

UNIVERSIDADE DE CAXIAS DO SUL
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA – PPGMEC
MESTRADO PROFISSIONAL

NATHALIA TESSARI MORAES

***MACHINE LEARNING* PARA PREDIÇÃO DE RUGOSIDADES E DESGASTES DE
FRESAS COM DIFERENTES POLIMENTOS POR ARRASTE**

CAXIAS DO SUL

2023

NATHALIA TESSARI MORAES

***MACHINE LEARNING* PARA PREDIÇÃO DE RUGOSIDADES E DESGASTES DE
FRESAS COM DIFERENTES POLIMENTOS POR ARRASTE**

Dissertação apresentada ao Programa de Pós Graduação em Engenharia Mecânica pela Universidade de Caxias do Sul como requisito à obtenção do título de Mestre em Engenharia Mecânica, na área de concentração de processos e fabricação.

Orientador: Prof. Dr. Rodrigo P. Zeilmann
Coorientador: Prof. Dr. Leandro L. Corso

CAXIAS DO SUL

2023

Dados Internacionais de Catalogação na Publicação (CIP)
Universidade de Caxias do Sul
Sistema de Bibliotecas UCS - Processamento Técnico

M827m Moraes, Nathalia Tessari

Machine learning para predição de rugosidades e desgastes de fresas com diferentes polimentos por arraste [recurso eletrônico] / Nathalia Tessari Moraes. – 2023.

Dados eletrônicos.

Dissertação (Mestrado) - Universidade de Caxias do Sul, Programa de Pós-Graduação em Engenharia Mecânica, 2023.

Orientação: Rodrigo Panosso Zeilmann.

Coorientação: Leandro Luis Corso.

Modo de acesso: World Wide Web

Disponível em: <https://repositorio.ucs.br>

1. Retificação e polimento. 2. Fresagem (Trabalhos em metal). 3. Desgaste mecânico. 4. Aprendizado do computador. 5. Inteligência artificial. I. Zeilmann, Rodrigo Panosso, orient. II. Corso, Leandro Luis, coorient. III. Título.

CDU 2. ed.: 621.923

Catalogação na fonte elaborada pela(o) bibliotecária(o)
Márcia Servi Gonçalves - CRB 10/1500

NATHALIA TESSARI MORAES

***MACHINE LEARNING* PARA PREDIÇÃO DE RUGOSIDADES E DESGASTES DE
FRESAS COM DIFERENTES POLIMENTOS POR ARRASTE**

Dissertação apresentada ao Programa de Pós Graduação em Engenharia Mecânica pela Universidade de Caxias do Sul como requisito à obtenção do título de Mestre em Engenharia Mecânica, na área de concentração de processos e fabricação.

Caxias do Sul, 15 de agosto de 2023.

Banca Examinadora

Prof. Dr. Rodrigo Panosso Zeilmann
Universidade de Caxias do Sul – UCS

Prof. Dr. Leandro Luis Corso
Universidade de Caxias do Sul - UCS

Prof. Dr. Alexandre Fassini Michels
Universidade de Caxias do Sul - UCS

Prof. Dra. Carine Geltrudes Webber
Universidade de Caxias do Sul - UCS

Prof. Dra. Marilda Machado Spindola
Universidade de Caxias do Sul – UCS

RESUMO

A preparação do gume da ferramenta é considerada um dos aspectos principais da fabricação de ferramentas de corte modernas e precisas. É um processo que possibilita maior vida útil para a ferramenta, melhor desempenho de corte e qualidade superficial do material usinado. Para compreender melhor o papel da preparação de gume, torna-se necessário o aprofundamento no entendimento das rugosidades do material usinado, desgaste da ferramenta e suas relações. Esta tarefa, embora seja desafiadora, pois é dependente de muitos fatores de configuração do processo de corte, é fundamental para uma otimização do processo. Prever as rugosidades e desgastes é um meio de redução de tempos e custos de produção, uma vez que diminui as operações de processo e viabiliza um melhor aproveitamento da ferramenta. Onde busca-se utilizar a ferramenta até o fim da sua vida, mas sem deixar chegar a um desgaste que comprometa a qualidade da superfície usinada por esta ferramenta. Em vista de explorar estes dois campos de desenvolvimento, preparação do gume e predição de desgastes e rugosidades, este trabalho desenvolveu experimentos para coleta de dados de desgaste e rugosidades obtidas por ferramentas com diferentes preparações de gume para compreender os efeitos desta preparação e treinar e avaliar modelos de predição. Por meio da avaliação dos experimentos, confirmou-se uma estabilidade e homogeneidade maior no fresamento com as ferramentas com polimento por arraste, ao avaliar as rugosidades e uma maior vida útil das ferramentas com preparação de gume com as mídias HSC 1/300 e H 4/400 de 18,62% e 20,49% maior, respectivamente, quando comparadas a vida útil das ferramentas sem qualquer preparação de gume. Para as predições dos desgastes e rugosidades, comparou-se diferentes métodos que alcançaram erros absolutos percentuais médios para desgaste, R_a , R_z e R_t em torno de 0,1%, 2,3%, 10,4% e 23,8%, respectivamente. A comparação de novos modelos trouxe novas contribuições para a literatura com testes de modelos de *machine learning*, ressaltando modelos baseados em árvores de decisão como *Random Forest*, *Extra Tree* e *XGBoost* potenciais para predições de rugosidades e NuSVR para desgaste.

Palavras-chave: polimento por arraste; rugosidade; desgaste; aprendizado de máquina; inteligência artificial.

ABSTRACT

Tool edge preparation is considered one of the key aspects of modern and accurate cutting tools. It is a process that allows longer tool life, better cutting performance and surface quality of the machined material. In order to better understand the role of cutting edge preparation, it is necessary to deepen the understanding of the roughness of the machined material, tool wear and their relationships. This task, although challenging, as it is dependent on many configuration factors of the cutting process, is fundamental for process optimization. Predicting roughness and wear is a means of reducing production times and costs, as it reduces process operations and makes better use of the tool possible, where one seeks to use the tool until the end of its life, but without leaving reach a wear that compromises the quality of the surface machined by this tool. In order to explore these two fields of development, edge preparation and wear and roughness prediction, this work developed experiments to collect wear and roughness data obtained by tools with different edge preparations to understand the effects of this preparation and to train and evaluate prediction models. Through the evaluation of the experiments, it was confirmed a greater stability and homogeneity in milling with the tools with drag polishing when evaluating the roughness and a longer useful life of the tools with edge preparation with the media HSC 1/300 and H 4/ 400 of 18.62% and 20.49% higher, respectively, when compared to tool life without any edge preparation. For the predictions of wear and roughness, different methods were compared that achieved mean percentage absolute errors for wear, R_a , R_z and R_t around 0.1%, 2.3%, 10.4% and 23.8%, respectively. The comparison of new models brought new contributions to the literature testing new machine learning models, highlighting models based on decision trees such as Random Forest, Extra Tree and XGBoost potential for roughness predictions and NuSVR for wear prediction.

Keywords: *drag finishing; roughness; wear; machine learning; artificial intelligence.*

LISTA DE FIGURAS

Figura 1 – Subdivisões do processo de fresamento	19
Figura 2– Geometrias da cunha de corte.....	21
Figura 3 – Aspectos do desenvolvimento de ferramentas modernas e precisas.....	22
Figura 4 – Tipos de fresas de topo.....	23
Figura 5 – Curva de comportamento do desgaste.....	24
Figura 6 – Ordem dos desvios e perfil de rugosidade.....	25
Figura 7 - Causa e efeito da rugosidade no fresamento	26
Figura 8 – Parâmetro de rugosidade R_a	27
Figura 9 – Parâmetro de rugosidade R_z	28
Figura 10 – Parâmetro de rugosidade R_t	29
Figura 11 – Preparação de gume	31
Figura 12 – Efeitos da preparação de gume	32
Figura 13 – Subdivisão do aprendizado de máquina	33
Figura 14 – Camadas das Redes Neurais Artificiais.....	38
Figura 15 – Modelo de um neurônio artificial.....	39
Figura 16 – Divisão dos dados em treino e teste com 5-folds validação cruzada	41
Figura 17 – Fluxograma das etapas do trabalho.....	42
Figura 18 – Configuração dos ensaios	44
Figura 19 – Etapas da coleta de dados	44
Figura 20 – Geometrias das ferramentas.....	46
Figura 21 – Coleta dos valores de rugosidade.....	49
Figura 22 – Sistema de medição das rugosidades	50
Figura 23 – Gráficos para análise das rugosidades.....	63
Figura 24 – Gráfico para análise dos desgastes.....	65
Figura 25 – Comparação dos erros dos modelos para desgaste das ferramentas padrões	68
Figura 26 – Comparação dos erros dos modelos para desgaste das ferramentas HSC 1/300..	69
Figura 27 – Comparação dos erros dos modelos para desgaste das ferramentas H 4/400.....	70
Figura 28 – Comparação dos erros dos modelos para R_a das ferramentas padrões	71
Figura 29 – Comparação dos erros dos modelos para R_a das ferramentas HSC 1/300.....	72
Figura 30 – Comparação dos erros dos modelos para R_a das ferramentas H 4/400.....	73
Figura 31 – Comparação dos erros dos modelos para R_z das ferramentas padrões.....	74

Figura 32 – Comparação dos erros dos modelos para R_z das ferramentas HSC 1/300	75
Figura 33 – Comparação dos erros dos modelos para R_z das ferramentas H 4/400.....	76
Figura 34 – Comparação dos erros dos modelos para R_t das ferramentas padrões.....	77
Figura 35 – Comparação dos erros dos modelos para R_t das ferramentas HSC 1/300.....	78
Figura 36 – Comparação dos erros dos modelos para R_t das ferramentas H 4/400	79

LISTA DE QUADROS

Quadro 1 – Variáveis e equações do processo de fresamento.....	20
Quadro 2 – Estruturação do conjunto de dados.....	52
Quadro 3 – Avaliação prévia das ferramentas.....	55
Quadro 4 – Flancos e faces dos gumes no final da vida útil.....	64
Quadro 5 – Resultados dos melhores modelos.....	80

LISTA DE TABELAS

Tabela 1 – Comprimento de amostragem	28
Tabela 2 – Composição química do material	45
Tabela 3 – Parâmetros de usinagem.....	48
Tabela 4 – Especificações rugosímetro Mitutoyo	51
Tabela 5 – Medições dos raios das ferramentas	56
Tabela 6 – Medições dos desgastes das ferramentas	57
Tabela 7 – Rugosidades e desgaste médios das ferramentas padrões.....	58
Tabela 8 – Rugosidades e desgaste médios das ferramentas HSC 1/300	59
Tabela 9 – Rugosidades e desgaste médios das ferramentas H 4/400	61
Tabela 10 – Avaliações das rugosidades.....	62

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AISI	American Iron and Steel Institute
AM	Aprendizado de máquina
DIN	<i>Deutsches Institut für Normung</i> (Instituto Alemão de Normalização)
HRC	Dureza Rockwell C
HSC 1/300	Polimento com carboneto de silício e casca de noz
H 4/400	Polimento com caca de noz e partículas de diamante
IA	Inteligência Artificial
ISO	<i>International Organization for Standardization</i> (Organização Internacional para Padronização)
KB	<i>Kernel Bayes</i>
KNN	K-Vizinhos Mais Próximos
LAMEC	Laboratório de Ensaios Mecânicos da Universidade de Caxias do Sul
MAE	Erro Médio Absoluto
ML	<i>Machine learning</i> (Aprendizado de Máquina)
MLP	<i>Multilayer Perceptron</i>
NuSVR	<i>Nu Support Vector Regressor</i>
RMSE	Raiz Quadrada do Erro Quadrático Médio
VC	Validação cruzada
RNA	Rede Neural Artificial
SVM	Máquina de Vetor de Suporte
SVR	<i>Support Vector Regressor</i>

LISTA DE SÍMBOLOS

l_t	Comprimento total (μm)
R_a	Rugosidade Média (μm)
R_z	Rugosidade Média Parcial (μm)
R_t	Rugosidade Total (μm)
y_i	Valores absolutos das ordenadas de afastamento (μm)
l_m	Intervalo do comprimento de medição (μm)
l_e	Comprimento de amostragem (μm)
Z_i, \bar{Z}_i	Média aritmética dos cinco valores da rugosidade parcial (μm)
V_B	Largura do desgaste do flanco (mm)
$V_{B\text{Máx}}$	Largura máxima do desgaste de flanco (mm)
V_{B_N}	Desgaste de entalhe (mm)
V_{B_C}	Desgaste de ponta (mm)
KT	Profundidade da cratera (mm)
KB	Largura da cratera (mm)
KM	Distância do centro à borda do gume (mm)
T	Vida da ferramenta de corte
x	Amostras de treinamento ou preditores
y	Valor alvo ou o que se deve predizer
C	Parâmetro de regularização
Nu	Limite de erros e de vetores
x_m	Entradas da RNA
w_{ki}	Pesos sinápticos
b_k	Termo bias
u_k	Combinação linear dos sinais de entrada
$f_{(vk)}$	Função de ativação
y_k	Saída do neurônio
a	Valor constante da regressão
b	Coefficiente angular
d	Amostra dos dados para validação cruzada
k	Subconjuntos dos dados da validação cruzada
m_k	Tamanho do subconjunto da validação cruzada

λ	Ângulo de hélice
γ	Ângulo de saída
α	Ângulo de folga
β	Ângulo de cunha
z_g	Número de gumes
D_h	Diâmetro da haste (mm)
d_c	Diâmetro de corte (mm)
L_t	Comprimento total (mm)
l_c	Comprimento de corte (mm)
l/d	Razão comprimento e diâmetro
V_c	Velocidade de corte (m/min)
f_z	Avanço por dente (mm/gume)
a_p	Profundidade de corte (mm)
a_e	Largura de corte (mm)
n	Rotação do eixo principal (rpm)
F	Avanço da mesa (mm/min)
L	Comprimento usinado na primeira passagem da ferramenta (mm)

