto grau de conectividade, o qual é determinado pelo número de sinapses entre os neurônios (AMARO; FERREIRA; SIMÕES, 2020).

Atendendo a essas características, o treinamento por retropropagação tem como objetivo principal reduzir o erro médio quadrático, ou função de custo, conforme descrito na equação 2.28 :

$$EQM = \frac{1}{N} \sum_{k=1}^N \sum_{i=1}^M (d_{k,i} - z_{k,i})^2 \quad (2.28)$$

Onde, EQM é o erro quadrático médio, em que Q representa o tamanho do conjunto de dados, K o número de neurônios da camada de saída, d_k e d_z são as respostas desejadas e a resposta atual do k -ésimo neurônio de saída.

Para reduzir o Erro Médio Quadrático (EMQ), é necessário ajustar os valores dos pesos sinápticos, conforme discutido anteriormente. Isso é realizado por meio da aplicação do algoritmo de treinamento, que inclui as fases de propagação direta e retropropagação. Esses processos computacionais podem ser vistos como dois tipos de sinais: o sinal funcional, que viaja através da rede, e o sinal de erro, que é gerado pelo algoritmo de treinamento e ajusta a estrutura interna da rede (pesos sinápticos) (HAYKIN, 2001; AMARO; FERREIRA; SIMÕES, 2020; ALBUQUERQUE, 2023). A alteração da estrutura interna da rede, especificamente os pesos sinápticos, é guiada pelo sinal de erro (retropropagação) e segue regras derivadas da função de custo em relação às mudanças nos pesos (HAYKIN, 2001). Com base nessas regras e considerando uma rede perceptron com múltiplas camadas, o treinamento pode ser dividido em cinco etapas:

1. Inicialização dos pesos aleatoriamente;
2. Apresentação dos dados de treinamento;
3. Propagação adiante (sinal funcional);
4. Retropropagação (sinal do erro) e;
5. Iteração.

2.5.5 Generalização

A capacidade de generalização é um aspecto essencial dos modelos de aprendizado de máquina, representando a habilidade de um modelo em lidar com dados e padrões que não foram previamente apresentados durante o treinamento (NIED, 2007). Para que um modelo consiga generalizar bem, ele deve ser capaz de absorver e reter as características do problema durante o treinamento. Haykin (2001) sugere que a qualidade da generalização é medida pela precisão do modelo ao mapear entradas e saídas em um conjunto de dados que não foi usado durante o treinamento.

Para garantir uma boa capacidade de generalização e evitar a necessidade de treinamentos excessivos, é fundamental considerar diversos fatores, como a escolha adequada da arquitetura do modelo, a configuração dos hiperparâmetros, a integração de conhecimento prévio sobre o contexto analisado, um conjunto de dados que represente bem a função desejada e a seleção do algoritmo mais apropriado (SILVA, 2009; NIED, 2007).

A validação cruzada é uma técnica essencial para avaliar a capacidade de generalização de um modelo de aprendizado de máquina. Introduzida por Stone (1974), Allen (1974) e Geisser (1975) para modelos de regressão, essa técnica permite que o desempenho do modelo seja testado em dados separados dos usados no treinamento. A validação cruzada ajuda a verificar a eficácia do modelo na previsão de novos dados, detectando problemas como overfitting e viés (JAMES et al., 2013). Ao realizar a validação cruzada, é possível obter uma estimativa precisa da performance do modelo em dados que não foram usados na fase de treinamento, garantindo que o modelo seja robusto e confiável para previsões futuras.

Assim, enquanto a capacidade de generalização reflete a eficácia geral do modelo, a validação cruzada é uma ferramenta crucial para garantir que essa eficácia seja mantida e otimizada, promovendo um desempenho consistente em dados não vistos (TITO, 2024).

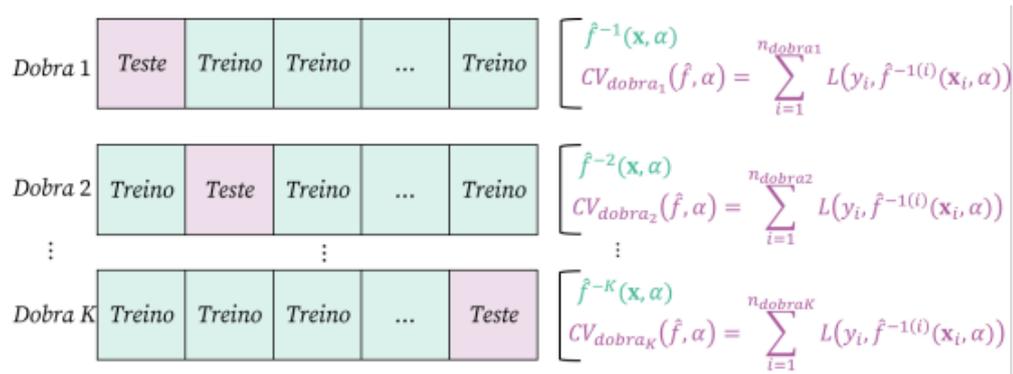
2.5.6 Validação Cruzada via k-dobras

No método de validação cruzada *k-folds* (k-dobras), os dados são divididos em k subconjuntos. Para cada um desses subconjuntos, o modelo treinado com os demais dados é testado para avaliar seu desempenho em dados não utilizados. O desempenho final do modelo é obtido calculando a média dos resultados de todas as iterações, conforme mostrado na Equação 2.29. Um caso particular dessa técnica é o método *leave-one-out*, onde k é igual ao número total de amostras disponíveis N . Essa abordagem é frequentemente utilizada quando o conjunto de dados é pequeno. Ao ajustar um modelo com um hiperparâmetro α , $\in \alpha \Lambda$, o modelo ajustado é representado por $\hat{f}^{-k}(\mathbf{x}, \alpha)$, calculado com base nos dados da k -ésima partição e no hiperparâmetro α . O modelo escolhido é aquele que minimiza a validação cruzada $CV(\hat{f}, \alpha)$, $\in \alpha \Lambda$. Após a seleção do modelo, ele é então

ajustado com todos os dados disponíveis ((HASTIE, 2009). A Figura 23 ilustra o processo da validação cruzada k-fold.

$$CV(\hat{f}, \alpha) = \frac{1}{N} \sum_{i=1}^N L(y_i, \hat{f}^{-k(i)}(\mathbf{x}_i, \alpha)) \quad (2.29)$$

Figura 23 – Validação k-Dobras



Fonte: Adaptado Tito (2024)

Conforme destacado por (BORRA; CIACCIO, 2010), o viés associado à validação cruzada por k-dobras tende a diminuir à medida que o número de dobras k aumenta. Contudo, embora um maior valor de k possa reduzir o viés, isso também eleva o custo computacional do processo, pois a técnica requer mais iterações de treinamento e avaliação. Além disso, valores excessivamente altos de k resultam em subconjuntos de teste menores, o que pode aumentar a variabilidade das estimativas, comprometendo a robustez do modelo.

A escolha do valor de k é, portanto, um equilíbrio entre viés, variância e custo computacional. A literatura apresenta diversos valores de k como opções práticas, sendo $k = 2$, $k = 5$ e $k = 10$ os mais comumente utilizados. O valor de $k = 10$ é amplamente recomendado, pois oferece uma boa relação entre viés e variância sem inflacionar demasiadamente o tempo de processamento. No entanto, em cenários onde o custo computacional é uma preocupação, um valor intermediário, como $k = 5$, pode ser mais adequado. Neste estudo, optou-se por utilizar $k = 5$, considerando-se o balanço entre precisão nas estimativas e eficiência computacional.

2.5.7 Métricas de Avaliação

Diversas métricas são essenciais para avaliar o desempenho de modelos de regressão. Na literatura, encontram-se muitos trabalhos que utilizaram essas métricas, como o MAE (*Mean Absolute Error* - (Erro Médio Absoluto)), o MSE (*Mean Square Error* - (Erro Quadrático Médio)), a RMSE e o Coeficiente de Determinação (R^2), para garantir uma análise abrangente do desempenho dos modelos (HAYKIN, 2001; MONTGOMERY, 2017).

O Erro Médio Quadrático (MSE) é uma métrica relacionada ao RMSE, mas sem a aplicação da raiz quadrada. Ele calcula a média dos quadrados das diferenças entre os valores reais e os previstos, conforme Equação 2.30 (VICKERS, 2017).

$$\text{MSE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.30)$$

O Erro Absoluto Médio (MAE) é calculado pela média das diferenças absolutas entre os valores reais e os valores previstos, como mostrado na equação 2.31. Essa métrica é menos sensível a outliers, o que a torna adequada em cenários onde se deseja uma avaliação mais estável do erro médio (VICKERS, 2017).

$$\text{MAE}(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.31)$$

Já o RMSE penaliza erros maiores, pois eleva as diferenças ao quadrado antes de calcular a média, conforme a equação 2.32 (VICKERS, 2017).

$$\text{RMSE}(y, \hat{y}) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.32)$$

O coeficiente R^2 varia de 0 a 1 e expressa a proporção da variância nos dados que é explicada pelo modelo. Quanto mais próximo de 1, maior a capacidade explicativa do modelo em relação aos dados previstos. O cálculo de R^2 é feito conforme a equação 2.33, onde y representa os valores reais, \hat{y}_i são os valores previstos e \bar{y} é a média dos valores reais (MONTGOMERY, 2017; MYERS; MONTGOMERY; ANDERSON-COOK, 2016).

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.33)$$

Tanto o MSE quanto o RMSE são sensíveis a outliers, o que pode ser benéfico em cenários onde se busca penalizar grandes desvios, mas pode também ser uma desvantagem quando há valores extremos nos dados. A principal diferença entre essas métricas é que o RMSE facilita a interpretação, uma vez que o valor resultante mantém a mesma unidade dos dados originais (VICKERS, 2017).

A aplicação de múltiplas métricas, como MAE , $RMSE$, MSE e R^2 , oferece uma visão mais ampla sobre o desempenho do modelo. Essas métricas são cruciais durante a validação cruzada, permitindo a identificação de problemas como overfitting ou viés, e auxiliando na escolha do modelo mais apropriado para o problema específico de regressão e para as características dos dados analisados (HAYKIN, 2001; MONTGOMERY, 2017; VICKERS, 2017).

2.5.8 Desenvolvimento de Modelos de Aprendizagem de máquina

Nesta etapa, uma sequência de ações é apresentada com a finalidade de sistematizar o processo de desenvolvimento de diferentes modelos de aprendizado de máquina, incluindo Redes Neurais Artificiais (*RNA*), Máquinas de Vetores de Suporte (*SVM*), Árvores de Decisão (*DTR*) e Florestas Aleatórias (*RF*). Essas ações visam garantir uma aplicação correta da metodologia para cada um desses algoritmos, prevenindo problemas durante as fases de treinamento, teste e validação.

2.5.8.1 Coleta de Dados

O primeiro passo no desenvolvimento de qualquer modelo de aprendizado de máquina é a coleta de dados relevantes para o problema em questão. A qualidade dos dados desempenha um papel crucial na eficácia dos modelos. Para evitar ambiguidade e minimizar erros, técnicas adequadas de amostragem devem ser usadas, garantindo que os dados sejam representativos do domínio do problema. Além disso, os dados devem incluir uma ampla gama de condições, cobrindo tanto cenários típicos quanto exceções, garantindo que o modelo possa generalizar adequadamente para novas situações (STEVENSON et al., 1981; HAYKIN, 2001)

2.5.8.2 Separação Treino e Teste

Os dados coletados devem ser divididos em dois conjuntos principais: conjunto de treinamento e conjunto de teste. Na literatura, é comum utilizar uma divisão de 70% para o treinamento e 30% para o teste. O conjunto de treinamento é utilizado para ajustar os parâmetros do modelo, seja ele uma *RNA*, *SVM*, *DTR* ou *RF*. Já o conjunto de teste é reservado para avaliar o desempenho final do modelo em dados não vistos anteriormente, verificando sua capacidade de generalização. Além disso, a aleatorização dos dados e um pré-processamento adequado, como normalização, padronização ou codificação, são etapas cruciais para otimizar o desempenho dos diferentes algoritmos (BORBA, 2023; FERNANDES, 2021).

2.5.8.3 Configuração dos hiperparâmetros

Tardivo (2024) diz que o próximo passo é a configuração do modelo, que varia de acordo com o algoritmo selecionado. Cada técnica possui especificidades que precisam ser ajustadas de acordo com a natureza do problema:

1. *RNA*: Configuração da arquitetura da rede, número de camadas, funções de ativação, taxa de aprendizado e outros parâmetros.
2. *SVM*: Escolha do tipo de kernel (linear, polinomial, RBF, etc.), ajuste de parâmetros como C e γ , que influenciam a margem de separação e a suavização do modelo.

3. DTR: Definição de critérios de divisão, profundidade máxima da árvore e número mínimo de amostras por folha, visando equilibrar precisão e generalização.
4. RF: Número de árvores no ensemble, profundidade de cada árvore e a quantidade de variáveis usadas em cada divisão.

Cada uma dessas escolhas pode impactar de forma significativa a performance final, e a seleção dos parâmetros pode ser feita por meio de métodos como validação cruzada e busca em grade.

2.5.8.4 Treinamento

Nesta fase, o modelo é treinado utilizando o conjunto de treinamento. Durante o processo de aprendizado:

Para *RNA*, os pesos das conexões são ajustados gradualmente por meio de algoritmos como backpropagation, até que a rede atinja um erro mínimo aceitável. Para *SVM*, o objetivo é encontrar o hiperplano que melhor separa as classes, maximizando a margem entre elas. Para *DTR*, a árvore é construída de maneira recursiva, selecionando os atributos que melhor separam os dados em cada nó. No caso de *RF*, múltiplas árvores são treinadas com diferentes subconjuntos de dados, e a decisão final é tomada com base na média ou votação das árvores. Cada algoritmo requer ajustes específicos para garantir que o modelo não sofra de underfitting (modelo muito simples) ou overfitting (modelo muito complexo). O uso de técnicas de regularização e a escolha de bons critérios de parada são essenciais para garantir que o treinamento resulte em um modelo capaz de generalizar para novos dados (FERNANDES, 2021).

2.5.8.5 Teste e Validação

Na fase final, o conjunto de teste é utilizado para avaliar a performance do modelo treinado, seja *RNA*, *SVM*, *DTR* ou *RF*, em dados que não foram utilizados durante o processo de treinamento. Para isso, são calculadas diversas métricas de desempenho, como acurácia, precisão, recall e *F1*-score, no caso de modelos de classificação, e erro médio quadrático (*MSE*), raiz do erro quadrático médio (*RMSE*), coeficiente de determinação (R^2) e erro absoluto médio (*MAE*), no caso de modelos de regressão. Essas métricas fornecem uma avaliação detalhada da eficácia do modelo e sua capacidade de generalização (BORBA, 2023).

Além disso, em aplicações práticas, é necessário validar a robustez do modelo em condições reais de operação. Isso pode envolver a integração do modelo treinado em um sistema de produção, onde seu desempenho é monitorado ao longo do tempo. Para garantir a validade estatística dos resultados e a confiabilidade do modelo, testes estatísticos, como o teste t de Student, ANOVA (Análise de Variância) ou teste de Mann-Whitney, podem ser

realizados. Esses testes ajudam a comparar o desempenho do modelo em diferentes cenários ou com outros modelos, avaliando a significância das diferenças observadas. Ajustes e recalibrações podem ser feitos periodicamente para assegurar que o modelo continue a fornecer resultados precisos e relevantes, especialmente em cenários onde os dados ou o ambiente operacional possam sofrer variações.

A aplicação de técnicas de aprendizado de máquina tem se mostrado uma abordagem eficaz para otimizar o processo de usinagem, permitindo a previsão e controle de variáveis como rugosidade superficial, forças de corte, taxa de remoção de material e desgaste de ferramenta. A busca por maior precisão e eficiência tem impulsionado o uso de modelos baseados em inteligência artificial, como máquinas de vetores de suporte, redes neurais artificiais e florestas aleatórias, que têm demonstrado resultados promissores na redução de custos, tempo de experimentação e melhoria na predição de variáveis essenciais no fresamento.

Estudos recentes exploram diferentes abordagens de aprendizado de máquina para melhorar a precisão e previsibilidade no fresamento de topo e outros processos de usinagem. No estudo de Pimenov, Bustillo e Mikolajczyk (2018), modelos de aprendizado de máquina como floresta aleatória, perceptron multicamadas, árvores de decisão e funções de base radial foram testados na previsão em tempo real de desvios de rugosidade superficial em processos de fresamento. A floresta aleatória se destacou, seguida pelas árvores de decisão, ambas superando o *MLP* e a função de base radial em precisão.

Já Flores e Keith (2019) utilizaram árvores com gradiente reforçado para prever a rugosidade superficial em fresamento de alta velocidade, aplicadas à indústria metalúrgica de aço e alumínio. Eles obtiveram precisão de 61,54% a 88,51%, com a profundidade de corte axial sendo o fator mais relevante nos dados de ranhuras, enquanto a dureza e o diâmetro da ferramenta de corte se mostraram os mais influentes nos dados de geometria.

Kara et al. (2020) investigaram o efeito da usinabilidade, microestrutura e dureza do tratamento criogênico profundo no torneamento do aço AISI D2 com corte cerâmico. O estudo utilizou redes neurais artificiais para estimar a rugosidade superficial com base em parâmetros como velocidade de corte, tipo de ferramenta, profundidade de corte e taxa de avanço.

Eser et al. (2021) previram a rugosidade superficial da liga AA6061 no fresamento usando redes neurais artificiais e metodologia de superfície de resposta. A *RNA* obteve R^2 de 92,7%, *MAE* de 28,11 e *RMSE* de 0,185, enquanto a metodologia de superfície de resposta alcançou R^2 de 99,9%, *MAE* de 2,17 e *RMSE* de 0,016. Karthik et al. (2021) analisaram a previsão e otimização da rugosidade superficial e do desgaste de flanco no fresamento de alta velocidade da liga de alumínio 6061. Utilizando quatro algoritmos — regressão linear, *SVR*, árvore de aumento de gradiente e redes neurais artificiais — os resultados indicaram que *SVR* e *RNA* tiveram melhor desempenho preditivo. Nguyen et al. (2021) realizaram uma otimização multiobjetivo da rugosidade superficial e desgaste

de ferramenta no fresamento de alta velocidade da liga AA6061, utilizando técnicas de aprendizado de máquina e *NSGA-II*, com *SVR* e *RNA* apresentando o melhor desempenho. Fertig, Weigold e Chen (2022) estudaram a previsão da qualidade no fresamento com base em aprendizado de máquina, usando dados internos da máquina-ferramenta. Métodos de ensemble como floresta aleatória e Extra Trees, além de algoritmos de aprendizado profundo como Inception Time e ResNet, demonstraram o melhor desempenho. Shah et al. (2022) utilizaram uma rede generativa adversarial singular e modelos *LSTM* de aprendizado profundo para prever o desgaste de ferramenta no fresamento de aço inoxidável. O modelo *LSTM* empilhado apresentou melhor desempenho em comparação com outros modelos. Xu et al. (2022) investigaram as forças de corte no fresamento de materiais funcionalmente classificados usando modelos de regressão de processo gaussiano, com previsões baseadas na profundidade de corte e na taxa de avanço. Li et al. (2022) aplicaram modelagem de sinais temporais no fresamento utilizando um modelo semi-Markov oculto aprimorado, enquanto Wang et al. (2022) utilizaram aprendizado de ensemble com algoritmo genético para prever a rugosidade no polimento multi-jato. Ding et al. (2023) desenvolveram um modelo de monitoramento online da força de microfresamento, integrando a previsão de desgaste de ferramenta ao processo. Cica et al. (2024) utilizaram três algoritmos de aprendizado de máquina — regressão polinomial, regressão de máquina de vetor de suporte (*SVR*) e regressão de processo gaussiano (*GPR*) — para prever a força e potência de corte no fresamento de AISI 1045 sob lubrificação mínima e refrigeração de alta pressão. *SVR* e *GPR* apresentaram melhor desempenho em relação à regressão polinomial.

Souza et al. (2024) propôs uma abordagem inovadora para prever a rugosidade superficial durante o torneamento seco de aço endurecido AISI 52100, integrando métodos de aprendizado de máquina. O estudo incluiu o desgaste da ferramenta como uma variável de entrada, além de velocidade de corte, avanço e profundidade de corte, para treinar três modelos de aprendizado de máquina: Regressão por Árvore de Decisão, Random Forest e Regressão por Vetores de Suporte. Todos os modelos demonstraram alta precisão na previsão, com valores de R-quadrado superiores a 90%, e baixos valores para Erro Absoluto Médio (MAE) e Erro Quadrático Médio (RMSE). No entanto, o modelo Random Forest superou os demais, apresentando os menores valores de RMSE. A Tabela 3 apresenta o resumo das principais particularidades de cada modelo.

Tabela 3 – Resumo das particularidades dos modelos utilizados

Modelo	Aplicações	Vantagens	Limitações
SVM	<ul style="list-style-type: none"> • Classificação e regressão • Alta dimensionalidade • Problemas não lineares 	<ul style="list-style-type: none"> • Lida bem com dados complexos usando kernels • Boa generalização para conjuntos pequenos e médios 	<ul style="list-style-type: none"> • Sensível à escolha do kernel e parâmetros • Alto custo computacional em grandes dados
DTR	<ul style="list-style-type: none"> • Regressão para dados tabulares • Fácil interpretação das regras 	<ul style="list-style-type: none"> • Fácil interpretação e visualização • Rápido no treinamento e predição 	<ul style="list-style-type: none"> • Propenso a overfitting • Baixa generalização em dados ruidosos
RF	<ul style="list-style-type: none"> • Regressão e classificação • Alta precisão em diversos tipos de dados • Redução de overfitting 	<ul style="list-style-type: none"> • Robusto a ruídos • Bom desempenho geral • Fácil ajuste de hiperparâmetros 	<ul style="list-style-type: none"> • Menor interpretabilidade que árvores simples • Maior custo computacional
RNA	<ul style="list-style-type: none"> • Modelagem de relações complexas e não lineares • Predição em larga escala 	<ul style="list-style-type: none"> • Alta flexibilidade • Capaz de modelar relações complexas 	<ul style="list-style-type: none"> • Necessita grande quantidade de dados • Ajuste complexo • Risco de overfitting

Fonte: Própria

2.6 Metodologia de Superfície de Resposta

De acordo com Montgomery (2017), a Metodologia de Superfície de Resposta (MSR) consiste em um conjunto de técnicas matemáticas e estatísticas usadas para modelar e analisar situações nas quais as respostas de interesse são afetadas por diversas variáveis.

Esta abordagem é empregada para desenvolver, aprimorar e otimizar processos (MYERS; MONTGOMERY; ANDERSON-COOK, 2016). O primeiro passo na aplicação da MSR é encontrar uma estimativa apropriada para a verdadeira relação funcional entre a resposta de interesse (y) e o conjunto de variáveis independentes (x) do processo, já que essa relação não é conhecida a priori (MOHAMMED; KHED; NURUDDIN, 2018).

Quando a resposta pode ser bem descrita por uma função linear em relação às variáveis independentes, o modelo de primeira ordem é o mais adequado, conforme indicado pela Equação 2.34. No entanto, se a resposta apresenta curvatura, é necessário utilizar um polinômio de grau superior, como o modelo de segunda ordem especificado pela Equação 2.35.

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \cdots + \beta_kx_k + \epsilon \quad (2.34)$$

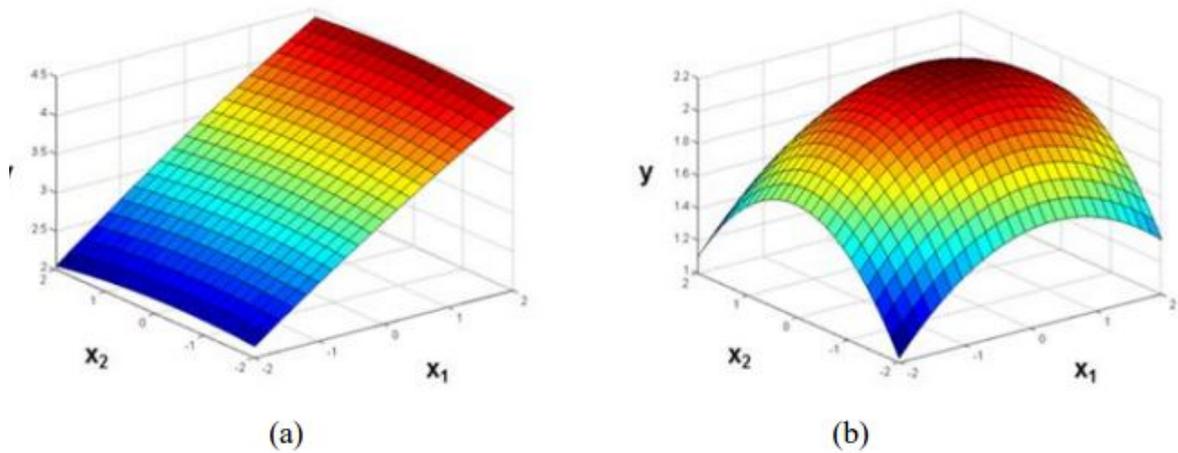
$$y = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \beta_{ij} x_i x_j + \epsilon \quad (2.35)$$

Onde:

- y = resposta de interesse;
- x_i = variáveis independentes;
- β_i = coeficientes a serem estimados;
- k = números de variáveis independentes;
- ϵ = erro experimental.

Uma representação da superfície de resposta, seja para um modelo de primeira ou de segunda ordem, contendo duas variáveis independentes para x_1 e x_2 pode ser observado na Figura 24

Figura 24 – Superfícies de resposta: (a) modelo linear; (b) modelo com curvatura



Fonte: GOMES (2013)

Conforme Box e Draper (2007), os modelos de primeira ordem, aplicados a sistemas sem curvatura, e de segunda ordem, para sistemas com curvatura, abrangem praticamente todos os problemas associados à superfície de resposta. O método de mínimos quadrados ordinários (OLS – Ordinary Least Squares) é empregado para estimar os parâmetros β_i dos modelos de regressão, buscando minimizar a soma dos quadrados dos erros ϵ_i . Assim, o objetivo é determinar o vetor estimado $\hat{\beta}$ pelos mínimos quadrados, de modo a minimizar a função L expressa em notação matricial, conforme apresentado na Equação 2.36.

$$L = \sum_{i=1}^n \epsilon_i^2 = \epsilon^T \epsilon = (\mathbf{y} - \mathbf{X}\beta)^T (\mathbf{y} - \mathbf{X}\beta) \quad (2.36)$$

Onde:

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}, \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_k \end{bmatrix} \quad (2.37)$$

- y é a matriz da variável dependente com dimensão $(n \times 1)$;
- X é a matriz das variáveis independentes com dimensão $(n \times k)$;
- β é a matriz dos coeficientes de regressão para o modelo com dimensão $(k \times 1)$;
- ϵ é a matriz dos erros aleatórios $(n \times 1)$;
- Sendo n a quantidade de experimentos a ser executado e k o número de variáveis independentes.

A função L multiplicando os fatores da equação 2.36, pode ser reescrita como:

$$L = \mathbf{y}^T \mathbf{y} - \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y} - \mathbf{y}^T \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{X} \boldsymbol{\beta} \quad (2.38)$$

A matriz (1×1) $\boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y}$, ou simplesmente um escalar, e a sua transposta $(\boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y}) = \mathbf{y}^T \mathbf{X} \boldsymbol{\beta}$ que também representa um escalar, a Equação 2.38 é reescrita como:

$$L = \mathbf{y}^T \mathbf{y} - 2\boldsymbol{\beta}^T \mathbf{X}^T \mathbf{y} + \boldsymbol{\beta}^T \mathbf{X}^T \mathbf{X} \boldsymbol{\beta} \quad (2.39)$$

Onde os estimadores do OLS devem satisfazer:

$$\left. \frac{\partial L}{\partial \boldsymbol{\beta}} \right|_{\boldsymbol{\beta}} = -2\mathbf{X}^T \mathbf{y} + 2\mathbf{X}^T \mathbf{X} \boldsymbol{\beta} \quad (2.40)$$

Simplificando a derivada parcial em relação a $\boldsymbol{\beta}$, tem-se:

$$\mathbf{X}^T \mathbf{X} \boldsymbol{\beta} = \mathbf{X}^T \mathbf{y} \quad (2.41)$$

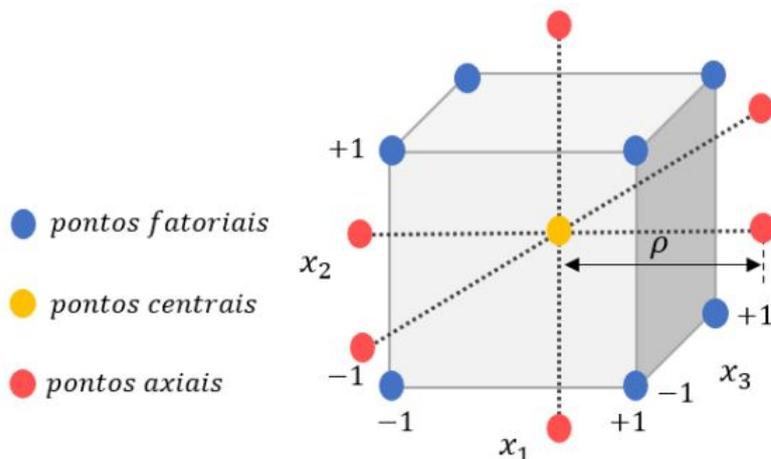
O estimador dos mínimos quadrados de $\boldsymbol{\beta}$ e $\hat{\boldsymbol{\beta}}$, é necessário realizar a multiplicação por $(\mathbf{X}^T \mathbf{X})^{-1}$ ambos membros da Equação 2.41. Por fim, é possível estabelecer os coeficientes dos modelos de regressão, conforme a Equação

$$\boldsymbol{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (2.42)$$

Quando se deseja modelar a relação entre uma variável de interesse e outras k variáveis, um polinômio de grau d pode ser utilizado dentro de uma região específica no espaço dessas variáveis. De acordo com Box et al. (1973), a determinação desse polinômio (incluindo todos os coeficientes) pode ser realizada por meio de um planejamento experimental com k dimensões e grau d sse planejamento é constituído por um conjunto de N pontos distribuídos no espaço k dimensional das variáveis selecionadas, e os dados coletados de cada ponto são utilizados na estimação.

Entre os métodos de planejamento para superfícies de resposta, o Planejamento Composto Central (Central Composite Design - CCD) se destaca como o mais utilizado para ajustar modelos de segunda ordem. A implementação do CCD geralmente ocorre de forma sequencial, especialmente quando se detecta a inadequação de um modelo de primeira ordem (MONTGOMERY, 2017).

No caso de k fatores, o CCD é composto por 2^k pontos fatoriais (ou 2^{k-p} para fração p desejada), n_c pontos centrais e $2k$ pontos axiais. Assim, o número total N de experimentos em um CCD é a soma dos pontos fatoriais, centrais e axiais ($N = n_f + n_c + n_a$). Como mostrado na Figura 25, os pontos centrais correspondem a condições intermediárias dos níveis das variáveis ou fatores, enquanto os pontos axiais indicam os níveis extremos.

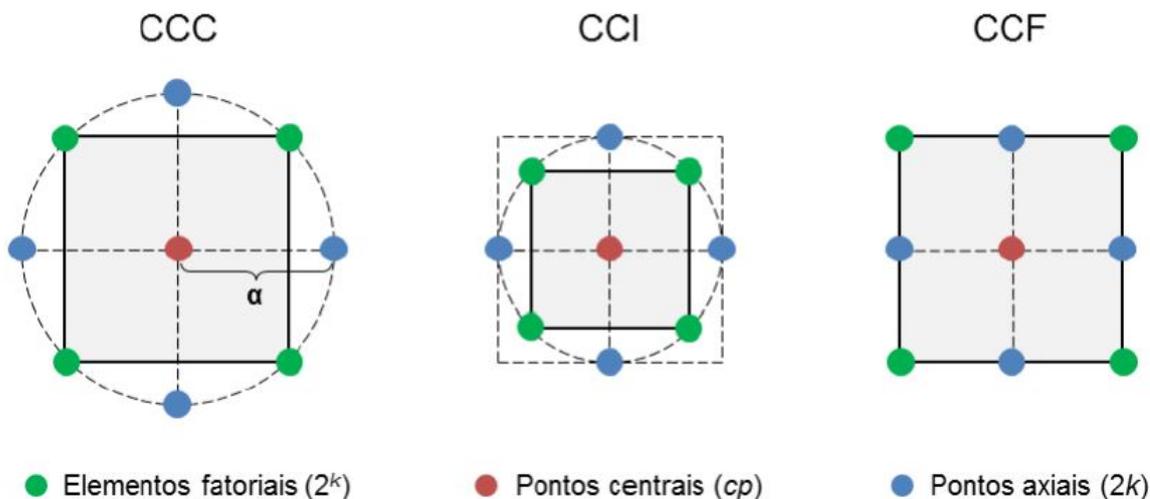
Figura 25 – Planejamento composto central para $k=3$ 

Fonte: Alvim et al. (2023)

No Planejamento Composto Central (CCD), cada tipo de ponto possui um papel específico no planejamento e na modelagem de processos. Os pontos fatoriais são responsáveis pela estimativa dos coeficientes lineares e das interações (β_i e β_{ij} conforme apresentado na Equação 2.35). Os pontos centrais, por sua vez, auxiliam na avaliação do erro experimental σ^2 e na determinação da relevância dos coeficientes quadráticos β_{ii} . Já os pontos axiais são utilizados para a estimativa dos coeficientes quadráticos, conforme Equação 2.35.

A posição dos pontos axiais permite classificar o CCD em três categorias distintas: Planejamento Composto Central Circunscrito (CCC), Planejamento Composto Central Inscrito (CCI) e Planejamento Composto Central de Face Centrada (CCF), conforme exemplificado na Figura 26. Para a configuração de um CCD, é necessário definir dois parâmetros principais: a distância ρ entre os pontos axiais e o centro do plano experimental (ou seja, a distância dos pontos centrais aos axiais) e o número de pontos centrais n_c . A Equação 2.43 é uma ferramenta eficaz para calcular ρ , assegurando que o CCD possa ser rotacionado adequadamente.

Figura 26 – Planejamento composto central - CCC, CCI, CCF



Fonte: GOMES (2013)

$$\rho = \sqrt[4]{2^k} \quad (2.43)$$

A rotacionalidade é uma característica essencial em um modelo quadrático de superfície de resposta, pois assegura que a variância do modelo $Var\hat{y}$, se mantenha constante quando a distância ρ é constante. Em um planejamento rotacionável, a variância é uniforme em todos os pontos cuja distância ao centro do planejamento é igual. A variância $Var\hat{y}$ para qualquer ponto x pode ser descrita pela Equação 2.44 (MONTGOMERY, 2017).

$$Var(\hat{y}) = \sigma^2 x^T (X^T X)^{-1} x \quad (2.44)$$

O Planejamento Composto Central (CCD) oferece várias vantagens, incluindo:

- (1) experimentação sequencial: o processo começa com a definição dos pontos fatoriais, a avaliação da curvatura e a adição dos pontos axiais;
- (2) eficiência na experimentação: a replicação é feita nos pontos centrais;
- (3) rotacionalidade: como descrito anteriormente, assegura que a variância dos valores previstos permaneça constante; e
- (4) opção para regiões experimentais restritas: o CCD de face centrada é apropriado para quando a região experimental é limitada.