SUMÁRIO

1. INTRODUÇÃO.....	14
1.1 JUSTIFICATIVA.....	15
1.2 OBJETIVOS	17
1.2.1 Objetivo geral.....	17
1.2.2 Objetivos específicos.....	17
2. REFERENCIAL TEÓRICO	18
2.1 FRESAMENTO.....	18
2.1.1 Fresamento de topo reto	22
2.1.2 Desgaste no fresamento.....	23
2.1.3 Rugosidade no fresamento.....	25
2.2 TRATAMENTO DE GUME POR ARRASTE.....	30
2.3 APRENDIZADO DE MÁQUINA.....	32
2.3.1 Algoritmos de Regressão	33
2.3.1.1 Random Forest Regressor.....	34
2.3.1.2 Gradient Boosting Regressor e XGBoost.....	35
2.3.1.3 Ada Boost Regressor	35
2.3.1.4 Support Vector Regressor e Nu Support Vector Regressor.....	36
2.3.1.5 Extra Tree Regressor	36
2.3.1.6 Regressão linear	37
2.3.2 Redes Neurais Artificiais.....	37
2.3.3 Métodos para avaliação das previsões	40
2.3.3.1 Raiz Quadrada do Erro Quadrático Médio	40
2.3.3.2 Erro Médio Absoluto.....	40
2.3.3.3 Validação cruzada utilizando k-folds	40
3. METODOLOGIA	42
3.1 ETAPAS DA METODOLOGIA	42
3.1.1 Definição do problema	43
3.1.2 Coleta de dados	43

3.1.2.1 Definição do material	44
3.1.2.2 Definição e fabricação das ferramentas	45
3.1.2.3 Polimento das ferramentas	46
3.1.2.4 Caracterização dos gumes	46
3.1.2.5 Fresamento do material e desgaste da ferramenta	47
3.1.2.6 Medição das rugosidades	49
3.1.3 Pré-processamento e avaliações prévias	51
3.1.4 Modelagem e ajustes dos modelos	53
3.1.5 Pós-processamento	53
4. RESULTADOS	54
4.1 COLETA DE DADOS	54
4.1.1 Caracterização das ferramentas	54
4.1.2 Medição dos desgastes	56
4.1.3 Medição das rugosidades	57
4.2 PRÉ-PROCESSAMENTO E AVALIAÇÕES PRÉVIAS	58
4.3 MODELAGEM E AJUSTE DOS MODELOS	66
4.4 PÓS-PROCESSAMENTO	67
5. CONCLUSÃO	81
6. SUGESTÕES PARA TRABALHOS FUTUROS	83
REFERÊNCIAS BIBLIOGRÁFICAS	84

1. INTRODUÇÃO

O fresamento de topo é um processo muito utilizado na indústria, a compreensão mais abrangente deste processo contribui na busca por melhorias de processos de fabricação. A preparação do gume da ferramenta surge como um fator potencial que contribui para estas melhorias, pois possibilita maior vida útil da ferramenta, melhor desempenho de corte e qualidade superficial do material usinado (XUEFENG, 2020). Esta preparação modifica a geometria da ferramenta, removendo os defeitos iniciais do gume, substituindo-os por um perfil suave, que aumenta a qualidade da ferramenta, melhora a estabilidade, diminui risco de lascamento e melhora a integridade do gume, o que facilita o fluxo de cavacos e a ação de corte (WANG, 2020). O resultado é, além de maior vida útil, viabiliza uma maior confiabilidade do processo, por meio da garantia de qualidade da peça de trabalho (BYRNE *et al.*, 2003; DENKENA, 2014).

A rugosidade da superfície de trabalho é o aspecto de qualidade que é afetado pelo desgaste da ferramenta. Uma ferramenta que não está afiada produz um acabamento superficial pior do que uma boa ferramenta (THANGARASU *et al.*, 2020). Desta forma, Yue *et al.* (2018) salienta que o desgaste da fresa durante o processo de usinagem afeta diretamente a qualidade da superfície. Portanto, combinar o desempenho da ferramenta com os requisitos de processamento é muito importante, já que a qualidade das peças é dependente do desempenho da ferramenta. A qualidade diminui gradativamente com o desgaste da ferramenta, até que não atenda aos requisitos de processamento. Sendo assim, o desgaste da ferramenta é um ponto-chave que conecta o status da ferramenta à qualidade da superfície (ZHAO; LIU; YUE; LI; ZHANG; LIANG, 2020), compreender esta relação é o que viabiliza uma maior confiabilidade do processo.

Segundo Saif (2014), a rugosidade é uma medida importante da qualidade do produto, impactante nas propriedades mecânicas como comportamento à fadiga e resistência à corrosão. Em vista disto, tem havido muitos desenvolvimentos de pesquisa para modelagem da rugosidade e otimização dos parâmetros para obter um acabamento superficial do nível desejado, visto que o mecanismo por trás da formação da rugosidade da superfície é muito dinâmico, complicado e dependente do processo.

Para avaliação da superfície, normalmente utilizam-se rugosímetros após a operação de usinagem, mas é uma operação que requer tempo e demanda de trabalho, o que acrescenta um custo adicional ao produto. De acordo com Mohanraj (2021), o desgaste da ferramenta pode ser medido diretamente (por microscópio dos fabricantes de ferramentas e sistema de visão) ou

indiretamente (por sensores). A medição direta acarreta na parada da máquina para remover a ferramenta e realizar a medição, embora pareça ser confiável e altamente preciso, aumenta o tempo de inatividade da máquina, o que, por sua vez, afeta a produtividade. Por conseguinte, considera-se a predição da rugosidade e dos desgastes, por modelos e/ou algoritmos, uma forma de diminuir os custos e o tempo de processo, podendo determinar rugosidades informando-se os parâmetros de entrada do processo aos modelos (AYKUT, 2011).

A tarefa de prever a rugosidade na usinagem é bastante desafiadora, mas fundamental para uma adequada otimização do processo (CHANDRASEKARAN *et al.*, 2010). Assim como o desgaste, devido a diferentes possibilidades de configuração, parâmetros, geometrias da ferramenta, estratégia de corte, entre outros fatores. Compreender estes dois parâmetros e a sua relação, por meio de modelos, significa redução de tempo e custos, uma vez que diminui operações de processos e garante um melhor aproveitamento da ferramenta.

Devida a importância da preparação de gume e a de utilizar métodos para prever a rugosidade e o desgaste, este trabalho busca prever a rugosidade da peça e o desgaste da ferramenta. Considerando também um cenário de diferentes polimentos de gume por arraste, busca-se encontrar o método mais eficaz de predição e compreender melhor os efeitos destes polimentos de gume no acabamento superficial e desgaste.

1.1 JUSTIFICATIVA

A preparação do gume de corte é amplamente considerada como a principal direção para melhorar o desempenho da ferramenta (WANG *et al.*, 2020; DENKANA *et al.* (2014); Li *et al.* (2017)). Além das contribuições já destacadas do ponto de vista do ciclo de desgaste e vida útil e acabamento superficial, a otimização da microgeometria também permite uma fabricação mais econômica, razão pela qual a pesquisa neste campo é importante. Dentro dos processos de preparação de gume, o acabamento por arraste é amplamente utilizado para acabamento de peças que precisam de boa qualidade superficial e sua principal vantagem é o tempo curto para obter o resultado necessário (BARLETTA *et al.*, 2014). Por meio de modificações de parâmetros, tipo e tamanho de granulado, taxa de alimentação e tempo de processo, a preparação de gume é eficiente na fabricação de ferramentas, o que gera um acabamento de gume uniforme para as ferramentas de metal duro (YUSSEFIAN, 2012).

Considerando a preparação de gume como principal direção para garantir um bom desempenho das ferramentas, alguns trabalhos vêm investigando sobre o acabamento por arraste aplicados na fabricação de ferramentas. Fulemova *et al.* (2014) trata da influência da

preparação do gume de corte e do raio do gume de corte na vida útil da ferramenta, nas forças de corte e na rugosidade da superfície usinada. Zhao *et al.* (2016) investigou os efeitos dos parâmetros de preparação sobre o gume de corte. Petera *et al.* (2018) descreve a influência da preparação do gume de corte por arraste no processo de fresamento, no tratamento da ferramenta, na rugosidade superficial do material usinado. Vozár *et al.* (2020) estudaram os parâmetros ótimos para o processo. Zhao *et al.* (2020) utilizou elementos discretos para otimizar as variáveis do processo de preparação de gume. Malkorra *et al.* (2021) destaca que a compreensão deste processo não é completa e buscou modelar como a forma do meio abrasivo (esférico ou piramidal) influencia os mecanismos de remoção de material na interface.

Além disso, destaca-se a importância de aplicação de métodos de otimização robustos no processo de fresamento, alguns trabalhos vêm explorando estas aplicações na área com foco em qualidade superficial. Santos (2001) aplicou Redes Neurais Artificiais (RNA) para relacionar acabamento superficial com base na rugosidade e desgaste de flanco variando parâmetros de corte. Escalona (2010), utilizou RNAs para predição de rugosidade no processo de faceamento. Vacaro (2013) aplicou Algoritmos Genéticos para otimizar parâmetros de corte no fresamento de topo esférico, considerando diferentes estratégias de usinagem. Saif (2014) aplicou RNA e Regressão na estimação da rugosidade no processo de micro-fresamento. Hübner (2016) utilizou RNA para estimar a rugosidade no fresamento frontal. Ameen (2018) previu a rugosidade obtida no fresamento do Inconel 718 utilizando RNA. Zhao *et al.* (2020) propõe um modelo de simulação para definir a vida útil da ferramenta em função da rugosidade superficial. Lin *et al.* (2020) apresentam a modelagem da rugosidade no processo de fresamento com base em parâmetros de corte e vibrações de usinagem, por meio de regressão múltipla e Redes Neurais Artificiais (RNAs), mostrando RNAs como o método mais eficiente, com uma acurácia de 93,14%.

As explorações feitas trouxeram as RNAs como potencial ferramenta. Ainda há uma gama de ferramentas de *Machine Learning* (ML) pouco exploradas para estas aplicações. Dentro da área de fresamento, poucos trabalhos exploraram métodos de ML, Thangarasu *et al.* (2020) utilizou os algoritmos Máquina de Vetor de Suporte (SVM), K-Vizinhos Mais Próximos (KNN), Kernel Bayes (KB), *Multilayer Perceptron* (MLP) e Árvores de Decisão para prever o desgaste de flanco. Os algoritmos de Árvores de Decisão e SVM tiveram melhores acurácias, de 100% e 99,86%, respectivamente. Outra interessante aplicação foi de Rodríguez *et al.* (2017) que propôs uma ferramenta de tomada de decisão, Árvore de Decisão, para prever rugosidade em faceamento em termos de desgaste e tipo de ferramenta.

Em vista destas oportunidades a serem exploradas, este trabalho busca juntar potenciais campos de desenvolvimento de melhorias no processo de fresamento, investigando o acabamento superficial resultante de ferramentas com diferentes polimentos pelo processo de arraste, bem como os seus desgastes, por meio de ferramentas de ML. Desta forma, busca-se responder: quais os melhores métodos para prever a rugosidade da peça e o desgaste da ferramenta ao longo da vida útil da ferramenta no cenário de diferentes polimentos por arraste?

1.2 OBJETIVOS

Nos tópicos a seguir são abordados o objetivo geral e os objetivos específicos deste trabalho.

1.2.1 Objetivo geral

O objetivo deste trabalho é propor modelos computacionais para predição de rugosidades e desgastes ao longo da vida útil da ferramenta no cenário de diferentes polimentos por arraste.

1.2.2 Objetivos específicos

Os objetivos específicos, a fim de se atingir o objetivo geral, foram definidos como:

- a) Buscar na literatura os parâmetros de avaliação da rugosidade e desgaste;
- b) Revisar na literatura os métodos utilizados para predição de rugosidade e desgaste;
- c) Realizar os experimentos para aquisição dos dados de rugosidade e desgaste;
- d) Explorar os dados e compreender os efeitos dos polimentos;
- e) Modelar os métodos de predição definidos; e
- f) Avaliar as métricas de erros dos modelos.

2. REFERENCIAL TEÓRICO

Nos tópicos a seguir são abordados os principais conceitos que fundamentam o trabalho.

2.1 FRESAMENTO

O fresamento é uma operação de usinagem por uma ferramenta de corte de vários gumes, sendo que cada um deles remove uma pequena quantidade de material. São programados avanços desta ferramenta em praticamente qualquer direção para remover material de uma peça de trabalho, podendo-se obter uma forma prismática, poliédrica ou livre (LACALLE *et al.*, 2011). Segundo Trent (2000), cada gume é submetido a impactos periódicos, caracterizando um tensionamento e aquecimento durante o corte, seguido por um período que não é tensionado e é resfriado. Os tempos de corte são de uma pequena fração de segundos e são repetidos várias vezes por segundo, causando fadiga térmica e mecânica na ferramenta.

Machado (2015) salienta que neste grupo de operações a ferramenta gira enquanto a peça, presa à mesa, é responsável pelos avanços longitudinais e transversais. Desta forma, este processo é reconhecido pela versatilidade na produção de geometrias diversas e é dividido pelo autor em fresamento tangencial (concordante ou discordante), fresamento tangencial de canais ou de perfis, fresamento de topo, fresamento frontal, fresamento com fresa de topo esférica e fresamento de cavidades.

Pela Norma DIN 8589 o fresamento pode ser subdividido de acordo com a superfície gerada, a forma da ferramenta e pela cinemática em fresamento plano, circular, de forma, de geração e de perfil. Além disso, quando a superfície da peça é gerada pelo topo da ferramenta então se designa processo de fresamento frontal, e quando a superfície é gerada pelos gumes na circunferência da fresa é designado de fresamento periférico. Quanto ao sentido de rotação da ferramenta e avanço da peça, distingue-se ainda entre concordante, avanço e movimento de corte apresentam o mesmo sentido, e discordante, que apresentam sentidos contrários. Dependendo da posição da fresa em relação à peça, um processo pode apresentar uma parte concordante e discordante (KLOCKE & KÖNIG, 2011). Na Figura 1 estão representadas estas subdivisões.