2.6.1 Projeto de Parâmetro Robusto

O RPD (*Robust Parameter Design* - (Projeto de parâmetro robusto)) é uma metodologia amplamente reconhecida pela sua eficiência econômica na melhoria da qualidade de

processos e produtos (JOSEPH et al., 2019). Conforme apontado por Myers, Montgomery e Anderson-Cook (2016), essa abordagem foi introduzida nos Estados Unidos no início da década de 1980 por Genichi Taguchi, um engenheiro japonês, com o objetivo central de reduzir a variabilidade em processos e produtos. O PPR visa principalmente identificar as condições operacionais que minimizam a variação na resposta (output) em torno de um valor-alvo predefinido (OZDEMIR; CHO, 2017). Taguchi propôs um conjunto de técnicas voltadas a definir as melhores combinações de variáveis controláveis para garantir um desempenho robusto, utilizando planejamento de experimentos e análises estatísticas, como observado por (NAIR et al., 1992).

Taguchi (1986) diferenciou as variáveis presentes em um sistema, produto ou processo em duas categorias: variáveis de controle (x) e variáveis de ruído (z). As primeiras referem-se àquelas que podem ser ajustadas e estabilizadas em níveis predeterminados, não influenciando a variação nos outputs. Já as variáveis de ruído são aquelas que não podem ser facilmente controladas e, portanto, causam variações indesejadas nos resultados do processo (BOYLAN; GOETHALS; CHO, 2013). De fato, as variáveis de ruído são as maiores responsáveis pela variabilidade nos processos (MONDAL; RAY; MAITI, 2014). O RPD, então, busca identificar os melhores níveis das variáveis de controle para reduzir a sensibilidade da resposta ao ruído (KHURI; MUKHOPADHYAY, 2010; MYERS; MONTGOMERY; ANDERSON-COOK, 2016). Conforme destacado por Joseph et al. (2019), essa técnica proporciona robustez ao sistema mesmo sem o controle direto das variáveis de ruído, o que torna o PPR uma abordagem mais acessível em termos de custo, especialmente quando comparada a outras metodologias que tentam controlar os fatores de ruído diretamente. Segundo Robinson, Borrer e Myers (2004), o controle de variáveis de ruído pode demandar alto custo e envolver complexidade significativa, devido à dificuldade de isolamento e monitoramento desses fatores durante o processo.

Montgomery (2017) descreve o RPD como uma abordagem que busca otimizar os níveis dos fatores controláveis com dois objetivos principais: (1) garantir que a média da resposta do processo esteja alinhada com o valor-alvo e (2) minimizar a variabilidade em torno desse alvo.

As estratégias propostas por Taguchi incluem o cruzamento de duas matrizes ortogonais: a matriz interna, relacionada às variáveis controláveis, e a matriz externa, que envolve as variáveis de ruído. Essa configuração permite testar diferentes combinações de variáveis sob cenários variados de ruído. Taguchi sugeriu a utilização de duas estatísticas para resumir os dados: a média das observações obtidas na matriz interna e a razão sinal-ruído (S/N), que combina informações sobre a média e a variância. Maximizar a razão sinal-ruído implica reduzir a variabilidade causada pelo ruído. A análise de variância (ANOVA) é então aplicada para identificar as configurações de variáveis controláveis que proporcionam um desempenho robusto (NAIR et al., 1992; MONTGOMERY, 2017)

Embora os conceitos de Taguchi sejam amplamente aplicados na melhoria da qua-

lidade, sua abordagem no RPD gera algumas controvérsias na comunidade científica, especialmente no que se refere aos procedimentos experimentais e métodos de análise (MONTGOMERY, 2017). Nair et al. (1992) promoveu um painel de discussão sobre o tema, reunindo diversas opiniões de especialistas.

Robinson, Borror e Myers (2004) apontam dois problemas principais no uso da matriz cruzada. Primeiro, ela exige um número elevado de execuções experimentais, o que pode ser inviável em ambientes industriais. Segundo, a matriz interna, geralmente uma fração de três níveis (ou de nível misto) de resolução III, combinada com a matriz externa de dois níveis, permite estimar apenas os efeitos lineares e quadráticos dos fatores de controle, omitindo interações importantes entre esses fatores. Isso pode resultar em perda de informações relevantes. Além disso, Montgomery (2017) observa que a matriz cruzada não explora diretamente as interações entre variáveis controláveis e variáveis de ruído, o que pode mascarar esses relacionamentos. Joseph et al. (2019) sugerem que o sucesso do PPR depende da identificação das interações mais relevantes entre as variáveis de controle e de ruído, pois é a partir dessas interações que se pode reduzir a sensibilidade ao ruído.

Em resposta às limitações do método de Taguchi, vários pesquisadores desenvolveram abordagens alternativas, combinando suas contribuições com outras metodologias, resultando em estratégias mais eficazes e robustas para o projeto e análise de experimentos (MYERS; KHURI; VINING, 1992)

2.6.2 Arranjo Combinado

O conceito de Arranjo Combinado envolve a construção de um modelo que correlaciona diretamente as variáveis de controle e de ruído com uma resposta de interesse. Esse arranjo foi proposto como uma alternativa ao arranjo cruzado de Taguchi, oferecendo maior flexibilidade na estimativa das interações entre essas variáveis e demandando um número menor de experimentos (SHOEMAKER; TSUI; WU, 1991; KÖKSOY; YALCINOZ, 2006). A redução no número de observações experimentais e a habilidade de modelar interações entre variáveis tornam o arranjo combinado mais eficiente do que a abordagem tradicional, como destaca (MONTGOMERY, 2017)

No contexto de projetos robustos, é essencial identificar interações significativas entre variáveis de controle e ruído, uma vez que estas interações desempenham um papel crucial na propagação do erro e, portanto, na robustez do processo. A equação geral que modela a resposta de interesse pode ser expressa como:

$$y(x, z) = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i=1}^r \sum_{j=1}^r \delta_{ij} x_i z_j + \sum_{i < j} \beta_{ij} x_i x_j + \epsilon \quad (2.45)$$

Nesta equação, β_0 é a constante, β_i são os coeficientes associados às variáveis de controle

x_i , enquanto γ_j representa os coeficientes das variáveis de ruído z_j . A interação entre variáveis de controle e ruído é capturada pelos coeficientes δ_{ij} .

O arranjo combinado permite a criação de modelos para a média $E_{z,\epsilon}$ e para a variância $V_{z,\epsilon}$ da resposta. Esses modelos podem ser ajustados utilizando o Método dos Mínimos Quadrados Ordinários (OLS) ou Ponderados (WLS). As expressões para média e variância podem ser vistas como:

$$E_{z,\epsilon}(y) = f(x) = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j} \beta_{ij} x_i x_j \quad (2.46)$$

$$V_{z,\epsilon}(y) = \sigma_{z_i}^2 \left\{ \sum_{i=1}^r \left[\frac{\partial y(x, z)}{\partial z_i} \right]^2 \right\} + \sigma^2 \quad (2.47)$$

Onde para a equação 2.47 assume-se $\sigma_z^2 = 1$ e σ^2 corresponde ao erro experimental do modelos de superfície de resposta ($\sigma^2 = S^2$), estimado pela ANOVA. Essas equações descrevem como as variáveis de controle afetam tanto a média quanto a variância da resposta, com a variância também sendo influenciada pelas interações entre variáveis de controle e ruído (MONTGOMERY, 2017).

Welch et al. (1990) e outros autores Shoemaker, Tsui e Wu (1991) e Myers, Khuri e Vining (1992) indicam que o arranjo combinado proporciona uma maneira eficiente de estimar as interações entre fatores controláveis e ruído, com implicações diretas na robustez do processo.

O desenvolvimento de metodologias robustas tem permitido a melhoria da qualidade e do desempenho desses processos, minimizando os efeitos de variáveis de ruído e maximizando a eficiência. Diversos autores têm contribuído para esse campo, propondo abordagens inovadoras que combinam técnicas como o Projeto de Parâmetros Robustos (PPR), arranjo combinado e metodologia de superfície de resposta.

Neste sentido, Paiva et al. (2014) aplicaram a abordagem de Projeto de Parâmetros Robustos (PPR) juntamente com a metodologia de superfície de resposta e análise de componentes principais (ACP) para um estudo bivariado no torneamento do aço AISI 52100. Foram selecionados como fatores de controle a velocidade de corte, a taxa de avanço e a profundidade de corte, enquanto a dureza do material foi escolhida como fator de ruído. As variáveis de resposta escolhidas foram rugosidade Ra e Ry. Os resultados dos experimentos demonstraram a eficácia da abordagem, confirmando a robustez do processo através de ensaios de validação.

Brito et al. (2016) propuseram um avanço metodológico, apresentando o Erro Quadrático Médio Ponderado (EQMP) para otimizar o fresamento do aço AISI 1045. Para validar a metodologia, foram considerados fatores controláveis como velocidade de corte, avanço por dente, largura fresada e profundidade de corte. e os ruídos considerados foram desgaste de flanco, vazão de fluido e concentração de fluido. As respostas analisadas

incluiram a energia específica de corte (E_c), rugosidades (R_a e R_t). Os resultados de confirmação mostram que os setups ótimos encontrados são capazes de mitigar a influência das variáveis de ruído, o que corrobora a boa adequação da proposta.

Lopes et al. (2016) combinaram os conceitos de projeto de parâmetros robustos, análise de componentes principais e o método de interseção normal à fronteira, buscando soluções ótimas de Pareto igualmente distribuídas, capazes de mitigar os efeitos dos fatores de ruído no fresamento. Utilizando dados experimentais de Brito et al. (2014) e o arranjo ortogonal de Taguchi L9, verificaram a robustez do processo com base nos intervalos de confiança da média e do desvio padrão das variáveis de resposta obtidas nos ensaios de confirmação.

Pereira et al. (2018) desenvolveram uma modelagem robusta e multivariada para otimizar os parâmetros do fresamento helicoidal da liga de alumínio Al 7075. Fatores como velocidade de corte e avanços axial e tangencial por dente foram escolhidos como fatores controláveis, enquanto o comprimento em balanço foi considerado fator de ruído. As forças de corte axial e radial foram utilizadas como variáveis de resposta, sendo aplicadas a análise de componentes principais e o método de interseção normal à fronteira para determinar os pontos ótimos de Pareto. Os experimentos confirmaram a robustez do processo em relação à variável de ruído.

SOUZA (2018) apresentou uma abordagem inovadora para a otimização robusta do torneamento do aço ABNT 52100 endurecido. O estudo utilizou uma metodologia híbrida e multiobjetivo que combinou o Projeto de Parâmetro Robusto Multiobjetivo, a Metodologia de Superfície de Resposta, a Análise de Componentes Principais (ACP), o Erro Quadrático Médio Multivariado (EQMM) e o Método da Interseção Normal à Fronteira (NBI). O principal objetivo foi definir os parâmetros de corte – velocidade de corte (V_c), avanço (f) e profundidade de corte (a_p) – de forma a minimizar a diferença entre os valores reais e os desejados das rugosidades R_a e R_t , ao mesmo tempo em que reduzia a variabilidade provocada pelo desgaste da ferramenta, considerado um fator de ruído no processo.

Rodrigues et al. (2019) analisaram o fresamento helicoidal da liga de alumínio Al 7075 para alargamento de furos, avaliando a força radial, circularidade e rugosidade R_a e R_t . A velocidade de corte e os avanços axial e tangencial por dente foram considerados fatores controláveis, enquanto o comprimento em balanço da ferramenta foi o fator de ruído. A robustez do processo foi garantida pelos conceitos de projeto de parâmetros robustos, erro quadrático médio e interseção normal à fronteira, com os resultados da otimização atingíveis na prática.

Arruda et al. (2019) combinaram diversas metodologias, como projeto de parâmetros robustos, superfície de resposta, interseção normal à fronteira e erro quadrático médio, para otimizar a rugosidade R_a no fresamento de topo esférico do aço AISI H13. Foram considerados como fatores controláveis a profundidade de corte radial e axial, o avanço por dente e a velocidade de corte, enquanto fatores de ruído incluíram o comprimento em

balanço, o ângulo de inclinação da peça, o desgaste de flanco da ferramenta e a estratégia de corte. Os resultados confirmaram que o conjunto de soluções de Pareto eram convexas e igualmente espaçadas, garantindo a robustez do processo.

Vieira et al. (2021) realizaram uma otimização robusta e multiobjetivo no mandrilamento do aço AISI 4130. Os fatores controláveis incluíram o avanço, a velocidade de corte e a posição de fixação da peça, enquanto o comprimento em balanço e a profundidade dos furos foram considerados fatores de ruído. As variáveis de resposta foram rugosidade R_a , circularidade e taxa de remoção de material. Utilizando o NSGA-II e o MOPSO-CD, foram gerados modelos robustos que neutralizaram os efeitos dos fatores de ruído, resultando em um conjunto de soluções ótimas para o processo.

OLIVEIRA et al. (2022) empregou uma abordagem robusta de otimização multivariada no fresamento de topo do aço inoxidável duplex UNS S32205, combinando as metodologias de Projeto de Parâmetro Robusto, Metodologia de Superfície de Resposta, Erro Quadrático Médio Multivariado e o Método da Interseção Normal à Fronteira (NBI). As variáveis controláveis selecionadas foram a velocidade de corte, o avanço por dente, a largura fresada e a profundidade de corte, enquanto o desgaste de flanco, o comprimento em balanço e a vazão de fluido foram considerados fatores de ruído. As respostas avaliadas incluíram as rugosidades R_a , R_q , R_t e R_z , consumo de energia elétrica e emissão de CO_2 e à taxa de remoção de material MRR . Os resultados mostraram que os setups ótimos encontrados foram eficazes em neutralizar os efeitos das variáveis de ruído nas respostas do processo, comprovando a adequação da metodologia e sua aplicação.

Pires et al. (2023) conduziu uma otimização robusta multiobjetivo do fresamento helicoidal do aço inoxidável super duplex UNS S32760. O fresamento helicoidal foi selecionado devido à sua maior eficiência em comparação com o processo de furação convencional, destacando-se por oferecer melhores resultados em termos de qualidade superficial, precisão dimensional e redução do esforço de corte. O planejamento experimental foi baseado em um arranjo composto central, considerando como fatores de controle o avanço axial e tangencial por dente, bem como a velocidade de corte. As respostas analisadas incluíram rugosidade média, força axial de avanço e desvios de circularidade. A metodologia empregada combinou a superfície de resposta e o projeto de parâmetro robusto, com variáveis de ruído como comprimento em balanço da fresa, altura do furo usinado e vazão do fluido de corte. Os resultados demonstraram que a metodologia aplicada é significativa e eficaz para otimizar o processo de fresamento helicoidal, proporcionando melhorias substanciais nas respostas de interesse.

Alvim et al. (2023) conduziu uma otimização robusta no torneamento de cabeças femorais para artroplastia de quadril, utilizando uma análise comparativa de ferramentas de corte com diferentes geometrias – redonda e rômbrica. A autora combinou a Metodologia de Superfície de Resposta e o Projeto de Parâmetros Robustos para otimizar duas respostas principais: rugosidade e esfericidade das cabeças femorais. Os experimentos foram realiza-

dos considerando três variáveis de controle – velocidade de corte, avanço e profundidade de usinagem – e duas variáveis de ruído – comprimento fixado do corpo de prova e vazão de fluido de corte. A qualidade superficial foi avaliada pela rugosidade, e a esfericidade pelo desvio de circularidade total. Os resultados indicaram que a ferramenta com geometria rômbrica proporcionou melhor acabamento superficial e menor desvio de forma. Os experimentos de confirmação demonstraram a robustez das soluções encontradas, mesmo com a presença de variáveis de ruído no processo.

2.6.3 Otimização por Enxame de Partículas (PSO)

A Otimização por Enxame de Partículas (PSO) é um algoritmo meta-heurístico inspirado no comportamento coletivo de animais sociais, como bandos de pássaros e cardumes de peixes (SER et al., 2019). Proposto por Kennedy e Eberhart (1995), o PSO é um método estocástico que modela um conjunto de soluções candidatas como partículas que se movem pelo espaço de busca com velocidades ajustadas dinamicamente. Essas partículas atualizam suas posições com base na melhor experiência individual e na influência de outros membros do enxame, permitindo uma convergência progressiva para soluções otimizadas.

Desde sua introdução em 1995, o PSO tem sido amplamente estudado e aplicado em diversas áreas, como engenharia (CHEN; LIU; CHOU, 2014), engenharia elétrica (SANTANA et al., 2021), manufatura (PANIGRAHI et al., 2022). De acordo com Gandomi e Alavi (2012), o algoritmo PSO está entre as metaheurísticas mais empregadas na solução de problemas de otimização. Esse destaque se deve a várias de suas qualidades, como a ampla aplicabilidade tanto em investigações científicas quanto em desafios práticos; a capacidade de explorar o espaço de busca de forma mais eficiente em comparação com algumas metaheurísticas convencionais; além de sua implementação ser relativamente simples.

Assim como outros métodos de inteligência de enxame ou computação evolutiva, o PSO exige a definição de alguns parâmetros de controle pelo usuário. O número desses parâmetros pode variar entre diferentes variantes do algoritmo, mas, nas versões mais utilizadas com peso de inércia, há quatro principais. Três deles – os coeficientes de aceleração, que regulam o impacto cognitivo e social, e o peso de inércia, introduzido em 1998 – têm sido amplamente estudados na literatura. Além disso, embora não seja um parâmetro de controle, a topologia da rede e seu impacto no desempenho do algoritmo também têm sido objeto de diversas pesquisas.

O quarto parâmetro de controle no PSO clássico é o tamanho do enxame, também chamado de tamanho da população ou número de partículas. Esse parâmetro pode ser considerado o mais fundamental, pois define diretamente o número de indivíduos no enxame, sendo um dos poucos que não pode ser evitado. No entanto, é também um dos mais difíceis de definir na maioria das meta-heurísticas.

No primeiro artigo sobre PSO, Kennedy e Eberhart referiram-se a estudos zoológicos que simulavam os movimentos de bandos compostos por 15 a 30 pássaros. Como resultado, os autores utilizaram 20 partículas nos primeiros experimentos com o PSO, o que acabou servindo como um ponto de partida para a escolha do tamanho do enxame. Desde então, a maioria das variantes do PSO adota populações entre 20 e 50 partículas, com base na suposição de que essa configuração resulta em um melhor desempenho.

No algoritmo PSO, a busca por soluções começa com um enxame de partículas distribuídas aleatoriamente, onde cada partícula representa uma possível resposta para o problema. O deslocamento dessas partículas, ilustrado na Figura 27, é determinado tanto pela melhor posição já alcançada individualmente quanto pela melhor posição identificada coletivamente pelo enxame dentro do espaço de busca. Conforme novas soluções promissoras são descobertas, essas informações são aproveitadas para direcionar o movimento das partículas de forma mais eficiente. Dessa maneira, a população inicial no PSO é definida por:

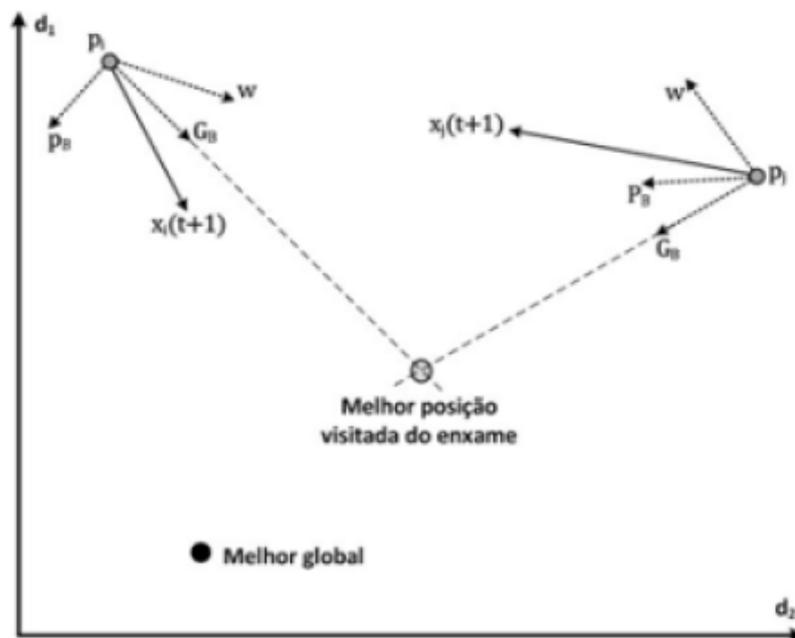
$$S = \{x_1, x_2, \dots, x_p, \dots, x_P\} \quad (2.48)$$

Onde P representa o número de partículas ou o tamanho do enxame. Ademais, a posição de cada partícula no PSO pode ser expressa por:

$$x_i = [x_{p1} \ x_{p2} \ \dots \ x_{pj}]^T \in \mathcal{A}; \quad j = 1, 2, \dots, \mathcal{I}_{\max} \quad (2.49)$$

Sendo \mathcal{I}_{\max} o número máximo de interações.

Figura 27 – Deslocamento de partículas no PSO



Fonte: Adaptado Kennedy e Eberhart (1995)

Considere que x_i^j representa a posição da i -ésima partícula na j -ésima iteração dentro do espaço de busca. A atualização dessa posição para a próxima iteração ($j + 1$) ocorre somando a velocidade v_i^{j+1} à posição atual, conforme expresso em (23):

$$v_i^{j+1} = \omega \cdot v_i^j + c_1 \cdot U_1 \cdot (p_i^j - x_i^j) + c_2 \cdot U_2 \cdot (g^j - x_i^j) \quad (2.50)$$

$$x_i^{j+1} = x_i^j + v_i^{j+1} \quad (2.51)$$

onde ω representa o fator de inércia, enquanto x_i^j e v_i^j correspondem, respectivamente, à posição e velocidade da partícula na iteração j . Os parâmetros c_1 e c_2 são coeficientes de aceleração que contribuem para a influência dos aspectos cognitivo e social. As variáveis p_i^j e g^j indicam os melhores valores individual e global encontrados até o momento. Já U_1 e U_2 são números aleatórios gerados a partir de uma distribuição uniforme no intervalo $[0, 1]$.

De maneira geral, o algoritmo PSO segue três etapas principais: **a)** Avaliação de cada partícula; **b)** Atualização dos melhores valores individual e global encontrados até o momento; **c)** Ajuste da velocidade e da posição de cada partícula. Esse processo é conduzido de forma iterativa, visando encontrar uma solução satisfatória para o problema em questão.

Neste sentido, Zhou, Ren e Yao (2017) desenvolveram um método de otimização multiobjetivo para o fresamento com ponta esférica de múltiplos eixos da liga Inconel 718. O estudo integrou a análise relacional cinza (GRA), redes neurais de função de base radial (RBF) e o algoritmo PSO para otimizar simultaneamente a rugosidade da superfície e a tensão residual compressiva. A abordagem proposta expande o espaço de soluções do GRA original, permitindo otimização em um espaço contínuo. O método foi validado por meio de experimentos que mostraram uma redução significativa no erro preditivo da rede neural e um aumento expressivo na melhoria do grau de relação cinza (GRG) ao utilizar o PSO. Assim, os autores demonstraram que essa abordagem integrada é uma solução eficiente para otimização de múltiplos critérios na manufatura.

Li e Tian (2021) propuseram um método de previsão da rugosidade da superfície no fresamento de alta precisão utilizando uma abordagem baseada em otimização por enxame de partículas e máquina de vetor de suporte de mínimos quadrados (PSO-LSSVM). O método desenvolvido utiliza parâmetros de corte padronizados e desgaste da ferramenta como variáveis de entrada, enquanto o algoritmo LSSVM modela a relação entre essas variáveis e a rugosidade da superfície. Para aprimorar a capacidade de generalização do modelo, os hiperparâmetros do LSSVM foram otimizados com um algoritmo PSO aprimorado. A eficácia do modelo PSO-LSSVM foi validada por meio da comparação com métodos convencionais de previsão de rugosidade, incluindo suporte a vetores de máquina (SVM) e método de superfície de resposta (RSM). Os resultados demonstraram que o modelo PSO-LSSVM apresentou os menores erros médios relativos e de raiz quadrática

média, além de um coeficiente de correlação superior, indicando uma maior precisão e capacidade de generalização na previsão da rugosidade superficial.

Xu et al. (2021) propuseram um modelo inteligente baseado no sistema adaptativo de inferência neuro-fuzzy (ANFIS), otimizado por um algoritmo PSO aprimorado, para estimar o desgaste da ferramenta no fresamento do ferro fundido grafite compactado (CGI). Como o PSO convencional pode ficar preso em mínimos locais, os autores introduziram o algoritmo PSO com vibração e comunicação interpartícula (VCPSO) para melhorar a busca global. Além da estimativa do desgaste da ferramenta, o modelo foi empregado na otimização multiobjetivo dos parâmetros de corte, visando minimizar o consumo de energia e a rugosidade da superfície, maximizando a taxa de remoção de material. Os resultados experimentais confirmaram que o modelo ANFIS-VCPSO apresentou desempenho superior na estimativa do desgaste da ferramenta e na otimização dos parâmetros de fresamento, contribuindo para maior eficiência e durabilidade da ferramenta.

Xu et al. (2022) desenvolveram um modelo baseado no sistema adaptativo de inferência neuro-fuzzy (ANFIS) para prever a largura do desgaste da ferramenta e otimizar os parâmetros de corte no processo de fresamento. Para aprimorar o desempenho do ANFIS, foi proposto um novo algoritmo de otimização denominado PSO com vibração aleatória e cruzamento (RV-CPSO). Os autores demonstraram que esse algoritmo superou o PSO convencional e outros métodos evolucionários na busca por soluções globais. A metodologia desenvolvida permitiu uma previsão mais precisa do desgaste da ferramenta e a definição de parâmetros de corte ideais para prolongar a vida útil da ferramenta e melhorar a eficiência do processo de usinagem.

Zhao (2024) investigou a otimização do trajeto de usinagem de impulsores integrais em máquinas CNC, utilizando um algoritmo híbrido de otimização por enxame de partículas e recozimento simulado (SA-PSO). O estudo focou na redução do erro de sobrecorte e subcorte das lâminas do impulsor, melhorando a precisão e a eficiência da usinagem. A pesquisa mostrou que o algoritmo híbrido SA-PSO apresentou um erro estável 30,45% menor em relação ao PSO convencional, além de uma maior convergência na busca do caminho de corte ideal. Os resultados indicam que essa abordagem pode ser aplicada para aprimorar a trajetória das ferramentas CNC, contribuindo para o avanço da manufatura inteligente.

3 METODOLOGIA

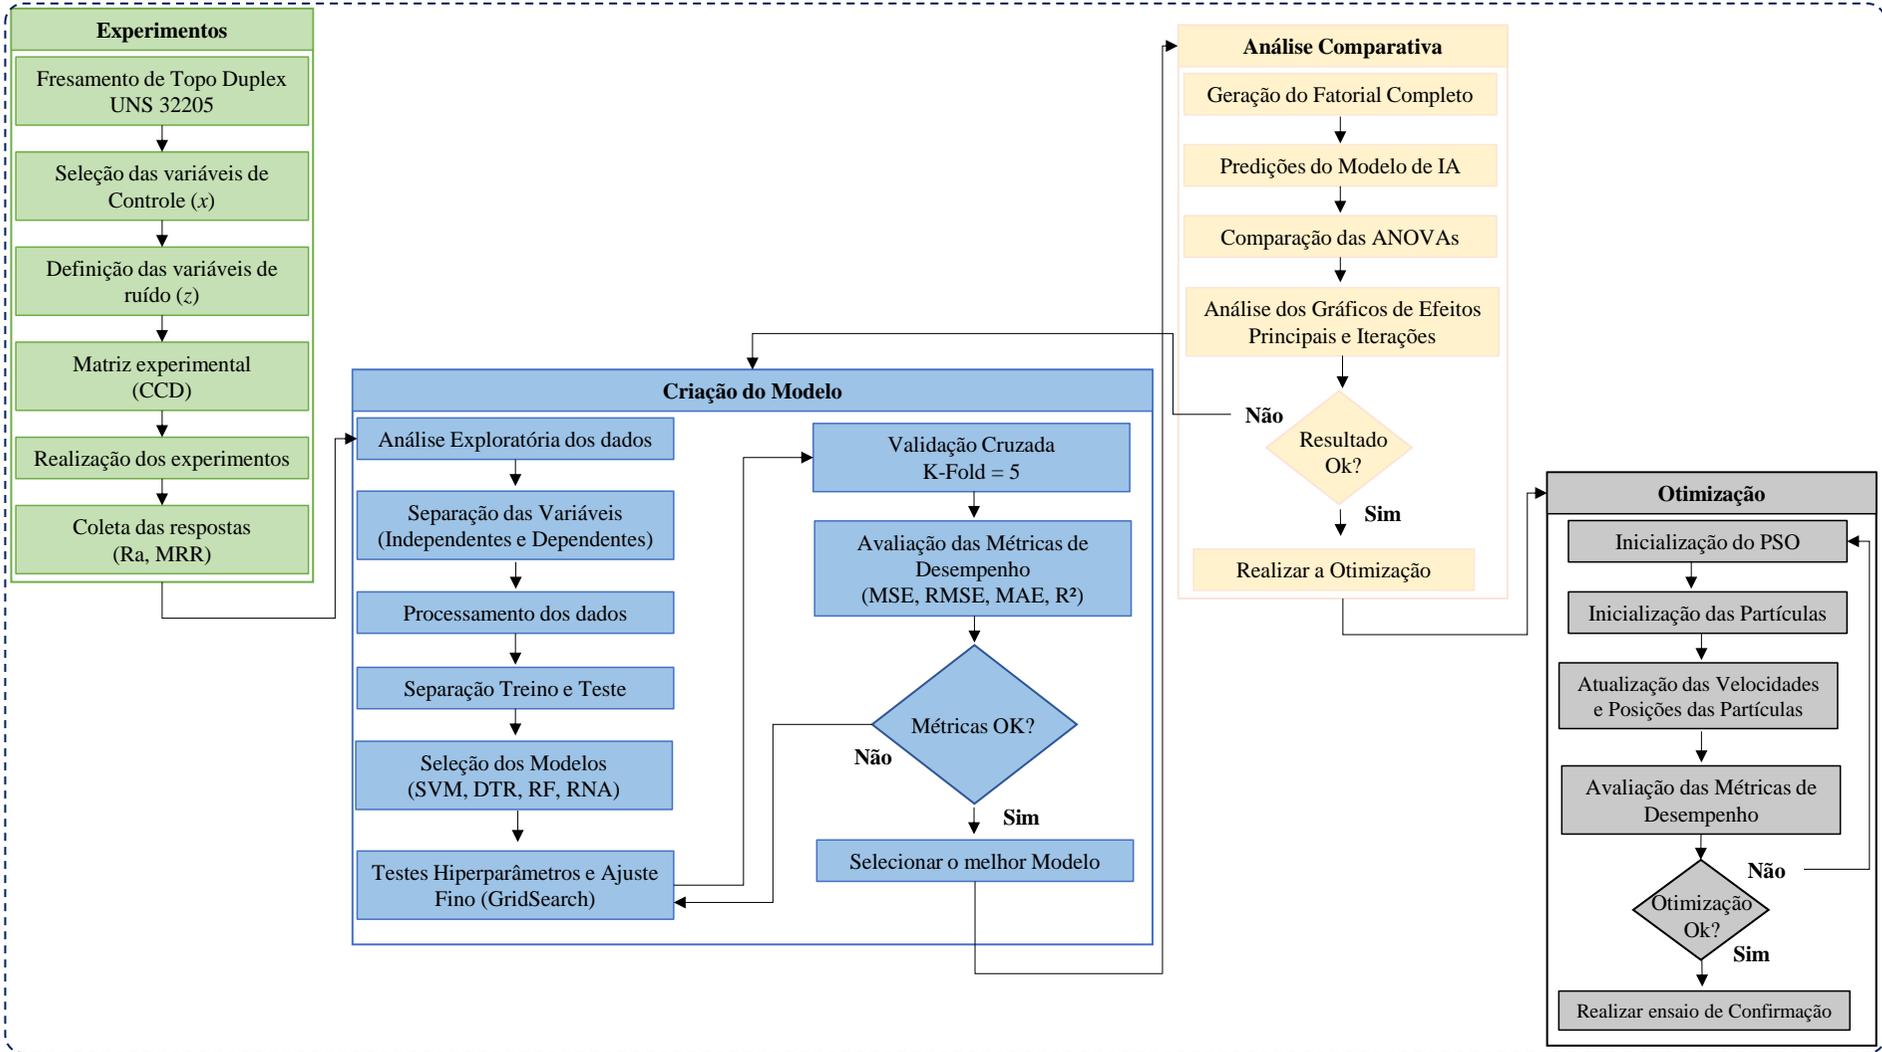
Neste capítulo, são apresentados os materiais e os métodos utilizados para o desenvolvimento deste trabalho, abrangendo desde a seleção das variáveis controláveis e incontrolláveis, com a definição de seus respectivos níveis, até a descrição detalhada das etapas de construção e validação dos modelos de aprendizagem de máquina.

A pesquisa é entendida como um estudo sistemático e organizado sobre um determinado problema ou contexto (PRODANOV; FREITAS, 2013), cabendo ao método de abordagem adotado conferir ao estudo o seu caráter científico. A classificação da pesquisa pode ser estabelecida com base em sua natureza, objetivos, abordagem e procedimentos metodológicos (MIGUEL et al., 2010). No presente estudo, a pesquisa é caracterizada como de natureza aplicada, com objetivos de cunho exploratório e explicativo, empregando uma abordagem quantitativa e o método experimental.

No que tange à natureza, a pesquisa é classificada como aplicada. No âmbito dos objetivos, ela é definida como exploratória, uma vez que busca investigar e mapear o tema na literatura existente, e explicativa, por pretender analisar fenômenos em processos reais, com o intuito de identificar relações entre variáveis e parâmetros, visando à proposição de soluções otimizadas. A abordagem adotada é quantitativa, pois opera com dados numéricos, opiniões e informações que são traduzidos e analisados para a obtenção de conclusões (MIGUEL et al., 2010). Essa abordagem parte de pressupostos teóricos, formula hipóteses, realiza a coleta de dados por meio de observações sistemáticas, analisa os dados coletados e, por fim, gera resultados. No que concerne ao método, a pesquisa fundamenta-se na experimentação. Para tanto, são conduzidos experimentos no processo de fresamento de topo do aço inoxidável duplex UNS S32205.

Para facilitar a compreensão, a Figura 28 apresenta um fluxograma da metodologia adotada, detalhando o fluxo das atividades e etapas desenvolvidas ao longo da pesquisa. Este estudo propõe uma abordagem que integra aprendizagem de máquina e otimização. Conforme ilustrado, são seguidas quatro etapas principais: a primeira refere-se ao processo experimental, a segunda à construção dos modelos de aprendizagem de máquina, a terceira à aplicação e validação desses modelos, e a quarta à otimização.

Figura 28 – Fluxograma geral da metodologia adotada



Fonte: Própria

Os experimentos foram conduzidos no LMAUT (Laboratório de Manufatura e Automação), pertencente ao NOMATI (Núcleo de Otimização da Manufatura e Tecnologia da Inovação) do IEPG (Instituto de Engenharia de Produção e Gestão) da UNIFEI (Universidade Federal de Itajubá).