Figura 1 – Subdivisões do processo de fresamento



Fonte: Adaptado de Klocke (2011).

Conforme KLOCKE & KÖNIG (2011), as vantagens do fresamento concordante comparando-o ao discordante são em relação às forças resultantes que minimizam a vibração, menor desgaste da ferramenta, melhor qualidade superficial gerada, devido ao movimento relativo entre velocidades de avanço e de corte, potência de avanço menor e menor caminho percorrido pelo gume. Quanto às principais variáveis do processo de fresamento, observa-se no Quadro 1 a seguir suas definições e fórmulas.

Quadro 1 – Variáveis e equações do processo de fresamento

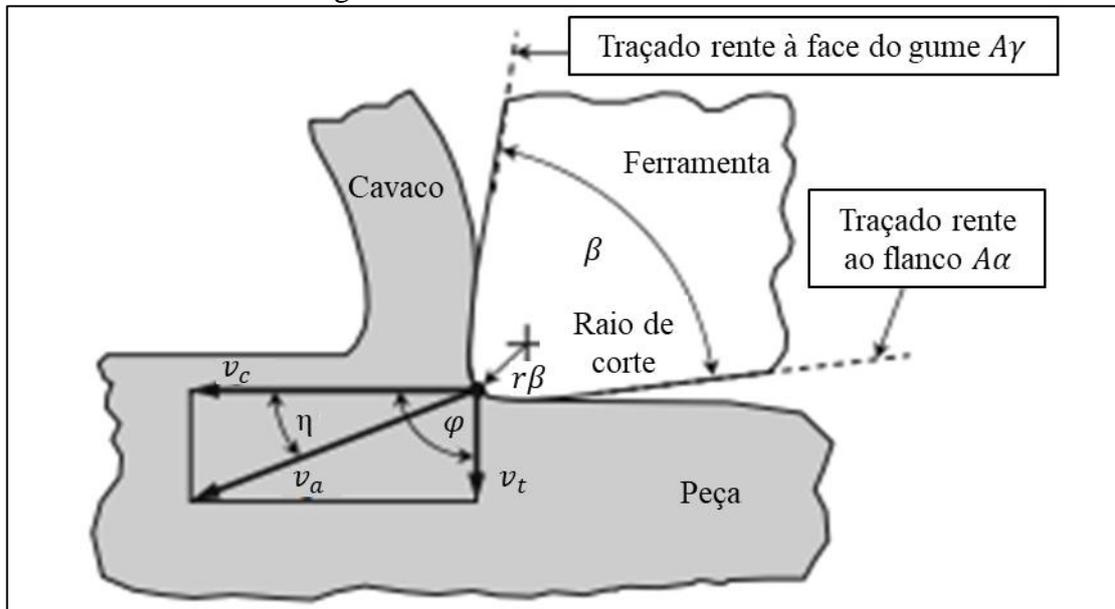
Velocidade de corte	$V_c = \frac{\pi \times D \times n}{1000}$ [m/min]	Onde: D = diâmetro da peça ou ferramenta [mm] n = número de rotações da peça ou ferramenta [rpm]	velocidade instantânea do ponto de referência do gume da ferramenta segundo a direção e o sentido de corte
Velocidade de avanço	$V_f = f \times n$ [mm/min]	Onde: f = avanço [mm] n = número de rotações da peça ou da ferramenta [rpm]	velocidade instantânea do ponto de referência do gume, segundo a direção e sentido de avanço
Avanço	$f = f_z \times z$ [mm]	Onde: f _z = avanço por gume [mm/gume] z = número de gumes da ferramenta	percurso de avanço em cada volta
Profundidade de corte	a_p [mm]		profundidade de penetração do gume principal
Penetração de trabalho	a_e [mm]		penetração da ferramenta em relação à peça numa direção perpendicular à direção de avanço

Fonte: Adaptado Klocke & König (2011).

Em relação a geometria da ferramenta de corte, os conceitos, designações e termos são estabelecidos na norma DIN 6581. Klocke (2011), mostra na Figura 2 as principais geometrias da ferramenta de corte, a cunha de corte é composta por duas faces: face de saída e face de flanco. O ângulo entre estas duas faces é designado como ângulo de cunha β . A face de saída

$A\gamma$ é a face onde o cavaco escoa. A face de flanco $A\alpha$ é a face na cunha de corte, que é voltada para a nova superfície da peça de trabalho (a superfície de corte).

Figura 2– Geometrias da cunha de corte



Fonte: Klocke & König (2011).

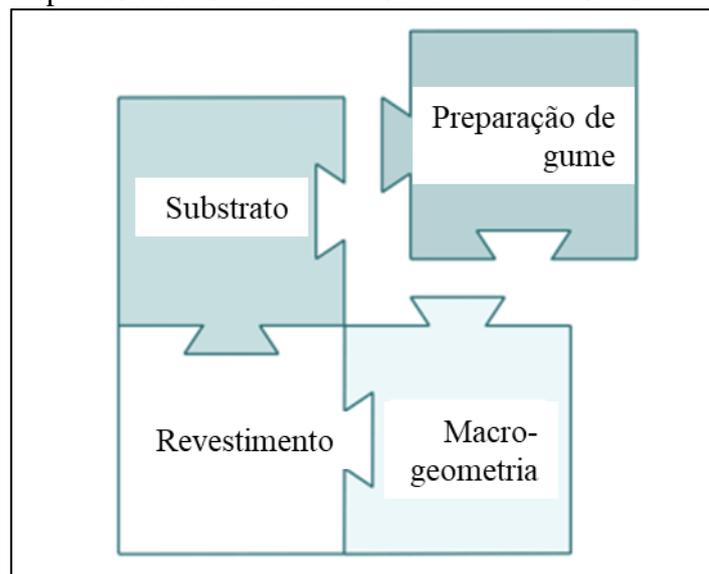
Para descrever o comportamento do material e da ferramenta durante o processo de corte, foi introduzido o termo comportamento da vida da ferramenta, sendo descrito pela norma DIN 6583 como a capacidade de um par de trabalho (ferramenta e peça) de resistir a um determinado processo de corte. Isto é influenciado pela durabilidade do gume da ferramenta, pela usinabilidade da peça e pelas condições de vida da ferramenta. O comportamento da vida útil da ferramenta é avaliado por meio das condições, critérios e parâmetros de vida da ferramenta. Sendo que, as condições de vida da ferramenta são todas as condições presentes durante o processo de corte ou teste operacional, compreendendo componentes como ferramenta (forma, geometria e material, por exemplo), peça de trabalho (forma e material, por exemplo), máquina-ferramenta (rigidez estática e dinâmica, por exemplo), processo de corte (cinemática e engajamento de ponta, por exemplo) e ambiente (tipo de fluido de corte e condições térmicas, por exemplo).

Para avaliar o comportamento da vida da ferramenta do sistema que abrange a peça, ferramenta, fixação, máquina-ferramenta e refrigeração, são usados critérios de vida da ferramenta que representam valores limites para alterações indesejadas na ferramenta, peça ou processo de corte causados pela usinagem. É importante que as condições, critérios e parâmetros de vida útil da ferramenta sejam sempre especificados. Alguns critérios de vida útil

são: valores de desgaste de flanco mensuráveis, alterações na rugosidade, mudanças na potência de corte, temperatura e forma de cavaco (Klocke, 2011).

Segundo Rodríguez (2009), o desenvolvimento de ferramentas de corte modernas e precisas contribui para novas estratégias de corte em busca de melhorar a produtividade na usinagem e a qualidade superficial dos materiais usinados. Para este desenvolvimento, quatro aspectos importantes são considerados e estão representados na Figura 3.

Figura 3 – Aspectos do desenvolvimento de ferramentas modernas e precisas



Fonte: Adaptado de Rodríguez (2009).

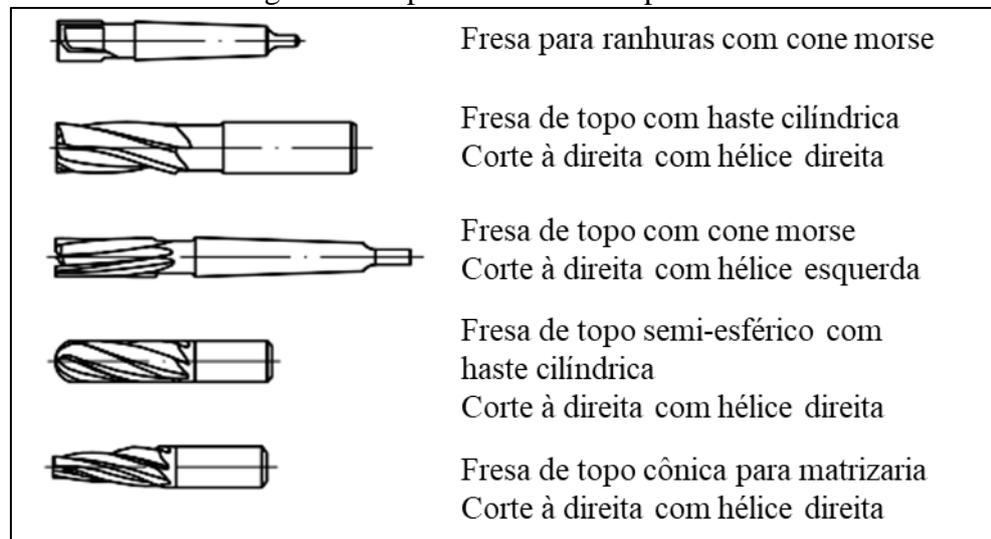
Os quatro pontos importantes para melhorar o desenvolvimento das ferramentas modernas são o substrato da ferramenta de corte, as tecnologias de revestimento, a macro-geometria e preparação do gume. A macro-geometria refere-se aos ângulos e raios dos gumes, o substrato é o material utilizado na fabricação destas ferramentas e o revestimento é um processo a mais, que cobre os gumes e, por meio dele, dá novas propriedades à ferramenta. A preparação do gume recebe destaque entre eles, tornou-se frequente em pesquisas por ser preciso, replicável, controlável e compatível com aplicações específicas e por melhorar a aderência de um possível subsequente revestimento, sendo um potencial elemento para extrair bons resultados na busca de processos de corte mais eficientes.

2.1.1 Fresamento de topo reto

O fresamento de topo é um processo de fresamento contínuo, circunferencial e frontal empregando uma fresa de topo. Segundo Trent (2000) é empregado na produção de formas

ocas, como cavidades para matrizes, podendo ser utilizada para usinar um recurso como um bolsão retangular com paredes idealmente verticais. A vantagem deste processo é na execução de superfícies de forma livre, como matrizes, rasgos de chaveta, bolsas, bem como rasgos e cortes de todos os tipos e tamanhos. Neste processo ocorrem vibrações regenerativas e deflexão das ferramentas, que levam a erros de forma e de medida nas peças. A otimização da geometria da ferramenta e da cunha de corte, das condições de engajamento, da estratégia de corte, bem como das condições de corte, são importantes para minimizar estes fenômenos (KLOCKE & KÖNIG, 2011). Os tipos de fresas de topo estão ilustradas na Figura 4.

Figura 4 – Tipos de fresas de topo



Fonte: Klocke & König (2011).

Segundo o autor, são fresas circunferenciais frontais e para a fixação dispõem de uma haste cilíndrica ou cônica. A escolha da fresa se dá pelo tipo de trabalho em forma cilíndrica, cônica ou de acordo com o desenho do componente a ser fabricado e o lado frontal geralmente possui forma plana ou semi-esférica.

2.1.2 Desgaste no fresamento

A utilização da ferramenta até o desgaste próximo ao fim da sua vida garante um melhor aproveitamento da ferramenta e economia. Em contrapartida, o desgaste possui relação direta com a rugosidade da superfície. Desta forma, a ferramenta deve ser substituída próximo ao fim da vida, mas antes do desgaste acelerar de forma acentuada, para evitar o aumento excessivo

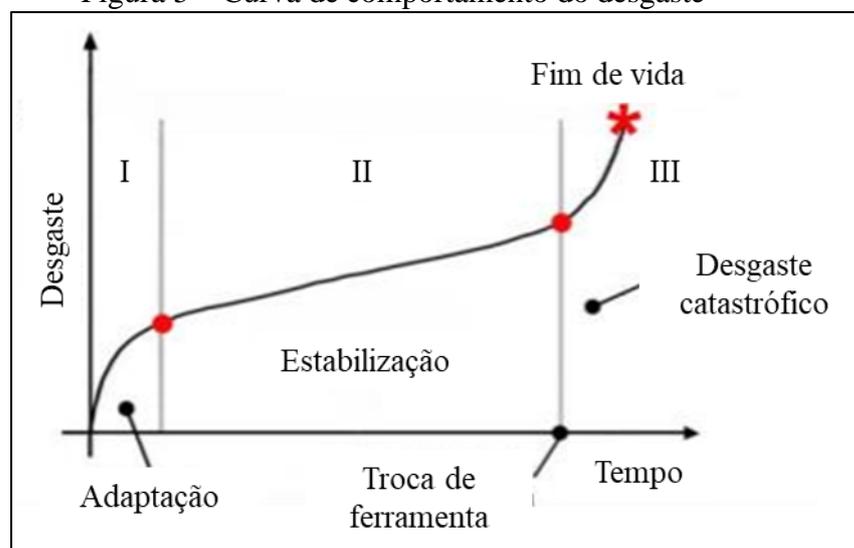
das forças de usinagem, acabamento superficial não adequado, e possível quebra da ferramenta (FERRARESI, 1970).

Diversos são os tipos de desgaste que ocorrem em uma ferramenta de usinagem. Os principais são: Desgaste frontal ou de flanco – o mais comum e ocorre na superfície de folga da ferramenta, causado pelo contato entre a ferramenta e a peça. Desgaste de cratera – ocorre na superfície de saída da ferramenta, causado pelo atrito entre ferramenta e cavaco, que pode não acontecer em alguns processos, principalmente quando utiliza-se ferramentas de metal duro recobertas. Deformação plástica do gume – que é um tipo de avaria, onde a pressão aplicada à ponta somada à alta temperatura gera deformação plástica (DINIZ, 1999).