Na primeira fase, os experimentos foram conduzidos no processo de fresamento de topo utilizando o aço inoxidável duplex UNS S32205. É importante salientar que os dados analisados neste estudo foram coletados em um trabalho colaborativo dos autores (VASCONCELOS, 2022) e (OLIVEIRA et al., 2022). Com o processo definido, as variáveis controláveis (x) e incontroláveis (z) foram determinadas, juntamente com seus respectivos níveis. Esses níveis foram estabelecidos com base em catálogos dos fornecedores, ensaios preliminares conforme OLIVEIRA et al. (2022) e informações encontradas na literatura. As variáveis controláveis selecionadas foram a velocidade de corte (v_c), avanço por dente (f_z), largura de corte (a_e) e profundidade de corte (a_p). As variáveis classificadas como ruído incluíram o desgaste de flanco (v_b), comprimento em balanço da ferramenta lt_0 e vazão de fluido (Q). Já a resposta considerada foi a rugosidade (R_a).

A etapa subsequente consistiu na definição do arranjo experimental. O arranjo combinado foi projetado considerando um CCD (*Central Composite Design* - (Planejamento composto central)) para sete fatores, que combinou as variáveis de controle e de ruído. O CCD utilizado foi um fatorial fracionado de $\frac{1}{2}$, complementado por níveis axiais e pontos centrais, visando à estimativa do erro experimental. Em seguida, os experimentos foram realizados, e as variáveis de resposta foram coletadas. A execução dos experimentos ocorreu de forma aleatória, a fim de minimizar possíveis erros.

A próxima etapa foi a criação dos modelos de aprendizagem de máquina. Esse desenvolvimento seguiu uma série de etapas organizadas e estruturadas, como demonstrado no fluxograma da Figura 28. Todo o desenvolvimento foi feito na linguagem *Python*. A plataforma utilizada foi o *google colab*, devido a sua fácil aplicação e entendimento. As bibliotecas utilizadas foram a *Numpy*, *Skitlearn*, *Seaborn*, *Tensorflow* e o *Pandas*. Para a otimização dos melhores níveis dos hiperparâmetros foi utilizada a função *GridSearch* também foi utilizada para a otimização dos hiperparâmetros. A seleção desses hiperparâmetros e seus níveis foi fundamentada na estrutura base das bibliotecas e em revisões da literatura abordados nos capítulos anteriores.

Inicialmente, realizou-se uma exploração detalhada da base de dados com o objetivo de garantir sua completude e consistência. Essa verificação incluiu a identificação de valores ausentes, dados incompletos e potenciais erros de medição que poderiam comprometer a qualidade das análises subsequentes. A qualidade dos dados é fundamental para a construção de modelos de aprendizado de máquina precisos e confiáveis, pois modelos treinados com dados deficientes tendem a apresentar baixa performance.

Para essa etapa, foram utilizadas as bibliotecas *Pandas* e *NumPy*, amplamente reconhecidas por suas funcionalidades eficazes para manipulação, limpeza e pré-processamento

de grandes volumes de dados. Além da exploração inicial, procedeu-se à detecção e remoção de *outliers* na variável resposta (rugosidade superficial R_a). *Outliers* podem ser causados por erros de medição ou inserção incorreta de dados, e sua presença pode influenciar significativamente o desempenho do modelo, levando a previsões distorcidas ou imprecisas.

O tratamento adequado desses dados contribui para a construção de modelos mais confiáveis, porém é importante destacar que a robustez dos modelos de aprendizado de máquina — ou seja, a capacidade de manter bom desempenho diante de ruídos, *outliers* e pequenas variações nos dados — será analisada e discutida posteriormente no estudo.

Outra análise fundamental conduzida para aprofundar a compreensão da relação entre as variáveis controláveis (x) e as variáveis resposta (y) foi a análise de correlação. Compreender como essas variáveis interagem e influenciam as respostas é crucial para a modelagem preditiva e a inferência estatística. A correlação tem o objetivo de medir o grau e o tipo de associação linear entre as variáveis, sendo que diferentes padrões de correlação indicam distintos níveis de relacionamento entre elas (BENESTY; CHEN; HUANG, 2008). Entre os tipos mais comumente observados, destacam-se:

1. Correlação Positiva: Indica que, à medida que uma variável aumenta, a outra tende a aumentar também, sugerindo uma associação direta.
2. Correlação Negativa: Sugere que, à medida que uma variável aumenta, a outra tende a diminuir, caracterizando uma associação inversa.
3. Correlação Fraca: Refere-se a uma baixa associação linear entre as variáveis, com valores do coeficiente de correlação próximos de zero, implicando pouca ou nenhuma relação significativa.
4. Correlação Forte: Indica um alto grau de associação linear, com valores do coeficiente de correlação próximos de +1 ou -1, evidenciando uma relação direta ou inversa muito clara.

Para quantificar essa associação, utilizou-se o coeficiente de correlação de Pearson. É importante ressaltar que esse coeficiente é sensível à presença de outliers, os quais podem distorcer substancialmente os resultados, comprometendo a validade das conclusões. O valor do coeficiente de Pearson varia entre -1 e 1, representando desde uma correlação negativa perfeita (-1) até uma correlação positiva perfeita (1) (FERTIG; WEIGOLD; CHEN, 2022).

A simplicidade do cálculo e da interpretação do coeficiente de *Pearson*, além da sua capacidade de ser aplicado em diferentes conjuntos de dados para fins de comparação, tornam-no uma ferramenta amplamente utilizada em estudos de correlação. No contexto deste trabalho, sua implementação foi realizada utilizando as bibliotecas *Pandas* e *Seaborn*

no ambiente *Python*, que oferecem funcionalidades robustas para o cálculo e a visualização gráfica das correlações, permitindo uma análise precisa e eficiente.

O passo subsequente no processo de construção do modelo consistiu na normalização dos dados. Esta etapa mostrou-se imprescindível neste estudo, considerando que as variáveis independentes apresentam unidades de medida distintas, decorrentes da natureza multifacetada do processo investigado. Tal discrepância nas escalas poderia comprometer significativamente o desempenho de alguns dos modelos utilizados neste estudo como o SVM, RNA. A normalização, bem como a padronização, são técnicas amplamente adotadas na preparação de dados com o objetivo de ajustar as variáveis a uma escala comum. Embora não sejam invariavelmente mandatórias, sua aplicação pode influenciar de forma substancial a eficiência e a convergência de determinados algoritmos (LI; LIN, 2023).

No presente estudo, optou-se pela padronização dos dados, a qual foi implementada utilizando a biblioteca *Sklearn*. Esse procedimento envolve a subtração da média de cada valor da variável e a subsequente divisão pelo desvio padrão, conforme a Equação 3.1. Tal abordagem assegura que os dados transformados possuam média 0 e desvio padrão 1, eliminando possíveis impactos negativos causados por variáveis com escalas significativamente discrepantes. Essa padronização é particularmente importante para preservar a integridade do processo de aprendizado e maximizar o desempenho dos modelos preditivos.

$$z = \frac{x - \mu}{\sigma} \quad (3.1)$$

Na sequência o conjunto de dados foi dividido em dados de treinamento, teste e validação. A divisão foi feita de forma estratificada, preservando a distribuição das variáveis de resposta em todos os conjuntos, com o objetivo de minimizar possíveis vieses de amostragem. Embora a literatura recomende uma divisão de 70% dos dados para treinamento e 30% para teste, neste estudo foram avaliadas diferentes proporções para otimizar o desenvolvimento dos modelos. Para os modelos SVM, DTR e RF, utilizou-se uma divisão de 90% dos dados para treinamento e 10% para teste, pois, devido ao tamanho reduzido do conjunto de dados, a proporção sugerida pela literatura não permitia o ajuste adequado dos modelos. No caso das redes neurais artificiais, a configuração que apresentou os melhores resultados foi a divisão de 70% para treinamento e 30% para teste. Essa proporção se mostrou adequada especificamente neste estudo, diante das características do conjunto de dados e do comportamento da rede durante o treinamento.

Após a preparação adequada dos dados, diversos algoritmos de aprendizado supervisionado foram avaliados para o desenvolvimento do modelo de Inteligência Artificial (IA). Entre os métodos avaliados, destacaram-se as Redes Neurais Artificiais (RNA), Florestas Aleatórias (RF), Árvores de Decisão (CART/DTR) e Máquinas de Vetores de Suporte (SVM), todos amplamente reconhecidos por sua capacidade de lidar com problemas de regressão e classificação em domínios complexos.

A implementação dos modelos SVM, DTR e RF foi realizada utilizando as bibliotecas padrão do *Python*, como *scikit-learn*, amplamente utilizadas para algoritmos de aprendizado supervisionado. No caso específico das Redes Neurais Artificiais, a construção dos modelos foi realizada por meio da biblioteca *TensorFlow*. Foram desenvolvidas oito arquiteturas distintas de redes neurais do tipo MLP (perceptron multicamada), com o objetivo de identificar aquela que apresentasse o melhor desempenho preditivo. Esse procedimento foi conduzido com base no trabalho de (ZAIN; HARON; SHARIF, 2010), que serviu como referência para a construção das arquiteturas.

A otimização dos hiperparâmetros, etapa crucial para o desempenho dos modelos, foi realizada utilizando a técnica do *Gridsearch*. A escolha do *GridSearch* justifica-se por sua capacidade de explorar sistematicamente uma grade de combinações de parâmetros, identificando de forma eficiente as melhores configurações para cada modelo, conforme apontado por (INJADAT et al., 2020).

A validação cruzada foi incorporada ao processo com o objetivo de avaliar a capacidade de generalização dos modelos. Na literatura, o valor de k mais comumente adotado no método de validação cruzada k -fold é $k = 10$. No entanto, devido ao tamanho relativamente reduzido da base de dados neste estudo, optou-se por utilizar $k = 5$. Nesse procedimento, os dados foram divididos em cinco partes, sendo que, a cada iteração, uma parte foi utilizada para validação e as quatro restantes para treinamento. Essa abordagem contribui para uma avaliação mais realista do desempenho dos modelos, reduzindo o risco de *overfitting*, ou seja, a tendência de um modelo se ajustar excessivamente aos dados de treinamento, comprometendo sua performance em dados novos.

A seleção do modelo com o melhor desempenho foi realizada com base em métricas de avaliação específicas, conforme descrito nas Equações 2.30, 2.31, 2.32 e 2.33. De acordo com a literatura, o modelo ideal é definido quando o erro quadrático médio (RMSE) é minimizado e o coeficiente de determinação R^2 é maximizado. Assim, a escolha do modelo com a melhor performance envolveu a identificação do menor RMSE e do maior R^2 , refletindo a precisão do modelo em relação aos dados analisados. Para avaliar a normalidade dos resíduos utilizou-se o teste de Shapiro-Wilk, amplamente reconhecido como um dos métodos mais eficazes para verificar a normalidade.

A etapa mais fundamental deste trabalho consistiu na validação do modelo de aprendizado de máquina desenvolvido. Para isso, foi gerado um planejamento fatorial completo, considerando todas as combinações possíveis dos fatores experimentais com o objetivo de avaliar o comportamento da variável resposta rugosidade superficial (R_a). Todas as respostas correspondentes a esse planejamento foram geradas por meio do modelo preditivo de melhor desempenho, treinado com os dados reais obtidos em bancada. Ou seja, o modelo foi utilizado como função geradora de resposta para o planejamento experimental, substituindo experimentos físicos. Com base nessas respostas previstas, foi realizada uma análise estatística completa, incluindo a comparação entre as análises de variância

(ANOVA) provenientes dos dados experimentais e daquelas estimadas pelo modelo. Essa comparação teve como propósito avaliar a capacidade do modelo não apenas de prever os valores de R_a com acurácia, mas também de capturar os efeitos principais e as interações entre os parâmetros controláveis e incontroláveis, assim como sua significância estatística. Além disso, foram construídas representações gráficas — como gráficos de efeitos principais, interações e superfícies de resposta — para permitir uma visualização clara e interpretativa da influência individual e combinada dos fatores sobre a rugosidade. Essa abordagem reforça a análise quantitativa, evidenciando se o modelo é capaz de simular adequadamente o comportamento do processo de fresamento em condições realistas.

Por fim, a otimização do processo foi conduzida por meio do algoritmo *Particle Swarm Optimization* (PSO), seguindo uma sequência estruturada de etapas. Primeiramente, definiu-se a configuração inicial do algoritmo, incluindo o número de partículas, os coeficientes de aceleração e os limites do espaço de busca. Em seguida, as partículas foram inicializadas com posições e velocidades aleatórias dentro do espaço multidimensional. A partir dessa preparação, o PSO iniciou seu ciclo iterativo de busca por soluções. A cada iteração, as velocidades e posições das partículas foram atualizadas com base em dois componentes: a melhor posição já encontrada individualmente por cada partícula e a melhor posição global encontrada pelo grupo. Essa estratégia permite uma busca cooperativa e adaptativa por melhores soluções. As posições atualizadas foram avaliadas por meio de uma função objetivo baseada no modelo de regressão obtido via análise de variância (ANOVA) para a rugosidade superficial R_a . Esse modelo serviu como base para estimar a qualidade das soluções, garantindo que a otimização estivesse alinhada com os efeitos estatisticamente significativos identificados no planejamento experimental. O algoritmo foi executado até que um critério de parada fosse atingido, como o número máximo de iterações ou a estabilização dos resultados. Ao final, realizou-se um ensaio de confirmação para validar a eficácia da solução proposta pelo PSO, comprovando sua viabilidade prática no contexto do fresamento do aço inoxidável duplex.

3.1 Equipamentos e Materiais

Os ensaios para o levantamento da base de dados foram conduzidos utilizando um centro de usinagem vertical ROMI D 600. O equipamento possui um curso longitudinal (eixo X) de 600 mm, curso transversal (eixo Y) de 530 mm e um curso vertical do cabeçote (eixo Z) de 600 mm. O cabeçote é equipado com um cone ISO 40 no eixo-árvore, permitindo um avanço rápido de até 30 m/min em todos os três eixos de programação (X, Y e Z). A potência máxima do eixo-árvore é de 15 kW, com uma rotação máxima de 10.000 rpm. O sistema de controle numérico utilizado foi o FANUC 0i-MD, conforme ilustrado na Figura 29.

Figura 29 – Centro de Usinagem Vertical ROMI D 600

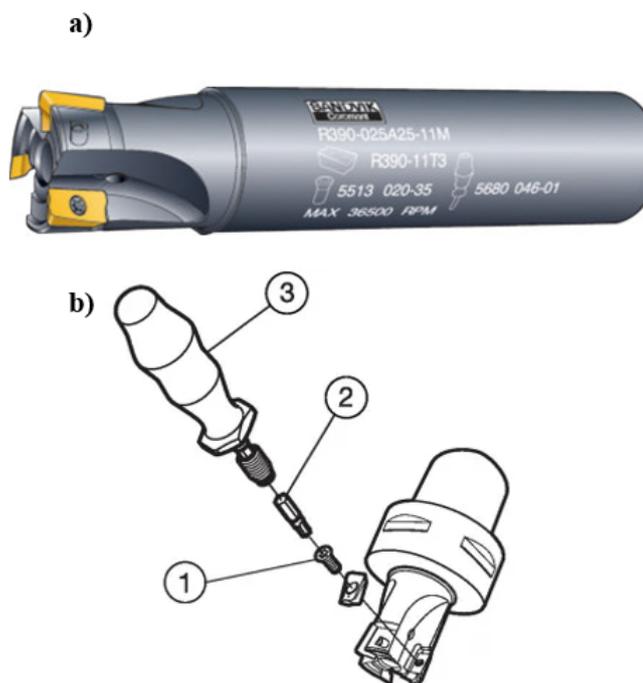


Fonte: Própria

Para realizar a operação de fresamento foi utilizada a fresa CoroMill® *R390-025A25-11M* (*Sandvik Coromant*), com diâmetro de 25 mm, ângulo de posição $\chi_r = 90^\circ$, haste cilíndrica e passo médio com três insertos, fixados mecanicamente por pinça. A ferramenta empregada durante os ensaios pode ser visualizada na Figura 30.

Assumiu-se que o processo de fresamento foi conduzido sob condições constantes, ou seja, que o batimento axial da ferramenta manteve-se constante e desprezível para os fins da análise. Além disso, considerou-se que todas as trocas de insertos foram realizadas corretamente, garantindo que o sistema de fixação e a geometria da ferramenta permanecessem inalterados ao longo dos ensaios.

Figura 30 – Porta Ferramentas: a) Suporte montado; b) Sistema de fixação dos insertos



Fonte: Própria

O inserto utilizado nos experimentos foi o CoroMill R390-11T308M-MM GC 2030 (*Sandvik Coromant*), fabricado em metal duro e revestido com dupla camada de nitreto de titânio (TiN) e nitreto de titânio alumínio ($TiAlN$), aplicados por deposição física de vapor (PVD). Suas dimensões incluem: largura de 6,8 mm (W_1), comprimento efetivo da aresta de corte de 10 mm (L_E), raio de canto de 0,8 mm (R_E), comprimento da aresta alisadora de 1,2 mm (B_S), espessura de 3,59 mm (S), e duas arestas de corte. A escolha desse inserto foi embasada em recomendações da literatura, como as de Sahoo et al. (2020) e Sousa et al. (2023), que destacam a eficácia do revestimento de $TiAlN$ no fresamento de aços de baixa condutividade térmica, devido à sua alta resistência ao desgaste, especialmente em materiais com alto encruamento. O uso adequado desses insertos é essencial para otimizar a qualidade superficial da peça usinada, aumentar a produtividade e reduzir os custos do processo, conforme ilustrado na Figura 31.

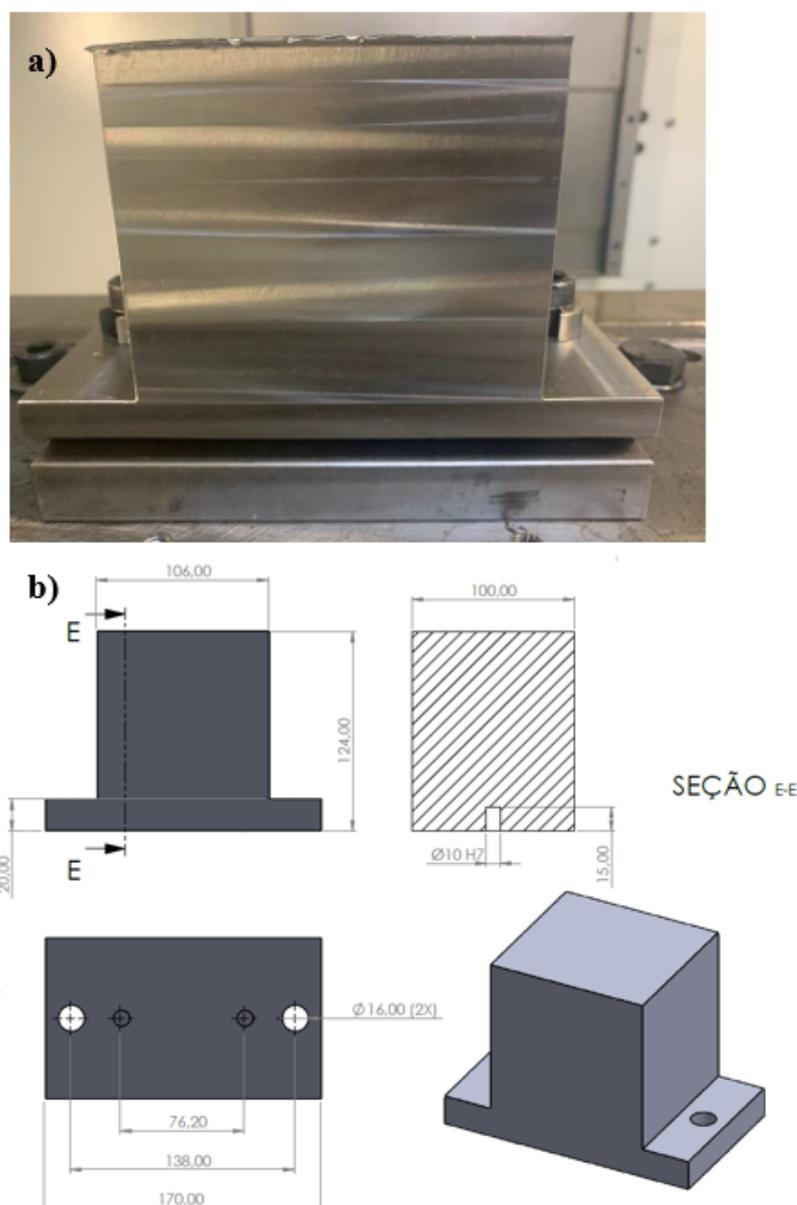
Figura 31 – Inserto de metal duro R390-11T308M-MM 2030



Fonte: Própria

O corpo de prova utilizado nos experimentos foi o inoxidável duplex UNS S32205, com dureza de 250 HB, em uma seção retangular com dimensões de $106 \times 100 \times 120 \text{ mm}$, conforme mostrado na Figura 32a. A Figura 32b apresenta um detalhamento adicional do corpo de prova.

Figura 32 – Material: a)Aço Inoxidável Duplex UNS S32205; b)Detalhamento dimensional



Fonte: Própria

A Tabela 4 descreve a composição química do aço inoxidável duplex UNS S32205, que contém elementos como carbono, silício, manganês, cromo, molibdênio e níquel. Esse tipo de aço é caracterizado por uma microestrutura que combina ferrita e austenita em proporções volumétricas equilibradas (BERGUIGA; BOUMERZOUG, 2019). A fase austenítica confere ao material maior ductilidade, tenacidade e soldabilidade, enquanto a fase ferrítica oferece alta resistência à corrosão sob tensão (MAVI, 2020).

Tabela 4 – Composição química do Aço Inoxidável Duplex UNS S32205

C	S_i	M_n	P	S	N	A_l	C_r	M_o	N_i	C_u	W	C_o
0,013	0,47	1,22	0,019	0,010	0,19	0,008	22,24	3,14	5,62	0,19	0,02	0,05

Fonte: Própria

3.2 Procedimento Experimental

As variáveis controláveis (x) selecionadas foram aquelas diretamente relacionadas ao processo de fresamento, como a velocidade de corte v_c (m/min), o avanço por dente f_z (mm/dente), a largura fresada a_e (mm) e a profundidade de corte a_p (mm). Adicionalmente, foram consideradas como variáveis de ruído (z) fatores que podem influenciar o processo de maneira não controlada. Entre esses, destaca-se o desgaste de flanco v_b (mm), que, segundo Arruda et al. (2019), ocorre de forma contínua e gradual durante o corte, sem depender da intervenção do engenheiro de processo. Esse fenômeno afeta diretamente a produtividade e a rugosidade das peças usinadas.

Outro fator de ruído considerado foi o comprimento em balanço da ferramenta (*tool overhang length* – lt_0), que pode impactar a estabilidade do processo, os esforços de corte, a deflexão da ferramenta, as tolerâncias dimensionais e o acabamento superficial. Por fim, a vazão de fluido (Q) também foi incluída como variável de ruído. Embora seja uma variável controlável, a literatura indica que garantir sua efetiva influência na região de corte pode ser complexo, pois não é possível assegurar que a ponta do inserto de corte receba a quantidade adequada de fluido para um resfriamento eficiente. Os níveis das variáveis de controle (x) e de ruído (z) são apresentados na tabela 5 e 6.

Tabela 5 – Níveis para as variáveis controláveis

Variáveis de controle	-2,83	-1,00	0,00	+1,00	+2,83
v_c - Velocidade de corte [m/min]	32,57	60,00	75,00	90,00	117,43
f_z - Avanço por dente [mm/dente]	0,04	0,10	0,13	0,16	0,21
a_e - Largura fresada [mm]	12,26	15,00	16,50	18,00	20,74
a_p - Profundidade de corte [mm]	0,43	0,80	1,00	1,20	1,57

Fonte: Própria

Tabela 6 – Níveis para as variáveis de ruído

Variáveis de ruído	-1	0	1
v_b - Desgaste do flanco [mm]	0	0,15	0,30
Q - Vazão de fluido [l/min]	0	0,20	20
lt_0 - Comprimento em balanço [mm]	30	40	50

Fonte: Própria

Os ruídos são fatores que não podem ser controlados diretamente, tampouco sua influência sobre as respostas do processo pode ser completamente eliminada. Contudo, é possível controlá-los experimentalmente, permitindo que sejam incorporados de maneira mais realista no planejamento dos experimentos, garantindo assim uma simulação mais precisa do comportamento do processo.

Nesse contexto, o controle do desgaste de flanco v_b foi realizado utilizando o analisador de imagens (*Global Image Analyzer*), o software Global Lab 97 Image e um microscópio

estereoscópico modelo SZ 61, com ampliação de 45 vezes foi utilizado após cada execução de uma linha da matriz experimental. A Figura 33 ilustra o microscópio utilizado nesse processo.

Importante destacar que os desgastes foram gerados de forma proposital, seguindo um procedimento controlado para garantir as condições desejadas. Para o desgaste inicial de $0,15 \mu m$, utilizou-se um inserto novo que foi previamente submetido à usinagem de um material adjacente ao material experimental, até atingir a condição estabelecida de desgaste. Já para o desgaste de flanco de $0,30 \mu m$, empregaram-se os insertos previamente desgastados a $0,15 \mu m$, os quais continuaram a ser usados até alcançar o valor de desgaste de $0,30 \mu m$, com a confirmação do estado do desgaste realizada por meio do microscópio estereoscópico.

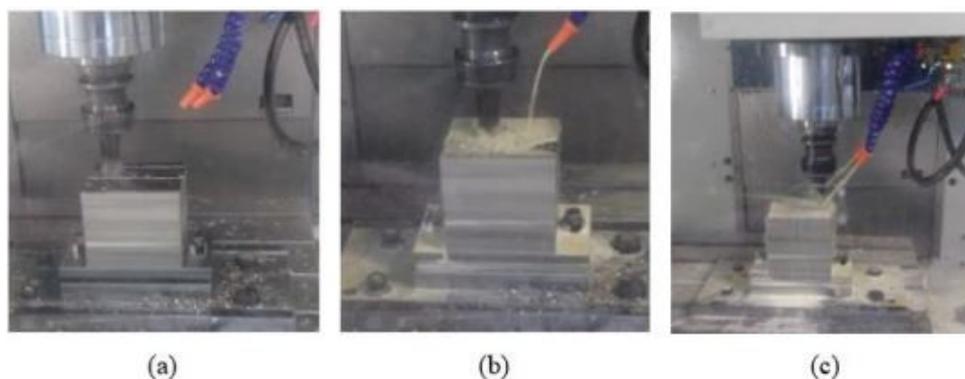
Figura 33 – Microscópio estereoscópico utilizado na medição do desgaste de flanco



Fonte: Própria

O controle da vazão de fluido (Q) foi realizado por meio das válvulas de regulagem presentes na máquina CNC, conforme mostrado na Figura 34. Para atingir a menor vazão, ajustou-se uma leve abertura na válvula 1, sendo a quantidade de fluido medida com um Becker graduado. No caso da vazão máxima, ambas as válvulas foram completamente abertas. Já para a usinagem a seco, as válvulas foram fechadas, impedindo o fluxo de fluido para a região de corte.

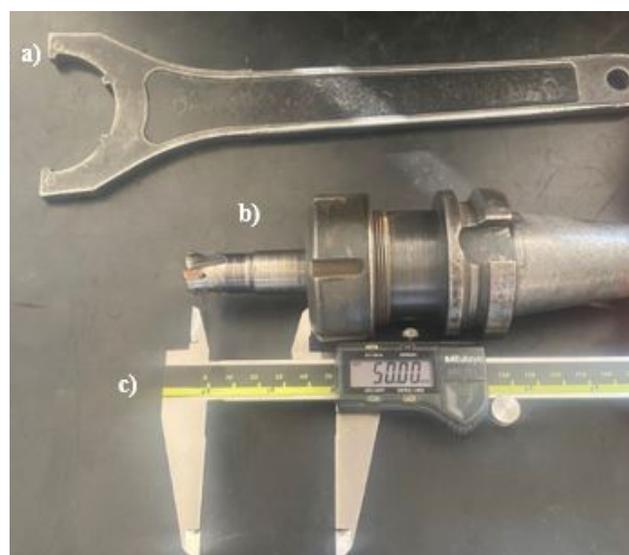
Figura 34 – Controle da vazão: a) Sem fluido; b) Média vazão; c) Máxima vazão



Fonte: Vasconcelos (2022), OLIVEIRA et al. (2022)

O controle do comprimento em balanço foi realizado por meio do sistema de fixação ISO BT40, composto por pinça, cone, porca de aperto e chave de aperto. Esse sistema foi ajustado de acordo com as condições previamente estabelecidas no planejamento dos experimentos. O comprimento efetivo do balanço foi medido com o auxílio de um paquímetro. A Figura 35 ilustra os componentes para o controle do comprimento em balanço.

Figura 35 – Controle do balanço: a) Chave; b) Ferramenta de corte; c) Paquímetro



Fonte: Própria

A resposta analisada neste estudo foi a rugosidade superficial R_a . A rugosidade foi medida com um rugosímetro portátil Mitutoyo SurfTest 201, previamente aferido e calibrado antes das medições, conforme Figura 36. O parâmetro de cut-off foi fixado em 0,8 mm em todas as medições. A rugosidade foi coletada após cada passe realizado pela ferramenta no início do corte, no meio e no final. Foram realizadas 3 medições e considerada a média entre elas. A Figura 37 apresenta o sistema das medições.

Figura 36 – Equipamentos de medição da rugosidade



Fonte: Própria

Figura 37 – Sistema de Medição de Rugosidade



Fonte: OLIVEIRA et al. (2022)

3.3 Criação da Base de Dados

Para a construção da base de dados, foi utilizado um arranjo composto central (CCD) com sete fatores, conforme mostrado na Tabela 7. O projeto fatorial foi uma meia fração, onde os pontos fatoriais são dados por $(2^k = 2^{k-1} = 2^6 = 64)$. Os pontos axiais são: $(2^k = 2 \times 7 = 14)$. No entanto, como as variáveis de ruído não são testadas nos níveis axiais, o arranjo final para cada geometria é composto por apenas 8 pontos. Por fim, os pontos

centrais foram $n_c = 10$, totalizando 82 experimentos. O valor da região experimental para a distância axial ou raio foi $\alpha = 2,83$.

Tabela 7 – Planejamento Experimental - Base de Dados

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
1	60,00	0,10	15,00	0,80	0,00	0,00	50,00	0,520
2	90,00	0,10	15,00	0,80	0,00	0,00	30,00	0,347
3	60,00	0,16	15,00	0,80	0,00	0,00	30,00	0,630
4	90,00	0,16	15,00	0,80	0,00	0,00	50,00	0,717
5	60,00	0,10	18,00	0,80	0,00	0,00	30,00	0,503
6	90,00	0,10	18,00	0,80	0,00	0,00	50,00	0,360
7	60,00	0,16	18,00	0,80	0,00	0,00	50,00	0,657
8	90,00	0,16	18,00	0,80	0,00	0,00	30,00	0,747
9	60,00	0,10	15,00	1,20	0,00	0,00	30,00	0,503
10	90,00	0,10	15,00	1,20	0,00	0,00	50,00	0,30
11	60,00	0,16	15,00	1,20	0,00	0,00	50,00	0,653
12	90,00	0,16	15,00	1,20	0,00	0,00	30,00	0,700
13	60,00	0,10	18,00	1,20	0,00	0,00	50,00	0,487
14	90,00	0,10	18,00	1,20	0,00	0,00	30,00	0,317
15	60,00	0,16	18,00	1,20	0,00	0,00	30,00	0,653
16	90,00	0,16	18,00	1,20	0,00	0,00	50,00	0,737
17	60,00	0,10	15,00	0,80	0,30	0,00	30,00	0,837
18	90,00	0,10	15,00	0,80	0,30	0,00	50,00	0,867
19	60,00	0,16	15,00	0,80	0,30	0,00	50,00	0,637
20	90,00	0,16	15,00	0,80	0,30	0,00	30,00	0,960
21	60,00	0,10	18,00	0,80	0,30	0,00	50,00	0,930
22	90,00	0,10	18,00	0,80	0,30	0,00	30,00	0,813
23	60,00	0,16	18,00	0,80	0,30	0,00	30,00	0,667
24	90,00	0,16	18,00	0,80	0,30	0,00	50,00	1,003
25	60,00	0,10	15,00	1,20	0,30	0,00	50,00	0,958
26	90,00	0,10	15,00	1,20	0,30	0,00	30,00	0,858
27	60,00	0,16	15,00	1,20	0,30	0,00	30,00	0,683
28	90,00	0,16	15,00	1,20	0,30	0,00	50,00	1,033
29	60,00	0,10	18,00	1,20	0,30	0,00	30,00	0,971
30	90,00	0,10	18,00	1,20	0,30	0,00	50,00	0,719
31	60,00	0,16	18,00	1,20	0,30	0,00	50,00	0,670
32	90,00	0,16	18,00	1,20	0,30	0,00	30,00	1,097

Continua na próxima página

Tabela 7 -Planejamento Experimental - Base de Dados - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
33	60,00	0,10	15,00	0,80	0,00	20,00	30,00	0,453
34	90,00	0,10	15,00	0,80	0,00	20,00	50,00	0,277
35	60,00	0,16	15,00	0,80	0,00	20,00	50,00	0,570
36	90,00	0,16	15,00	0,80	0,00	20,00	30,00	0,630
37	60,00	0,10	18,00	0,80	0,00	20,00	50,00	0,403
38	90,00	0,10	18,00	0,80	0,00	20,00	30,00	0,270
39	60,00	0,16	18,00	0,80	0,00	20,00	30,00	0,487
40	90,00	0,16	18,00	0,80	0,00	20,00	50,00	0,657
41	60,00	0,10	15,00	1,20	0,00	20,00	50,00	0,440
42	90,00	0,10	15,00	1,20	0,00	20,00	30,00	0,287
43	60,00	0,16	15,00	1,20	0,00	20,00	30,00	0,523
44	90,00	0,16	15,00	1,20	0,00	20,00	50,00	0,693
45	60,00	0,10	18,00	1,20	0,00	20,00	30,00	0,430
46	90,00	0,10	18,00	1,20	0,00	20,00	50,00	0,243
47	60,00	0,16	18,00	1,20	0,00	20,00	50,00	0,540
48	90,00	0,16	18,00	1,20	0,00	20,00	30,00	0,667
49	60,00	0,10	15,00	0,80	0,30	20,00	50,00	0,716
50	90,00	0,10	15,00	0,80	0,30	20,00	30,00	0,707
51	60,00	0,16	15,00	0,80	0,30	20,00	30,00	0,447
52	90,00	0,16	15,00	0,80	0,30	20,00	50,00	0,840
53	60,00	0,10	18,00	0,80	0,30	20,00	30,00	0,820
54	90,00	0,10	18,00	0,80	0,30	20,00	50,00	0,773
55	60,00	0,16	18,00	0,80	0,30	20,00	50,00	0,510
56	90,00	0,16	18,00	0,80	0,30	20,00	30,00	0,800
57	60,00	0,10	15,00	1,20	0,30	20,00	30,00	0,823
58	90,00	0,10	15,00	1,20	0,30	20,00	50,00	0,723
59	60,00	0,16	15,00	1,20	0,30	20,00	50,00	0,593
60	90,00	0,16	15,00	1,20	0,30	20,00	30,00	0,830
61	60,00	0,10	18,00	1,20	0,30	20,00	50,00	0,873
62	90,00	0,10	18,00	1,20	0,30	20,00	30,00	0,603
63	60,00	0,16	18,00	1,20	0,30	20,00	30,00	0,620
64	90,00	0,16	18,00	1,20	0,30	20,00	50,00	0,870
65	32,57	0,13	16,50	1,00	0,15	0,20	40,00	0,754
66	117,43	0,13	16,50	1,00	0,15	0,20	40,00	0,767
67	75,00	0,05	16,50	1,00	0,15	0,20	40,00	0,692

Continua na próxima página

Tabela 7 -Planejamento Experimental - Base de Dados - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
68	75,00	0,21	16,50	1,00	0,15	0,20	40,00	1,071
69	75,00	0,13	12,26	1,00	0,15	0,20	40,00	0,933
70	75,00	0,13	20,74	1,00	0,15	0,20	40,00	0,940
71	75,00	0,13	16,50	0,43	0,15	0,20	40,00	0,743
72	75,00	0,13	16,50	1,57	0,15	0,20	40,00	0,784
73	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,530
74	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,393
75	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,413
76	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,393
77	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,387
78	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,393
79	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,413
80	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,380
81	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,340
82	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,397

Fonte: Própria.