As medições dos desgastes são realizadas no plano ortogonal da ferramenta. Na superfície de folga mede-se a largura do desgaste do flanco (V_B) que é um valor médio do desgaste e a largura máxima do desgaste de flanco ($V_{B_{máx}}$). Quando há, são medidos os entalhes (V_{B_N} e V_{B_C}) e as crateras são medidas pela profundidade (K_T), largura (K_B) e distância do centro à borda do gume (K_M). Entre os critérios de fim de vida, estão os valores limites para (V_B e/ou $V_{B_{máx}}$), tempo de trabalho, percurso de corte, peças produzidas e rugosidade da peça (DINIZ, 1999).

Segundo Machado *et al.* (2015), mesmo se a ferramenta possuir uma boa tenacidade, sempre estará sujeita ao desgaste, que será progressivo nas superfícies de folga e de saída. O tempo que a ferramenta trabalha efetivamente antes de ser substituída ou afiada é a vida da ferramenta de corte (T). Este comportamento possui uma curva padrão representada na Figura 5.

Figura 5 – Curva de comportamento do desgaste



Fonte: Machado *et al.* (2015).

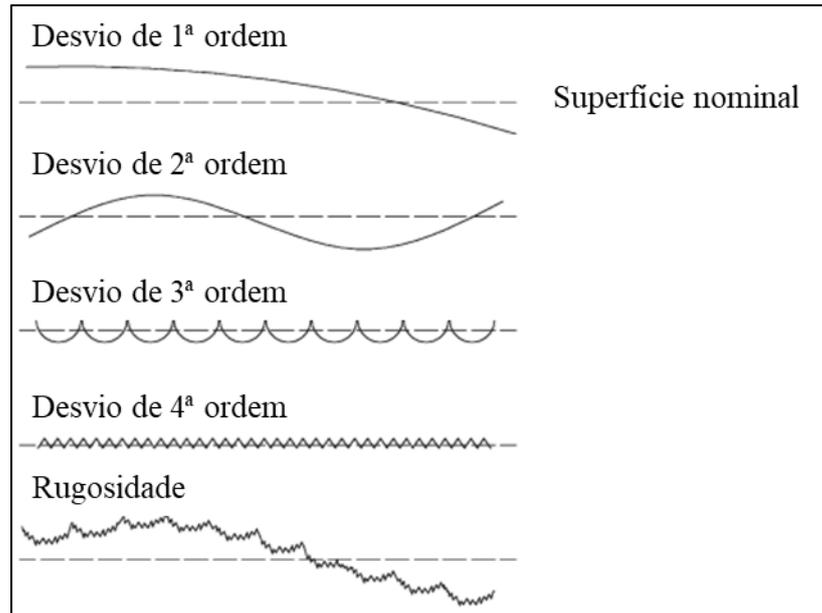
Onde, no Estágio I, nos primeiros instantes de corte, o desgaste é acelerado, nesta etapa a ferramenta está se acomodando ao processo. No Estágio II ocorre a estabilização e o desgaste tende a ser mais constante e a ferramenta já está adequada ao processo. No último, Estágio III, ocorre uma aceleração novamente do desgaste que, em curto espaço de tempo, promove a quebra da ferramenta. Portanto, o objetivo é identificar o início deste último estágio e substituir a ferramenta antes de atingi-lo.

2.1.3 Rugosidade no fresamento

Segundo Kalpakijan (2003), a garantia da qualidade é o esforço do fabricante para garantir que o produto esteja em conformidade com as especificações e padrões, como dimensões, acabamento superficial, tolerâncias, composição, cor e propriedades mecânicas, físicas e químicas. Esta garantia é de responsabilidade de todos envolvidos no projeto e fabricação, a prevenção de defeitos é um dos principais objetivos, uma vez que a qualidade deve ser incorporada ao produto e não apenas após a fabricação do produto. Quanto às rugosidades, Bernardos e Vosniakos (2002) elencaram as principais abordagens para assegurar a qualidade, que são abordagens baseadas na teoria de usinagem para desenvolver modelos analíticos para representar a superfície usinada, que são as abordagens que examinam os efeitos de diversos fatores por meio da execução de experimentos e da análise dos resultados, abordagens que utilizam experimentos planejados e as de Inteligência Artificial (IA).

A rugosidade refere-se ao desvio da superfície nominal da terceira até a sexta ordem. A ordem de desvio é definida em padrões internacionais (DIN4760). Na Figura 6 estão representados os desvios de forma. Os desvios de primeira e segunda ordem referem-se à forma, ou seja, planicidade, circularidade, etc. e à ondulação, respectivamente, e ocorrem devido aos erros da máquina-ferramenta, deformação da peça, configurações e fixação errôneas, vibração e homogeneidade do material da peça. Já os de terceira e quarta ordem referem-se a ranhuras periódicas e a trincas e dilapidações, que estão ligadas à forma e condição dos gumes, formação de cavacos e cinemática do processo. Os desvios de quinta e sexta ordem referem-se à estrutura do material da peça, que está ligada a mecanismos físico-químicos que atuam em escala de grão (deslizamento, difusão, oxidação, tensão residual, etc.). Estes diferentes desvios de ordem são sobrepostos e formam o perfil de rugosidade da superfície.

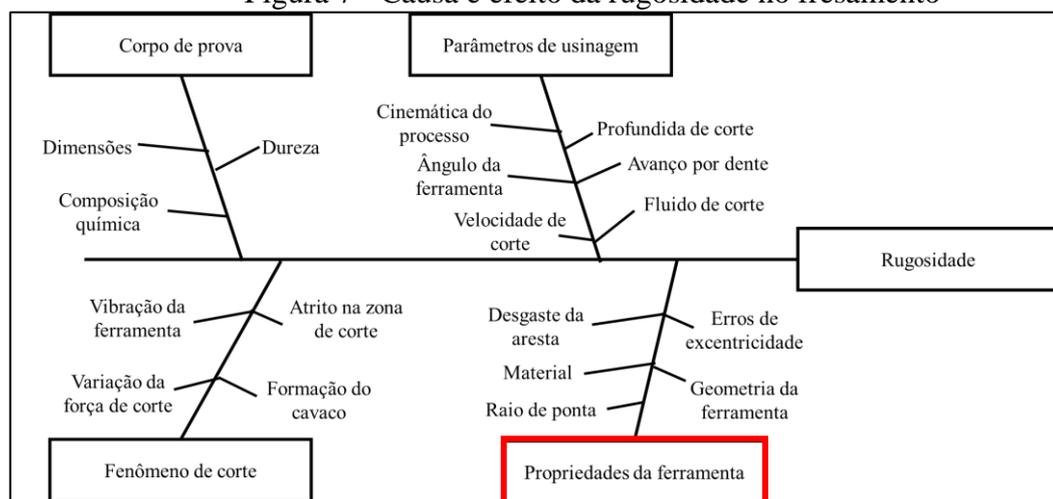
Figura 6 – Ordem dos desvios e perfil de rugosidade



Fonte: Adaptado de Bajić *et al.* (2012).

Este perfil de rugosidade formado sofre influência de diferentes variáveis do processo, Bajić *et al.* (2012) apresentaram um diagrama de Ishikawa, também conhecido como diagrama de causa e efeito, para mostrar os principais fatores que impactam na rugosidade de um componente usinado, destaca-se as propriedades das ferramentas, foco deste trabalho, principalmente raio de ponta e desgaste da aresta, conforme pode ser visto na Figura 7 a seguir.

Figura 7 - Causa e efeito da rugosidade no fresamento



Fonte: Adaptado de Bajić *et al.* (2012).

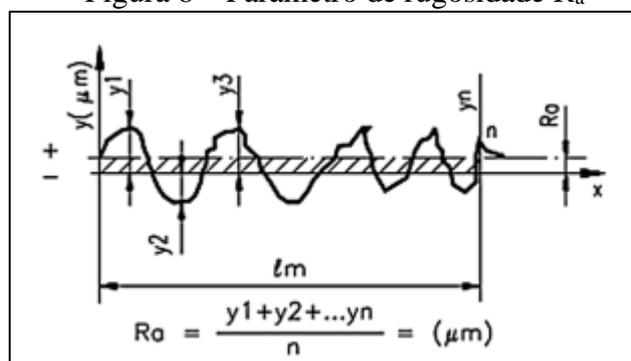
Yue *et al.* (2018) salienta que a qualidade da superfície é um dos requisitos de processamento mais influentes, sendo um indicador importante para julgar o desempenho de uma ferramenta, já que o desgaste da ferramenta durante o processo afeta diretamente a qualidade da superfície. A rugosidade da superfície está relacionada com a vida útil da

ferramenta, e a capacidade de utilizar toda a expectativa de vida de uma ferramenta pode reduzir significativamente os custos de produção e até melhorar a qualidade do processamento (Allaudin, 1997). Por isso a importância de prever a vida útil da ferramenta ao passo de garantir, por meio da predição, a qualidade superficial gerada conforme a condição da ferramenta.

Para medição da rugosidade, normalmente é utilizado rugosímetros de contato, por ser mais simples, versátil e barato. O medidor consiste em um apalpador que percorre em linha reta uma distância previamente definida como comprimento total (l_t), esse deslocamento é convertido em sinal elétrico e amplificado. Pode ser também medido sem contato com uso de sonda óptica que incide raios infravermelhos sobre a superfície e detecta a dispersão que é calculada e depois correlacionada com os parâmetros de rugosidade, normalmente são empregadas em situações nas quais tais apalpadores podem causar danos à superfície, ou vice-versa, como em borrachas, folhas delgadas, discos rígidos e cilindros de fotocopiadora (Machado *et al.*, 2015).

A rugosidade pode ser avaliada quantitativamente por meio de alguns parâmetros, os principais são: Rugosidade Média (R_a), Rugosidade Média Parcial (R_z) e Rugosidade Total (R_t). O R_a é o mais comum para descrever a rugosidade de uma superfície usinada (ÖKTEM, 2009; PALANISAMY *et al.*, 2007, ZAIN *et al.*, 2010b). Este parâmetro calcula a média aritmética dos valores absolutos das ordenadas de afastamento (y_i) dos pontos do perfil de rugosidade em relação à linha média, no intervalo do comprimento de medição (l_m). De acordo com a norma ABNT NBR ISO 4287, 2002, o comprimento de amostragem (l_e), ou *cutoff*, é o comprimento da direção x usado para identificar as irregularidades do perfil de avaliação. O l_m é o comprimento na direção x para avaliação, para maior confiabilidade dos dados, recomenda-se que seja 5 vezes o valor de l_e . Na Figura 8 está representado a medição e o cálculo do R_a .

Figura 8 – Parâmetro de rugosidade R_a



Fonte: Carter (2000).

Sempre que é realizada uma medição, o equipamento é calibrado e após é determinado os valores de comprimento de amostragem com base na faixa do valor de R_a de acordo com a norma ABNT NBR ISO 4288, 2008. Estes valores estão estabelecidos na Tabela 1 a seguir.

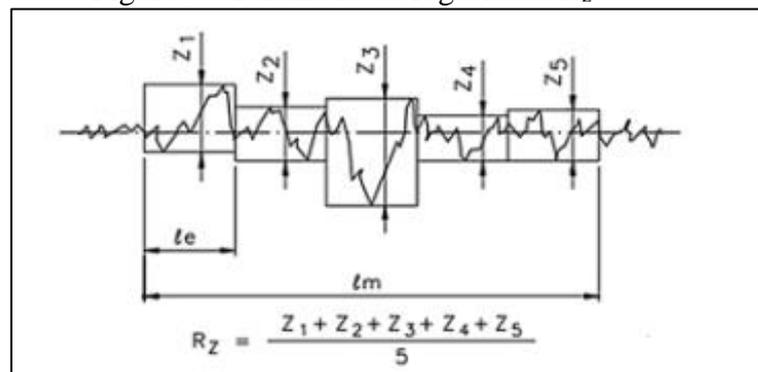
Tabela 1 – Comprimento de amostragem

Faixa de R_a [μm]	Comprimento de amostragem l_e [mm]	Comprimento de medição l_m [mm]
até 0,02	0,08	0,4
de 0,02 a 0,1	0,25	1,25
de 0,1 a 2	0,8	4
de 2 a 10	2,5	12,5
de 10 a 80	8	40

Fonte: Adaptado de Norma ABNT NBR ISO 4288 (2008).

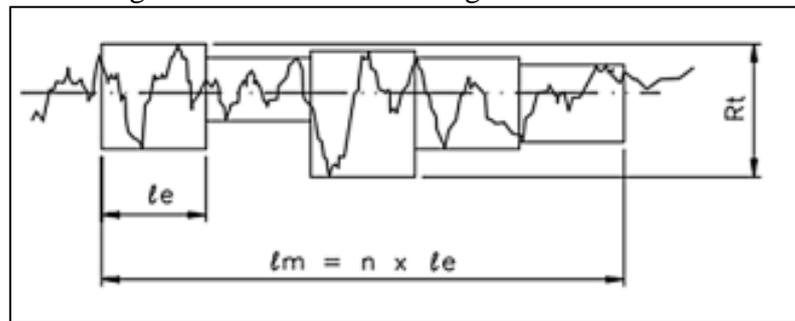
O parâmetro R_z representa a média aritmética dos cinco valores da rugosidade parcial (Z_i). Cada valor de Z é definido como o valor absoluto da ordenada do ponto de maior afastamento, acima e abaixo da linha média, em cada comprimento de amostragem (l_e). Na Figura 9 está representado o parâmetro R_z e o seu cálculo.

Figura 9 – Parâmetro de rugosidade R_z



Fonte: Carter (2000).

Já o parâmetro R_t , representado na Figura 10, diz respeito à distância vertical entre o pico mais alto e o vale mais profundo no comprimento de medição (l_m), independentemente dos valores de rugosidade parcial (Z_i).

Figura 10 – Parâmetro de rugosidade R_t 

Fonte: Carter (2000).