4 RESULTADOS E DISCUSSÃO

Neste capítulo, são apresentados os resultados da criação dos algoritmos de aprendizagem de máquina aplicados ao processo de fresamento de topo do aço inoxidável duplex. Em seguida, as etapas propostas no fluxograma da Figura 28 serão detalhadamente seguidas.

4.1 Análise Exploratória

As etapas descritas nos tópicos seguintes têm como objetivo definir a sequência de preparação dos dados para alimentar os modelos de regressão.

4.1.1 Limpeza dos Dados

O objetivo desta etapa é realizar uma avaliação do conjunto de dados antes de qualquer tipo de inferência. Para isso, foi conduzida uma análise dos dados obtidos a partir do planejamento dos experimentos, com o intuito de identificar e corrigir possíveis problemas de qualidade que possam comprometer o desempenho dos modelos de previsão e, conseqüentemente, afetar o processo de análise e seus resultados.

A Tabela 8 apresenta um resumo das colunas do conjunto de dados, incluindo o nome de cada variável, a quantidade de valores não nulos e o tipo de dado. Observa-se que o conjunto de dados possui 82 registros em todas as variáveis, sem valores ausentes (*non-null*), garantindo a integridade dos dados para a modelagem. Todas as variáveis são do tipo *float64* o que indica que representam valores numéricos contínuos, essenciais para a análise e previsão de valores contínuos no estudo.

Dessa forma, observa-se que a base de dados está completa e isenta de valores nulos, assegurando que o processo de análise e a construção dos modelos de previsão não serão comprometidos por problemas relacionados à qualidade dos dados. Essa verificação preliminar é crucial para garantir a robustez e a confiabilidade das etapas subsequentes de análise.

Tabela 8 – Resumo das colunas do DataFrame

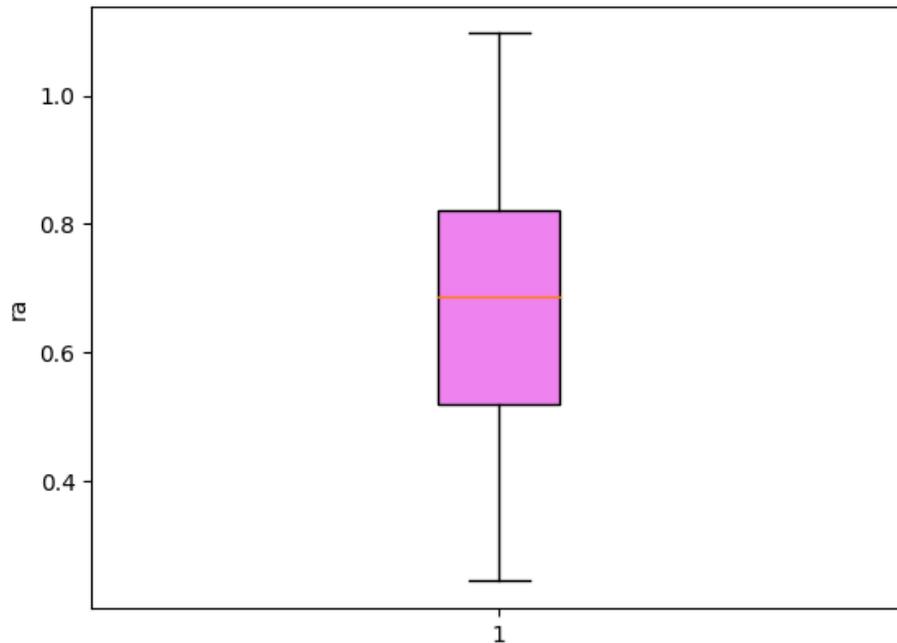
Id	Column	Non-Null Count	Dtype
0	v_c	82 non-null	float64
1	f_z	82 non-null	float64
2	a_e	82 non-null	float64
3	a_p	82 non-null	float64
4	v_b	82 non-null	float64
5	Q	82 non-null	float64
6	lt_0	82 non-null	float64
7	R_a	82 non-null	float64

Fonte: Própria

4.1.2 Análise de Outliers

O *box plot*, introduzido pelo estatístico americano John Tukey em 1977, é uma forma gráfica de representar a distribuição de uma variável quantitativa com base em seus principais parâmetros. A construção do *box plot* leva em consideração os quartis e os limites da distribuição, proporcionando uma visualização clara do posicionamento dos dados na escala da variável. A análise de *outliers* em dados obtidos por meio de um DOE é altamente recomendada, mesmo quando a coleta segue um protocolo rigoroso e sistemático (TRAINI et al., 2019). Embora a base de dados derive de um planejamento experimental bem estruturado, o processo de coleta e registro está sujeito a várias fontes de erro, como configurações incorretas no *setup* da máquina, erros de digitação e imprecisões nas medições. Assim, a detecção de outliers torna-se essencial para garantir a integridade e a confiabilidade dos dados, assegurando a precisão das análises subsequentes.

A Figura 38 apresenta a distribuição da variável resposta R_a associada à rugosidade superficial. Nota-se que a mediana, indicada pela linha vermelha, encontra-se centralizada dentro da caixa, evidenciando uma distribuição simétrica dos valores de R_a . A caixa delimita a amplitude interquartil (IQR), que abrange os dados situados entre o primeiro quartil (Q1) e o terceiro quartil (Q3), onde estão concentrados 50% dos valores observados. Além disso, os bigodes, que representam os limites superiores e inferiores, se estendem até os valores mínimo e máximo situados dentro de 1,5 vezes o IQR, sem a presença de pontos fora desses limites. Isso indica a ausência de outliers na variável analisada. A análise reforça a consistência e a confiabilidade dos dados, sugerindo que as medições foram realizadas de forma precisa e sem indícios de erros experimentais relevantes.

Figura 38 – Análise de *Outliers* - Rugosidade R_a 

Fonte: Própria

4.1.3 Análise de Correlação

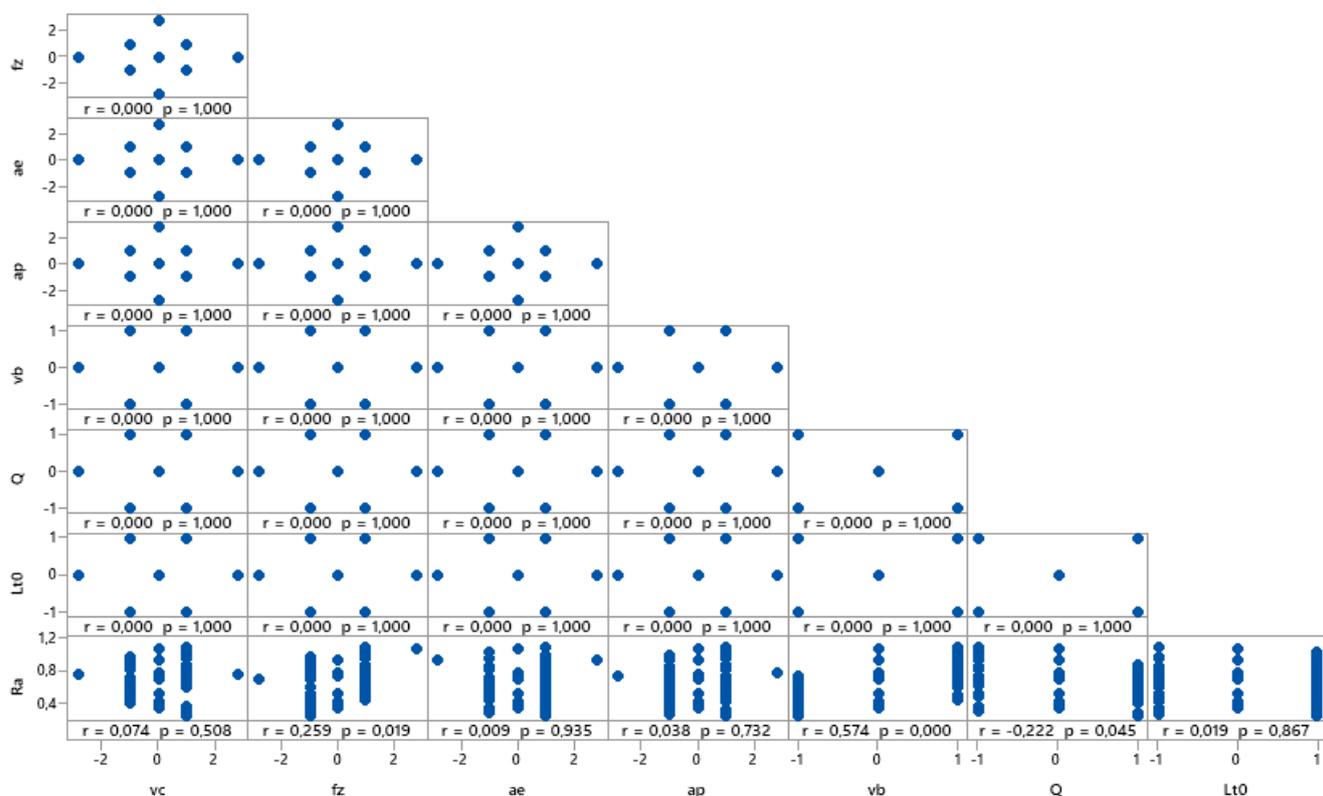
A Figura 39 apresenta a correlação de Pearson da rugosidade (R_a) em relação as variáveis controláveis (x) e incontroláveis (z). O resultado mostra que a variável com a maior correlação positiva com a rugosidade é o desgaste de flanco (v_b). Isso indica que, com o aumento do desgaste de flanco, a aresta de corte da ferramenta se danifica ou se desgasta, resultando em menor eficiência de corte, com a ferramenta falhando em cortar o material corretamente, o que leva a uma superfície usinada menos uniforme e mais áspera. Esse resultado está em conformidade com a literatura, que também destaca o desgaste de flanco como um dos principais fatores que influenciam negativamente a rugosidade da superfície.

Em seguida, a variável que apresenta a segunda maior correlação com a rugosidade é o avanço por dente (f_z), novamente indicando uma relação positiva. Isso pode ser explicado pelo fato de que, quando o avanço aumenta, uma carga maior é aplicada à ferramenta de corte, especialmente ao usinar materiais com baixa condutividade térmica. Essa carga adicional pode causar vibrações e deformações na ferramenta, resultando em imperfeições na superfície usinada e, conseqüentemente, maior rugosidade. Além disso, o aumento no avanço também eleva a rugosidade devido ao maior avanço da ferramenta, resultando em maiores marcas na superfície usinada, o que contribui para uma textura mais áspera.

De forma semelhante, as outras variáveis, como velocidade de corte (c_c), profundidade de corte (a_p), altura em balanço (lt_0) e largura fresada (a_e), também mostram algum grau de correlação com a rugosidade, mas em intensidades menores. Contudo, como todas as

variáveis são importantes pro processo, todas serão consideradas para a criação do modelo.

Figura 39 – Correlação de Pearson R_a



Fonte: Própia

4.1.4 Pré Processamento

Após a conclusão das análises exploratórias, foi realizada a separação do banco de dados em variáveis preditoras e variáveis alvo, ou variáveis independentes e dependentes. Essa separação é fundamental para o desenvolvimento dos modelos de predição, permitindo que as variáveis preditoras sejam utilizadas como entradas nos algoritmos de aprendizado de máquina, enquanto as variáveis alvo servem para avaliar a precisão e a eficiência das previsões geradas.

As variáveis preditoras selecionadas foram: velocidade de corte (v_c), avanço por dente (f_z), largura de corte (a_e), profundidade de corte (a_p), desgaste de flanco (v_b), comprimento em balanço da ferramenta (lt_0) e vazão de fluido (Q). E a variável alvo foi a rugosidade superficial (R_a). Após a separação das variáveis, procedeu-se com a padronização das variáveis preditoras. O objetivo desse processo foi ajustar todas as variáveis à mesma escala, visando aumentar a precisão dos modelos de predição. Embora os modelos baseados em árvores de decisão não necessitem de normalização, uma vez que são capazes de lidar eficientemente com dados em escalas diferentes, optou-se por padronizar todas as variáveis. Essa decisão foi tomada para garantir uniformidade no processo de treinamento e teste, além de facilitar a comparação entre os diferentes modelos utilizados.

Dessa forma, buscou-se assegurar que todos os modelos fossem avaliados sob as mesmas condições, promovendo uma análise mais consistente e confiável.

Após a padronização, a divisão dos dados foi realizada utilizando a biblioteca *Scikit-learn*. Em testes preliminares, observou-se que a proporção de 70% para treino e 30% para teste resultou em um ajuste insatisfatório para os modelos de *Support Vector Machine (SVM)*, *Árvores de Decisão (DTR)* e *Florestas Aleatórias (RF)*. Diante disso, optou-se por uma divisão de 90% para treino e 10% para teste, que se mostrou mais adequada para esses modelos. Por outro lado, para os modelos de redes neurais, a divisão de 70% para treino e 30% para teste foi a mais eficaz, devido à maior robustez e capacidade de generalização desse tipo de modelo. Essa abordagem diferenciada garantiu que cada modelo fosse treinado e avaliado sob as condições mais apropriadas, otimizando seu desempenho.

4.2 Criação dos Modelos - Rugosidade Superficial

Os modelos foram desenvolvidos baseados na literatura e nas bibliotecas disponíveis na plataforma *google colab*, com foco na precisão preditiva e na capacidade de generalização. Durante o processo de desenvolvimento, foram testados diversos algoritmos de aprendizado de máquina, ajustando cuidadosamente seus hiperparâmetros para garantir que os modelos não apenas apresentassem boa acurácia nos dados de treinamento, mas também fossem capazes de generalizar para novos conjuntos de dados.

4.2.1 Treinamento dos modelos

A escolha dos algoritmos e a definição dos hiperparâmetros foram fundamentadas em revisões da literatura, com o objetivo de garantir um ajuste adequado dos modelos ao problema em estudo. O processo de otimização dos hiperparâmetros foi conduzido por meio da técnica de *Grid Search*, permitindo a avaliação sistemática de diferentes combinações de parâmetros.

Foram testados modelos de Máquinas de Vetores de Suporte (SVM, do inglês *Support Vector Machines*), Árvores de Decisão (DTR, do inglês *Decision Tree Regressor*), Florestas Aleatórias (RF, do inglês *Random Forest*) e Redes Neurais Artificiais (RNA). A implementação dos modelos SVM, DTR e RF foi realizada utilizando a biblioteca *scikit-learn*, enquanto o *TensorFlow* foi empregado para o desenvolvimento e treinamento das RNAs. A Tabela 9 apresenta os hiperparâmetros avaliados e os respectivos intervalos testados.

Tabela 9 – Hiperparâmetros dos modelos - R_a

Modelo	Hiperparâmetros	Níveis dos hiperparâmetros	Resposta
SVR	Kernel	['rbf', 'sigmoid', 'poly']	'rbf'
	C	[80, 100, 120, 150]	100
	epsilon	[$1e^{-3}$, $1e^{-4}$, $1e^{-5}$, $5e^{-3}$]	$1e^{-4}$
	gamma	[0.02, 0.04, 0.05, 0.06]	0.05
	cv	[6, 10, 15, 20]	5
DTR	max_depth	[None, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	3
	min_samples_split	[2, 3, 4, 5, 6, 7, 8, 9, 10]	2
	min_samples_leaf	[1, 2, 3, 4, 5]	1
	cv	[6, 10, 15, 20]	5
RF	n_estimators	[10, 80, 150, 400, 500]	100
	criterion	['squared_error', 'absolute_error', 'friedman_mse', 'poisson']	'squared_error'
	max_depth	[None, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10]	'4'
	cv	[6, 10, 15, 20]	5
RNA Sequential	hidden_layers	[1,2,3]	2
	neurons_per_layer	[6-6,7-7,8-8,9-9, 14-12,15-15,20-14,64-32]	20-14
	Activation hidden layers	['ReLU', 'Sigmoid', 'Tanh']	'ReLU'
	Activation output	-	'Linear'
	Kernel_regularizer	['L1', 'L2', 'L1_L2']	'L2'
	Optimizer	['SGD', 'Adam', 'RMSprop']	'Adam'
	Learning_rate	[0.001, 0.002, 0.01]	0.002
	Epochs	[500,1000,200]	2000
	Loss	['Mean squared error']	'Mean squared error'
	Metrics	['Mean squared error']	'Mean squared error'

Fonte: Própria

Cada modelo de aprendizado de máquina possui um processo de treinamento distinto, o que influencia diretamente sua eficácia e capacidade de generalização. Modelos como *Support Vector Machine* (SVM), *Decision Tree Regressor* (DTR) e *Random Forest* (RF) ajustam seus hiperparâmetros com base no conjunto de dados de treinamento em uma única etapa de aprendizado, ou seja, sem a necessidade de múltiplas épocas de treinamento. Diferentemente das redes neurais, que são treinadas ao longo de várias épocas — passando repetidamente pelo conjunto de dados para ajustar seus pesos — esses modelos não geram curvas de perda (loss) e validação (val_loss) durante o processo. A avaliação de desempenho dos modelos como SVM, DTR e RF é realizada diretamente por meio de métricas como erro quadrático médio, precisão e recall.

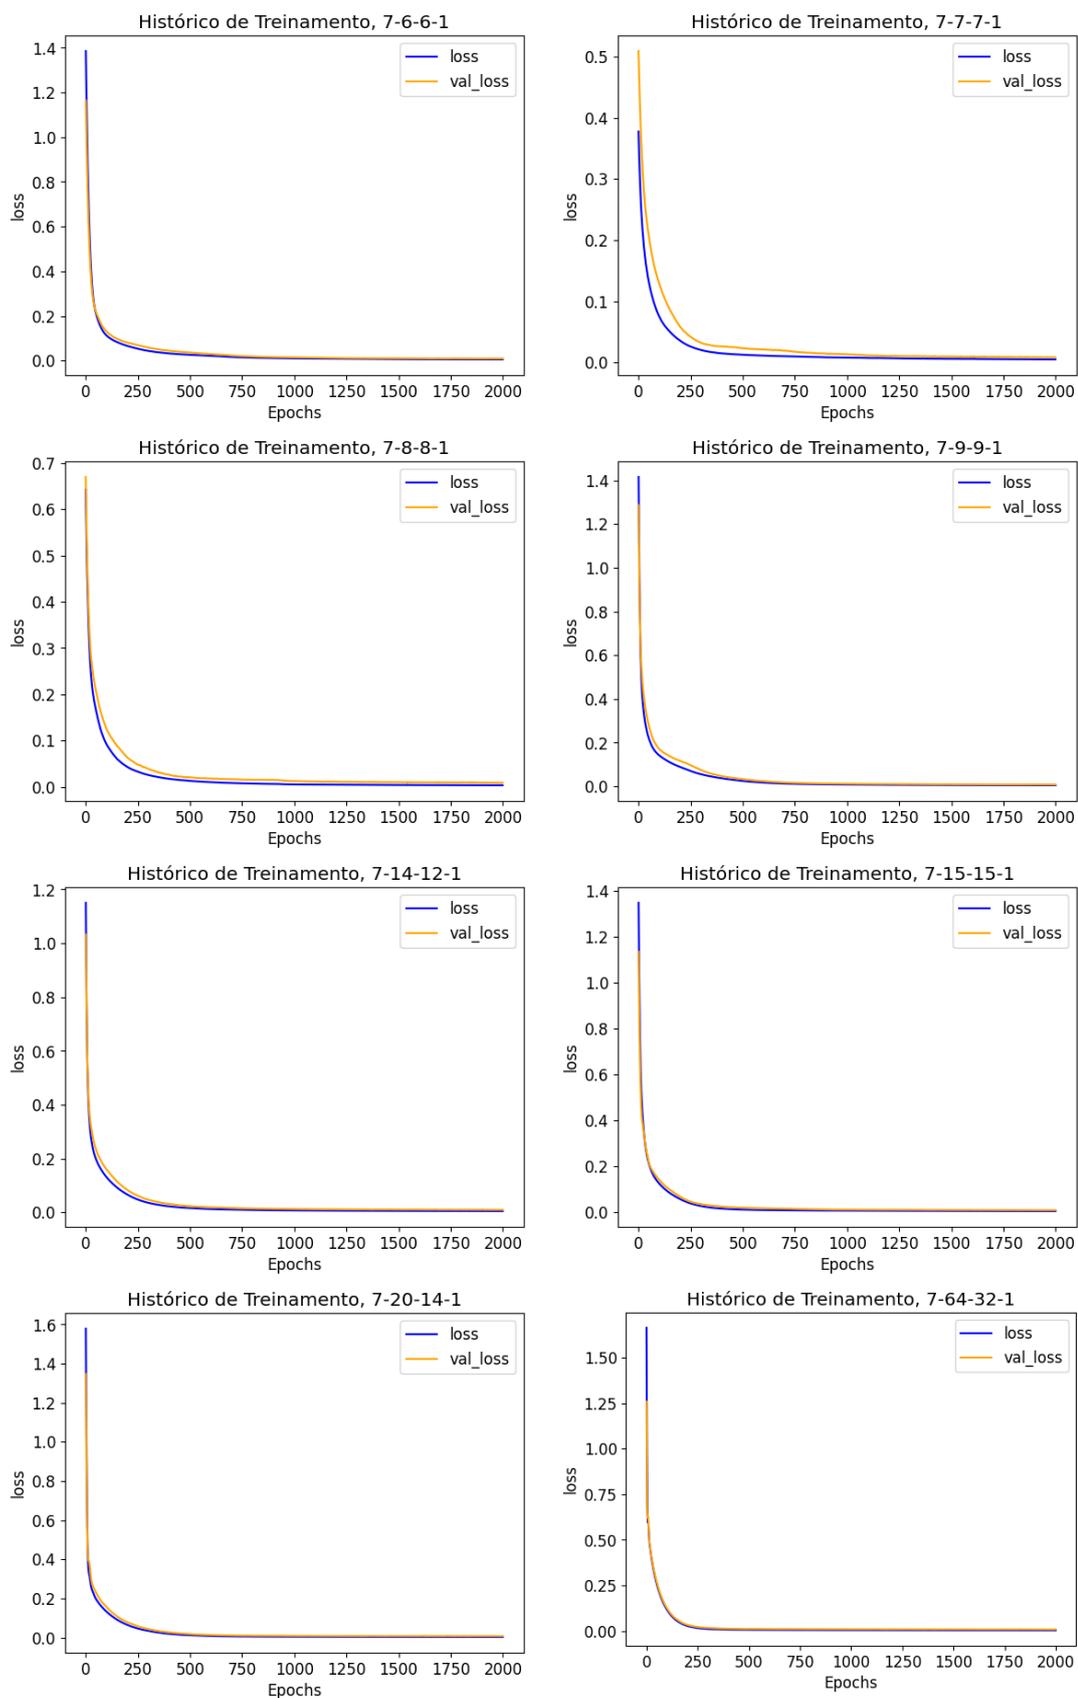
Por outro lado, o treinamento e teste de redes neurais permitem o monitoramento da evolução da função de perda (loss) em relação aos dados de treinamento e da função de perda de validação (val_loss) em relação aos dados de teste ao longo de várias épocas. Esse processo reflete a natureza iterativa do aprendizado das redes neurais, em que os

pesos do modelo são ajustados continuamente para minimizar a discrepância entre as previsões e os valores reais. O acompanhamento dessas métricas é crucial para avaliar a convergência do modelo e realizar ajustes que otimizem seu desempenho (XU et al., 2022).

A função de perda (*loss*) quantifica a eficácia do modelo durante o treinamento, enquanto a função de perda de validação (*val_loss*) mede sua capacidade de generalização para dados não vistos. Esse monitoramento é fundamental para identificar problemas como o sobreajuste (*overfitting*), que ocorre quando o modelo memoriza os dados de treinamento, resultando em um *val_loss* elevado no conjunto de validação, apesar de um *loss* reduzido nos dados de treinamento. Esse comportamento indica que o modelo não está aprendendo padrões gerais, mas sim se adaptando excessivamente a características específicas do conjunto de treinamento.

Nesse contexto, a Figura 40 ilustra as curvas de perda (*loss*) e perda de validação (*val_loss*) ao longo das épocas de treinamento para diferentes arquiteturas de redes neurais. Essa visualização é essencial para compreender o comportamento dos modelos, identificar possíveis problemas de convergência e embasar a escolha das métricas de avaliação apresentadas a seguir.

Figura 40 – Curvas de perdas e validação para diferentes arquiteturas de redes neurais



Fonte: Própria

Esses gráficos fornecem uma análise detalhada do comportamento do treinamento de cada modelo de rede, destacando a convergência entre a perda de treinamento e a perda do teste. Isso evidencia que os modelos foram capazes de minimizar a função de perda de maneira eficiente, indicando que não há grandes indícios de overfitting, já que as curvas de teste acompanham de perto as curvas de treinamento.

Após o treinamento e teste dos modelos, foi aplicada a validação cruzada utilizando o método k-fold com k igual a 5. Essa etapa teve como objetivo não apenas verificar a eficácia de generalização dos modelos selecionados, mas também assegurar que o desempenho observado não fosse resultado de uma divisão específica dos dados, garantindo uma avaliação mais robusta e confiável da capacidade preditiva dos modelos em diferentes subconjuntos do conjunto de dados.

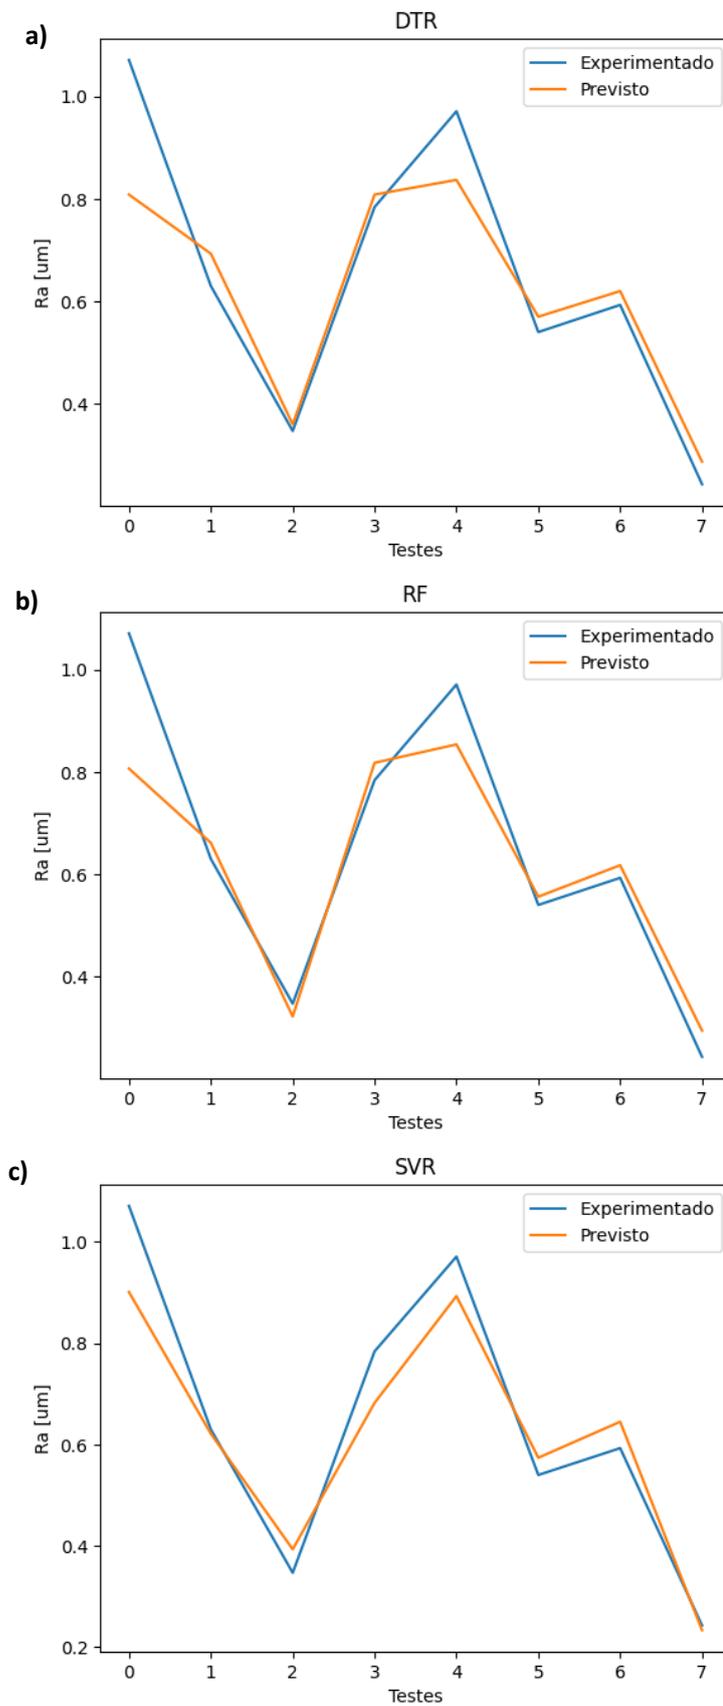
4.2.2 Previsão dos modelos

A Tabela 10 e a Figura 41, exibem os resultados das previsões gerados pelos modelos de aprendizado de máquina convencionais, como SVM, DTR e RF com os dados de teste.

Tabela 10 – Previsões dos modelos SVM, DTR, RF

Ra (exp)	SVM	DTR	RF
1.033	0.901	0.901	0.806
0.631	0.621	0.702	0.658
0.347	0.393	0.302	0.315
0.784	0.682	0.901	0.809
0.971	0.893	0.838	0.851
0.541	0.574	0.569	0.553
0.593	0.645	0.604	0.606
0.243	0.233	0.302	0.291

Fonte: Própria

Figura 41 – Previsões do modelo a) DTR, b) RF, c) SVM para R_a 

Fonte: Própria

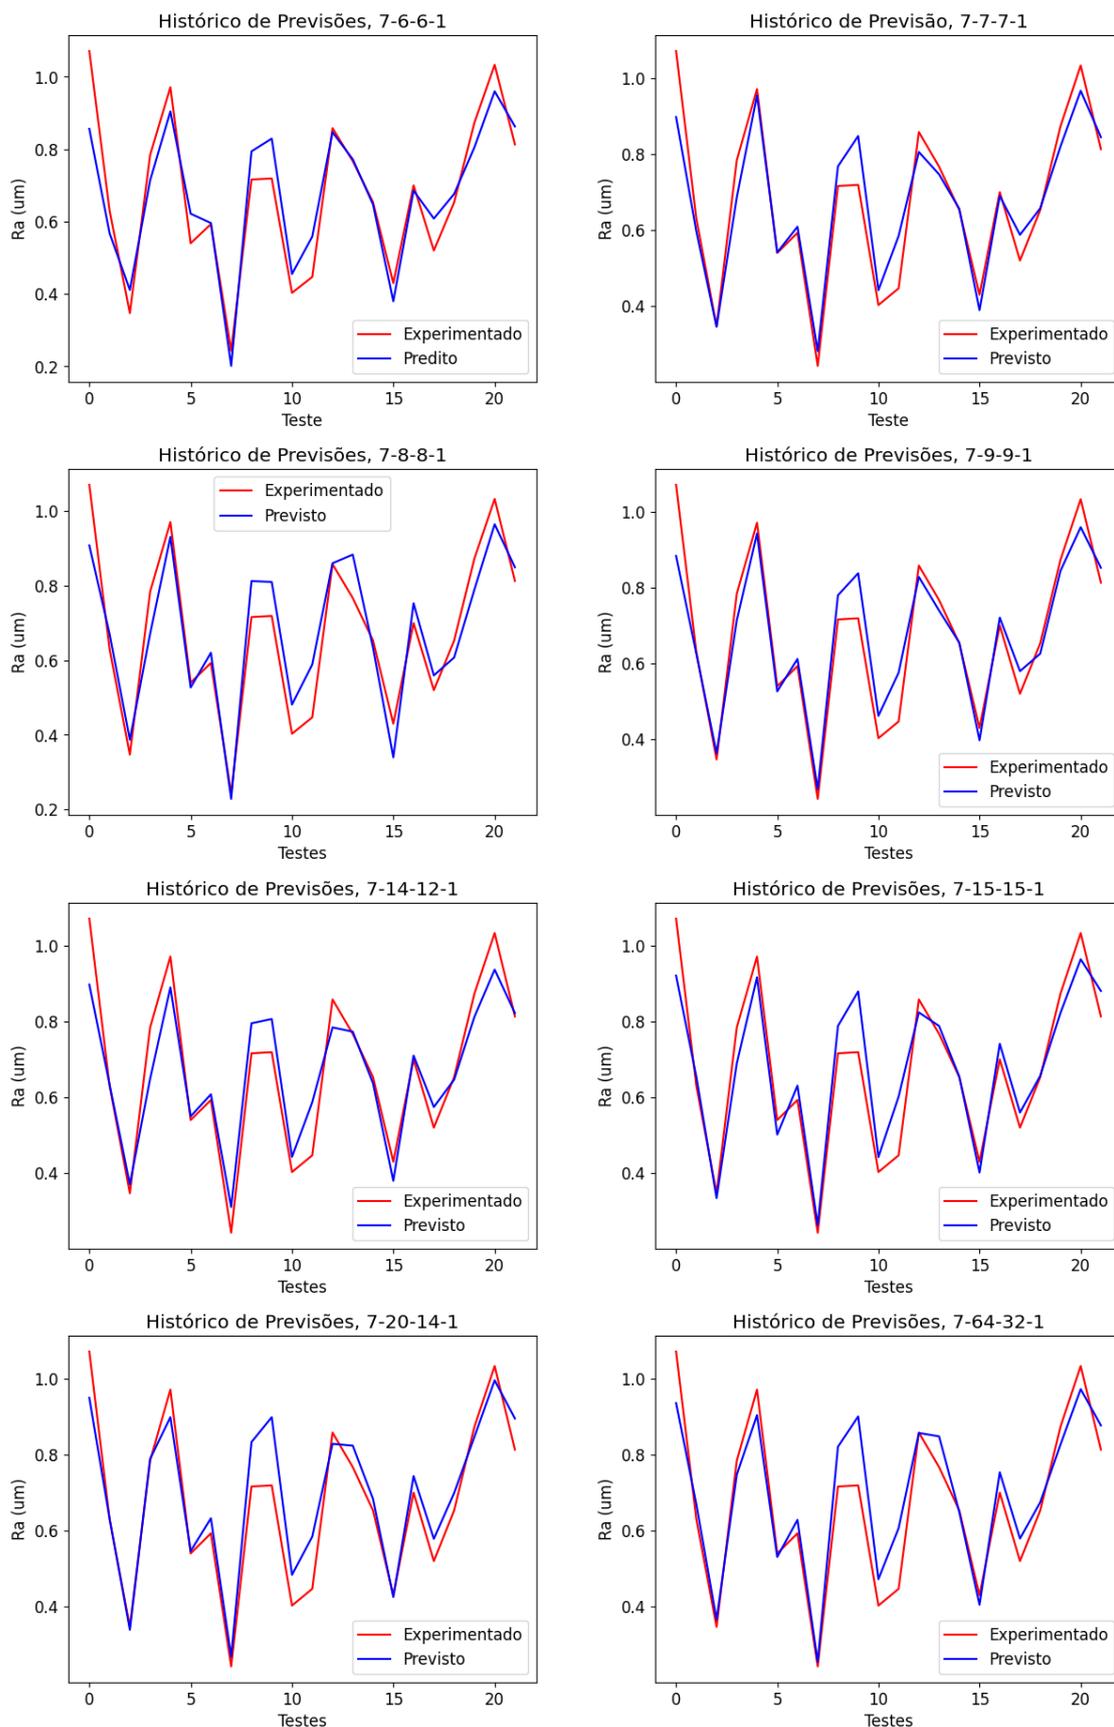
De maneira geral, os modelos de aprendizado de máquina convencionais demonstraram uma capacidade eficaz de aprender e capturar as nuances e os padrões subjacentes nos dados. As previsões realizadas estiveram, em sua maioria, muito próximas dos valores reais, o que indica que os modelos foram bem-sucedidos em identificar as relações significativas entre as variáveis e em generalizar adequadamente para os dados de teste. No entanto, apesar do bom desempenho observado na maior parte dos casos, algumas discrepâncias nos resultados podem ser atribuídas a fatores como a variabilidade intrínseca dos dados, a complexidade dos padrões subjacentes ou a limitação do tamanho da base de dados, que pode não ter representado completamente todas as possíveis variações nos dados de treinamento. A Tabela 11 e a Figura 42 apresentam as previsões obtidas a partir dos modelos de Redes Neurais Artificiais (RNA).