Segundo Carter (2000), comparando-se os parâmetros, o R_a normalmente é utilizado em linhas de produção, nos casos em que é necessário o controle contínuo da rugosidade nas linhas de produção, em superfícies em que o acabamento apresenta sulcos de usinagem bem orientados (como fresamento) e em superfícies com acabamentos de fins apenas estéticos. Como vantagens cita-se que quase todos os equipamentos de medição de rugosidade medem este parâmetro, devido a sua grande utilização e sua aplicabilidade à maioria dos processos de fabricação. Como desvantagens têm-se os fatos de o valor da R_a não sofrer grande alteração se um pico ou vale atípico aparecer na superfície e de não definir a forma das irregularidades do perfil.

O parâmetro R_z pode ser empregado nos casos em que pontos isolados não influenciam na função da peça a ser controlada. Como vantagens, podem ser citados os fatos de que ele indica a distribuição média da superfície vertical e que riscos isolados serão considerados apenas parcialmente, de acordo com o número de pontos isolados. Além disso, este parâmetro define muito bem a superfície em perfis periódicos. Como desvantagens, cita-se o fato de que nem todos os equipamentos fornecem o parâmetro e o valor de R_z , de forma isolada sem outros parâmetros, não apresenta informação suficiente a respeito da superfície, principalmente quanto ao formato da superfície. Já o parâmetro R_t considera o comprimento de amostragem (l_e) igual ao comprimento de medição (l_m). Como vantagem, é mais fácil obter R_t por meio do gráfico de superfície, como desvantagem, a rigidez de avaliação leva a resultados enganosos.

Entre os trabalhos desenvolvidos aplicando métodos para predição dos parâmetros de rugosidade, a maioria dos trabalhos utilizaram apenas o R_a , e outros trabalhos como Al Hazza e Adesta (2013), predisseram R_a , R_q , R_z e R_t com Redes Neurais Artificiais (RNA), assim como Rajesh e Manu (2014) que fizeram a predição dos valores de R_a e R_t e Samek e Bilek (2013) que utilizaram R_a e R_z .

2.2 TRATAMENTO DE GUME POR ARRASTE

A fabricação de ferramentas de corte de metal duro geralmente é realizada com as etapas do processo de sinterização ou prensagem do *blank*, retificação, preparação do gume e revestimento com pré e pós-tratamento. As peças brutas de metal duro produzidas no processo de sinterização ou prensagem apresentam desvios dimensionais e de forma devido ao encolhimento relacionado ao processo. Além disso, suas superfícies muitas vezes não atendem aos requisitos das ferramentas de corte (FRIEMUTH, 2002). Portanto, a retificação é utilizada após o processo de sinterização ou prensagem para gerar a forma macrogeométrica final das ferramentas e para produzir superfícies que atendam aos requisitos. Geralmente é realizada com rebolos diamantados devido à alta dureza, alta resistência ao desgaste e baixa ductilidade para ferramentas de metal duro (MALDANER, 2008). Além disso, rebolos resinados também são usados, assim como rebolos cerâmicos e híbridos, que possuem fases metálicas combinadas com partes de outros sistemas de colagem (BIERMAN *et al.* (2012); ÖZEL *et al.* (2005).

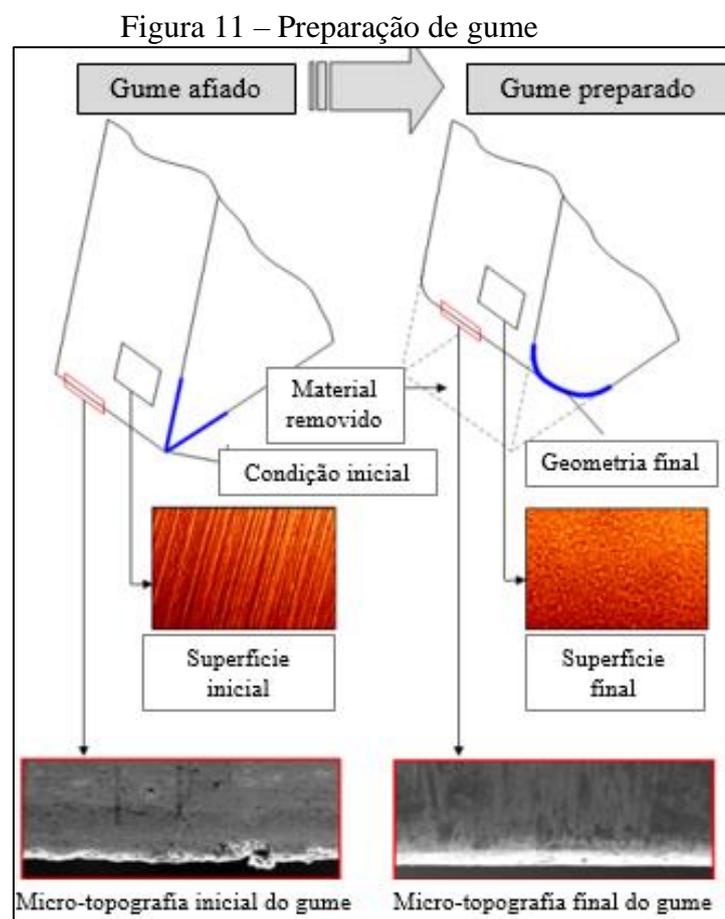
Segundo Tikal *et al.* (2009), após a retificação, os gumes das ferramentas geralmente apresentam micro-defeitos ou rebarbas. Isso desestabiliza o gume e resulta em redução da vida útil da ferramenta, qualidade da peça e confiabilidade do processo. Assim, os custos das ferramentas e os tempos de produção aumentam. Isso se deve à maior probabilidade de falha esporádica causada por picos de tensão que ocorrem localmente no gume. A aplicação controlada da preparação de gume tem vários propósitos principais para aumentar a resistência, eliminar o defeito anterior, para aumentar a vida útil da ferramenta, minimizar o lascamento e preparar a superfície da ferramenta para o revestimento (RAMESH, 2014).

Existem diferentes métodos para a preparação de gumes, como: jato abrasivo seco e úmido, escovação, arraste, usinagem magneto-abrasiva, usinagem de fluxo abrasivo, laser, descarga elétrica e soluções de retificação. Os métodos diferem em termos de produtividade, precisão e a variabilidade do gume, de modo que o método mais adequado deve ser selecionado para cada aplicação e geometria (DENKENA *et al.*, 2014). O acabamento por arraste é indicado nos casos de tratamento de ferramentas rotativas, por conta da sua topografia complexa, pois garante uma ação homogênea em toda superfície, por mais complexa que essa possa ser (PAUCKSH, 2008). Quando a qualidade superficial é o elemento de maior importância, esse processo é recomendado, pois é confiável e reprodutível, além de gerar melhores distribuições das cargas e um arredondamento bem definido (TIKAL *et al.*, 2009).

Este processo caracteriza-se pela imersão da ferramenta de corte em um meio abrasivo, constituído por elementos cerâmicos com granulometrias conhecidas, utilizadas de acordo com

o arredondamento do gume ou polimento desejado. O processo é realizado com o deslocamento da ferramenta no meio, sofrendo a ação abrasiva dos grãos. A ferramenta é fixada e gira em torno do seu eixo, enquanto a máquina faz com que a ferramenta realize o seu movimento de translação. Com essa combinação de movimentos garante-se um tratamento uniforme em todas as áreas da ferramenta (RISSE, 2006; OTEC, 2008).

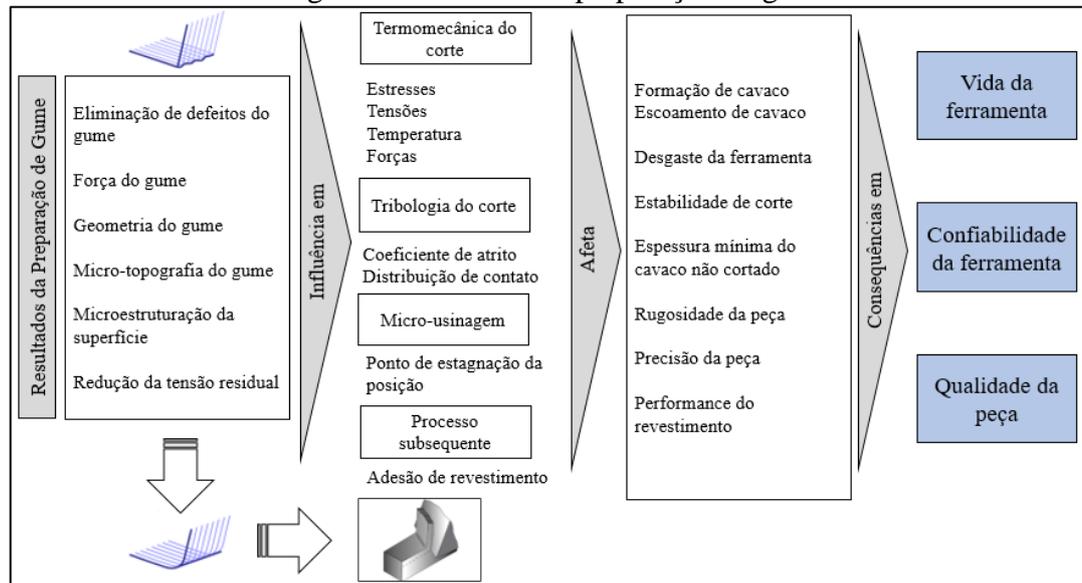
A preparação do gume gera um arredondamento bem definido, altera a sua microtopografia e também, modifica a microestrutura das superfícies nas proximidades do gume, como pode ser visto na Figura 11 a seguir.



Fonte: Adaptado de Rodríguez (2009).

Estas alterações do gume obtidas por meio da preparação de gume influenciam o processo de corte, estas influências estão explicadas na Figura 12.

Figura 12 – Efeitos da preparação de gume



Fonte: Rodríguez (2009).

Segundo Rodríguez (2009), a preparação de gume tem como resultados a eliminação de defeitos, influencia na geometria do gume, na micro-topografia do gume, distribuição de temperaturas, de tensões, forças de corte e na microestrutura da superfície. Estes resultados influenciam na termomecânica do corte, tribologia, micro-usinagem e nos processos subsequentes (como adesão de revestimento). Isto afeta diretamente a formação e escoamento do cavaco, o desgaste da ferramenta, estabilidade de corte, rugosidade e precisão da peça e performance do revestimento. Sendo pontos importantes que impactarão na vida e confiabilidade da ferramenta e qualidade da peça.

2.3 APRENDIZADO DE MÁQUINA

Entre as principais aplicações da Inteligência Artificial estão os sistemas de predição, onde aplicam-se algoritmos capazes de melhorar continuamente por meio de processos de tentativa e erro e não apenas com base nos aspectos tradicionais baseados em lógica de programação (MAKRIDAKIS; SPILLOTIS; ASSIMAKOPOULOS, 2018). O Aprendizado de Máquina (AM) é uma área de IA que tem o objetivo de desenvolver técnicas computacionais de aprendizado e a construção de sistemas capazes de adquirir conhecimento de forma automática (MONARD; BARANAUSKAS, 2003).

Segundo (SHWARTZ-SHALEV; BEN-DAVID, 2014), a AM é capaz de detectar, de forma automatizada, significativos padrões de dados. Ou seja, é um método de análise de dados que, de forma inteligente, desenvolve modelos analíticos, por meio do uso de algoritmos que

aprendem interativamente a partir de entradas de dados, permitindo que computadores encontrem resultados preditivos com base no que aprenderam.

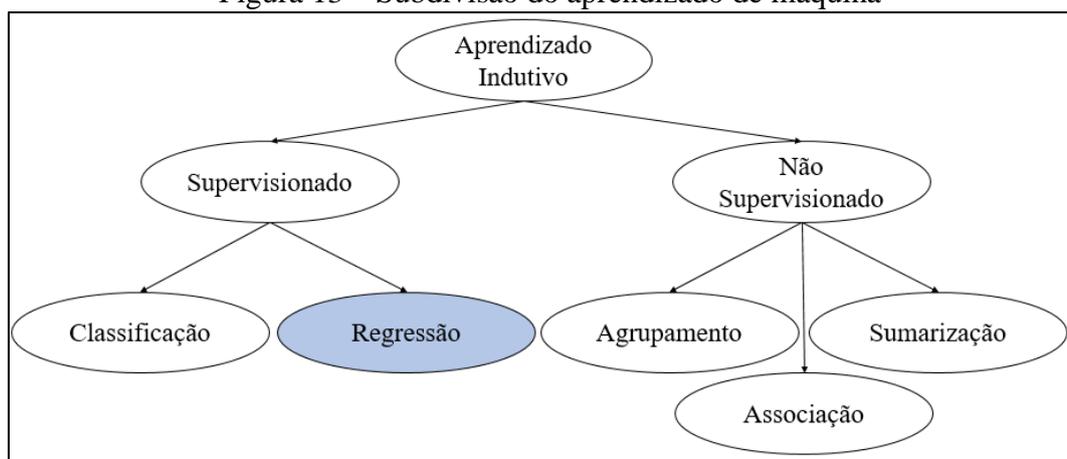
Nas seguintes seções são abordados os principais tópicos do AM utilizados no trabalho para predição, como os Algoritmos de Regressão, as Redes Neurais Artificiais (RNA) e a Regressão Linear, este último como um modelo simples para comparação com modelos mais robustos de AM. Também são abordados os conceitos e formas de avaliação dos modelos de predição.

2.3.1 Algoritmos de Regressão

O AM pode ser dividido em aprendizado por hábito, por instrução, por dedução, por analogia e por indução; e dentre estes o aprendizado indutivo é um dos mais úteis por permitir a obtenção de novos conhecimentos com base em exemplos ou casos particulares previamente observados (BATISTA *et al.*, 2003).

O aprendizado indutivo pode ser dividido em Aprendizado Supervisionado e Aprendizado Não Supervisionado. Sendo que o Aprendizado Supervisionado é dividido em modelos de Classificação e Regressão, enquanto o Aprendizado Não Supervisionado é dividido em modelos de Agrupamento, Associação e Sumarização. Na Figura 13 está ilustrada essa divisão.