Tabela 11 – Previsões dos modelos de rede neural

Ra (exp)	7-6-6-1	7-7-7-1	7-8-8-1	7-9-9-1	7-14-12-1	7-15-15-1	7-20-14-1	7-64-32-1
1.071	0.726	0.862	0.860	0.911	0.989	0.971	0.895	0.967
0.630	0.579	0.664	0.569	0.621	0.659	0.659	0.628	0.651
0.347	0.330	0.408	0.405	0.367	0.365	0.340	0.369	0.310
0.784	0.772	0.690	0.834	0.689	0.704	0.767	0.697	0.747
0.971	0.854	0.941	0.950	0.902	0.915	0.889	0.936	0.914
0.540	0.562	0.587	0.520	0.575	0.505	0.488	0.539	0.512
0.593	0.574	0.690	0.575	0.604	0.594	0.626	0.597	0.627
0.243	0.338	0.274	0.243	0.305	0.250	0.262	0.256	0.258
0.716	0.843	0.841	0.816	0.860	0.826	0.828	0.800	0.812
0.719	0.931	0.799	0.903	0.880	0.840	0.888	0.847	0.875
0.403	0.420	0.535	0.470	0.449	0.425	0.465	0.444	0.438
0.447	0.464	0.516	0.557	0.571	0.583	0.594	0.512	0.569
0.858	0.869	0.932	0.900	0.720	0.824	0.825	0.861	0.845
0.767	0.737	0.847	0.744	0.789	0.765	0.827	0.789	0.830
0.653	0.575	0.685	0.617	0.659	0.700	0.656	0.686	0.664
0.430	0.306	0.411	0.397	0.393	0.311	0.340	0.413	0.389
0.700	0.657	0.763	0.736	0.693	0.764	0.747	0.731	0.751
0.520	0.711	0.528	0.566	0.582	0.574	0.566	0.561	0.557
0.653	0.638	0.616	0.658	0.592	0.642	0.714	0.693	0.681
0.873	0.867	0.873	0.831	0.862	0.820	0.840	0.813	0.818
1.033	1.010	0.987	0.962	0.980	0.951	1.011	0.972	0.971
0.813	0.851	0.852	0.860	0.883	0.866	0.877	0.882	0.893

Fonte: Própria

Figura 42 – Previsões do modelo RNA - R_a



Fonte: Própria

A análise dos resultados das previsões feitas pelas Redes Neurais Artificiais (RNAs) revela um desempenho variado entre os diferentes modelos testados. A Tabela 11 apresenta as previsões dos valores de rugosidade (R_a) para várias arquiteturas de rede neural, demonstrando que a rede com estrutura 7-14-12-1 obteve os melhores resultados na maioria das instâncias. Esse modelo teve um desempenho próximo aos valores reais em diversos casos, com destaque para as previsões de $R_a = 1.071$, $R_a = 0.971$ e $R_a = 0.719$, onde os valores previstos foram muito próximos dos valores experimentais.

Por outro lado, alguns modelos, como o 7-6-6-1 e o 7-7-7-1, apresentaram desvios consideráveis em certos pontos, como em $R_a = 0.347$ e $R_a = 0.243$. Esses erros podem ser atribuídos a fatores como a arquitetura da rede, que pode não ser suficientemente complexa para capturar padrões mais sutis nos dados, ou a limitação de dados durante o treinamento. Redes neurais com estruturas mais simples podem não ser capazes de modelar as relações não lineares complexas entre as variáveis, levando a previsões imprecisas.

É interessante observar que, em geral, os modelos com mais camadas e unidades por camada (como o 7-14-12-1 e o 7-15-15-1) tenderam a apresentar previsões mais precisas e próximas dos valores experimentais. Isso sugere que arquiteturas mais complexas podem ter melhor capacidade de generalização, capturando com maior eficiência as características dos dados de usinagem. Por fim, as redes neurais artificiais demonstraram um bom desempenho geral na previsão dos valores de rugosidade (R_a), com destaque para as arquiteturas mais complexas.

4.2.3 Métricas

Para avaliar o desempenho dos modelos, foram utilizadas as métricas de avaliação descritas nas Equações 2.31, 2.30, 2.32 e 2.33. Com base na revisão da literatura, o melhor modelo é definido como aquele que apresenta o menor $RMSE$ e o maior R^2 . No entanto, uma outra métrica crucial para a seleção do modelo mais adequado é a análise da porcentagem de acerto obtida na validação cruzada, pois, como mencionado anteriormente, essa técnica é fundamental para medir a capacidade de generalização do modelo em relação a novos dados. Assim, nesta tese, a escolha do melhor modelo foi feita considerando o menor $RMSE$, o maior R^2 e o melhor desempenho na validação cruzada que representa o R^2 médio entre os folds. A tabela 12 apresenta os resultados das principais métricas utilizadas para avaliar o desempenho de cada modelo criado.

Tabela 12 – Resultados das métricas para diferentes configurações de modelos para R_a

Modelos	MAE	MSE	RMSE	R^2 - Treino/Teste	Validação Cruzada
SVM	0,052	0,004	0,066	0,99 / 0,91	0,81
DTR	0,034	0,001	0,038	0,86 / 0,87	0,61
RF	0,024	0,001	0,031	0,94 / 0,84	0,76
7-6-6-1	0,073	0,012	0,111	0,83 / 0,85	0,76
7-7-7-1	0,063	0,006	0,079	0,86 / 0,88	0,81
7-8-8-1	0,058	0,006	0,077	0,86 / 0,87	0,83
7-9-9-1	0,063	0,006	0,081	0,85 / 0,88	0,84
7-14-12-1	0,055	0,004	0,068	0,90 / 0,91	0,89
7-15-15-1	0,058	0,005	0,072	0,88 / 0,89	0,82
7-20-14-1	0,046	0,003	0,063	0,91 / 0,92	0,90
7-64-32-1	0,053	0,004	0,064	0,90 / 0,91	0,88

Fonte: Própria

Analisando a Tabela 12, observa-se que todos os modelos desenvolvidos para a previsão da rugosidade superficial no fresamento de topo do aço inoxidável duplex apresentaram desempenhos satisfatórios. De maneira geral, todos os modelos demonstraram habilidade em capturar os padrões dos dados, resultando em previsões consistentes e precisas. Essa capacidade de generalização é corroborada pelos excelentes resultados obtidos tanto nas fases de treinamento quanto de teste.

É possível observar que o aumento da complexidade nas redes neurais — representado pelas diferentes arquiteturas de MLP testadas — não resultou em uma melhoria substancial de desempenho. Embora pequenas variações tenham sido notadas nas métricas de erro e nos coeficientes de determinação, tais diferenças não foram suficientemente significativas para justificar o maior custo computacional e a maior dificuldade de configuração associada às redes neurais. Além disso, vale destacar que o desempenho da MLP não foi consideravelmente superior ao dos modelos clássicos, como o Decision Tree Regressor (DTR) e o Random Forest (RF). Isso sugere que, neste caso específico, modelos mais simples apresentaram resultados comparáveis, mesmo com menor complexidade e custo computacional reduzido.

Já os modelos convencionais é possível perceber que DTR e RF apresentaram os menores valores de RMSE, com 0,038 e 0,031, respectivamente. Contudo, ambos mostraram limitações na capacidade de generalização, o que tende a ser um possível *overfitting*. O modelo SVM, por sua vez, alcançou uma validação cruzada de 0,81, no entanto, os demais indicadores de desempenho foram inferiores aos dos modelos de redes neurais testados. O modelo de rede neural 7-20-14-1 destacou-se pelo desempenho superior, com um RMSE de 0,063, coeficientes de determinação R^2 de 0,91 e 0,92, e uma validação cruzada de 0,90, indicando excelente capacidade preditiva e robustez. Em segundo lugar, o modelo 7-14-12-1 também apresentou resultados expressivos, com um RMSE de 0,068, R^2 de 0,90 e 0,91, e uma validação cruzada de 0,89.

4.2.4 Teste de Normalidade

A distribuição normal desempenha um papel crucial na estatística inferencial, uma vez que afeta diretamente a qualidade e a confiabilidade dos resultados em análises estatísticas. A suposição de normalidade dos dados é essencial, quando não confirmada, pode levar a conclusões imprecisas. Para avaliar essa suposição, utilizou-se o teste de Shapiro-Wilk, amplamente reconhecido como um dos métodos mais eficazes para verificar a normalidade. Este teste fornece uma estatística que varia de 0 a 1, onde valores mais próximos de 1 indicam uma maior conformidade com a normalidade.

Além disso, um p-valor maior ou igual a 5% sugere que os dados podem ser considerados aproximadamente normais, enquanto um p-valor inferior a 5% indica que os dados provavelmente não seguem uma distribuição normal. Essa verificação é de suma importância, pois muitos métodos estatísticos, como a análise de variância (ANOVA) e os testes t, baseiam-se na suposição de normalidade, e a sua violação pode comprometer a interpretação dos resultados (GUO et al., 2024). A tabela 13 apresenta os resultados do teste de Shapiro-Wilk.

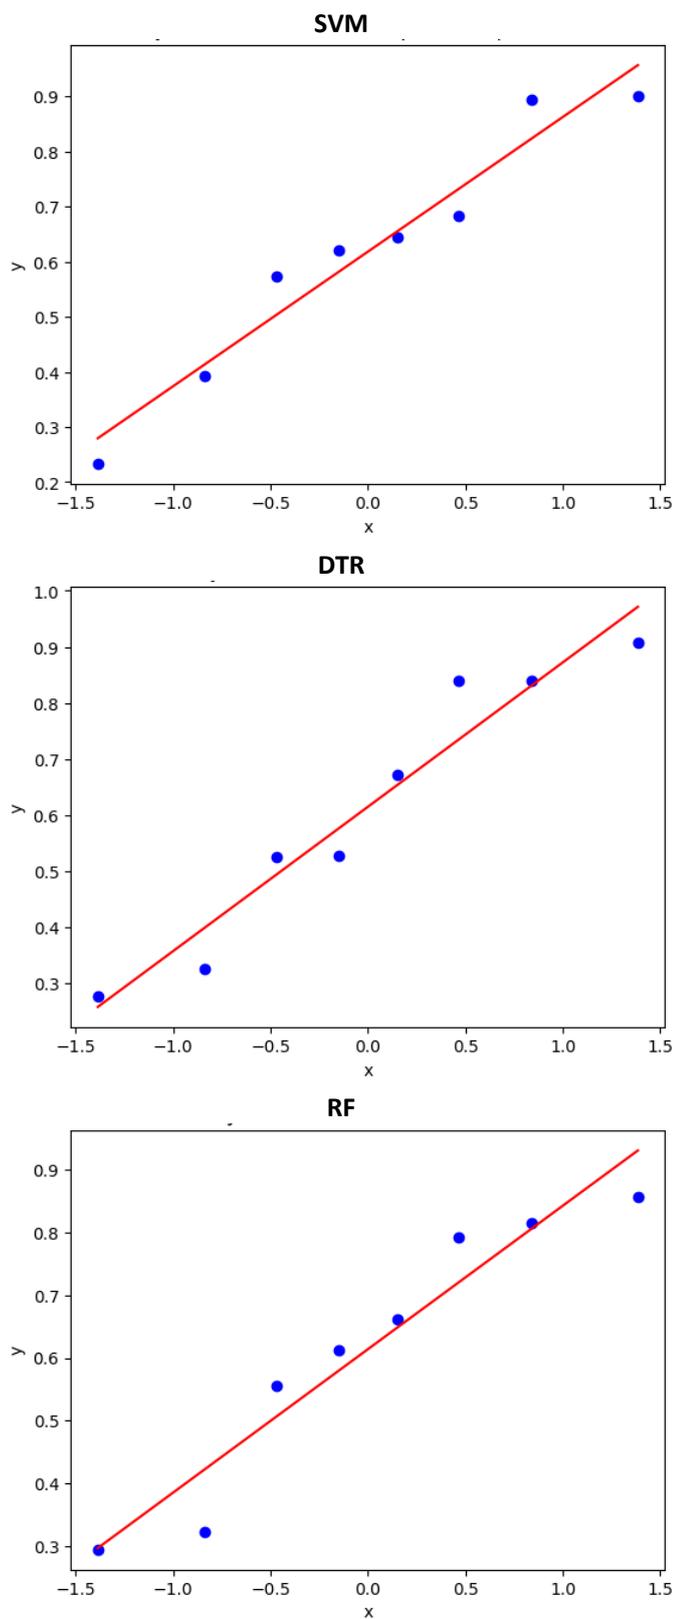
Tabela 13 – Resultados do teste de Shapiro-Wilk para os modelos

Modelo	Resultado Shapiro-Wilk	P-value
SVM	0,939	0,606
DTR	0,913	0,382
RF	0,899	0,287
7-6-6-1	0,954	0,412
7-7-7-1	0,958	0,463
7-8-8-1	0,945	0,261
7-9-9-1	0,951	0,331
7-14-12-1	0,955	0,407
7-15-15-1	0,948	0,294
7-20-14-1	0,962	0,551
7-64-32-1	0,947	0,279

Fonte: Própria

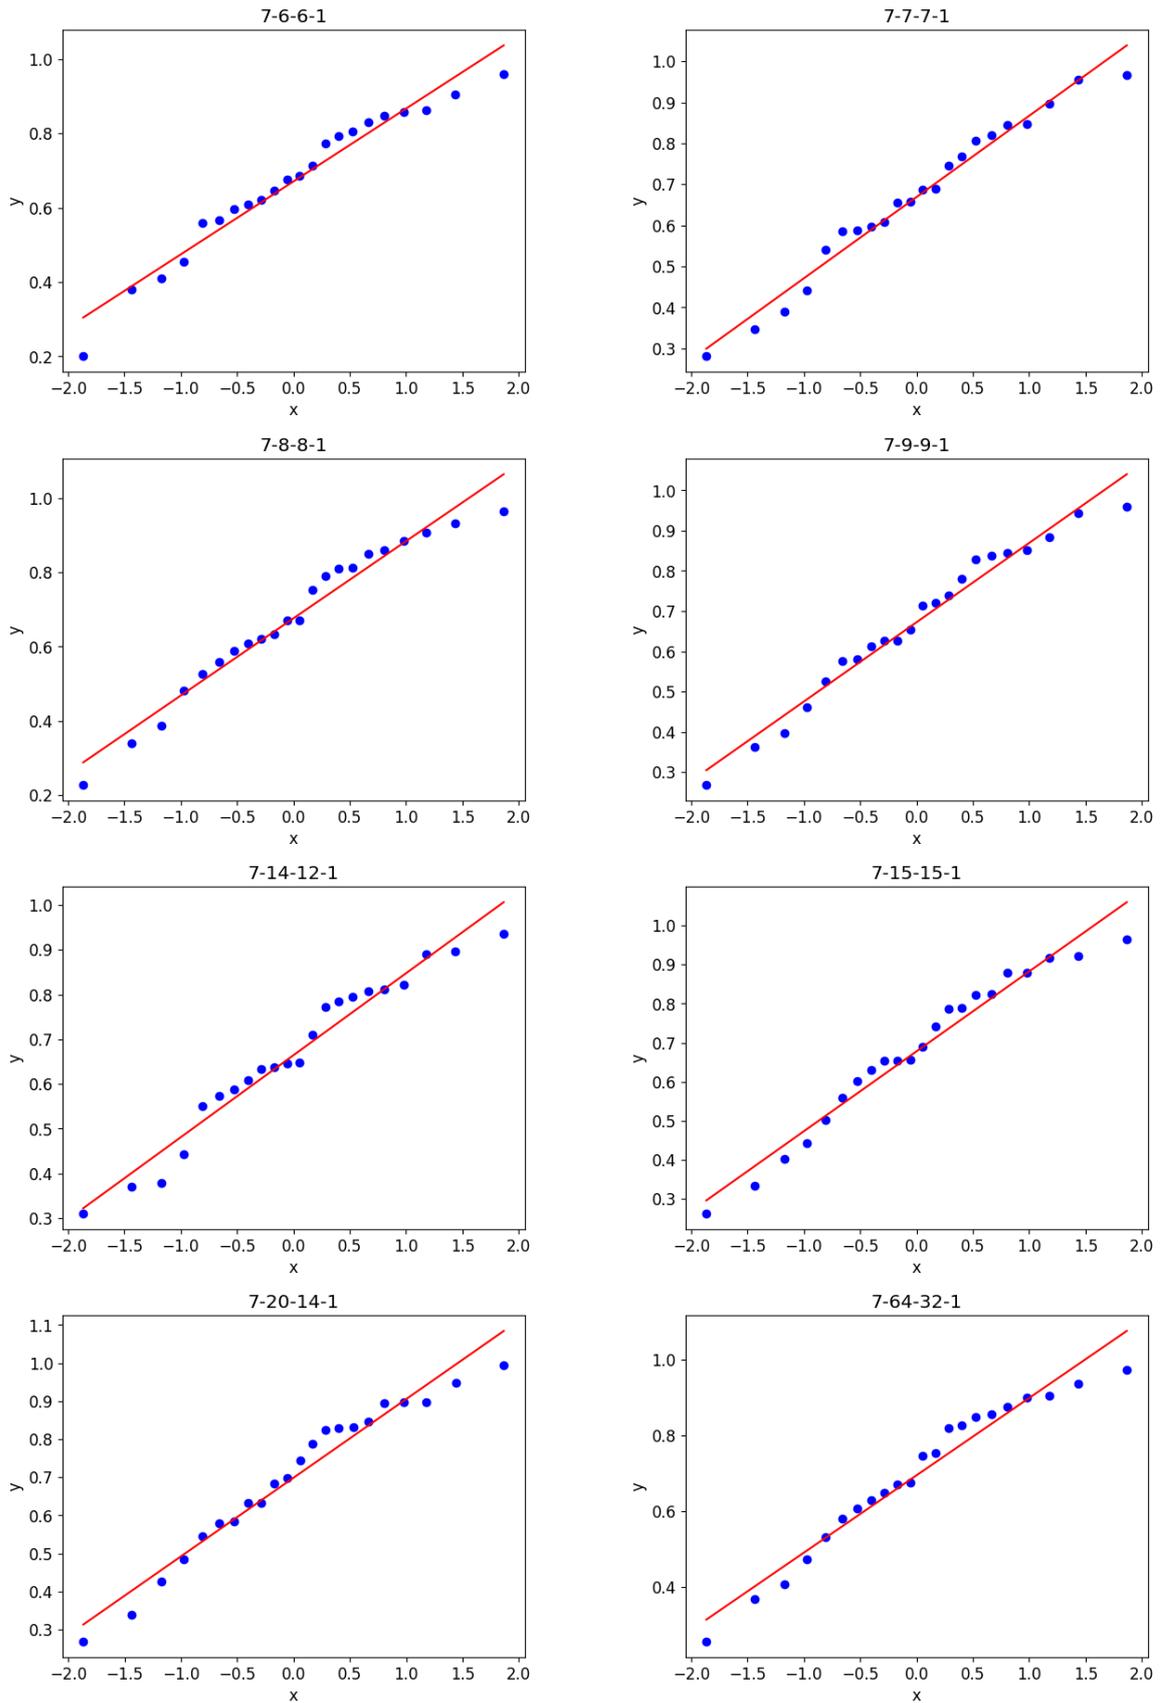
Os resultados do teste de Shapiro-Wilk para os modelos de aprendizagem de máquina indicam que não há evidências significativas de que os resíduos de qualquer um dos modelos se desviem da normalidade, uma vez que todos os *p-values* são superiores a 0,05. O modelo 7-20-14-1 apresentou o melhor desempenho em termos de aderência à normalidade dos resíduos, enquanto o modelo Random Forest (RF) mostrou o maior desvio, embora ainda dentro de limites aceitáveis. Os valores do teste Shapiro-Wilk variam entre 0,899 e 0,962, com *p-values* entre 0,261 e 0,606. As Figuras 43 e 44 ilustram gráficos de resíduos em relação aos valores ajustados, com linhas de tendência representadas em vermelho.

Figura 43 – Teste Shapiro Wilk - SVM - DTR - RF



Fonte: Própria

Figura 44 – Teste Shapiro Wilk - RNA



Fonte: Própria

De modo geral, os pontos azuis, que representam os resíduos, estão próximos da linha vermelha de tendência, indicando uma distribuição aproximadamente normal dos resíduos. Pequenos desvios observados em algumas figuras são mínimos e não comprometem a análise. Esses gráficos fornecem uma avaliação visual eficiente da normalidade dos resíduos e confirmam que o ajuste dos modelos é adequado para as análises subsequentes.

4.3 Análise Comparativa

Neste capítulo, será conduzida uma análise comparativa do modelo selecionado utilizando um planejamento fatorial completo. É importante destacar que o planejamento experimental real, baseado em ensaios práticos, é um fatorial fracionado, contendo um número reduzido de pontos devido a limitações experimentais. Já as predições do modelo de inteligência artificial (IA) foram geradas a partir de um planejamento fatorial completo, com todas as combinações possíveis dos fatores, o que permite avaliar o desempenho do modelo em um conjunto mais abrangente e inéditos de condições.

Serão avaliadas as predições geradas pelo modelo de IA e comparadas por meio de ANOVAs, além da interpretação de gráficos de efeitos principais, interações e modelos de superfície de resposta. Essa abordagem permitirá verificar a capacidade do modelo em generalizar para novos dados, identificando seus pontos fortes e possíveis limitações, garantindo que a solução proposta seja eficaz para aplicação no contexto da usinagem.

4.3.1 Nova Base de dados

Para a construção da base de dados para a verificação da eficiência do modelo, foi selecionado o modelo de aprendizagem de máquina de redes neurais artificiais 7-20-14, pois este obteve o melhor desempenho com as seguintes métricas: MAE 0,046, MSE 0,003, RMSE 0,063, com desempenho de treino e teste de 0,91 / 0,92 e validação cruzada de 0,90. Com base nesse modelo, foi utilizado um arranjo composto central (CCD) com sete fatores, conforme apresentado na Tabela 5 e com base nos fatores incontrolláveis apresentados na Tabela 6. Para avaliar a eficiência do modelo, foi desenvolvido um planejamento fatorial completo. Contudo, como as variáveis de ruído não são testadas nos níveis axiais, esses pontos foram excluídos do arranjo final. A distância axial (ou raio) da região experimental foi definida como $\alpha = 3,36$.

Tabela 14 – Novo Planejamento Experimental

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
1	60,00	0,10	15,00	0,80	0,00	0,00	30,00	0,543

Continua na próxima página

Tabela 14 - Novo Planejamento Experimental - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
2	90,00	0,10	15,00	0,80	0,00	0,00	30,00	0,347
3	60,00	0,16	15,00	0,80	0,00	0,00	30,00	0,636
4	90,00	0,16	15,00	0,80	0,00	0,00	30,00	0,755
5	60,00	0,10	18,00	0,80	0,00	0,00	30,00	0,525
6	90,00	0,10	18,00	0,80	0,00	0,00	30,00	0,381
7	60,00	0,16	18,00	0,80	0,00	0,00	30,00	0,642
8	90,00	0,16	18,00	0,80	0,00	0,00	30,00	0,762
9	60,00	0,10	15,00	1,20	0,00	0,00	30,00	0,507
10	90,00	0,10	15,00	1,20	0,00	0,00	30,00	0,335
11	60,00	0,16	15,00	1,20	0,00	0,00	30,00	0,649
12	90,00	0,16	15,00	1,20	0,00	0,00	30,00	0,745
13	60,00	0,10	18,00	1,20	0,00	0,00	30,00	0,489
14	90,00	0,10	18,00	1,20	0,00	0,00	30,00	0,349
15	60,00	0,16	18,00	1,20	0,00	0,00	30,00	0,662
16	90,00	0,16	18,00	1,20	0,00	0,00	30,00	0,759
17	60,00	0,10	15,00	0,80	0,30	0,00	30,00	0,887
18	90,00	0,10	15,00	0,80	0,30	0,00	30,00	0,857
19	60,00	0,16	15,00	0,80	0,30	0,00	30,00	0,659
20	90,00	0,16	15,00	0,80	0,30	0,00	30,00	0,934
21	60,00	0,10	18,00	0,80	0,30	0,00	30,00	0,908
22	90,00	0,10	18,00	0,80	0,30	0,00	30,00	0,871
23	60,00	0,16	18,00	0,80	0,30	0,00	30,00	0,679
24	90,00	0,16	18,00	0,80	0,30	0,00	30,00	0,983
25	60,00	0,10	15,00	1,20	0,30	0,00	30,00	0,908
26	90,00	0,10	15,00	1,20	0,30	0,00	30,00	0,832
27	60,00	0,16	15,00	1,20	0,30	0,00	30,00	0,702
28	90,00	0,16	15,00	1,20	0,30	0,00	30,00	0,970
29	60,00	0,10	18,00	1,20	0,30	0,00	30,00	0,922
30	90,00	0,10	18,00	1,20	0,30	0,00	30,00	0,817
31	60,00	0,16	18,00	1,20	0,30	0,00	30,00	0,731
32	90,00	0,16	18,00	1,20	0,30	0,00	30,00	1,040
33	60,00	0,10	15,00	0,80	0,00	20,00	30,00	0,465
34	90,00	0,10	15,00	0,80	0,00	20,00	30,00	0,302
35	60,00	0,16	15,00	0,80	0,00	20,00	30,00	0,527
36	90,00	0,16	15,00	0,80	0,00	20,00	30,00	0,664

Continua na próxima página

Tabela 14 - Novo Planejamento Experimental - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
37	60,00	0,10	18,00	0,80	0,00	20,00	30,00	0,443
38	90,00	0,10	18,00	0,80	0,00	20,00	30,00	0,277
39	60,00	0,16	18,00	0,80	0,00	20,00	30,00	0,484
40	90,00	0,16	18,00	0,80	0,00	20,00	30,00	0,666
41	60,00	0,10	15,00	1,20	0,00	20,00	30,00	0,434
42	90,00	0,10	15,00	1,20	0,00	20,00	30,00	0,282
43	60,00	0,16	15,00	1,20	0,00	20,00	30,00	0,538
44	90,00	0,16	15,00	1,20	0,00	20,00	30,00	0,668
45	60,00	0,10	18,00	1,20	0,00	20,00	30,00	0,421
46	90,00	0,10	18,00	1,20	0,00	20,00	30,00	0,249
47	60,00	0,16	18,00	1,20	0,00	20,00	30,00	0,484
48	90,00	0,16	18,00	1,20	0,00	20,00	30,00	0,662
49	60,00	0,10	15,00	0,80	0,30	20,00	30,00	0,781
50	90,00	0,10	15,00	0,80	0,30	20,00	30,00	0,720
51	60,00	0,16	15,00	0,80	0,30	20,00	30,00	0,578
52	90,00	0,16	15,00	0,80	0,30	20,00	30,00	0,812
53	60,00	0,10	18,00	0,80	0,30	20,00	30,00	0,795
54	90,00	0,10	18,00	0,80	0,30	20,00	30,00	0,693
55	60,00	0,16	18,00	0,80	0,30	20,00	30,00	0,551
56	90,00	0,16	18,00	0,80	0,30	20,00	30,00	0,832
57	60,00	0,10	15,00	1,20	0,30	20,00	30,00	0,801
58	90,00	0,10	15,00	1,20	0,30	20,00	30,00	0,698
59	60,00	0,16	15,00	1,20	0,30	20,00	30,00	0,615
60	90,00	0,16	15,00	1,20	0,30	20,00	30,00	0,844
61	60,00	0,10	18,00	1,20	0,30	20,00	30,00	0,792
62	90,00	0,10	18,00	1,20	0,30	20,00	30,00	0,631
63	60,00	0,16	18,00	1,20	0,30	20,00	30,00	0,604
64	90,00	0,16	18,00	1,20	0,30	20,00	30,00	0,891
65	60,00	0,10	15,00	0,80	0,00	0,00	50,00	0,567
66	90,00	0,10	15,00	0,80	0,00	0,00	50,00	0,369
67	60,00	0,16	15,00	0,80	0,00	0,00	50,00	0,624
68	90,00	0,16	15,00	0,80	0,00	0,00	50,00	0,740
69	60,00	0,10	18,00	0,80	0,00	0,00	50,00	0,556
70	90,00	0,10	18,00	0,80	0,00	0,00	50,00	0,390
71	60,00	0,16	18,00	0,80	0,00	0,00	50,00	0,650

Continua na próxima página

Tabela 14 - Novo Planejamento Experimental - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
72	90,00	0,16	18,00	0,80	0,00	0,00	50,00	0,750
73	60,00	0,10	15,00	1,20	0,00	0,00	50,00	0,529
74	90,00	0,10	15,00	1,20	0,00	0,00	50,00	0,332
75	60,00	0,16	15,00	1,20	0,00	0,00	50,00	0,655
76	90,00	0,16	15,00	1,20	0,00	0,00	50,00	0,730
77	60,00	0,10	18,00	1,20	0,00	0,00	50,00	0,512
78	90,00	0,10	18,00	1,20	0,00	0,00	50,00	0,358
79	60,00	0,16	18,00	1,20	0,00	0,00	50,00	0,656
80	90,00	0,16	18,00	1,20	0,00	0,00	50,00	0,738
81	60,00	0,10	15,00	0,80	0,30	0,00	50,00	0,918
82	90,00	0,10	15,00	0,80	0,30	0,00	50,00	0,880
83	60,00	0,16	15,00	0,80	0,30	0,00	50,00	0,667
84	90,00	0,16	15,00	0,80	0,30	0,00	50,00	0,928
85	60,00	0,10	18,00	0,80	0,30	0,00	50,00	0,939
86	90,00	0,10	18,00	0,80	0,30	0,00	50,00	0,923
87	60,00	0,16	18,00	0,80	0,30	0,00	50,00	0,697
88	90,00	0,16	18,00	0,80	0,30	0,00	50,00	0,972
89	60,00	0,10	15,00	1,20	0,30	0,00	50,00	0,932
90	90,00	0,10	15,00	1,20	0,30	0,00	50,00	0,875
91	60,00	0,16	15,00	1,20	0,30	0,00	50,00	0,705
92	90,00	0,16	15,00	1,20	0,30	0,00	50,00	0,963
93	60,00	0,10	18,00	1,20	0,30	0,00	50,00	0,943
94	90,00	0,10	18,00	1,20	0,30	0,00	50,00	0,871
95	60,00	0,16	18,00	1,20	0,30	0,00	50,00	0,711
96	90,00	0,16	18,00	1,20	0,30	0,00	50,00	1,015
97	60,00	0,10	15,00	0,80	0,00	20,00	50,00	0,504
98	90,00	0,10	15,00	0,80	0,00	20,00	50,00	0,333
99	60,00	0,16	15,00	0,80	0,00	20,00	50,00	0,561
100	90,00	0,16	15,00	0,80	0,00	20,00	50,00	0,676
101	60,00	0,10	18,00	0,80	0,00	20,00	50,00	0,472
102	90,00	0,10	18,00	0,80	0,00	20,00	50,00	0,301
103	60,00	0,16	18,00	0,80	0,00	20,00	50,00	0,535
104	90,00	0,16	18,00	0,80	0,00	20,00	50,00	0,662
105	60,00	0,10	15,00	1,20	0,00	20,00	50,00	0,462
106	90,00	0,10	15,00	1,20	0,00	20,00	50,00	0,282

Continua na próxima página

Tabela 14 - Novo Planejamento Experimental - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
107	60,00	0,16	15,00	1,20	0,00	20,00	50,00	0,569
108	90,00	0,16	15,00	1,20	0,00	20,00	50,00	0,671
109	60,00	0,10	18,00	1,20	0,00	20,00	50,00	0,435
110	90,00	0,10	18,00	1,20	0,00	20,00	50,00	0,265
111	60,00	0,16	18,00	1,20	0,00	20,00	50,00	0,523
112	90,00	0,16	18,00	1,20	0,00	20,00	50,00	0,651
113	60,00	0,10	15,00	0,80	0,30	20,00	50,00	0,806
114	90,00	0,10	15,00	0,80	0,30	20,00	50,00	0,763
115	60,00	0,16	15,00	0,80	0,30	20,00	50,00	0,585
116	90,00	0,16	15,00	0,80	0,30	20,00	50,00	0,82
117	60,00	0,10	18,00	0,80	0,30	20,00	50,00	0,826
118	90,00	0,10	18,00	0,80	0,30	20,00	50,00	0,762
119	60,00	0,16	18,00	0,80	0,30	20,00	50,00	0,543
120	90,00	0,16	18,00	0,80	0,30	20,00	50,00	0,822
121	60,00	0,10	15,00	1,20	0,30	20,00	50,00	0,826
122	90,00	0,10	15,00	1,20	0,30	20,00	50,00	0,729
123	60,00	0,16	15,00	1,20	0,30	20,00	50,00	0,62
124	90,00	0,16	15,00	1,20	0,30	20,00	50,00	0,853
125	60,00	0,10	18,00	1,20	0,30	20,00	50,00	0,841
126	90,00	0,10	18,00	1,20	0,30	20,00	50,00	0,699
127	60,00	0,16	18,00	1,20	0,30	20,00	50,00	0,583
128	90,00	0,16	18,00	1,20	0,30	20,00	50,00	0,871
129	24,55	0,13	16,50	1,00	0,15	0,20	40,00	0,734
130	125,45	0,13	16,50	1,00	0,15	0,20	40,00	0,814
131	75,00	0,03	16,50	1,00	0,15	0,20	40,00	0,651
132	75,00	0,23	16,50	1,00	0,15	0,20	40,00	0,914
133	75,00	0,13	11,45	1,00	0,15	0,20	40,00	0,892
134	75,00	0,13	21,55	1,00	0,15	0,20	40,00	0,895
135	75,00	0,13	16,50	0,33	0,15	0,20	40,00	0,746
136	75,00	0,13	16,50	1,67	0,15	0,20	40,00	0,717
137	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
138	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
139	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
140	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
141	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736

Continua na próxima página

Tabela 14 - Novo Planejamento Experimental - Continuação

Exp.	v_c (m/min)	f_z (mm/z)	a_e (mm)	a_p (mm)	v_b (mm)	Q (L/min)	lt_0 (mm)	R_a (μm)
142	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
143	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
144	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
145	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736
146	75,00	0,13	16,50	1,00	0,15	0,20	40,00	0,736

Fonte: Própria.