Figura 13 – Subdivisão do aprendizado de máquina



Fonte: Adaptado de Monteiro (2018).

O Aprendizado Não Supervisionado permite abordar problemas com pouca ou nenhuma ideia dos resultados esperados. Desta forma o algoritmo deve ser capaz de agrupar os dados de forma que os dados mais semelhantes fiquem mais próximos através de *clusters* (MONARD;

BARANAUSKAS, 2003). O objetivo deste aprendizado é relacionar os dados entre si para construir agrupamentos (MARSLAND, 2015).

Na Aprendizagem Supervisionada o valor de saída já é conhecido e já sabe-se que há uma relação entre os valores de entrada e saída. Desta forma, o objetivo da máquina é encontrar uma função que represente esta relação e espera-se prever resultados de uma saída contínua (MARSLAND, 2015). Segundo Monard & Baranauskas (2003), é fornecido ao algoritmo de aprendizado um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido. Entre eles, os modelos de Classificação têm como objetivo a construção de um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados para rótulos de classe discretos. Os modelos de Regressão, foco deste trabalho, têm como objetivo determinar valores quantitativos, tratando-se de valores contínuos (FRIEDMAN *et al.*, 2001). É focado na busca por funções lineares, sendo a variável a prever um atributo numérico (contínuo) (GALVÃO; MARIN, 2009).

Nos seguintes tópicos desta seção são apresentados os algoritmos de aprendizado supervisionado de regressão utilizados no trabalho.

2.3.1.1 Random Forest Regressor

O *Random Forest Regressor* é formado por uma coleção de árvores de regressão, onde cada árvore é construída a partir de uma nova amostragem aleatória do conjunto de treinamento original (BASTOS *et al.*, 2013). De acordo com Pedregosa *et al.* (2011), pode ser considerado como um meta-estimador que ajusta várias árvores de decisão de classificação em várias subamostras do conjunto de dados e usa a média para melhorar a precisão preditiva e controlar o ajuste excessivo. Precisam ser ajustados com dois vetores, um esparsos ou denso de forma contendo as amostras de treinamento (x) e um de forma contendo os valores alvo (y) para as amostras de treinamento. Assim como as árvores de decisão, as florestas de árvores também se estendem a problemas de múltiplas saídas.

2.3.1.2 Gradient Boosting Regressor e XGBoost

Segundo Gilbert *et al.* (2020), o *Gradient Boosting Regressor* é um algoritmo de árvore de regressão que envolve uma abordagem de aprendizado conjunto, em que modelos de previsão robustos são formados pela integração de várias árvores individuais, que são chamados de aprendizes fracos, ou seja, que possuem alto viés e baixa variância. Este algoritmo identifica as limitações de modelos fracos por meio de gradientes, por meio de uma abordagem iterativa, onde a tarefa é finalmente juntar os aprendizes de base para diminuir os erros de previsão, onde as árvores de decisão são combinadas por meio de um modelo aditivo enquanto reduz a função de perda via gradiente descendente.

Este modelo é uma generalização de impulsionamento para funções de perda diferenciáveis arbitrárias. Caracteriza-se como um procedimento de prateleira preciso e eficaz que pode ser usado para problemas de regressão e classificação em várias áreas. Este estimador constrói um modelo aditivo de forma progressiva, de forma que permite a otimização das funções de perda diferenciáveis arbitrárias. Em cada estágio uma árvore de regressão é ajustada no gradiente negativo da função de perda dada (FRIEDMAN *et al.*, 2001). O XGBoost implementa algoritmos de aprendizado de máquina sob a estrutura Gradient Boosting, por meio de árvores paralelas, que vão corrigindo os erros das anteriores e melhorando os resultados.

2.3.1.3 Ada Boost Regressor

O algoritmo *Ada Boost Regressor* gera múltiplos regressores para finalizar um modelo ponderado e pode ajustar automaticamente os pesos com base em erros de estimativa, representando um grande potencial para lidar com problemas complicados de regressão não lineares (ZHAO, *et al.*, 2019). Este algoritmo é um meta-estimador que inicia o ajuste dos dados originais e depois ajusta cópias adicionais do regressor no mesmo conjunto de dados, mas onde os pesos das instâncias são ajustados de acordo com o erro da previsão atual. O princípio central deste modelo é ajustar uma sequência de aprendizes fracos, ou seja, aqueles modelos que são apenas um pouco melhores do que suposições aleatórias, como pequenas árvores de decisão, em versões repetidamente modificadas dos dados. As previsões de todos eles são então combinadas por meio de uma votação majoritária ponderada ou soma para produzir a previsão final (FREUND & SCHAPIRE, 1995).

2.3.1.4 Support Vector Regressor e Nu Support Vector Regressor

O modelo base *Support Vector Regressor* (SVR) é fundamentado no aprendizado supervisionado, onde tem como objetivo encontrar uma função que apresente uma margem de erro caracterizada por um intervalo. Os parâmetros livres no modelo são “C” e “Epsilon”, onde “C” é o parâmetro de regularização, em que a força é inversamente proporcional a “C” e deve ser positiva, enquanto o “Epsilon” é um tubo dentro do qual nenhuma penalidade é associada na função de perda de treinamento com pontos previstos dentro de uma distância “Epsilon” do valor real. O algoritmo *Nu Support Vector Regressor* (NuSVR) aplica o parâmetro “Nu” substituindo o parâmetro “Epsilon” do método SVR. Onde o parâmetro “Nu” é um limite superior da fração de erros de treinamento e um limite inferior da fração de vetores de suporte (PEDREGOSA, 2011).

Segundo Awad (2015), esse algoritmo envolve encontrar a margem máxima que separa o hiperplano, classificando corretamente o maior número possível de pontos de treinamento, este hiperplano é representado com vetores de suporte. É realizada a introdução de uma região insensível a “Epsilon” ao redor da função, chamada de ϵ -tubo. Este tubo reformula o problema de otimização para encontrar o tubo que melhor se aproxima da função de valor contínuo, equilibrando a complexidade do modelo e o erro de previsão.

2.3.1.5 Extra Tree Regressor

De acordo com Pedregosa *et al.* (2011), o algoritmo *Extra Tree Regressor* implementa um meta-estimador que ajusta várias árvores de decisão aleatórias, também conhecidas como extra-árvores, em várias subamostras do conjunto de dados e usa a média para melhorar a precisão preditiva e controlar o ajuste excessivo. Assim como *Random Forest Regressor*, é uma técnica de perturbação e combinação especificamente projetadas para árvores. Isso significa que um conjunto diversificado de classificadores é criado pela introdução de aleatoriedade na construção do classificador. A previsão do conjunto é dada como a previsão média dos classificadores individuais (BREIMAN, 1998). Onde, segundo Singh *et al.* (2021), envolvem uma técnica de aprendizado de máquina ensemble. O algoritmo evoluiu como uma expansão do algoritmo de floresta aleatória, mas a principal diferença é que ele escolhe aleatoriamente pontos de corte parcial ou total, com atributos individuais, e seleciona divisões.

2.3.1.6 Regressão linear

O objetivo da regressão linear simples (uni-variada) é modelar a relação entre uma única *feature* (variável explicativa x) e uma resposta contínua com valor (variável de destino y) (RASCHKA, 2015). Para Pestana & Gageiro (2003), é constituída por uma equação matemática linear que descreve o relacionamento entre duas variáveis. A Equação 1 expressa a equação linear, onde a e b são valores que se determinam com base nos dados amostrais, ou seja, a é uma constante e b é o coeficiente angular. A variável y é o que se deve predizer e x é o valor preditor.

$$y = a + bx \quad (1)$$

A diferença entre a regressão linear simples e a múltipla está na quantidade de variáveis explicativas consideradas. No caso da regressão simples, assume-se que há uma relação linear entre uma variável dependente y e uma independente (preditora) x , enquanto na regressão múltipla são consideradas duas ou mais variáveis explicativas (independentes). As variáveis independentes são chamadas de variáveis explicativas, pois explicam a variação de y (RODRIGUES, 2012).

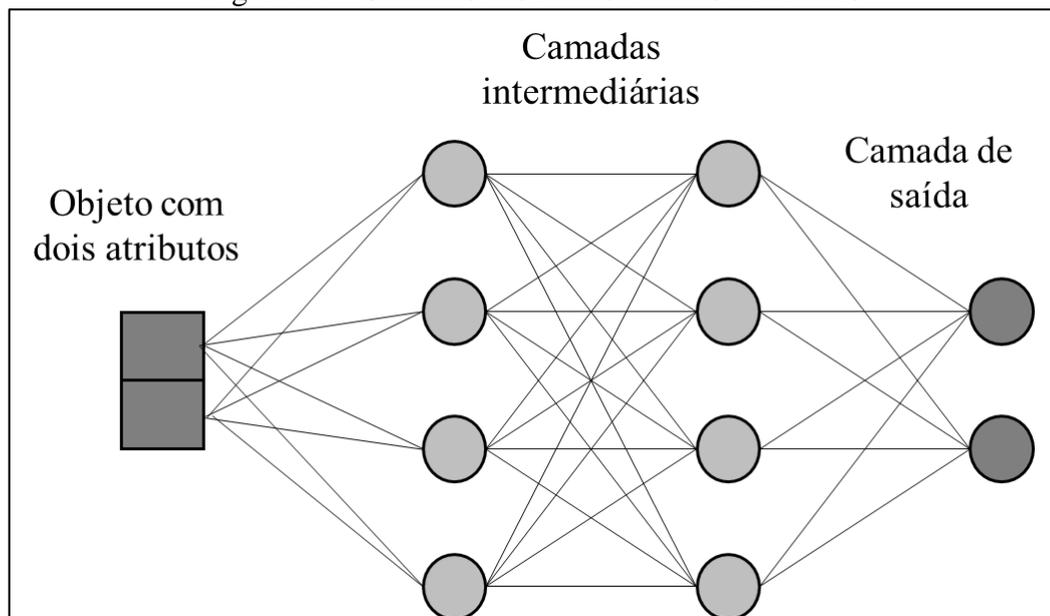
2.3.2 Redes Neurais Artificiais

A estrutura das Redes Neurais Artificiais é uma técnica inspirada no funcionamento do cérebro humano. É baseada em sistemas paralelos distribuídos compostos por unidades de processamento simples, conhecidas como nós ou neurônios, que calculam determinadas funções matemáticas, geralmente não lineares (Ribeiro, 2013). Estes nós possuem associações ponderadas, que representam neurônios e as forças de sinapses entre eles. A rede é estimulada por entradas nestes nós e é espalhada pelas conexões da rede. A ativação de um nó visa modelar o disparo médio dos picos observados como resultado da atividade elétrica em neurônios biológicos (GÉRON, 2017). Segundo Russel e Norvig (2013), cada iteração tem um peso numérico associado a ela, que determina a força e sinal de conexão, onde cada unidade calcula uma soma ponderada de suas entradas e, em seguida, aplica uma função de ativação a essa soma para obter a saída. Esta configuração forma um sistema computacional paralelo para executar uma determinada tarefa (BULLINARIA, 2014).

De acordo com Facelli *et al.* (2015), os neurônios podem estar dispostos em uma ou mais camadas, quando há mais de uma camada um neurônio pode receber como entrada os

valores de saída de neurônios da camada anterior e/ou enviar seu valor de saída para entrada de neurônios da camada seguinte. Quando há múltiplas camadas, a RNA pode ser chamada de *Multilayer Perceptron* (MLP). De acordo com Haykin (2001), esse algoritmo é frequentemente utilizado em aplicações práticas de previsão, classificação e reconhecimento de padrões de forma geral. Na Figura 14 é mostrado uma rede com três camadas, onde recebe valores de dois atributos e gera dois valores em sua saída.

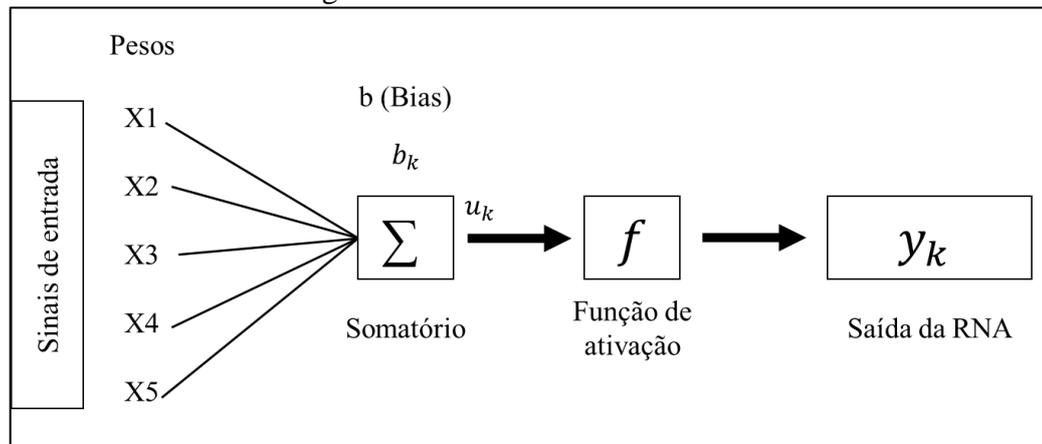
Figura 14 – Camadas das Redes Neurais Artificiais



Fonte: Adaptado de Faceli (2015).

Conforme é descrito por Sitton *et al.* (2017), estes neurônios que simulam a função dos neurônios biológicos possuem nas entradas um peso sináptico inicialmente aleatório, assim as entradas ponderadas são somadas e incrementadas alterando a saída do neurônio. O valor adquirido é passado por uma função de ativação, que consiste em uma função de normalização. Na Figura 15 está ilustrado um modelo não linear de um neurônio artificial do ponto de vista matemático.

Figura 15 – Modelo de um neurônio artificial



Fonte: Adaptado de Sitton *et al.* (2017).