A norma NBR 8404/1984, que aborda a Indicação do Estado de Superfícies em Desenhos Técnicos, especifica que o valor da rugosidade R_a pode ser indicado pelos números da classe de rugosidade correspondente. Como ilustrado na Tabela 14, os valores de rugosidade gerados pelo modelo de aprendizado de máquina variam entre as classes N5 e N7, correspondendo a rugosidades no intervalo de 0,4 a 1,6 μm . Isso indica que os valores previstos se encontram dentro da faixa especificada pela norma para processos especiais, como a retificação.

Para avaliar a qualidade das previsões do modelo de aprendizado de máquina, foi realizado um teste t, conforme apresentado na Tabela 15. O objetivo do teste é verificar se há uma diferença estatisticamente significativa entre as médias de dois conjuntos de dados: os valores reais e aqueles previstos pelos modelos de aprendizagem de máquina, considerando a variação das amostras.

As hipóteses formuladas foram:

- Hipótese nula (H_0): Não há diferença significativa entre as médias dos dados reais e dos previstos pelo modelo de aprendizagem de máquina, ou seja, as médias são estatisticamente iguais.
- Hipótese alternativa (H_1): Há uma diferença significativa entre as médias dos dados reais e dos previstos pelo modelo de aprendizagem de máquina, ou seja, as médias são diferentes.

É importante destacar que, para a aplicação do teste t nos dados gerados pelos modelos de aprendizado de máquina, os valores referentes ao ponto central foram excluídos, uma vez que, nesses pontos, o modelo não consegue estimar adequadamente o erro.

Tabela 15 – Teste T comparando dados reais e previsões geradas pelo modelo de IA.

Teste T R_a (Real)				
N	Média	DesvPad	EP Média	IC de 95% para μ
82	0,6388	0,2141	0,0236	(0,5917; 0,6858)
Teste T R_a (Modelo IA)				
N	Média	DesvPad	EP Média	IC de 95% para μ
138	0,6719	0,1915	0,0163	(0,6397; 0,7042)

Fonte: Própria

A comparação entre os testes T realizados nos dados reais e nos valores gerados pela IA para a rugosidade da superfície (R_a) revela *insights* importantes. A média dos valores de rugosidade nos dados reais é $0,6388 \mu m$, enquanto a média dos valores previstos pela IA é $0,6719 \mu m$. Apesar dessa variação, ela está dentro do intervalo de confiança de 95% para a média de ambos os conjuntos de dados, o que indica que a diferença observada não é estatisticamente significativa. Em outras palavras, não há evidências suficientes para rejeitar a hipótese nula, sugerindo que o modelo de IA apresenta um bom nível de precisão ao prever os valores de rugosidade.

4.3.2 Desenvolvimento dos modelos matemáticos

A partir deste ponto, será avaliada a eficiência do modelo de aprendizado de máquina RNA 7-20-14-1 em um novo experimento. Além disso, os resultados do modelo serão comparados com os dados reais, com o objetivo de verificar se o modelo é capaz de identificar a influência dos parâmetros do processo na resposta analisada. A Tabela 16 apresenta os coeficientes codificados do modelo de resposta completo de R_a para o modelo de RNA 7-20-14-1 e a Tabela 17 apresenta os coeficientes codificados do modelo de resposta completo de R_a real.

Tabela 16 – Coeficientes codificados e seus efeitos na rugosidade R_a usando-se RNA

termo	coef	valor-p
constante	0,64308	0,000
v_c	0,01687	0,000
f_z	0,04606	0,000
a_e	0,00028	0,932
a_p	-0,00091	0,782
v_b	0,13703	0,000
Q	-0,05352	0,000
l_{t0}	0,00714	0,048
v_c^2	0,00596	0,032
f_z^2	0,00671	0,016
a_e^2	0,01652	0,000
a_p^2	0,00220	0,425
$v_c \times f_z$	0,07950	0,000
$v_c \times a_e$	0,00352	0,327
$v_c \times a_p$	-0,00352	0,327
$v_c \times v_b$	0,03089	0,000
$v_c \times Q$	-0,00191	0,594
$v_c \times l_{t0}$	-0,00203	0,571
$f_z \times a_e$	0,00206	0,565
$f_z \times a_p$	0,01097	0,003
$f_z \times v_b$	-0,07319	0,000
$f_z \times Q$	-0,00186	0,604
$f_z \times l_{t0}$	-0,00686	0,057
$a_e \times a_p$	-0,00158	0,659
$a_e \times v_b$	0,00430	0,231
$a_e \times Q$	-0,00791	0,049
$a_e \times l_{t0}$	0,00025	0,944
$a_p \times Q$	0,00711	0,049
$a_p \times v_b$	-0,00022	0,951
$a_p \times l_{t0}$	-0,00144	0,688

fonte: elaboração Própria.

Tabela 17 – Coeficientes codificados e seus efeitos na rugosidade R_a usando-se os dados reais

termo	coef	valor-p
constante	0,414	0,000
v_c	0,01653	0,026
f_z	0,05396	0,000
a_e	0,00173	0,812
a_p	0,00895	0,222
v_b	0,13823	0,000
Q	-0,0387	0,000
l_{t0}	0,00452	0,572
v_c^2	0,04608	0,000
f_z^2	0,0612	0,000
a_e^2	0,06808	0,000
a_p^2	0,04645	0,000
$v_c \times f_z$	0,08814	0,000
$v_c \times a_e$	-0,00517	0,517
$v_c \times a_p$	-0,01127	0,161
$v_c \times v_b$	0,03502	0,000
$v_c \times Q$	0,00285	0,696
$v_c \times l_{t0}$	0,00117	0,883
$f_z \times a_e$	0,00542	0,497
$f_z \times a_p$	0,01033	0,199
$f_z \times v_b$	-0,07577	0,000
$f_z \times Q$	-0,00906	0,218
$f_z \times l_{t0}$	0,00295	0,711
$a_e \times a_p$	-0,00548	0,492
$a_e \times v_b$	0,00492	0,538
$a_e \times Q$	-0,0013	0,859
$a_e \times l_{t0}$	-0,00555	0,487
$a_p \times v_b$	0,01014	0,207
$a_p \times Q$	0,0035	0,632
$a_p \times l_{t0}$	-0,00545	0,495

fonte: elaboração Própria.

Os termos cujos efeitos foram estatisticamente significativos, ou seja, com valor-p inferior a 5%, estão destacados em negrito. O modelo de aprendizado de máquina (ML) demonstrou sucesso ao identificar as relações entre as variáveis controláveis e incontroláveis do processo e a rugosidade superficial R_a . Observa-se que as variáveis v_c , f_z , v_b , Q e as interações $v_c \times f_z$, $v_c \times v_b$ e $f_z \times v_b$ apresentaram valor-p menores que 5%. Esses resultados são consistentes com os dados reais, nos quais as variáveis v_c , f_z , v_b e Q também mostraram significância, assim como as interações $v_c \times f_z$, $v_c \times v_b$ e $f_z \times v_b$.

Analisando os valores de R_{aj}^2 , que é uma métrica que avalia a proporção da variabili-

dade na variável dependente explicada pelo modelo, considerando o número de variáveis independentes utilizadas, observamos o modelo de aprendizado de máquina (ML) obteve um $R_{a_j}^2 = 95,32\%$. Isso indica que o modelo de aprendizagem de máquina conseguiu capturar com ainda mais precisão a complexidade das interações entre as variáveis controláveis e incontroláveis do processo e a rugosidade, oferecendo uma explicação mais robusta da variabilidade observada. As Equações 4.1 e 4.2 mostram, respectivamente, os modelos de regressão para os dados experimentais e para os gerados pelo modelo de aprendizado de máquina.

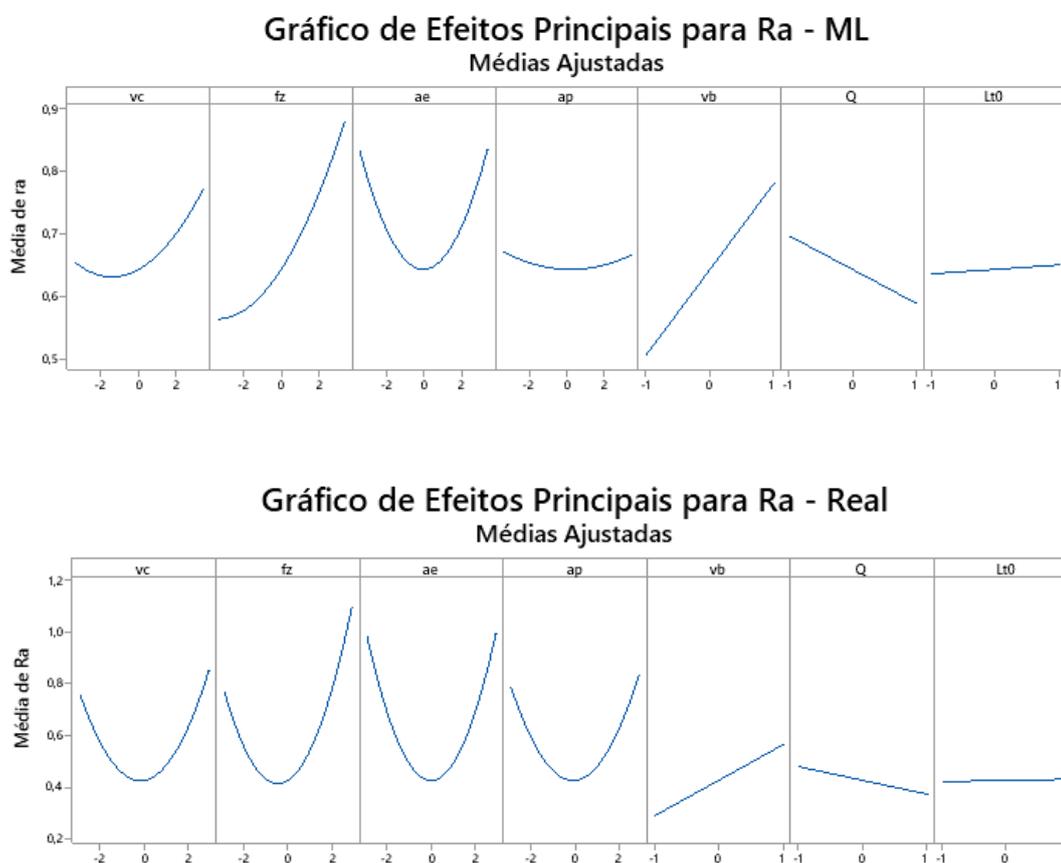
$$\begin{aligned}
R_a(\mu m) = & 0,425 + 0,01597v_c + 0,05574f_z + 0,00198a_e + 0,00826a_p + 0,13823v_b - 0,05342Q \\
& + 0,00452l_{t0} + 0,04525v_c^2 + 0,06038f_z^2 + 0,06725a_e^2 + 0,04563a_p^2 + 0,08814v_c f_z \\
& - 0,00517v_c a_e - 0,01127v_c a_p + 0,03502v_c v_b + 0,00005v_c Q + 0,00117v_c l_{t0} + 0,00542f_z a_e \\
& + 0,01033f_z a_p - 0,07577f_z v_b - 0,00805f_z Q + 0,00295f_z l_{t0} - 0,00548a_e a_p + 0,00492a_e v_b \\
& - 0,00173a_e Q - 0,00555a_e l_{t0} + 0,01014a_p v_b + 0,00392a_p Q - 0,00545a_p l_{t0} \quad (4.1)
\end{aligned}$$

$$\begin{aligned}
R_a(\mu m) = & 0,64308 + 0,01687v_c + 0,04606f_z + 0,00028a_e - 0,00091a_p + 0,13703v_b - 0,05352Q \\
& + 0,00714l_{t0} + 0,00596v_c^2 + 0,00671f_z^2 + 0,01652a_e^2 + 0,00220a_p^2 + 0,07950v_c f_z \\
& + 0,00352v_c a_e - 0,00352v_c a_p + 0,03089v_c v_b - 0,00191v_c Q - 0,00203v_c l_{t0} + 0,00206f_z a_e \\
& + 0,01097f_z a_p - 0,07319f_z v_b - 0,00186f_z Q - 0,00686f_z l_{t0} - 0,00158a_e a_p + 0,00430a_e v_b \\
& - 0,00791a_e Q + 0,00025a_e l_{t0} + 0,00711a_p v_b - 0,00022a_p Q - 0,00144a_p l_{t0} \quad (4.2)
\end{aligned}$$

4.3.3 Análise dos efeitos principais

A Figura 45 compara os efeitos principais das variáveis controláveis e incontroláveis no processo de fresamento de topo do aço inoxidável duplex sobre a rugosidade R_a , considerando o modelo preditivo baseado em aprendizagem de máquina (ML) e os dados experimentais reais. Os efeitos quadráticos estão relacionados às variáveis de controle e os efeitos lineares às variáveis de ruído. De modo geral, observa-se que o modelo de ML foi capaz de identificar como essas variáveis influenciam a rugosidade. Conforme apresentado nas Tabelas 16 e 17, as variáveis estatisticamente significativas incluem o avanço por dente (f_z), o desgaste de flanco (v_b), a vazão de fluido (Q) e a velocidade de corte (v_c).

Figura 45 – Comparação dos efeitos principais



Fonte: Própria

O modelo de aprendizagem de máquina identificou que a velocidade de corte (v_c) apresenta um efeito quadrático positivo sobre a rugosidade (R_a), em concordância com os dados experimentais. Isso significa que, à medida que a velocidade de corte aumenta, a rugosidade também tende a crescer. Esse comportamento pode ser explicado pelo fato de que, em baixas velocidades, pode ocorrer a formação de arestas postiças de corte, resultando em um aumento da rugosidade R_a . No entanto, em velocidades mais altas, a rotação da ferramenta se intensifica, favorecendo a geração de vibrações no processo e levando a um acabamento superficial inferior (KOYEE et al., 2014).

O avanço por dente (f_z) apresentou um efeito positivo na rugosidade, ou seja, à medida que o avanço aumenta, a rugosidade também tende a crescer. O modelo de aprendizagem de máquina conseguiu identificar essa tendência, o que pode ser explicado pelo aumento da força de corte e da deformação plástica da peça em níveis mais altos de avanço. Por outro lado, quando o avanço por dente é muito baixo, a qualidade da superfície pode ser comprometida devido ao efeito do riscamento. Nessa condição, a espessura do cavaco gerado pode ser insuficiente para um corte eficiente, fazendo com que a ferramenta deslize

sobre a superfície da peça em vez de removê-la adequadamente. Isso resulta no riscamento, no qual a ferramenta apenas esfrega contra a peça sem formar cavacos adequados (TOLEDO, 2018).

O desgaste de flanco (v_b) apresentou um efeito linear positivo, indicando que seu aumento resulta em uma elevação da rugosidade. Esse comportamento pode ser atribuído ao desgaste do raio de ponta da ferramenta, causado pela deformação plástica do material e pelas altas temperaturas geradas na interface ferramenta-cavaco. Esse efeito é especialmente significativo em materiais com alto grau de encruamento e baixa condutividade térmica, como os aços inoxidáveis duplex (DINIZ et al., 2014).

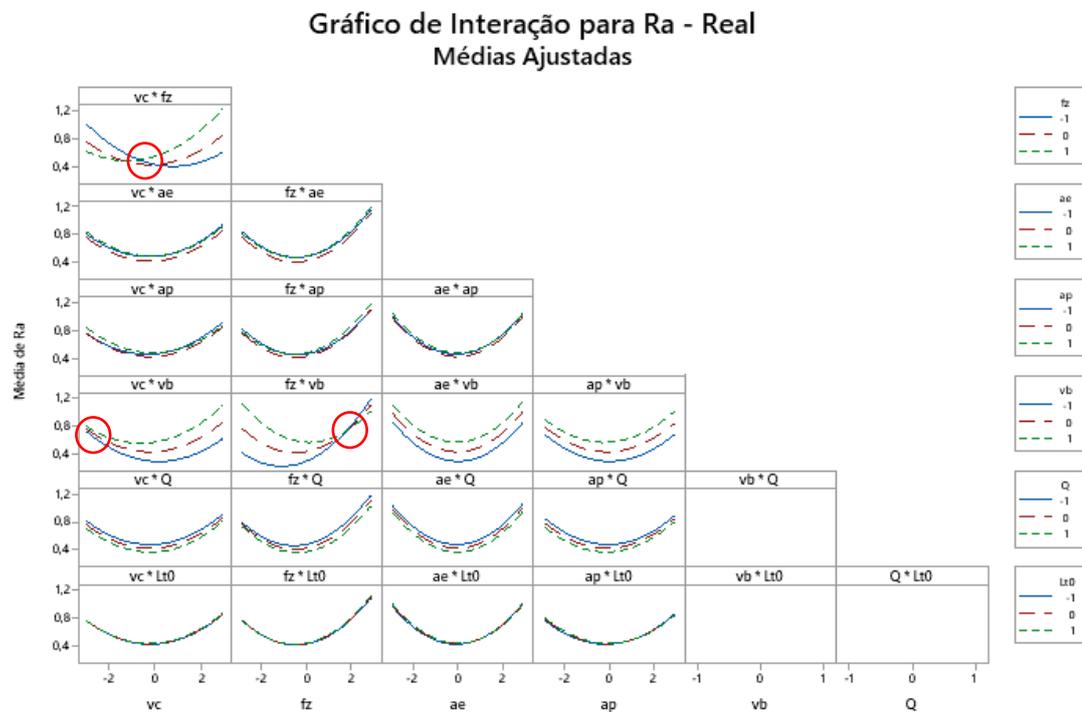
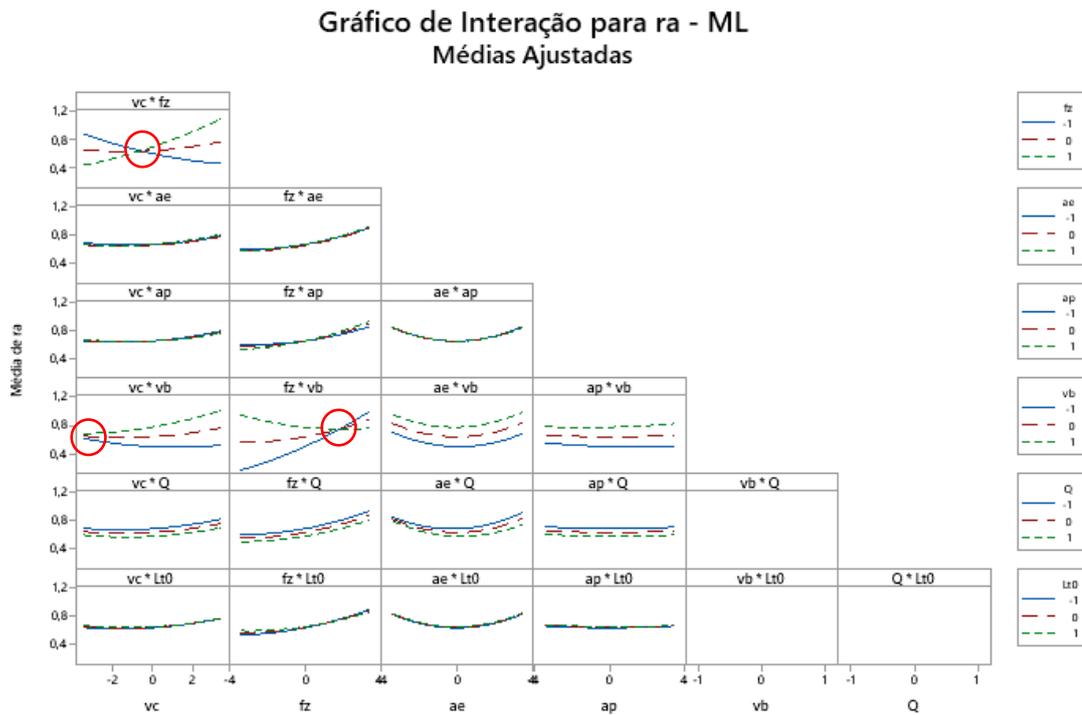
Por fim, a vazão de fluido (Q) demonstrou um efeito linear negativo, ou seja, o aumento da vazão contribui para a redução da rugosidade em ambos os modelos. Isso ocorre porque o fluido de corte auxilia na dissipação de calor e na remoção de cavacos na região cavaco-ferramenta, reduzindo o atrito e melhorando o acabamento superficial.

A comparação entre os gráficos mostra que o modelo baseado em aprendizagem de máquina conseguiu reproduzir com boa precisão os efeitos identificados experimentalmente.

4.3.4 Análise dos efeitos das interações

A Figura 46 apresenta o efeitos das interações para a rugosidade R_a . De acordo com as Tabelas 16 e 17, as interações significativas identificadas foram $v_c \times f_z$, $v_c \times v_b$ e $f_z \times v_b$. Observa-se que, assim como nos efeitos principais, o modelo de aprendizagem de máquina também foi capaz de identificar a influência das interações entre os parâmetros na rugosidade R_a .

Figura 46 – Comparação dos efeitos das interações



Fonte: Própria

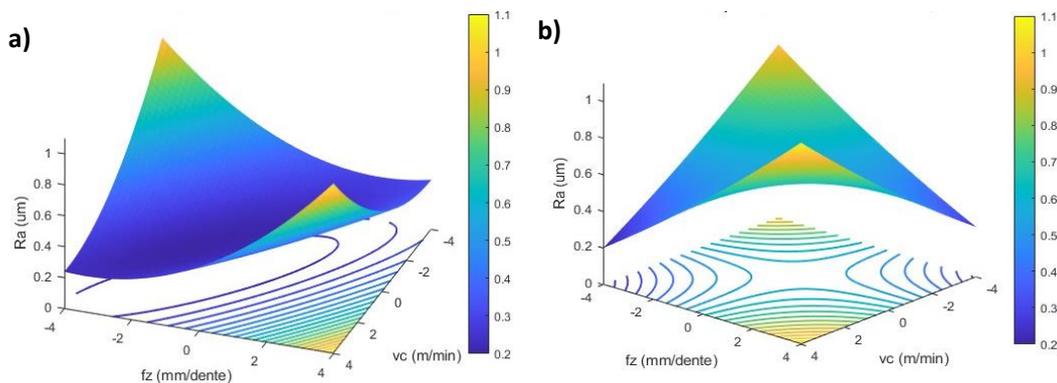
Analisando a interação $v_c \times f_z$ observa-se que, no modelo real, altas velocidades de corte combinadas com baixos avanços por dente resultam em uma menor rugosidade superficial. Esse comportamento foi corretamente capturado pelo modelo de aprendizado de máquina,

demonstrando sua capacidade de reconhecer padrões reais do processo. Além disso, o modelo identificou que, quando a velocidade de corte diminui e o avanço aumenta, a rugosidade também tende a diminuir. Esse efeito reflete a influência das condições de corte na qualidade da superfície usinada. Já para velocidades de corte médias e avanços médios, é possível observar uma tendência em que a rugosidade apresenta valores intermediários, sugerindo um equilíbrio entre os efeitos desses dois parâmetros. Isso reforça a precisão do modelo de aprendizado de máquina na captura das relações entre as variáveis do processo.

Na interação $v_c \times v_b$ o modelo identificou que é possível obter valores mais baixos de rugosidade quando a velocidade de corte é maior e o desgaste da ferramenta é menor. Por outro lado, também foi observado que, mesmo com diferentes níveis de desgaste, rugosidades menores podem ser alcançadas quando se utiliza uma velocidade de corte mais baixa.

Já na interação $f_z \times v_b$ o modelo identificou que as menores rugosidades ocorrem quando tanto o avanço por dente quanto o desgaste de flanco estão em níveis reduzidos. Além disso, um aspecto relevante capturado pelo modelo é que, à medida que o desgaste aumenta, a rugosidade tende a se elevar significativamente. Esse comportamento sugere que o controle rigoroso do desgaste da ferramenta é essencial para minimizar os impactos negativos na qualidade da superfície usinada. Os pontos vermelhos destacados indicam as regiões em que o processo de fresamento de topo do aço inoxidável duplex UNS 32205 demonstra maior robustez.

Uma análise semelhante pode ser realizada comparando as superfícies de resposta do modelo real e do modelo gerado por aprendizado de máquina. A Figura 47 apresenta a comparação entre a interação $v_c \times f_z$. Na Figura 47a é exibida a superfície de resposta do modelo de regressão real, enquanto a Figura 47b mostra a superfície de resposta do modelo gerado por aprendizado de máquina. Observa-se que a superfície gerada pelo modelo de aprendizado de máquina conseguiu representar com boa precisão o comportamento do processo real. Em altas velocidades de corte e avanços elevados, ocorre um aumento da rugosidade devido ao intenso encruamento do aço inoxidável duplex e à sua baixa condutividade térmica. Nessas condições, a geração de calor é elevada, agravando o endurecimento superficial e aumentando a adesão de material na ferramenta, o que compromete a qualidade da superfície usinada. Por outro lado, em menores velocidades de corte e avanços reduzidos, a rugosidade tende a diminuir, pois a geração de calor é menor, reduzindo o encruamento e minimizando o desgaste adesivo da ferramenta. Isso proporciona uma usinagem mais estável e melhora a qualidade superficial da peça.

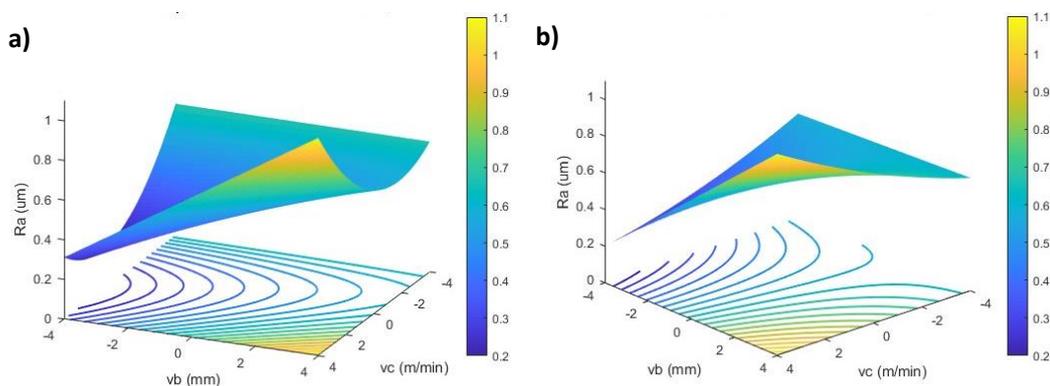
Figura 47 – Superfícies de resposta $v_c \times f_z$ - a) Real , b) ML

Fonte: Própria

Além da influência da interação entre velocidade de corte e avanço sobre a rugosidade, é importante avaliar o efeito do desgaste da ferramenta no acabamento superficial. Nesse contexto, a Figura 48 apresenta a comparação entre a interação $v_c \times v_b$. Na Figura 48a é exibida a superfície de resposta do modelo de regressão real, enquanto a Figura 48b mostra a superfície de resposta do modelo gerado por aprendizado de máquina.

É possível notar que o modelo de aprendizado de máquina conseguiu entender a relação entre o desgaste de flanco e a velocidade de corte, pois quando ocorre o aumento da velocidade de corte juntamente com o aumento do desgaste, há também um aumento da rugosidade. Isso ocorre porque, em velocidades mais altas, o atrito entre a ferramenta e a peça é intensificado, gerando maior calor e acelerando o desgaste da ferramenta. O aumento do desgaste de flanco reduz a integridade da aresta de corte, tornando-a menos eficiente e mais propensa a gerar irregularidades na superfície usinada. Além disso, a degradação da aresta ativa da ferramenta pode levar à formação de rebarbas e ao fenômeno de vibração, impactando negativamente a qualidade do acabamento superficial.

Por outro lado, quando o desgaste é menor e a velocidade de corte é reduzida, ocorre uma diminuição da rugosidade. Nessas condições, a ferramenta mantém sua aresta de corte mais íntegra por um período mais longo, garantindo uma remoção de material mais uniforme e estável. Além disso, a menor velocidade de corte reduz a geração de calor, minimizando os efeitos negativos do encruamento e do desgaste adesivo. Como resultado, a rugosidade superficial é reduzida, proporcionando um acabamento de melhor qualidade.

Figura 48 – Superfícies de resposta $v_c \times v_b$ - a) Real , b) ML

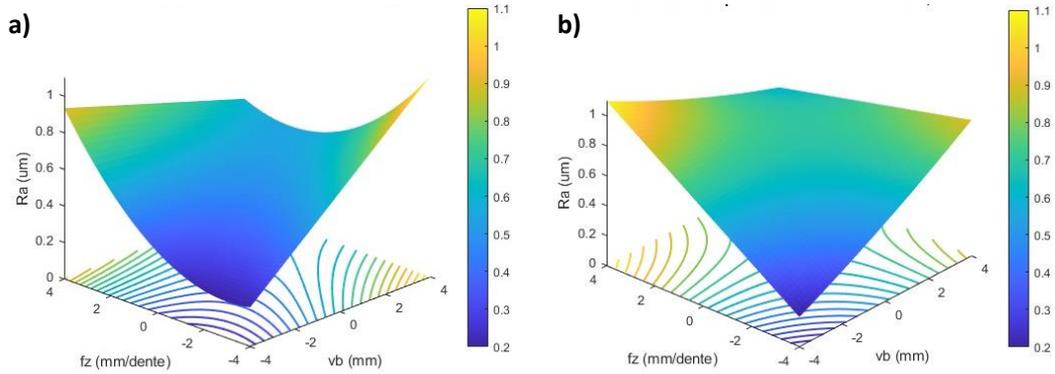
Fonte: Própria

Por fim, a Figura 49 apresenta a comparação entre a interação $f_z \times v_b$. Na Figura 49a é exibida a superfície de resposta do modelo de regressão real, enquanto a Figura 49b mostra a superfície de resposta do modelo gerado por aprendizado de máquina. Assim como nas análises anteriores, o modelo de aprendizado de máquina conseguiu reproduzir com elevada precisão o comportamento dos parâmetros do processo.

Observa-se que, quando o desgaste de flanco é nulo, ou seja, a ferramenta possui uma aresta de corte nova, combinada com baixos avanços, a rugosidade tende a ser reduzida. Isso pode ser explicado porque, nessas condições, a remoção de material ocorre de maneira mais controlada, minimizando a formação de irregularidades na superfície usinada e garantindo um acabamento de melhor qualidade.

À medida que o desgaste da ferramenta aumenta, mesmo com baixos avanços, verifica-se um aumento da rugosidade. Esse efeito pode ser atribuído à degradação da aresta de corte, que compromete sua capacidade de cisalhamento eficiente, favorecendo a formação de rebarbas e aumentando as forças de usinagem, o que resulta em uma superfície menos uniforme.

Esse comportamento se torna ainda mais evidente quando tanto o avanço quanto o desgaste da ferramenta são elevados. Nessas condições, há um aumento significativo do esforço de corte, resultando em maiores vibrações e instabilidades no processo. Como consequência, a rugosidade superficial se intensifica, uma vez que o desgaste excessivo pode levar à formação de arestas postiças e falhas no contato entre a ferramenta e a peça, deteriorando ainda mais a qualidade do acabamento.

Figura 49 – Superfícies de resposta $f_z \times v_b$ - a) Real , b) ML

Fonte: Própria

4.3.5 Otimização PSO

Conforme o fluxograma do método proposto Figura 28, este tópico apresenta a etapa de otimização do modelo de regressão obtido a partir da rede neural artificial (RNA) com arquitetura 7-20-14-1, descrito na Equação 4.2. O objetivo dessa otimização é identificar a combinação de parâmetros de usinagem que minimize a rugosidade média (R_a). Para tal finalidade, foi empregada a metaheurística *Particle Swarm Optimization* (PSO), amplamente utilizada na literatura para a otimização de processos de fresamento, conforme discutido anteriormente. No processo de otimização, foram consideradas exclusivamente as variáveis controláveis do modelo de regressão, a saber: velocidade de corte (v_c), avanço por dente (f_z), largura fresada (a_e) e profundidade de corte (a_p) conforme Equação 4.3.

Cabe destacar que, embora variáveis de ruído — como o desgaste de flanco (v_b), a altura em balanço da ferramenta (Lt_0) e a vazão do fluido de corte (Q) — tenham sido incorporadas durante a construção da matriz de experimentos, na análise dos resultados e no treinamento do modelo preditivo, a etapa de otimização considerou apenas os parâmetros controláveis. Essa decisão está em conformidade com a proposta de avaliar a robustez do modelo. Assim, o objetivo da otimização foi não apenas minimizar a rugosidade prevista pela função de aprendizado de máquina, mas também assegurar que o modelo seja capaz de absorver as variações inerentes ao processo produtivo, fornecendo respostas robustas e confiáveis.

$$\begin{aligned}
 R_a(\mu m) = & 0,64308 + 0,01687 \cdot v_c + 0,04606 \cdot f_z + 0,00028 \cdot a_e - 0,00091 \cdot a_p + 0,00596 \cdot v_c^2 \\
 & + 0,00671 \cdot f_z^2 + 0,01652 \cdot a_e^2 + 0,00220 \cdot a_p^2 + 0,07950 \cdot v_c \cdot f_z + 0,00352 \cdot v_c \cdot a_e \\
 & - 0,00352 \cdot v_c \cdot a_p + 0,00206 \cdot f_z \cdot a_e + 0,01097 \cdot f_z \cdot a_p - 0,00158 \cdot a_e \cdot a_p \quad (4.3)
 \end{aligned}$$

Para a execução da metaheurística Particle Swarm Optimization (PSO), foram definidas diferentes configurações de parâmetros conforme Tabela 18 a fim de realizar uma

análise de sensibilidade e avaliar o impacto das variações no comportamento do algoritmo. Os parâmetros testados foram:

Tabela 18 – Parâmetros utilizados nas simulações com o algoritmo PSO

Tamanho do Enxame	w	c₁	c₂	Interações
20	0,2	1,0	1,5	300
30	0,3	1,5	1,5	500
50	0,5	1,0	1,0	1000
70	0,7	2,0	2,0	800
100	0,9	2,5	2,5	400

Essas configurações foram escolhidas com base na literatura e têm como objetivo promover um equilíbrio entre exploração e convergência. Os limites inferiores e superiores para os parâmetros de corte utilizados na otimização foram definidos com base na região experimental aplicada no planejamento de experimentos (DOE), conforme segue:

- Velocidade de corte (v_c): 60 – 90 m/min
- Avanço por dente (f_z): 0,10 – 0,16 mm/dente
- Largura fresada (a_e): 15 – 18 mm
- Profundidade de corte (a_p): 0,8 – 1,2 mm

As restrições do processo de otimização foram estabelecidas com base nos limites inferiores e superiores dos parâmetros de corte definidos no planejamento experimental, bem como nos valores admissíveis para a rugosidade média, fixados entre 0,4 e 1,2 μm . O algoritmo PSO foi configurado de modo a explorar exclusivamente a região experimentalmente viável, assegurando que todas as partículas geradas durante o processo de otimização estivessem contidas dentro dos domínios definidos para cada variável. Essa abordagem garante que as soluções obtidas respeitem as condições operacionais do processo, mantendo coerência com os critérios técnicos e qualitativos adotados. Os resultados da otimização são apresentados na Tabela 19.

Tabela 19 – Resultados da otimização com PSO

v_c (m/min)	f_z (mm/dente)	a_e (mm)	a_p (mm)	R_a (μm)
67,270	0,158	16,840	0,816	0,6395

Ao comparar os resultados obtidos por meio da metaheurística *PSO*, aplicada à função de regressão gerada pelo modelo de Rede Neural Artificial (RNA), com os dados experimentais reportados por Vasconcelos (2022) que empregaram o método de otimização baseado no *Normal Boundary Intersection (NBI)*, utilizando o algoritmo *Generalized Reduced Gradient (GRG)* como otimizador observa-se uma notável concordância entre as

soluções encontradas. Essa proximidade entre os resultados reforça a capacidade preditiva do modelo desenvolvido neste trabalho, indicando que, mesmo com abordagens de otimização distintas, os valores ótimos tendem a convergir para uma mesma região do espaço de busca.

É importante destacar, contudo, que o valor de rugosidade superficial (R_a) previsto pela otimização com *PSO* de $-0,6395 \mu\text{m}$ é superior a alguns valores experimentais mínimos observados na base de dados, como $0,27 \mu\text{m}$ e $0,30 \mu\text{m}$. Essa discrepância não compromete a robustez da solução encontrada, pois o processo de otimização é conduzido sobre a superfície de resposta gerada pelo modelo de *RNA*, e não diretamente sobre os dados empíricos. Como o modelo preditivo representa uma função de regressão ajustada aos dados experimentais, ele pode atribuir menor relevância a pontos isolados ou atípicos da base, priorizando regiões do espaço de busca com maior densidade de amostras e comportamento mais consistente.

Adicionalmente, fatores como a suavização inerente à generalização da *RNA*, a distribuição não uniforme dos dados e a presença de variabilidade experimental contribuem para que o algoritmo *PSO* identifique, como ponto ótimo, uma condição considerada mais estável e representativa do comportamento global do processo mesmo que ela não corresponda ao menor valor pontual observado nos ensaios. Tal escolha favorece a obtenção de soluções robustas, menos sensíveis a flutuações ou ruídos, o que é especialmente desejável em ambientes industriais.

Por fim, ressalta-se que o valor de R_a otimizado situa-se dentro de uma faixa geralmente associada a processos de retificação, tradicionalmente reconhecidos pela elevada qualidade do acabamento superficial. Esse resultado evidencia não apenas a eficácia da função preditiva construída via aprendizado de máquina, mas também a competência do algoritmo *PSO* em identificar condições de usinagem capazes de promover excelente qualidade superficial, mesmo em operações como o fresamento, menos usuais para esse tipo de desempenho.

5 EXPERIMENTOS DE CONFIRMAÇÃO

Com o objetivo de verificar a eficácia tanto do modelo de regressão gerado por meio de aprendizado de máquina quanto da otimização realizada pela metaheurística Particle Swarm Optimization (PSO), foi conduzido um experimento de confirmação. Essa etapa visou validar a capacidade preditiva do modelo e a viabilidade prática dos parâmetros de usinagem otimizados.

O experimento foi desenvolvido com base nos procedimentos metodológicos apresentados na Figura 28. Para tal, foi elaborado um planejamento experimental do tipo Taguchi L9, com foco na análise da robustez do modelo frente às variações introduzidas por variáveis de ruído.

Durante os ensaios, os parâmetros controláveis, como velocidade de corte (v_c), avanço por dente (f_z), largura fresada (a_e) e profundidade de corte (a_p), foram mantidos fixos conforme os valores definidos como ótimos na Tabela 19. Já os níveis das variáveis de ruído, como desgaste de flanco (v_b), altura em balanço (l_{t0}) e vazão de fluido de corte (Q), foram combinados de acordo com a matriz ortogonal L9. A Tabela 20 apresenta esse arranjo experimental juntamente com os valores médios de rugosidade (R_a) obtidos para cada condição avaliada.

Após a realização de cada ensaio, a rugosidade superficial (R_a) foi medida em três posições distintas da peça usinada: início, meio e final da usinagem. A média desses três valores foi considerada como representativa da condição testada, proporcionando uma avaliação mais precisa do comportamento do processo diante das variações introduzidas pelas variáveis de ruído.

Tabela 20 – Matriz experimental Taguchi L9

Nº Exp	v_b (mm)	Q (l/min)	l_{t0} (mm)	R_a (μm)
1	0,00	0,0	30	0,664
2	0,00	0,2	40	0,622
3	0,00	20,0	50	0,588
4	0,15	0,0	40	0,673
5	0,15	0,2	50	0,667
6	0,15	20,0	30	0,656
7	0,30	0,0	50	0,772
8	0,30	0,2	30	0,713
9	0,30	20,0	40	0,686

Os resultados obtidos nos experimentos de confirmação demonstraram que os valores reais se aproximam significativamente das previsões teóricas. Verificou-se uma boa concordância entre os valores estimados pelo modelo de aprendizagem de máquina, aliado à otimização por PSO, e os dados experimentais, o que reforça a validade da metodologia

adotada. Assim, pode-se afirmar que a otimização do processo de fresamento de topo do aço inoxidável duplex UNS S32205, por meio da integração entre técnicas de aprendizagem de máquina e o algoritmo PSO, resultou em previsões confiáveis e desempenho robusto.

A fim de verificar a robustez do processo, foi empregada a estatística *t* de *Student* para uma amostra. Os resultados podem ser observados na Tabela 21. Verificou-se que a hipótese nula foi aceita, uma vez que o valor de p foi superior a 5%. Isso indica que a média da variável de resposta obtida nos ensaios de confirmação é estatisticamente igual à média prevista pelo modelo de regressão. Dessa forma, pode-se concluir que a robustez do processo foi confirmada.

Tabela 21 – Teste de Hipotese *t- Student*

Variável de resposta	Média	DesvPad	Teste de hipótese	IC (95%)	Valor-P
Ra	0.6712	0.0523	$H_0 = 0.64$ $H_1 \neq 0.64$	(0.6310 ; 0.7114)	0.111

Para avaliar a influência das variáveis de ruído sobre a variável de resposta, foi realizada uma análise de variância (ANOVA), adotando-se um nível de significância de 0,05. A Tabela 22 apresenta os valores de p associados às variáveis de ruído em relação à rugosidade média (R_a).

Como todos os valores de p foram superiores a 5%, infere-se que nenhuma das variáveis de ruído exerceu efeito estatisticamente significativo sobre a variável de resposta. Dessa forma, conclui-se que o processo de fresamento de topo do aço inoxidável duplex UNS S32205 apresenta robustez frente às perturbações consideradas.

Tabela 22 – Análise de Variância - Experimentos de Confirmação

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Vb	2	0.014838	0.007419	15.53	0.061
Q	2	0.005529	0.002765	5.79	0.147
Lt0	2	0.000538	0.000269	0.56	0.640
Erro		0.000956	0.000478		
Total	8	0.021861			

Os resultados apresentados neste tópico demonstram que a aplicação de modelos de aprendizado de máquina na previsão da rugosidade superficial (R_a) no processo de fresa-

mento de topo do aço inoxidável duplex possibilita a construção de um modelo estatisticamente significativo e capaz de apreender a influência conjunta das variáveis controláveis e incontroláveis sobre a resposta do processo. A otimização da função objetivo, realizada por meio do método metaheurístico *Particle Swarm Optimization* (PSO), mostrou-se altamente eficaz, conforme validado experimentalmente. A robustez do ponto ótimo identificado foi comprovada por meio do teste *t* de *Student* e da análise de variância (ANOVA), os quais indicaram que as variáveis de ruído — vazão de fluido de corte, desgaste do flanco da ferramenta e comprimento em balanço — não exerceram influência estatisticamente significativa sobre a variável de resposta neste ponto de operação.

É relevante destacar que, em vez de realizar uma nova rodada de experimentação baseada em planejamento tradicional, optou-se por validar o modelo previamente treinado, o que reforça a capacidade de generalização das redes neurais utilizadas e sua aplicabilidade prática ao contexto fabril. Essa abordagem, além de tecnicamente consistente, promove uma racionalização do processo experimental, reduzindo o uso de insumos e contribuindo para práticas mais sustentáveis em pesquisa aplicada.

A ausência de significância estatística dos ruídos no ponto ótimo apresenta implicações relevantes do ponto de vista operacional. Por exemplo, a vazão do fluido de corte, embora tenha apresentado tendência de redução da rugosidade ao longo dos ensaios, mostrou-se desnecessária como fator de compensação no regime otimizado, o que abre margem para a minimização do uso de fluido refrigerante sem prejuízo à qualidade superficial. Isso contribui para a redução dos custos operacionais, além de atender a diretrizes de manufatura sustentável, considerando os impactos ambientais associados ao descarte e tratamento de fluidos.

Da mesma forma, o desgaste do flanco da ferramenta e o comprimento em balanço — variáveis críticas para a estabilidade do processo e vida útil da ferramenta — não afetaram significativamente a rugosidade no ponto otimizado, indicando que os parâmetros de corte definidos promovem uma condição de usinagem estável, mesmo diante de degradações naturais do sistema. Tal robustez pode refletir-se diretamente em maior vida útil do ferramental, menor frequência de ajustes e troca de ferramentas, e redução de peças rejeitadas por inconsistência dimensional ou superficial.

Além dos benefícios diretos ao processo produtivo, destaca-se que a metodologia baseada em aprendizado de máquina contribui, por si só, para uma abordagem mais eficiente e sustentável no desenvolvimento de experimentos. Ao evitar experimentações excessivas e focar em validações pontuais, essa estratégia reduz significativamente o consumo de energia, matéria-prima e fluido de corte durante a fase de modelagem e otimização — aspectos que também devem ser considerados sob a ótica da sustentabilidade em pesquisa aplicada.

Em síntese, os resultados não apenas atestam a robustez estatística do modelo, mas evidenciam sua viabilidade técnica e econômica para aplicação industrial, uma vez que

permitem a definição de condições operacionais eficientes, ambientalmente mais responsáveis e alinhadas aos princípios da usinagem inteligente.

6 CONCLUSÃO

Esta pesquisa apresentou uma contribuição significativa para a aplicação de técnicas de aprendizado de máquina e métodos de otimização no processo de fresamento de topo do aço inoxidável duplex UNS S32205. O objetivo central foi o desenvolvimento de modelos preditivos capazes de estimar a rugosidade superficial (R_a) a partir de variáveis tanto controláveis quanto incontroláveis do processo, abordagem ainda pouco explorada na literatura especializada.

A revisão sistemática da literatura revelou que a maioria dos estudos concentra-se exclusivamente em variáveis controláveis na construção de modelos preditivos. Com base nessa lacuna, este trabalho propôs uma abordagem inovadora ao integrar variáveis de ruído (incontroláveis) na modelagem, ampliando a representatividade dos modelos e aumentando sua robustez frente às variabilidades inerentes ao ambiente de usinagem.

Os principais resultados obtidos foram:

- Todos os modelos preditivos apresentaram desempenho satisfatório na previsão da rugosidade superficial (R_a), com destaque para os modelos baseados em redes neurais artificiais (RNA), que superaram as abordagens tradicionais;
- Arquiteturas mais complexas de RNA não trouxeram ganhos estatisticamente relevantes sobre configurações mais simples, indicando que estruturas enxutas podem ser tão eficazes quanto;
- Embora os modelos DTR e RF tenham alcançado RMSE de 0,066 e 0,031 μm , respectivamente, e o SVM obtido validação cruzada de $R^2 = 0,80$, a RNA 7-20-14-1 apresentou desempenho superior, com $R^2 = 0,92$, RMSE = 0,06 μm e R^2 médio = 0,90;
- Os valores previstos pela RNA foram bastante próximos dos observados experimentalmente, com uma diferença média inferior a 9,7%, reforçando sua capacidade de previsão precisa em regime industrial;
- A RNA 7-20-14-1 destacou-se como o modelo com maior capacidade de generalização, com $R_{aj}^2 = 93,91\%$;
- A variável desgaste do flanco (v_b) foi a que mais influenciou a rugosidade, demonstrando a habilidade dos modelos de capturar relações complexas do processo;
- Os gráficos de superfície de resposta e interação gerados refletiram com fidelidade os resultados experimentais;

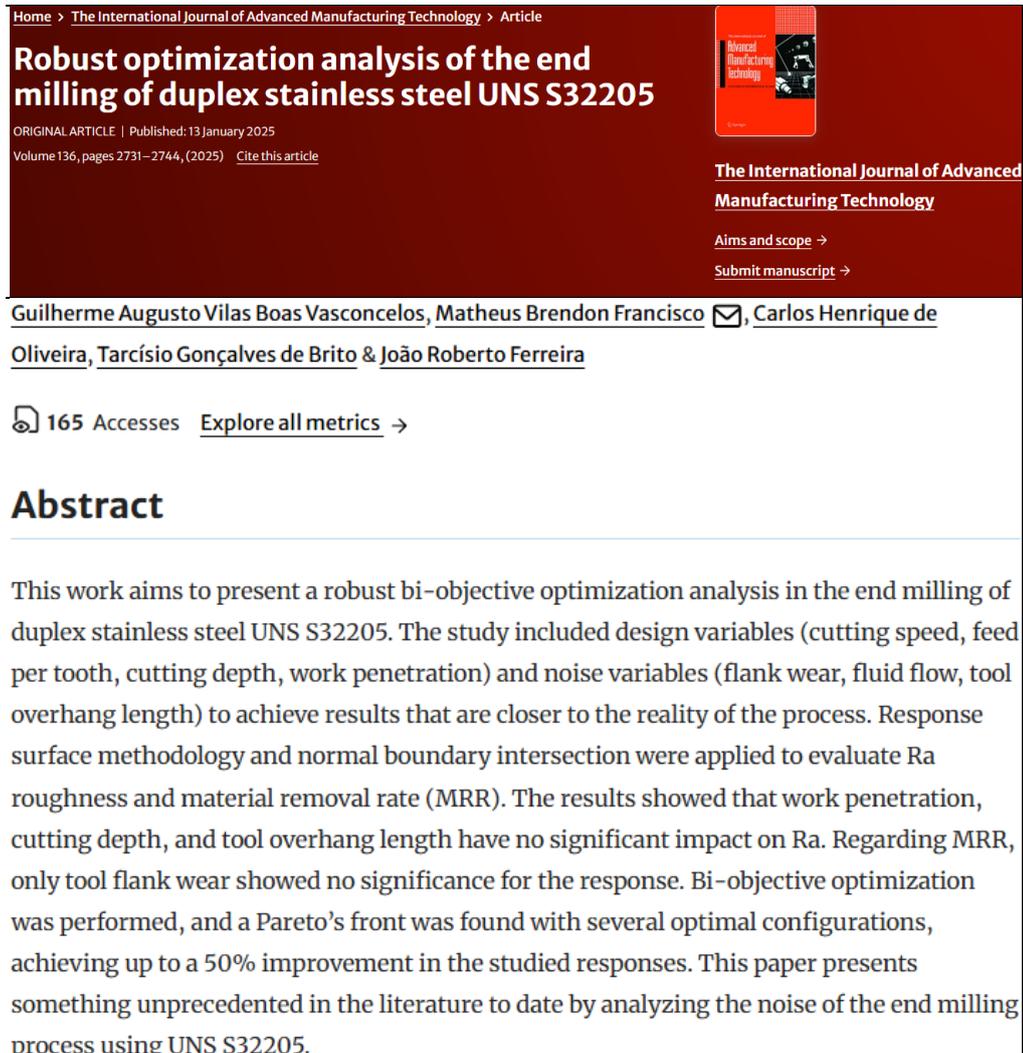
- A otimização com o algoritmo PSO resultou em parâmetros que geraram R_a entre 0,60 e 0,65 μm — valores consistentes com estudos anteriores (VASCONCELOS et al., 2022), confirmando a eficácia da estratégia;
- O experimento de confirmação validou a solução otimizada com alta precisão, demonstrando que é possível empregar modelos de aprendizado de máquina como suporte à tomada de decisão na usinagem, utilizando apenas um experimento de verificação.

Essa constatação representa um avanço metodológico relevante, pois reduz significativamente a necessidade de testes extensivos, contribuindo diretamente para a redução de custos com insumos, ferramentas, tempo de máquina e energia. Além disso, abre perspectivas para minimização do uso de fluido de corte, uma vez que, no ponto ótimo identificado, as variáveis de ruído — incluindo vazão, desgaste do flanco e comprimento em balanço — não apresentaram efeitos estatisticamente significativos. Tal robustez operacional viabiliza práticas mais sustentáveis, tanto do ponto de vista técnico quanto ambiental.

Em síntese, os resultados desta pesquisa demonstram que a integração entre aprendizado de máquina, variáveis de ruído e métodos de otimização é uma estratégia promissora para modelar e otimizar processos de manufatura de forma robusta, confiável, sustentável e economicamente viável.

7 PUBLICAÇÕES

Figura 50 – Artigo 1



Home > [The International Journal of Advanced Manufacturing Technology](#) > Article

Robust optimization analysis of the end milling of duplex stainless steel UNS S32205

ORIGINAL ARTICLE | Published: 13 January 2025
Volume 136, pages 2731–2744, (2025) [Cite this article](#)

[The International Journal of Advanced Manufacturing Technology](#)
[Aims and scope](#) →
[Submit manuscript](#) →

[Guilherme Augusto Vilas Boas Vasconcelos](#), [Matheus Brendon Francisco](#) ✉, [Carlos Henrique de Oliveira](#), [Tarcísio Gonçalves de Brito](#) & [João Roberto Ferreira](#)

 165 Accesses [Explore all metrics](#) →

Abstract

This work aims to present a robust bi-objective optimization analysis in the end milling of duplex stainless steel UNS S32205. The study included design variables (cutting speed, feed per tooth, cutting depth, work penetration) and noise variables (flank wear, fluid flow, tool overhang length) to achieve results that are closer to the reality of the process. Response surface methodology and normal boundary intersection were applied to evaluate Ra roughness and material removal rate (MRR). The results showed that work penetration, cutting depth, and tool overhang length have no significant impact on Ra. Regarding MRR, only tool flank wear showed no significance for the response. Bi-objective optimization was performed, and a Pareto's front was found with several optimal configurations, achieving up to a 50% improvement in the studied responses. This paper presents something unprecedented in the literature to date by analyzing the noise of the end milling process using UNS S32205.

Figura 51 – Artigo 2

The International Journal of Advanced Manufacturing Technology
<https://doi.org/10.1007/s00170-024-13955-4>

CRITICAL REVIEW



Prediction of surface roughness in duplex stainless steel face milling using artificial neural network

Guilherme Augusto Vilas Boas Vasconcelos¹ · Matheus Brendon Francisco² · Lucas Ribeiro Alves da Costa² · Ronny Francis Ribeiro Junior¹ · Mirian de Lourdes Noronha Motta Melo¹

Received: 26 February 2024 / Accepted: 29 May 2024

© The Author(s), under exclusive licence to Springer-Verlag London Ltd., part of Springer Nature 2024

Abstract

This study proposes the inclusion of noise variables in an experimental design to develop a predictive model of surface roughness in the face milling process of duplex stainless steel. A central composite design arrangement was conducted, incorporating controlled variables (cutting speed, feed rate, milling width, and depth of cut) and noise variables (tool flank wear, fluid flow, and protrusion length). Each experimental configuration was employed in duplex stainless steel milling, with the collection of roughness data under each condition. The collected data were used to train eight configurations of artificial neural networks, which were then applied to predict roughness. The results indicate that the 7-20-14-1 network configuration exhibited the lowest root mean square error, which is a measure of the difference between predicted and observed values of (0.063), followed by 7-64-32-1 (0.064) and 7-14-12-1 (0.068), respectively. Additionally, these configurations also demonstrated the lowest mean absolute error values, which calculate the average of the absolute differences between predicted and observed values of (0.046, 0.053, and 0.055, respectively), and the coefficient of determination, which is a statistical measure indicating the proportion of data variability explained by the statistical model of (0.914, 0.908, and 0.901, respectively). Therefore, the inclusion of noise variables alongside controllable process factors resulted in a more accurate and robust predictive model of surface roughness for duplex stainless steel face milling.

Keywords Machining · Artificial intelligence · Mean square error · Surface quality · Robust parameter design

1 Introduction

Duplex stainless steels (DSS) are applied in varied industrial sectors, due to their exceptional properties, which combine remarkable mechanical characteristics, such as high strength and hardness, with an effective resistance to corrosion. These properties give DSS a wide range of possible uses, especially in the petroleum, chemical, and energy industry segments.

Stainless steels often exhibit a distinct machining behavior compared to other types of steel. They are mainly notable for their high hardening rates, which results in mechanical modifications and heterogeneous behavior on the machined surfaces, leading to the formation of unstable chips and vibrations. They

have low thermal conductivity, resulting in higher temperatures at the interfaces between the tool and the chip, as well as between the tool and the workpiece [1]. These characteristics contribute to more pronounced wear of the cutting tools and impair the quality of the machined surface finish [2].

In this context, the quality of the machined surface plays a critical role in evaluating the standard of excellence of the products. The measurement of surface roughness (Ra) is often employed as an essential metric to measure surface condition in machining operations [3]. Modeling techniques for Ra prediction can be categorized into three groups: experimental models, analytical models, and artificial intelligence (AI)-based models [4]. In recent times, models driven by artificial intelligence have emerged as the primary option and are widely adopted by researchers in the design of predictions related to machining processes. Several authors have employed artificial neural networks (ANNs) to predict surface roughness in machining operations [5].

The study by Thangarasu et al. [6] developed an artificial neural network model to predict surface roughness in the

✉ Guilherme Augusto Vilas Boas Vasconcelos
guilhermevasconcelos01@yahoo.com.br

¹ Mechanical Engineering Institute, Federal University of Itajubá–UNIFEI, Itajubá, Brazil

² Production and Management Engineering Institute, Federal University of Itajubá–UNIFEI, Itajubá, Brazil

Figura 52 – Artigo 3

The International Journal of Advanced Manufacturing Technology
<https://doi.org/10.1007/s00170-024-14290-4>

ORIGINAL ARTICLE



Prediction of surface roughness in duplex stainless steel top milling using machine learning techniques

Guilherme Augusto Vilas Boas Vasconcelos¹ · Matheus Brendon Francisco² · Carlos Henrique de Oliveira² · Elioenai Levi Barbedo¹ · Luiz Gustavo Paes de Souza² · Mirian de Lourdes Noronha Motta Melo¹

Received: 3 July 2024 / Accepted: 12 August 2024
 © The Author(s), under exclusive licence to Springer-Verlag London Ltd., part of Springer Nature 2024

Abstract

This study presents an innovative approach to predicting the quality of finished parts in top milling processes by integrating robust parameter design with artificial intelligence techniques. A central composite design was used to combine controllable variables (cutting speed, tooth advance, milled width, and cutting depth) with noise variables (tool flank wear, fluid flow, and cantilevered length). Duplex stainless steel was milled under each experimental setup, and roughness data were collected. These data were used to train three machine learning models: random forest, decision tree, and support vector machine. The models predicted surface roughness, and their predictions were validated through experimental tests. The root means square error values were 0.031 for the random forest, 0.038 for the decision tree, and 0.066 for the support vector machine, indicating that the random forest model performed the best. This innovative study highlights the importance of including noise variables along with controllable factors in machine learning models, significantly improving prediction accuracy and making them more reflective of real-world results. Including these variables is crucial, as neglecting them can lead to inaccurate predictions.

Keywords Design of experiments · Artificial Intelligence · Surface quality · Robust parameter design

1 Introduction

Duplex stainless steels are widely used in various industries due to their balanced combination of ferrite and austenite, giving them desirable properties such as ductility, toughness, and resistance to stress corrosion [24]. However, machining these alloys is challenging due to their low machinability, which results in problems such as crunching, low thermal conductivity, and high strength, leading to tool wear and compromise of workpiece integrity. These stainless-steel alloys are widely used in various industrial fields such as automotive, aerospace, medical, chemical, and petrochemical [37].

Milling is a subtractive machining process that uses a rotating tool to cut flat surfaces. There are two main milling

methods: up milling and down milling. In down milling, the cutting tool and the workpiece rotate in the same direction, which eliminates the possibility of chatter, as the tool's teeth cut into the workpiece and deposit the cut chips behind the cutter. The chip thickness starts at its maximum and decreases as the cut progresses. Due to the complexity of machining duplex stainless steels, down milling methods often do not provide the required level of finish. CNC machining (up milling) stands out as a superior alternative, offering much higher surface quality and finish compared to traditional methods and is widely used in modern industry for producing mechanical parts with high precision and quality [26].

In the context of milling, surface quality monitoring is essential due to the significant investment of time and money in this process. The average surface roughness, measured by the R_a parameter, plays a crucial role in the esthetics of the products, as well as in the resistance to corrosion, fatigue, and tribological properties. The R_a value is influenced by several factors, such as feed rate, cutting speed, cutting depth, tool geometry, tool wear, temperature, and false edge formation.

✉ Guilherme Augusto Vilas Boas Vasconcelos
guilhermevasconcelos01@yahoo.com.br

¹ Mechanical Engineering Institute, Federal University of Itajubá – UNIFEI, Itajubá, Brazil

² Production and Management Institute, Federal University of Itajubá – UNIFEI, Itajubá, Brazil

Figura 53 – Artigo 4

The International Journal of Advanced Manufacturing Technology
<https://doi.org/10.1007/s00170-024-13951-8>

ORIGINAL ARTICLE



Roughness prediction using machine learning models in hard turning: an approach to avoid rework and scrap

Luiz Gustavo Paes de Souza¹ · Guilherme Augusto Vilas Boas Vasconcelos² · Lucas Alves Ribeiro Costa¹ · Matheus Brendon Francisco¹ · Anderson Paulo de Paiva¹ · João Roberto Ferreira¹

Received: 1 February 2024 / Accepted: 29 May 2024

© The Author(s), under exclusive licence to Springer-Verlag London Ltd., part of Springer Nature 2024

Abstract

In recent years, the effectiveness of integrating machine learning methods to predict surface roughness in machining processes has become well-established. However, there is a noticeable gap in the literature concerning the inclusion of tool wear as an input variable. In this context, this study proposed an innovative approach by including tool flank wear as an input variable along with cutting speed, feed rate, and depth of cut to train three machine learning models: Decision Tree Regression, Random Forest, and Support Vector Regression. These models aim to predict surface roughness during the dry turning of hardened AISI 52100 steel. As a result, all three models exhibited high prediction accuracy, with *R*-squared values exceeding 90% and lower values for both the Mean Absolute Error (MAE) and Root Mean Square Error (RMSE). However, the Random Forest model outperformed the others, boasting the lowest RMSE and MAE values of 0.05 and 0.038, respectively, alongside the highest *R*-squared value of 0.91. The confirmation runs demonstrated the accuracy of the Random Forest model, with actual roughness values very close to those predicted (variation of $\pm 0.01 \mu\text{m}$). The correlation analysis revealed that roughness is correlated with feed rate and flank wear. This outcome underscores the importance of including tool wear as an input variable for roughness modeling. Since roughness prediction depends on the tool wear level, it is feasible to forecast the roughness of parts machined using the same cutting edge until flank wear reaches 0.30 mm (end of life). By anticipating and understanding roughness behavior as wear progresses, decision-makers can choose cutting configurations that ensure parts meet specifications, thus avoiding rework and scrap.

Keywords Sustainable machining · Hard turning · Machine learning · Surface roughness · Flank wear

✉ Luiz Gustavo Paes de Souza
 luizpaesp@gmail.com

Guilherme Augusto Vilas Boas Vasconcelos
 guilhermevasconcelos01@yahoo.com.br

Lucas Alves Ribeiro Costa
 lucas.ribeirocosta@hotmail.com

Matheus Brendon Francisco
 matheus_brendon@unifei.edu.br

Anderson Paulo de Paiva
 andersonppaiva@unifei.edu.br

João Roberto Ferreira
 jorofe@unifei.edu.br

¹ Institute of Industrial Engineering and Management, Federal University of Itajubá, 1303 BPS Avenue, Itajubá 37500-903, MG, Brazil

² Mechanical Engineering Institute, Federal University of Itajubá, 1303 BPS Avenue, Itajubá 37500-903, MG, Brazil

1 Introduction

Hard turning is the machining process of materials with hardness in the range of 45 to 68 HRC, and it has been employed in the industry since the 1980s as a finishing or semi-finishing process or as a hybrid process associated with grinding [1]. When considering hard turning as a finishing step, the process must be capable of producing parts with high-quality surface finishes, as the achieved surface finish will decisively influence the functional behavior and lifespan of the machined part [2]. When machining high-performance metals, such as superalloys and hardened steels, the surface finish quality becomes crucial because these metals are widely used to manufacture high-performance components in the aerospace and automotive industries [3].

Surface roughness has often been used to evaluate the quality of the finish [4, 5]. It plays a significant role in the functionality of the machined surface as it influences the

Figura 54 – Artigo 5

**Otimização do Processo de Fresamento de Topo no Aço Inoxidável Duplex por meio de Inteligência Artificial****Matheus Brendon Francisco**

Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
matheus_brendon@unifei.edu.br

Deborah Borges da Silva

Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
deborahborgessilva@unifei.edu.br

Guilherme Augusto Vilas Boas Vasconcelos

Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
d2020102469@unifei.edu.br

Giovana Carla da Silva Moraes

Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
giovana.moraes.ismart@gmail.com

Carlos Henrique de Oliveira

Universidade Federal de Itajubá (UNIFEI)
Av. BPS, 1303, Pinheirinho, Itajubá – MG.
carlos.henrique@unifei.edu.br

RESUMO

O fresamento de topo do aço inoxidável duplex UNS S32205 apresenta desafios significativos devido à complexidade de controlar a rugosidade da superfície resultante. Encontrar os parâmetros ideais de usinagem é crucial para garantir a qualidade final das peças e a eficiência do processo. Neste estudo, foi utilizado um Modelo Preditivo baseado em uma Rede Neural Artificial para otimizar os parâmetros de usinagem, como velocidade de corte, avanço por dente, largura fresada e profundidade de corte. A meta-heurística Particles Swarm Optimization foi aplicada para determinar o ponto ótimo do processo, visando a menor rugosidade superficial. A combinação dos parâmetros ótimos resultou em uma rugosidade de $R_a = 0.5913637 \mu\text{m}$. Além disso, foi realizada uma análise da influência de ruídos no ponto ótimo, revelando que fatores incontroláveis têm um impacto significativo no processo e devem ser considerados durante a análise.

PALAVRAS-CHAVE. Meta-heurística, Particle Swarm Optimization (PSO), Redes Neurais Artificiais, Rugosidade Superficial.

Tópicos. Meta-heuristics, Combinatorial Optimization, Computational Intelligence,

Figura 55 – Certificado de Registro de Programa de Computador



REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA, COMÉRCIO E SERVIÇOS
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512024002260-0**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 02/04/2024, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: SOFTWARE PARA PREVISÃO DA RUGOSIDADE NO PROCESSO DE FRESAMENTO DO AÇO INOXIDÁVEL DUPLEX UNS S32205

Data de publicação: 02/04/2024

Data de criação: 10/11/2023

Titular(es): UNIFEI - UNIVERSIDADE FEDERAL DE ITAJUBÁ

Autor(es): MATHEUS BRENDON FRANCISCO; MIRIAN DE LOURDES NORONHA MOTTA MELO; GUILHERME AUGUSTO VILAS BOAS VASCONCELOS; RONNY FRANCIS RIBEIRO JUNIOR

Linguagem: PYTHON

Campo de aplicação: IN-03; IN-05

Tipo de programa: IA-01; IA-02; TC-03

Algoritmo hash: SHA-256

Resumo digital hash: 33639c487ac1821e741c7236189545176811550010af23cf2a1593b420254952

Expedido em: 09/07/2024

Aprovado por:
Carlos Alexandre Fernandes Silva
Chefe da DIPTO



REFERÊNCIAS

- ABBAS, A. T. et al. Effect of different cooling strategies on surface quality and power consumption in finishing end milling of stainless steel 316. *Materials*, MDPI, v. 14, n. 4, p. 903, 2021. Citado 2 vezes nas páginas 19 e 32.
- ABNT, N. 4287 especificações geométricas do produto (gps)-rugosidade: Método do perfil-termos, definições e parâmetros da rugosidade. *Associação Brasileira de Normas Técnicas*, 2002. Citado na página 35.
- AFANADOR, N. L. et al. Unsupervised random forest: a tutorial with case studies. *journal of Chemometrics*, Wiley Online Library, v. 30, n. 5, p. 232–241, 2016. Citado na página 46.
- AGOSTINHO, O. L.; RODRIGUES, A. C. S.; LIRANI, J. *Tolerâncias, Ajustes, Desvios e Análise de Dimensões*. São Paulo: Editora Edgard Blücher, 2004. Citado na página 34.
- ALBUQUERQUE, R. M. d. Redes de petri coloridas para representação do conhecimento e aprendizado de redes neurais artificiais. 2023. Citado 5 vezes nas páginas 47, 48, 52, 53 e 55.
- ALLEN, D. M. The relationship between variable selection and data augmentation and a method for prediction. *technometrics*, Taylor & Francis, v. 16, n. 1, p. 125–127, 1974. Citado na página 56.
- ALVAREZ-ARMAS, I. Duplex stainless steels: brief history and some recent alloys. *Recent Patents on Mechanical Engineering*, Bentham Science Publishers, v. 1, n. 1, p. 51–57, 2008. Citado na página 27.
- ALVIM, A. C. et al. Otimização robusta no torneamento de cabeças femorais para artroplastia de quadril: uma análise comparativa de ferramentas. Universidade Federal de Itajubá, 2023. Citado 2 vezes nas páginas 67 e 73.
- AMARO, P.; FERREIRA, P.; SIMÕES, F. Comparative analysis of different cutting milling strategies applied in duplex stainless steel. *Procedia Manufacturing*, Elsevier, v. 47, p. 517–524, 2020. Citado 3 vezes nas páginas 31, 32 e 55.
- AMORIM, H. J. d. Estudo da relação entre velocidade de corte, desgaste de ferramenta, rugosidade e forças de usinagem em torneamento com ferramenta de metal duro. 2002. Citado na página 34.
- ARA RAYDONAL OSPINA, M. M. A. *Modelos de Vetores de Suporte: Uma Introdução ao Aprendizado Estatístico de Máquina*. [S.l.], 2023. 24 a 28 de Julho de 2023, CC BY NC ND. Citado 2 vezes nas páginas 38 e 39.
- ARRUDA, É. M. et al. Robust optimisation of surface roughness of aisi h13 hardened steel in the finishing milling using ball nose end mills. *Precision Engineering*, Elsevier, v. 60, p. 194–214, 2019. Citado 2 vezes nas páginas 72 e 89.