As seguintes equações 2, 3 e 4 representam o modelo de rede.

$$u_k = \sum_{i=1}^m w_{ki} x_i \quad (2)$$

$$v_k = u_k + b_k \quad (3)$$

$$y_k = f(v_k) \quad (4)$$

Onde:

x_m : entradas da RNA;

w_{ki} : pesos sinápticos;

b_k : termo bias;

u_k : combinação linear dos sinais de entrada;

$f(v_k)$: função de ativação; e

y_k : saída do neurônio.

De acordo com Ribeiro *et al.* (2018), uma das propriedades mais consideráveis de uma RNA é a sua aptidão de aprender a partir dos exemplos e assim, melhorar seu desempenho a partir de um processo contínuo de treinamento. O treinamento da referida rede fundamenta-se na alteração de todos os pesos sinápticos e limiares existentes, com base na experiência conhecida acerca do fenômeno em questão, comumente disponíveis em um conjunto de dados que contenha pares de entrada e saída conhecidos.

2.3.3 Métodos para avaliação das predições

Nos seguintes tópicos deste capítulo são apresentados os métodos de avaliação dos modelos testados nos conjuntos de dados coletados.

2.3.3.1 Raiz Quadrada do Erro Quadrático Médio

A Raiz Quadrada do Erro Quadrático Médio ou *Root Mean Squared Error* (RMSE) é normalmente utilizada para expressar a acurácia dos resultados numéricos, apresentando valores do erro nas mesmas dimensões da variável analisada (HALLAK *et al.*, 2011). O seu valor é sempre positivo e quanto menor for o valor, melhor é o desempenho dos modelos, seu valor ideal é zero (ORTEGA; ROCIO, 2020). Este erro é calculado pela Equação 5 a seguir.

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

2.3.3.2 Erro Médio Absoluto

O Erro Médio Absoluto (MAE) é menos afetado por pontos com valores anormalmente extremos, os *outliers*, o MAE é considerado preciso e robusto como medida da habilidade de modelos numéricos em reproduzir a realidade (FOX, 1981). Esta métrica de erro é calculada por meio da Equação 6.

$$MAE = \frac{1}{N} \sum_{i=1}^N |d_i| \quad (6)$$

2.3.3.3 Validação cruzada utilizando k-folds

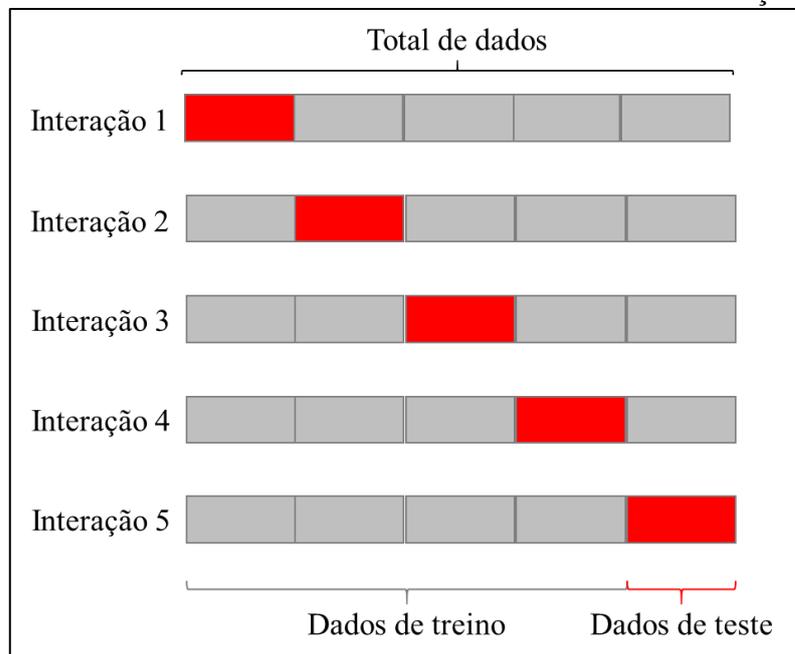
A Validação Cruzada (VC) é utilizada para estimar o erro de teste do ajuste de um método de aprendizagem estatística em um conjunto de observações. Além de ser útil na avaliação do modelo, ajuda a garantir que não sofra sobreajuste (*overfitting*) (AZEVEDO,

2018). O *overfitting* é um problema comum que acontece, segundo Jabbar e Khan (2014), quando um algoritmo de aprendizado se ajusta tão bem que o ruído e as peculiaridades dos dados de treinamento são memorizados. Portanto, o desempenho do modelo cai drasticamente quando é testado em um conjunto de dados desconhecidos.

Desta forma, é considerada uma boa técnica para avaliar a capacidade de generalização de um modelo a partir de um conjunto de dados. O objetivo da técnica é dividir o conjunto de dados em subconjuntos e utilizá-los para estimar os parâmetros dos modelos. Este subconjunto é denominado de conjunto de teste. Por meio do método de Validação Cruzada k-fold, o conjunto de dados é dividido em “k” subconjuntos do mesmo tamanho, um deles é utilizado para teste e os k-1 restantes são utilizados na estimação dos parâmetros. Após, calcula-se o desempenho geral do modelo, entre todas as classificações, quantas o modelo classificou corretamente, repetindo-se k vezes, onde se alterna, de forma circular, o subconjunto de teste. Desta forma, pode-se calcular os erros por fold ou de todos os folds (KOHAVI, 1995).

Na Figura 16 a seguir, é demonstrado a divisão dos dados por k-folds para treino e teste dos modelos.

Figura 16 – Divisão dos dados em treino e teste com 5-folds validação cruzada



Fonte: Adaptado de Kriegeskorte (2015).

Burman (1989) trouxe o método de k-fold e representou-o pela Equação 7.

$$kfK = \frac{1}{K} \sum_{k=1}^K \frac{1}{mk} \sum_{i=1}^{mk} L(y_{ik}, f_{(-k)}(x_{ik})) \quad (7)$$

Onde a amostra d é dividida em K partes (d_1, d_2, \dots, d_k), de tamanho próximo a m_k , em que $\sum_{k=1}^K m_k = n$. O processo terá K iterações, onde em cada uma, a amostra de validação será dada por d_k , com $k = 1, 2, \dots, K$, enquanto a amostra de treino para o preditor será o conjunto das outras $K - 1$ partes. Assim, ao final dos K passos, usam-se todos os dados tanto na parte de treino, quanto na parte de validação.

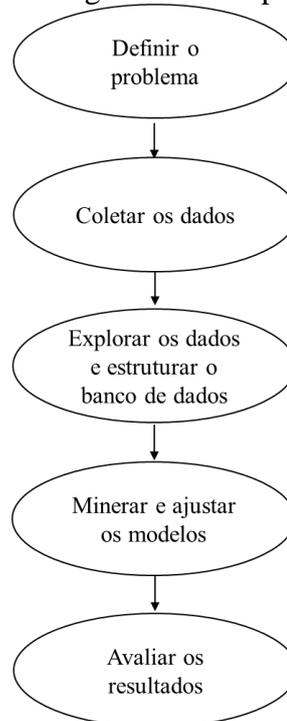
3. METODOLOGIA

Neste capítulo é abordada, detalhadamente, a metodologia adotada para propor modelos de previsão do desgaste de fresas com diferentes tratamentos de gume e da rugosidade de materiais usinados por estas ferramentas.

3.1 ETAPAS DA METODOLOGIA

As etapas da metodologia estão ilustradas no fluxograma da Figura 17 e detalhadas nos próximos tópicos.

Figura 17 – Fluxograma das etapas do trabalho



Fonte: Autor (2023).

3.1.1 Definição do problema

Em vista da importância de desenvolver melhorias nos processos de fresamento, busca-se explorar o cenário de preparação de gume pelo processo de arraste, por ser um processo potencial para trazer desenvolvimentos nessa área e ainda pouco explorado, analisando o efeito de diferentes polimentos no desempenho de fresas e as rugosidades obtidas por este processo.

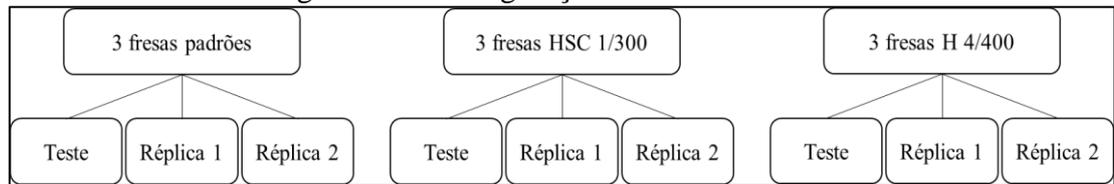
Considerando que a rugosidade no processo de fresamento é afetada diretamente pelo desgaste da ferramenta, pretende-se avaliar o comportamento do desgaste ao longo da vida útil de ferramentas com e sem polimento e as respectivas rugosidades geradas no material usinado. Com o intuito de investigar melhor os efeitos desses polimentos e propor métodos ainda não explorados para predição de rugosidade e desgaste, apresentando o melhor método para esta tarefa.

Para a avaliação da rugosidade, o parâmetro mais explorado na literatura foi o R_a , porém este trabalho, além de prever o R_a , propõe modelos para predição dos parâmetros R_t e R_z . Com o objetivo de seguir a linha dos trabalhos referenciado que também utilizaram mais parâmetros além do R_a , que destacaram a relevância de mais parâmetros de rugosidade para as avaliações relacionadas ao atrito e desgaste. Para a previsão do desgaste, foi utilizado o $VB_{máx}$ para as medições do desgaste da ferramenta no decorrer da sua vida útil e também como critério de fim de vida. Nos seguintes tópicos são detalhados os processos de coleta e processamento destes dados.

3.1.2 Coleta de dados

A coleta de dados para treinamento e teste dos modelos de predição foi baseada na realização de ensaios de fresamento de um material em diferentes cenários de polimento de gume. Onde foram considerados dois tipos de polimento por arraste com mídias abrasivas, o HSC 1/300 e o H 4/400, uma menos abrasiva e outra mais abrasiva, respectivamente, e também, a forma padrão da ferramenta, sem nenhum polimento, para comparar com os diferentes polimentos. Realizou-se testes e 2 réplicas para cada condição, com o intuito de utilizar a média das 3 amostras. Na Figura 18 está representado um esquema da configuração dos ensaios para a coleta dos dados.

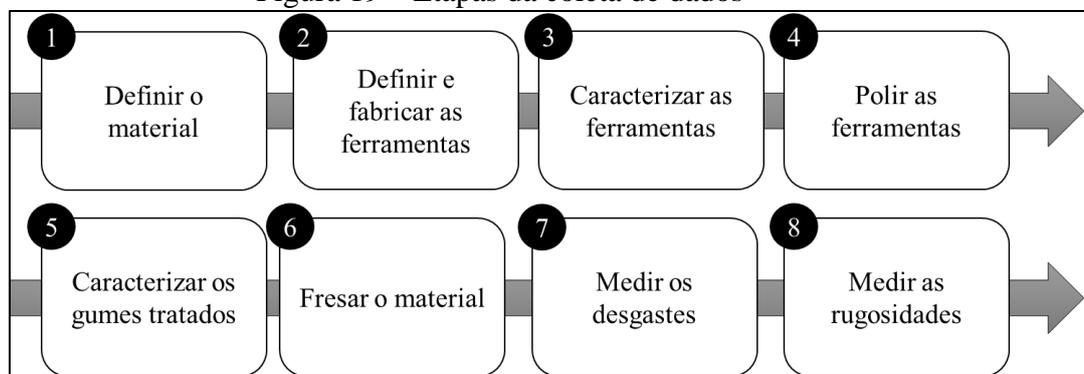
Figura 18 – Configuração dos ensaios



Fonte: Autor (2023).

Com base nessa configuração, algumas etapas precisaram ser elencadas para a coleta de dados de desgaste e rugosidade, que são as ilustradas na Figura 19 a seguir.

Figura 19 – Etapas da coleta de dados



Fonte: Autor (2023).

Primeiro, define-se o material a ser estudado e justifica-se esta escolha, em seguida as ferramentas e suas características são estabelecidas. Após, as ferramentas são fabricadas e caracterizadas, em seguida dois terços delas são polidas e terão seus novos gumes caracterizados novamente, com o intuito de diferenciar o raio e a rugosidade dos gumes sobre suas diferentes condições de polimento e em seu estado padrão, quantificando suas diferenças. Então, é realizado o fresamento do material, onde a superfície de avaliação é gerada e a ferramenta é desgastada até o critério definido para o final da sua vida útil. Com este processo realizado, é possível mensurar os desgastes da ferramenta e, por fim, as rugosidades da superfície. Assim, gera-se dados para treinar os modelos que auxiliarão na compreensão do comportamento da rugosidade e desgaste no decorrer da vida útil da ferramenta, em diferentes cenários de polimento por arraste. Nos próximos tópicos cada uma das etapas foram detalhadas.

3.1.2.1 Definição do material

O material utilizado no trabalho é o AISI P20 temperado e revenido a uma temperatura de, aproximadamente, 600 °C. Segundo Ganesh (2018), é um aço de liga de cromo-manganês-

molibdênio com baixo teor de carbono, mas versátil, com pequena quantidade de enxofre, caracterizado por boa tenacidade, resistência ao desgaste e usinabilidade em nível de resistência moderado sob uma condição endurecida e revenida. Pode ser aplicado no desenvolvimento de parafusos, porcas, componentes de acessórios automotivos e aeroespaciais, hidroformagem e acessórios eletrodomésticos. Além disso é muito utilizado na fabricação de moldes termoplásticos, matrizes de extrusão, moldes de injeção e matrizes de fundição (DEVARANI & JOSHI, 2020). Na Tabela 2 são representadas as composições químicas deste material.

Tabela 2 – Composição química do material

Elementos	C	Si	Mn	P	S	Cr	Mo	Ni	Al	Co
Teor %	0,458	0,333	1,953	0,023	0,010	1,844	0,231	0,708	0,001	0.100
Elementos	Cu	Nb	Ti	V	W	Sn	Fe			
Teor %	0,010	0,059	0,001	0,010	0,031	0,009	94,219			

Fonte: Autor (2023).