- ASLAN, A. Machine learning models and machinability analysis for comparison of various cooling and lubricating mediums during milling of hardox 400 steel. *Tribology International*, Elsevier, p. 109860, 2024. Citado na página 19.
- BANDA, T. et al. A machine learning model for flank wear prediction in face milling of inconel 718. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 126, n. 3, p. 935–945, 2023. Citado na página 19.
- BEAM, A. L.; KOHANE, I. S. Big data and machine learning in health care. *Jama*, American Medical Association, v. 319, n. 13, p. 1317–1318, 2018. Citado na página 36.
- BELGIU, M.; DRĂGUTȚ, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, Elsevier, v. 114, p. 24–31, 2016. Citado na página 46.
- BELÍCIO, A. S.; DINIZ, B. d. C.; JÚNIOR, R. C. S. F. Development of probabilistic constant life diagrams using modular networks. *Journal of Composite Materials*, SAGE Publications Sage UK: London, England, v. 50, n. 12, p. 1661–1669, 2016. Citado na página 54.
- BENESTY, J.; CHEN, J.; HUANG, Y. On the importance of the pearson correlation coefficient in noise reduction. *IEEE Transactions on Audio, Speech, and Language Processing*, IEEE, v. 16, n. 4, p. 757–765, 2008. Citado na página 81.
- BERGUIGA, T.; BOUMERZOUG, Z. Effect of sigma phase precipitation on mechanical behavior and pitting corrosion of duplex stainless steel. *Acta Metallurgica Slovaca*, v. 25, n. 1, p. 4–17, 2019. Citado na página 88.
- BHISE, V. Y.; JOGI, B. F. Experimental investigation and theoretical modelling of p20 steel by using cnc end milling machining process. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2021. v. 1854, n. 1, p. 012011. Citado na página 25.
- BIN, J. et al. A modified random forest approach to improve multi-class classification performance of tobacco leaf grades coupled with nir spectroscopy. *RSC advances*, Royal Society of Chemistry, v. 6, n. 36, p. 30353–30361, 2016. Citado na página 47.
- BINALI, R. et al. Machinability investigations based on tool wear, surface roughness, cutting temperature, chip morphology and material removal rate during dry and mql-assisted milling of nimax mold steel. *Lubricants*, MDPI, v. 11, n. 3, p. 101, 2023. Citado na página 17.
- BORBA, M. F. *Análise da generalização de algoritmos de machine learning e suas aplicações na otimização de decisões em saúde*. Tese (Doutorado) — Universidade de São Paulo, 2023. Citado 2 vezes nas páginas 59 e 60.
- BORRA, S.; CIACCIO, A. D. Measuring the prediction error. a comparison of cross-validation, bootstrap and covariance penalty methods. *Computational statistics & data analysis*, Elsevier, v. 54, n. 12, p. 2976–2989, 2010. Citado na página 57.
- BOX, G. et al. Some problems associated with the analysis of multiresponse data. *Technometrics*, Taylor & Francis, v. 15, n. 1, p. 33–51, 1973. Citado na página 66.
- BOX, G. E.; DRAPER, N. R. Response surfaces. *Mixtures, and Ridge Analyses*, Springer, v. 649, 2007. Citado na página 65.

- BOYLAN, G. L.; GOETHALS, P. L.; CHO, B. R. Robust parameter design in resource-constrained environments: an investigation of trade-offs between costs and precision within variable processes. *Applied Mathematical Modelling*, Elsevier, v. 37, n. 4, p. 2394–2416, 2013. Citado na página 69.
- BRAGA, A. d. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. d. L. F. d. Redes neurais artificiais: teoria e aplicações. 2000. Citado 3 vezes nas páginas 47, 49 e 53.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, p. 5–32, 2001. Citado 3 vezes nas páginas 45, 46 e 47.
- BREIMAN, L. et al. Classification and regression trees. wadsworth & brooks. *Cole Statistics/Probability Series*, 1984. Citado 3 vezes nas páginas 42, 44 e 45.
- BRITO, T. et al. Optimization of aisi 1045 end milling using robust parameter design. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 84, p. 1185–1199, 2016. Citado na página 71.
- BUSTILLO, A. et al. Machine-learning for automatic prediction of flatness deviation considering the wear of the face mill teeth. *Journal of Intelligent Manufacturing*, Springer, v. 32, n. 3, p. 895–912, 2021. Citado na página 19.
- CÂMARA, E. C. B. Estudo do comportamento à fadiga de cabos condutores de energia com alma de alumínio utilizando redes neurais artificiais. Universidade Federal do Rio Grande do Norte, 2020. Citado 2 vezes nas páginas 49 e 53.
- CANIÇALI, J. Efeito do raio de ponta da ferramenta e dos parâmetros de corte no fresamento de topo do aço inoxidável duplex dx 2205. 2022. Citado na página 28.
- CARVALHO, J. J. d. *Efeito da frequência de pulsação na manufatura aditiva por DED-GTA do aço inoxidável AISI 308L*. Tese (Doutorado) — Universidade de São Paulo, 2024. Citado na página 28.
- CHANG, C.-C. Libsvm: a library for support vector machines, 2001. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 2001. Citado na página 41.
- CHEN, C.-H.; LIU, T.-K.; CHOU, J.-H. A novel crowding genetic algorithm and its applications to manufacturing robots. *IEEE Transactions on Industrial Informatics*, IEEE, v. 10, n. 3, p. 1705–1716, 2014. Citado na página 74.
- CICA, D. et al. Predictive modeling of turning operations under different cooling/lubricating conditions for sustainable manufacturing with machine learning techniques. *Applied Computing and Informatics*, Emerald Publishing Limited, v. 20, n. 1/2, p. 162–180, 2024. Citado na página 62.
- CIECIELAĞ, K.; ZALESKI, K. Milling of three types of thin-walled elements made of polymer composite and titanium and aluminum alloys used in the aviation industry. *Materials*, MDPI, v. 15, n. 17, p. 5949, 2022. Citado na página 17.
- DANISH, M. et al. Machine learning models for prediction and classification of tool wear in sustainable milling of additively manufactured 316 stainless steel. *Results in Engineering*, Elsevier, v. 22, p. 102015, 2024. Citado na página 19.

- DING, P. et al. Online monitoring model of micro-milling force incorporating tool wear prediction process. *Expert Systems with Applications*, Elsevier, v. 223, p. 119886, 2023. Citado na página 62.
- DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. *Tecnologia da usinagem dos materiais*. [S.l.]: Artliber, 2014. Citado 3 vezes nas páginas 23, 26 e 29.
- DRUCKER, H. et al. Support vector regression machines. *Advances in neural information processing systems*, v. 9, 1996. Citado 3 vezes nas páginas 37, 40 e 41.
- ESER, A. et al. Artificial intelligence-based surface roughness estimation modelling for milling of aa6061 alloy. *Advances in Materials Science and Engineering*, Wiley Online Library, v. 2021, n. 1, p. 5576600, 2021. Citado na página 61.
- FAHLMAN, S. E. et al. *An empirical study of learning speed in back-propagation networks*. [S.l.]: Carnegie Mellon University, Computer Science Department Pittsburgh, PA, USA, 1988. Citado na página 54.
- FERNANDES, F. T. *Machine learning em saúde e segurança do trabalhador: perspectivas, desafios e aplicações*. Tese (Doutorado) — Universidade de São Paulo, 2021. Citado 2 vezes nas páginas 59 e 60.
- FERRARESI, D.; PALLEROSI, C. A.; RUFFINO, R. T. Fresamento. EESC/USP, 1970. Citado na página 23.
- FERTIG, A.; WEIGOLD, M.; CHEN, Y. Machine learning based quality prediction for milling processes using internal machine tool data. *Advances in Industrial and Manufacturing Engineering*, Elsevier, v. 4, p. 100074, 2022. Citado 2 vezes nas páginas 62 e 81.
- FLORES, V.; KEITH, B. Gradient boosted trees predictive models for surface roughness in high-speed milling in the steel and aluminum metalworking industry. *Complexity*, Wiley Online Library, v. 2019, n. 1, p. 1536716, 2019. Citado na página 61.
- GADELMAWLA, E. et al. Roughness parameters. *Journal of materials processing Technology*, Elsevier, v. 123, n. 1, p. 133–145, 2002. Citado na página 35.
- GEISSER, S. The predictive sample reuse method with applications. *Journal of the American statistical Association*, Taylor & Francis, v. 70, n. 350, p. 320–328, 1975. Citado na página 56.
- GÉRON, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. [S.l.]: "O'Reilly Media, Inc.", 2022. Citado na página 37.
- GOMES, J. H. d. F. Método dos polinômios canônicos e misturas para otimização multi-objetivo. IEPG-Instituto de Engenharia de Produção e Gestão, 2013. Citado 2 vezes nas páginas 65 e 68.
- GOWTHAMAN, P.; JEYAKUMAR, S.; SARAVANAN, B. Machinability and tool wear mechanism of duplex stainless steel—a review. *Materials Today: Proceedings*, Elsevier, v. 26, p. 1423–1429, 2020. Citado na página 31.

- GRGURAŠ, D.; KERN, M.; PUŠAVEC, F. Cutting performance of solid ceramic and carbide end milling tools in machining of nickel based alloy inconel 718 and stainless steel 316l. *Advances in production engineering & management*, v. 14, n. 1, 2019. Citado na página 32.
- GROOVER, M. P. *Introdução aos processos de fabricação*. [S.l.]: Grupo Gen-LTC, 2000. Citado 2 vezes nas páginas 24 e 25.
- GROUS, A. *Applied metrology for manufacturing engineering*. [S.l.]: John Wiley & Sons, 2013. Citado na página 35.
- GRZESIK, W. *Advanced Machining Processes of Metallic Materials: Theory, Modelling, and Applications*. 2. ed. Amsterdam, Netherlands: Elsevier, 2017. Citado na página 34.
- GUIMARÃES, M. et al. Optimizing machining efficiency in high-speed milling of super duplex stainless steel with sialon ceramic inserts. *Machines*, MDPI, v. 12, n. 5, p. 349, 2024. Citado na página 17.
- GUNN, R. *Duplex Stainless Steels: Microstructure, Properties, and Applications*. 1. ed. Sawston, Cambridge: Woodhead Publishing, 1997. Citado na página 29.
- GUO, M. et al. A surface quality prediction model considering the machine-tool-material interactions. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 131, n. 7, p. 3937–3955, 2024. Citado na página 110.
- HASSOUN, M. *Fundamentals of Artificial Neural Networks*. [S.l.]: The MIT Press, 1995. Citado na página 54.
- HASTIE, T. *The elements of statistical learning: Data mining, inference, and prediction*. [S.l.]: Springer, 2009. Citado 3 vezes nas páginas 43, 47 e 57.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001. Citado 11 vezes nas páginas 47, 48, 49, 52, 53, 54, 55, 56, 57, 58 e 59.
- IMOA. *Orientações práticas para processamento dos aços inoxidáveis Duplex*. Londres: IMOA, 2012. Citado 4 vezes nas páginas 27, 28, 30 e 31.
- INJADAT, M. et al. Systematic ensemble model selection approach for educational data mining. *Knowledge-Based Systems*, Elsevier, v. 200, p. 105992, 2020. Citado na página 83.
- IYODA, E. M. *Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas*. Tese (Doutorado) — [sn], 2000. Citado na página 54.
- JAMES, G. et al. *An introduction to statistical learning*. [S.l.]: Springer, 2013. v. 112. Citado 3 vezes nas páginas 42, 45 e 56.
- JANARDHAN, L.; CHANDRAPPA, K.; SURESH, R. An experimental study on high-speed milling of super duplex stainless steel and to investigate the effect of cutting parameters on surface roughness. *Journal of The Institution of Engineers (India): Series D*, Springer, p. 1–6, 2023. Citado na página 33.
- JEBARAJ, A. V. et al. Weldability, machinability and surfacing of commercial duplex stainless steel aisi2205 for marine applications—a recent review. *Journal of advanced research*, Elsevier, v. 8, n. 3, p. 183–199, 2017. Citado na página 30.

- JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. *Science*, American Association for the Advancement of Science, v. 349, n. 6245, p. 255–260, 2015. Citado na página 36.
- JOSEPH, V. R. et al. Space-filling designs for robustness experiments. *Technometrics*, Taylor & Francis, v. 61, n. 1, p. 24–37, 2019. Citado 2 vezes nas páginas 69 e 70.
- KALIYANNAN, D. et al. Tool condition monitoring in the milling process using deep learning and reinforcement learning. *Journal of Sensor and Actuator Networks*, MDPI, v. 13, n. 4, p. 42, 2024. Citado na página 19.
- KARA, F. et al. Effect of machinability, microstructure and hardness of deep cryogenic treatment in hard turning of aisi d2 steel with ceramic cutting. *Journal of Materials Research and Technology*, Elsevier, v. 9, n. 1, p. 969–983, 2020. Citado na página 61.
- KARTHIK, R. M. et al. Influence of support vector regression (svr) on cryogenic face milling. *Advances in Materials Science and Engineering*, Wiley Online Library, v. 2021, n. 1, p. 9984369, 2021. Citado na página 19.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. *Proceedings of ICNN'95-international conference on neural networks*. [S.l.], 1995. v. 4, p. 1942–1948. Citado 2 vezes nas páginas 74 e 75.
- KHANNA, N. et al. In pursuit of sustainable cutting fluid strategy for machining ti-6al-4v using life cycle analysis. *Sustainable Materials and Technologies*, Elsevier, v. 29, p. e00301, 2021. Citado na página 18.
- KHURI, A. I.; MUKHOPADHYAY, S. Response surface methodology. *Wiley interdisciplinary reviews: Computational statistics*, Wiley Online Library, v. 2, n. 2, p. 128–149, 2010. Citado na página 69.
- KLOCKE, F. *Zerspanung mit geometrisch unbestimmter Schneide*. [S.l.]: Springer Vieweg, 2018. Citado 2 vezes nas páginas 23 e 24.
- KÖKSOY, O.; YALCINOZ, T. Mean square error criteria to multiresponse process optimization by a new genetic algorithm. *Applied Mathematics and Computation*, Elsevier, v. 175, n. 2, p. 1657–1674, 2006. Citado na página 70.
- KOYEE, R. D. et al. Experimental investigation and multiobjective optimization of turning duplex stainless steels. *International Journal of Manufacturing Engineering*, Wiley Online Library, v. 2014, n. 1, p. 921081, 2014. Citado 2 vezes nas páginas 30 e 31.
- KROLCZYK, G. et al. Microhardness changes gradient of the duplex stainless steel (dss) surface layer after dry turning. *Metallurgija*, Hrvatsko Metalursko Društvo (HMD), v. 53, n. 4, p. 529–532, 2014. Citado na página 30.
- KUMAR, S.; SARAVANAN, I.; PATNAIK, L. Optimization of surface roughness and material removal rate in milling of aisi 1005 carbon steel using taguchi approach. *Materials today: proceedings*, Elsevier, v. 22, p. 654–658, 2020. Citado na página 25.
- LI, B.; TIAN, X. An effective pso-lssvm-based approach for surface roughness prediction in high-speed precision milling. *Ieee Access*, IEEE, v. 9, p. 80006–80014, 2021. Citado na página 76.

- LI, G. et al. High definition metrology-based quality improvement of surface texture in face milling of workpieces with discontinuous surfaces. *Journal of Manufacturing Science and Engineering*, American Society of Mechanical Engineers, v. 144, n. 3, p. 031001, 2022. Citado na página 17.
- LI, G. et al. Compilation of load spectrum of machining center spindle and application in fatigue life prediction. *Journal of Mechanical Science and Technology*, Springer, v. 33, p. 1603–1613, 2019. Citado na página 17.
- LI, K. et al. Modeling and tagging of time sequence signals in the milling process based on an improved hidden semi-markov model. *Expert Systems with Applications*, Elsevier, v. 205, p. 117758, 2022. Citado na página 62.
- LI, K.-M.; LIN, Y.-Y. Tool wear classification in milling for varied cutting conditions: with emphasis on data pre-processing. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 125, n. 1, p. 341–355, 2023. Citado na página 82.
- LIMA, B. H. O. d. Estudo dos efeitos das condições de usinagem na microestrutura da superfície de um aço inoxidável super duplex. 2019. Citado na página 28.
- LOPES, L. G. D. et al. Robust parameter optimization based on multivariate normal boundary intersection. *Computers & Industrial Engineering*, Elsevier, v. 93, p. 55–66, 2016. Citado na página 72.
- LOUPPE, G. Understanding random forests: From theory to practice. *arXiv preprint arXiv:1407.7502*, 2014. Citado na página 45.
- MACHADO, Á. R. et al. *Teoria da usinagem dos materiais*. [S.l.]: Editora Blucher, 2015. Citado 2 vezes nas páginas 26 e 34.
- MAIOR, C. B. S. Development of machine and deep learning based models for risk and reliability problems. Universidade Federal de Pernambuco, 2020. Citado na página 36.
- MALI, R. A.; GUPTA, T.; RAMKUMAR, J. A comprehensive review of free-form surface milling—advances over a decade. *Journal of Manufacturing Processes*, Elsevier, v. 62, p. 132–167, 2021. Citado na página 17.
- MARQUES, D. C. et al. Influence of machining parameters on tool wear, residual stresses, and corrosion resistance after milling super duplex stainless steel uns s32750. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 129, n. 1, p. 801–814, 2023. Citado na página 18.
- MARTINHO, R. et al. Comparative study of pvd and cvd cutting tools performance in milling of duplex stainless steel. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 102, p. 2423–2439, 2019. Citado na página 31.
- MAVI, A. Evaluation of cutting parameters by determination of the grey correlation analysis methods of the effects on the cutting force and surface roughness of duplex stainless steels (2205). *Tehnički vjesnik*, Sveučilište u Slavenskom Brodu, Stojarski fakultet, v. 27, n. 1, p. 270–275, 2020. Citado na página 88.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, p. 115–133, 1943. Citado 2 vezes nas páginas 48 e 52.

- MIGUEL, P. A. C. et al. Metodologia de pesquisa em engenharia de produção e gestão de operações. 2010. Citado na página 78.
- MIKOLAJCZYK, T. Modeling of minimal thickness cutting layer influence on surface roughness in turning. *Applied Mechanics and Materials*, Trans Tech Publ, v. 656, p. 262–269, 2014. Citado na página 35.
- MOHAMMADI, Y.; AMIRABADI, H. Analytical modeling of work hardening of duplex steel alloys in the milling process. *Journal of Mechanical Science and Technology*, Springer, v. 36, n. 3, p. 1437–1449, 2022. Citado na página 30.
- MOHAMMED, B. S.; KHED, V. C.; NURUDDIN, M. F. Rubbercrete mixture optimization using response surface methodology. *Journal of Cleaner Production*, Elsevier, v. 171, p. 1605–1621, 2018. Citado na página 64.
- MOHANRAJ, T. et al. Review of advances in tool condition monitoring techniques in the milling process. *Measurement Science and Technology*, IOP Publishing, v. 35, n. 9, p. 092002, 2024. Citado na página 19.
- MONDAL, S.; RAY, P.; MAITI, J. Modelling robustness for manufacturing processes: a critical review. *International Journal of Production Research*, Taylor & Francis, v. 52, n. 2, p. 521–538, 2014. Citado na página 69.
- MONGAN, P. G. et al. An ensemble neural network for optimising a cnc milling process. *Journal of Manufacturing Systems*, Elsevier, v. 71, p. 377–389, 2023. Citado na página 18.
- MONTGOMERY, D. C. *Design and analysis of experiments*. [S.l.]: John wiley & sons, 2017. Citado 8 vezes nas páginas 57, 58, 63, 66, 68, 69, 70 e 71.
- MORELO, F. *Análise da influência do mandrilamento na integridade superficial do aço inoxidável super duplex*. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2014. Citado na página 27.
- MYERS, R. H.; KHURI, A. I.; VINING, G. Response surface alternatives to the taguchi robust parameter design approach. *The American Statistician*, Taylor & Francis, v. 46, n. 2, p. 131–139, 1992. Citado 2 vezes nas páginas 70 e 71.
- MYERS, R. H.; MONTGOMERY, D. C.; ANDERSON-COOK, C. M. *Response surface methodology: process and product optimization using designed experiments*. [S.l.]: John Wiley & Sons, 2016. Citado 3 vezes nas páginas 58, 64 e 69.
- NAIR, V. N. et al. Taguchi's parameter design: a panel discussion. *Technometrics*, Taylor & Francis, v. 34, n. 2, p. 127–161, 1992. Citado 2 vezes nas páginas 69 e 70.
- NGUYEN, N.-T. et al. Analysis of tool wear and surface roughness in high-speed milling process of aluminum alloy al6061. *EUREKA: Physics and Engineering*, (3), p. 71–84, 2021. Citado na página 61.
- NIED, A. Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com taxa de aprendizado adaptativa. Universidade Federal de Minas Gerais, 2007. Citado 2 vezes nas páginas 53 e 56.

- OLIVEIRA, C. H. d. et al. Otimização robusta multivariada no fresamento de topo do aço inoxidável duplex uns s32205. Universidade Federal de Itajubá, 2022. Citado 5 vezes nas páginas 18, 73, 80, 91 e 92.
- OLIVEIRA, L. G. de et al. Nonlinear optimization strategy based on multivariate prediction capability ratios: Analytical schemes and model validation for duplex stainless steel end milling. *Precision Engineering*, Elsevier, v. 66, p. 229–254, 2020. Citado na página 32.
- OZDEMIR, A.; CHO, B. R. Response surface-based robust parameter design optimization with both qualitative and quantitative variables. *Engineering Optimization*, Taylor & Francis, v. 49, n. 10, p. 1796–1812, 2017. Citado na página 69.
- PAIVA, A. P. D. et al. A multivariate robust parameter optimization approach based on principal component analysis with combined arrays. *Computers & Industrial Engineering*, Elsevier, v. 74, p. 186–198, 2014. Citado na página 71.
- PANIGRAHI, R. R. et al. Turning performance analysis and optimization of processing parameters using gra-pso approach in sustainable manufacturing. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, SAGE Publications Sage UK: London, England, v. 236, n. 6, p. 2404–2419, 2022. Citado na página 74.
- PARO, J.; HÄNNINEN, H.; KAUPPINEN, V. Tool wear and machinability of hiped p/m and conventional cast duplex stainless steels. *Wear*, Elsevier, v. 249, n. 3-4, p. 279–284, 2001. Citado na página 30.
- PATIL, V. T. Metrology and quality control. *15th editi ed. Shivaji Nagar: Nirali Prakashan*, 2018. Citado na página 34.
- PENG, D.; LI, H. Intelligent monitoring of milling tool wear based on milling force coefficients by prediction of instantaneous milling forces. *Mechanical Systems and Signal Processing*, Elsevier, v. 208, p. 111033, 2024. Citado na página 18.
- PEREIRA, R. B. D. et al. Multivariate robust modeling and optimization of cutting forces of the helical milling process of the aluminum alloy al 7075. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 95, p. 2691–2715, 2018. Citado na página 72.
- PETROPOULOS, G. P.; PANDAZARAS, C. N.; DAVIM, J. P. Surface texture characterization and evaluation related to machining. *Surface integrity in machining*, Springer, p. 37–66, 2010. Citado na página 34.
- PHILIP, S.; CHANDRAMOHAN, P.; RAJESH, P. Prediction of surface roughness in end milling operation of duplex stainless steel using response surface methodology. *J. Eng. Sci. Technol*, v. 10, n. 3, p. 340–352, 2015. Citado na página 27.
- PIMENOV, D. Y.; BUSTILLO, A.; MIKOLAJCZYK, T. Artificial intelligence for automatic prediction of required surface roughness by monitoring wear on face mill teeth. *Journal of Intelligent Manufacturing*, Springer, v. 29, n. 5, p. 1045–1061, 2018. Citado na página 61.

- PIRES, T. F. S. et al. Otimização robusta multiobjetivo do fresamento helicoidal do aço inoxidável super duplex uns s32760. Universidade Federal de Itajubá, 2023. Citado na página 73.
- POLICENA, M. R. et al. Surface roughness analysis in finishing end-milling of duplex stainless steel uns s32205. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 98, p. 1617–1625, 2018. Citado 2 vezes nas páginas 25 e 31.
- PRAKASH, T.; ARUN, A.; SACHIN, A. Investigation of non-edible vegetable oil as cutting fluid in boring operation using mql technique for cew-1 steel. *Materials Today: Proceedings*, Elsevier, v. 72, p. 1462–1466, 2023. Citado na página 18.
- PRODANOV, C. C.; FREITAS, E. C. D. *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico-2ª Edição*. [S.l.]: Editora Feevale, 2013. Citado na página 78.
- QIN, X. et al. Comparative analyses on tool wear in helical milling of ti-6al-4v using diamond-coated tool and tialn-coated tool. *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, The Japan Society of Mechanical Engineers, v. 8, n. 1, p. JAMDSM0004–JAMDSM0004, 2014. Citado na página 34.
- QUINTEN, M. *A practical guide to surface metrology*. [S.l.]: Springer, 2019. Citado na página 35.
- RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: The rprop algorithm. In: IEEE. *IEEE international conference on neural networks*. [S.l.], 1993. p. 586–591. Citado na página 54.
- ROBINSON, T. J.; BORROR, C. M.; MYERS, R. H. Robust parameter design: a review. *Quality and reliability engineering international*, Wiley Online Library, v. 20, n. 1, p. 81–101, 2004. Citado 2 vezes nas páginas 69 e 70.
- RODRIGUES, V. F. S. et al. Robust modeling and optimization of borehole enlarging by helical milling of aluminum alloy al7075. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 100, p. 2583–2599, 2019. Citado na página 72.
- SAHOO, P. et al. Influences of tialn coating and limiting angles of flutes on prediction of cutting forces and dynamic stability in micro milling of die steel (p-20). *Journal of Materials Processing Technology*, Elsevier, v. 278, p. 116500, 2020. Citado na página 86.
- SAMBEDANA, S. et al. Experimental study on surface roughness and optimization of process parameters using ann-ga in milling of super-duplex stainless steel under dry and wet conditions. In: SPRINGER. *Advances in Manufacturing Technology: Select Proceedings of ICAMT 2018*. [S.l.], 2019. p. 399–409. Citado na página 25.
- SANDVIK, C. Manual de treinamento: Tecnologia em usinagem. *C-2920*, v. 40, 2017. Citado 2 vezes nas páginas 24 e 26.
- SANTANA, F. B. de. *Floresta aleatória para desenvolvimento de modelos multivariados de classificação e regressão em química analítica*. Tese (Doutorado) — [sn], 2020. Citado 2 vezes nas páginas 44 e 46.

- SANTANA, G. A. et al. Halton-chaos-beta-pso: uma nova abordagem metaheurística baseada em enxame de partículas aplicada à problemas de engenharia elétrica. Universidade Tecnológica Federal do Paraná, 2021. Citado na página 74.
- SANTOS, C. E. dos et al. Residual stress and surface microhardness post-milling in 2205 duplex steel. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 113, p. 3445–3455, 2021. Citado na página 30.
- SEDRIKS, A. J. Corrosion of stainless steels. *John Wiley & Sons google schola*, v. 2, p. 3410–3413, 1996. Citado na página 28.
- SELVARAJ, D. P.; CHANDRAMOHAN, P.; RAJESH, P. Optimization of milling parameters of astm a 995 grade 4a duplex stainless steel using taguchi technique. *International Journal of Recent Technology and Engineering*, v. 8, n. 3, p. 5840–5843, 2019. Citado na página 31.
- SELVARAJ, D. P.; CHANDRASEKAR, P. Experimental investigations of nitrogen alloyed duplex stainless steel in dry milling process. *Journal of Engineering Science and Technology*, v. 13, n. 2, p. 321–331, 2018. Citado na página 31.
- SER, J. D. et al. *Bio-inspired computation: where we stand and what's next. Swarm Evol Comput* 48: 220–250. 2019. Citado na página 74.
- SERRATOOLS. *Cabeçotes para fresamento*. 2019. <<https://www.serratools.com.br/produtos/cabecote-para-fresamento/>>. Acesso em: 12 março 2024. Citado na página 27.
- SHAH, M. et al. Tool wear prediction in face milling of stainless steel using singular generative adversarial network and lstm deep learning models. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 121, n. 1, p. 723–736, 2022. Citado na página 62.
- SHALEV-SHWARTZ, S.; BEN-DAVID, S. *Understanding machine learning: From theory to algorithms*. [S.l.]: Cambridge university press, 2014. Citado na página 36.
- SHOEMAKER, A. C.; TSUI, K.-L.; WU, C. J. Economical experimentation methods for robust design. *Technometrics*, Taylor & Francis, v. 33, n. 4, p. 415–427, 1991. Citado 2 vezes nas páginas 70 e 71.
- SILVA, A. L. F. d. *Obtenção de distribuição de pressão em asas usando redes neurais*. Tese (Doutorado) — Universidade de São Paulo, 2009. Citado 2 vezes nas páginas 51 e 56.
- SILVA, F. J. et al. Wear behavior of coated tools when milling s32101 duplex stainless steel. *Materials Proceedings*, MDPI, v. 8, n. 1, p. 45, 2022. Citado na página 32.
- SILVA, M. A.; BATISTA, B. A.; BATISTA, L. A. Caracterização de um aço inoxidável duplex em comparação a aços inoxidáveis ferríticos e austeníticos em relação à microestrutura e propriedades mecânicas em tração. *Anais Do Enemet-Encontro Nacional de Estudantes de Engenharia Metalúrgica, de Materiais e de Minas*, p. 1571–1576, 2017. Citado na página 29.
- SLOW, K.; SONG, T.; QIU, J. Pitting corrosion of duplex stainless steels. *Anti-Corrosion Methods and Materials*, MCB UP Ltd, v. 48, n. 1, p. 31–37, 2001. Citado na página 29.

- SMITH, G. T. *Industrial metrology: surfaces and roundness*. [S.l.]: Springer Science & Business Media, 2002. Citado na página 34.
- SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. *Statistics and computing*, Springer, v. 14, p. 199–222, 2004. Citado na página 40.
- SNIS, M.; OLSSON, J. Reduce costs for storage and distribution of desalted water—use duplex stainless steel. *Desalination*, Elsevier, v. 223, n. 1-3, p. 476–486, 2008. Citado na página 28.
- SOUSA, V. F. et al. Wear behavior phenomena of tin/tialn hipims pvd-coated tools on milling inconel 718. *Metals*, MDPI, v. 13, n. 4, p. 684, 2023. Citado na página 86.
- SOUSA, V. F. et al. Investigations on the wear performance of coated tools in machining uns s32101 duplex stainless steel. *Metals*, MDPI, v. 12, n. 6, p. 896, 2022. Citado na página 33.
- SOUZA, C. B. de. *Árvores de Decisão: A Evolução do CART ao BART*. Tese (Doutorado) — Universidade de São Paulo, 2021. Citado 3 vezes nas páginas 42, 44 e 45.
- SOUZA, L. G. P. d. Otimização robusta do torneamento do aço abnt 52100 endurecido. IEPG-Instituto de Engenharia de Produção e Gestão, 2018. Citado na página 72.
- SOUZA, L. G. P. de et al. Roughness prediction using machine learning models in hard turning: an approach to avoid rework and scrap. *The International Journal of Advanced Manufacturing Technology*, Springer, p. 1–17, 2024. Citado na página 62.
- SQUEO, M.; FRIGERIO, N.; MATTA, A. Multiple sleeping states for energy saving in cnc machining centers. *Procedia CIRP*, Elsevier, v. 80, p. 144–149, 2019. Citado na página 17.
- STÅHL, J. et al. Metal cutting: theories and models. division of production and materials engineering. *Lund University in cooperation with SecoTools AB, Lund/Fagersta, Sweden*, 2012. Citado na página 31.
- STEMMER, C. E. *Ferramentas de Corte I*. 3. ed. Florianópolis: Editora da UFSC, 1993. Citado 2 vezes nas páginas 25 e 26.
- STEVENSON, W. J. et al. Estatística aplicada à administração. In: *Estatística aplicada a administração*. [S.l.: s.n.], 1981. p. 495–495. Citado na página 59.
- STONE, M. Cross-validatory choice and assessment of statistical predictions. *Journal of the royal statistical society: Series B (Methodological)*, Wiley Online Library, v. 36, n. 2, p. 111–133, 1974. Citado na página 56.
- TAGUCHI, G. *Introduction to quality engineering: designing quality into products and processes*. [S.l.: s.n.], 1986. Citado na página 69.
- TARDIVO, M. A. Uma aplicação de redes neurais artificiais para estimação da elevação de temperatura de transformadores monofásicos de distribuição imersos em líquido isolante. 2024. Citado 5 vezes nas páginas 49, 50, 51, 53 e 59.
- TIBSHIRANI, R. J.; EFRON, B. An introduction to the bootstrap. *Monographs on statistics and applied probability*, v. 57, n. 1, p. 1–436, 1993. Citado na página 45.

- TITO, J. Tese de Doutorado, *Tese de Doutorado*. 2024. Citado 3 vezes nas páginas 40, 56 e 57.
- TOLEDO, J. V. R. de et al. A multi-objective robust evolutionary optimization approach applied to the multivariate helical milling process of super duplex steel. *Applied Soft Computing*, Elsevier, v. 147, p. 110811, 2023. Citado na página 33.
- TRAINI, E. et al. Machine learning framework for predictive maintenance in milling. *IFAC-PapersOnLine*, Elsevier, v. 52, n. 13, p. 177–182, 2019. Citado na página 97.
- VAPNIK, V. N. An overview of statistical learning theory. *IEEE transactions on neural networks*, IEEE, v. 10, n. 5, p. 988–999, 1999. Citado 3 vezes nas páginas 37, 40 e 41.
- VASCONCELOS, G. A. V. B. *Otimização Robusta do Fresamento de Topo do Aço Inoxidável Duplex UNS S32205*. Dissertação (Dissertação de Mestrado) — Universidade Federal de Itajubá, Instituto de Engenharia Mecânica, Itajubá, agosto 2022. Orientador: Prof. Dr. João Roberto Ferreira. Citado 3 vezes nas páginas 18, 80 e 91.
- VICKERS, N. J. Animal communication: when i'm calling you, will you answer too? *Current biology*, Elsevier, v. 27, n. 14, p. R713–R715, 2017. Citado na página 58.
- VIEIRA, J. T. et al. Multi-objective robust evolutionary optimization of the boring process of aisi 4130 steel. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 112, p. 1745–1765, 2021. Citado na página 73.
- WANG, L. *Support vector machines: theory and applications*. [S.l.]: Springer Science & Business Media, 2005. v. 177. Citado na página 37.
- WANG, R. et al. Ensemble learning with a genetic algorithm for surface roughness prediction in multi-jet polishing. *Expert Systems with Applications*, Elsevier, v. 207, p. 118024, 2022. Citado na página 62.
- WELCH, W. J. et al. Computer experiments for quality control by parameter design. *Journal of quality technology*, Taylor & Francis, v. 22, n. 1, p. 15–22, 1990. Citado na página 71.
- WU, P. et al. A physics-informed machine learning model for surface roughness prediction in milling operations. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 123, n. 11, p. 4065–4076, 2022. Citado na página 19.
- WU, X. et al. Automatic identification of tool wear based on convolutional neural network in face milling process. *Sensors*, MDPI, v. 19, n. 18, p. 3817, 2019. Citado na página 19.
- XIAO, Y. et al. A novel approach to cnc machining center processing parameters optimization considering energy-saving and low-cost. *Journal of Manufacturing Systems*, Elsevier, v. 59, p. 535–548, 2021. Citado na página 17.
- XU, L. et al. Estimation of tool wear and optimization of cutting parameters based on novel anfis-pso method toward intelligent machining. *Journal of Intelligent Manufacturing*, Springer, v. 32, p. 77–90, 2021. Citado na página 77.
- XU, X. et al. Machine learning cutting forces in milling processes of functionally graded materials. *Advances in Computational Intelligence*, Springer, v. 2, n. 3, p. 25, 2022. Citado 3 vezes nas páginas 62, 77 e 102.

YASIR, M. et al. Investigation into the surface quality and stress corrosion cracking resistance of aisi 316l stainless steel via precision end-milling operation. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 112, p. 1065–1076, 2021. Citado na página 32.

ZAIN, A. M.; HARON, H.; SHARIF, S. Prediction of surface roughness in the end milling machining using artificial neural network. *Expert Systems with Applications*, Elsevier, v. 37, n. 2, p. 1755–1768, 2010. Citado na página 83.

ZHAO, Y. Optimization of machining path for integral impeller side milling based on sa-pso fusion algorithm in cnc machine tools. *Frontiers in Mechanical Engineering*, Frontiers Media SA, v. 10, p. 1361929, 2024. Citado na página 77.

ZHOU, J.; REN, J.; YAO, C. Multi-objective optimization of multi-axis ball-end milling inconel 718 via grey relational analysis coupled with rbf neural network and pso algorithm. *Measurement*, Elsevier, v. 102, p. 271–285, 2017. Citado na página 76.