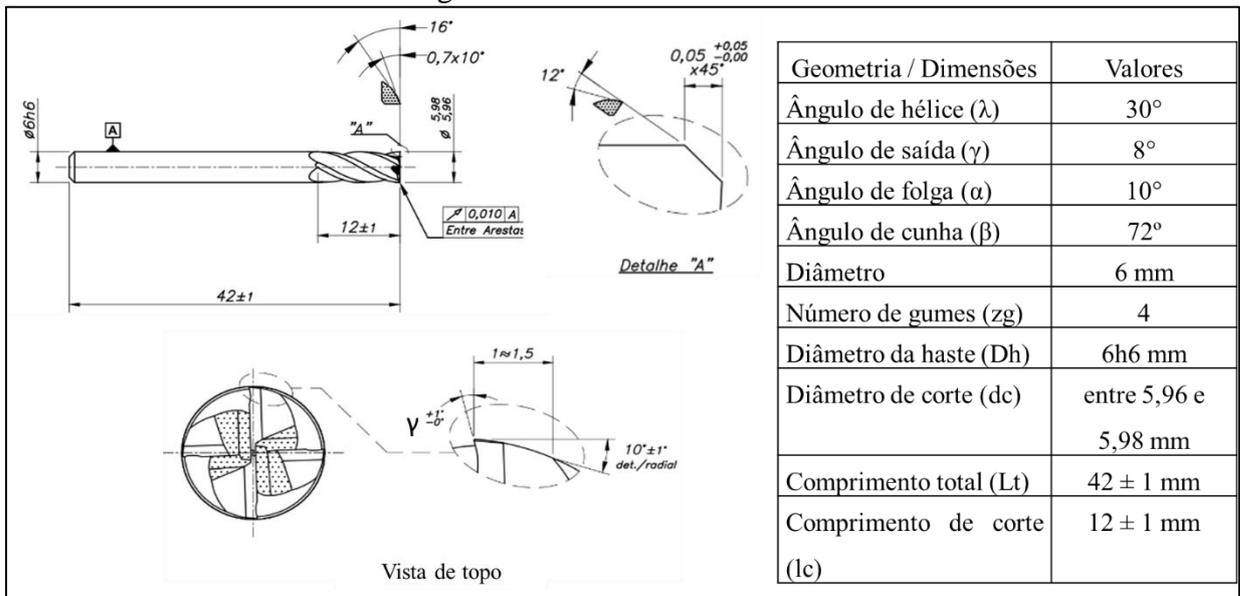
O Laboratório de Ensaio Mecânicos da Universidade de Caxias do Sul (LAMEC) avaliou a dureza dos corpos de prova nas quatro faces, conforme a norma ABNT NBR ISO 6508-1/09 e apresentaram uma dureza média de 35,85 HRC. Os corpos de prova utilizados para os ensaios possuem as dimensões de 80 mm por 252 mm e uma altura de 60 mm. Os corpos de prova já foram adquiridos nestas dimensões, e em seguida, passaram pelo processo de retifica, para que uma planicidade fosse garantida, contribuindo para melhor fixação na morsa mecânica acoplada no centro de usinagem.

3.1.2.2 Definição e fabricação das ferramentas

Foram utilizadas no trabalho fresas de topo reto inteiriças de metal duro, com diâmetro de 6 mm, o substrato destas ferramentas é o K40, com tamanho de grão de aproximadamente 0,6 μm , a dureza é de 1610 HV30, a densidade é de 14,45 g/cm^3 e sua composição é de 10% de cobalto e 90% de carboneto de tungstênio.

Foram utilizadas para os ensaios planejados 9 ferramentas, fabricadas pela empresa Secta Tools conforme as dimensões e geometrias descritas na Figura 20. As escolhas das geometrias das ferramentas foram baseadas nos valores já utilizados em projeto anterior realizado pelo Grupo de Usinagem da Universidade de Caxias do Sul (GUS).

Figura 20 – Geometrias das ferramentas



Fonte: Autor (2023).

3.1.2.3 Polimento das ferramentas

O tratamento por arraste foi realizado em 6 do total de 9 ferramentas. Foram consideradas 3 fresas sem nenhum tratamento, na sua condição padrão, 3 são tratadas por arraste com as mídias HSC 1/300 e as 3 restantes com as mídias H 4/400. O processo foi realizado pela empresa OTEC Präzisionsfinish GmbH, utilizando-se uma máquina modelo DF-3 Tool. Esta máquina possui duas unidades independentes de um sistema de rotação planetário e capacidade do tanque para mídia abrasiva de 80 litros.

As mídias foram fornecidas pela Empresa e suas composições são formadas por, no caso da mídia HSC 1/300, uma mistura de 30% de carboneto de silício (SiC), com diâmetro de grão de aproximadamente $200 \mu\text{m}$ e 70% de granulado de casca de noz, com diâmetro de grão entre 0,8 e 1,3 mm. Já a mídia H 4/400, é uma mistura de granulado de casca de noz, com diâmetro de grão entre 0,4 e 0,8 mm e uma pasta de polimento que contém partículas de diamante. E os parâmetros de tratamento são: rotação do cabeçote e mandril de 40 rpm no sentido horário e o tempo de processamento foi de 10 minutos.

3.1.2.4 Caracterização dos gumes

Antes de iniciar a preparação dos gumes, as ferramentas foram avaliadas em um estereoscópio binocular TNE-10B, da marca Entex com ampliação de 30 vezes para identificar

o estado das ferramentas e averiguar se não possuem falhas de fabricação ou lascamentos provenientes do transporte e manipulação durante o processo de identificação das amostras.

Depois disso, e também após passar pelos processos de tratamento, as ferramentas passaram por um processo de caracterização dos gumes. Para isso, considerando os três estados de gumes (padrão, HSC 1/300 e H 4/400) foi feita uma amostragem onde foram consideradas 3 ferramentas padrões, 3 ferramentas tratadas com HSC 1/300 e 3 ferramentas tratadas com H 4/400 para avaliação.

Esta caracterização consiste em avaliar estas amostras em um equipamento IF-SensorR25, da marca Alicona, que é um instrumento de medição 3D óptico sólido, capaz de medir de forma automatizada as formas e rugosidades das superfícies, baseado em variação de foco. foram medidos nas amostras os raios dos gumes das ferramentas para melhor distinguir as 3 condições de gume.

3.1.2.5 Fresamento do material e desgaste da ferramenta

Para os ensaios de desgaste das ferramentas de corte, o material foi fresado em um centro de usinagem LG-500, da marca Hartford. Este equipamento possui uma potência de 10 kW e rotação máxima de 10000 rpm. As fresas foram fixadas na máquina com um cone hidráulico SK40 da marca Schunk e com uma luva redutora de 20 mm para 6 mm. A razão comprimento/diâmetro (l/d) considerada foi de 3 mm, então as ferramentas foram fixadas com um comprimento em balanço de 18 mm.

Os batimentos das ferramentas, após serem montadas no mandril, foram medidos por um relógio DIGICO 10, da marca Tesa. Este relógio possui uma força de medição de $\pm 0,15$ N, resolução de 1 μm e repetibilidade de 5 μm . Os afastamentos máximos radiais do diâmetro da ferramenta em relação ao diâmetro nominal batimentos dos 4 gumes da ferramenta foram dimensionados. Foram considerados normais variações de até 20 μm , senão a fresa foi substituída por outra de mesma condição que apresente valores de batimento dentro da faixa estabelecida.

As ferramentas trabalharão até que seja alcançado o desgaste $VB_{\text{máx}}$ de 0,3 mm ou microfissuras, estabelecendo-se então como os critérios de fim de vida da ferramenta, para encontrar o início do desgaste catastrófico, que indica o momento ideal da substituição da ferramenta. Os parâmetros de usinagem do material estão expostos na Tabela 3 a seguir.

Tabela 3 – Parâmetros de usinagem

V_c (m/min)	f_z (mm/gume)	a_p (mm)	a_e (mm)	n (rpm)	F (mm/min)	Estratégia de corte
180	0,05	1,0	0,40	9549	1910	Concordante

Fonte: Autor (2023).

Os parâmetros de usinagem para os aços foram baseados no trabalho anterior realizado pelo GUS em primeiro projeto em parceria com a empresa OTEC Präzisionsfinish GmbH. Os parâmetros foram validados em pré-testes e os valores de a_e e a_p foram duplicados para acelerar a análise de desgastes, devido ao número alto de amostras do projeto que este trabalho faz parte.

3.1.2.5.1 Medições dos desgastes

Durante o processo de desgaste de cada uma das ferramentas, os valores de $VB_{m\acute{a}x}$ foram medidos de 2520 em 2520 mm, ou seja, de 10 em 10 passes. Para isso, foi utilizado o estereoscópio TNE-10B, que possui ampliação máxima de 45 vezes e contém uma câmera CCD acoplada, que está ligada ao software ScopePhoto para captura de imagens. Desta forma, foram fotografados para medições os flancos de cada um dos 4 gumes, na ampliação de 30 vezes.

As medições foram feitas pelo software, considerando escala real, por meio do traçado de uma linha rente ao gume e outra perpendicular - que inicia no local onde é notado o $VB_{m\acute{a}x}$ e termina na linha traçada sobre o gume. A medida desta linha perpendicular ao gume é equivalente ao valor em milímetros do $VB_{m\acute{a}x}$. Realizou-se três medidas em cada um dos gumes para obter mais precisão na localização do ponto onde está o desgaste de flanco máximo. Entre os valores medidos para cada um dos 4 gumes, foi calculado o valor médio destes valores.

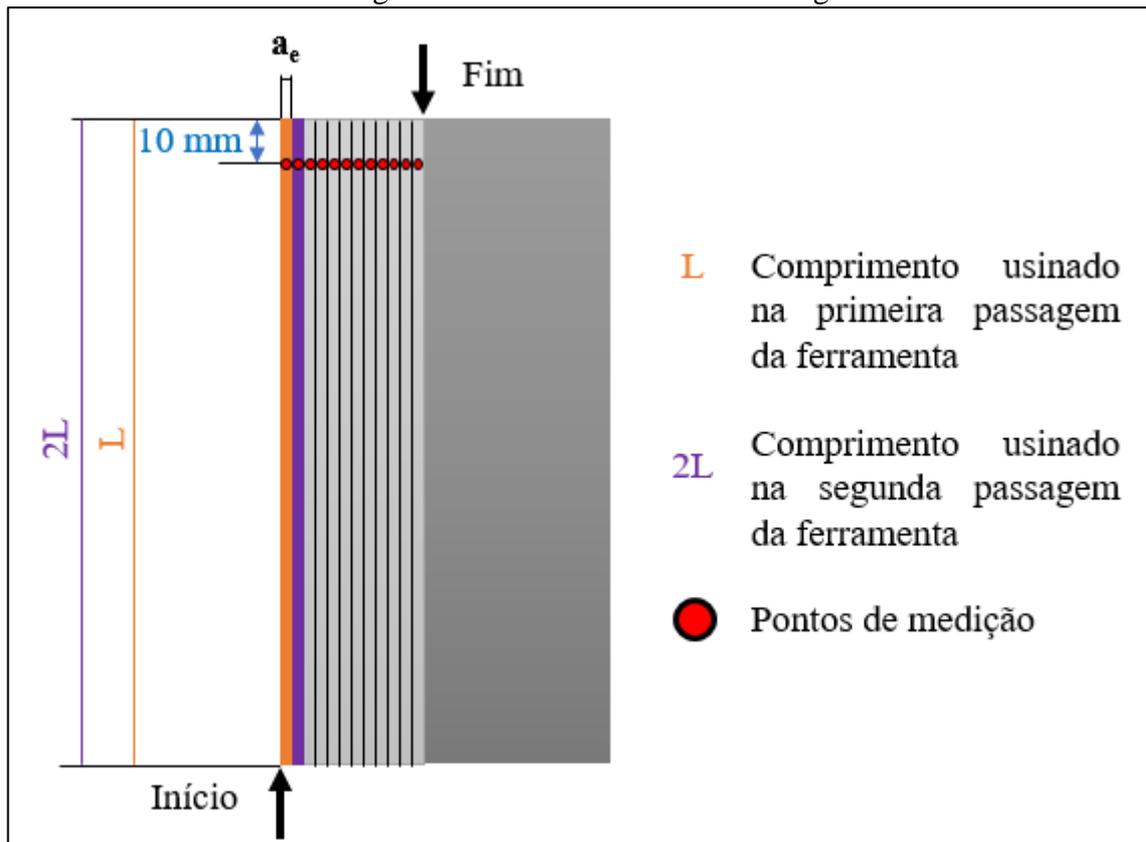
No final dos testes, após obter o valor médio dos gumes, foram calculados os valores médios de $VB_{m\acute{a}x}$ para cada condição, entre o teste e as duas réplicas. Estes valores de desgaste no decorrer da vida útil da ferramenta foram importantes para acompanhar o estado da ferramenta durante todo o processo, viabilizando as comparações das três condições (padrão, HSC 1/300 e H 4/400) e também para correlacionar os valores de desgaste com as rugosidades dos materiais, que são medidas durante todo o comprimento usinado.

3.1.2.6 Medição das rugosidades

Para coleta dos valores de R_a , R_z e R_t ao decorrer de todo comprimento usinado, foram medidos nos pontos indicados em vermelho na Figura 21. No ensaio de fresamento a ferramenta começa a trabalhar no local indicado como “Início” e vai até o final da borda superior, volta para a parte de baixo, incrementa o valor de a_e e usina outra fileira. Assim se repete, de fileira em fileira, até o final da vida útil da ferramenta, representada pela última fileira hipotética com indicação de “Fim”.

Desta forma, na primeira passagem da ferramenta, na primeira fileira indicada no desenho, considera-se que a ferramenta usinou L mm, sendo L o valor do comprimento do corpo de prova, de 252 mm. Na segunda passagem, o comprimento usinado era equivalente a 2 vezes o valor de L , e assim sucessivamente.

Figura 21 – Coleta dos valores de rugosidade

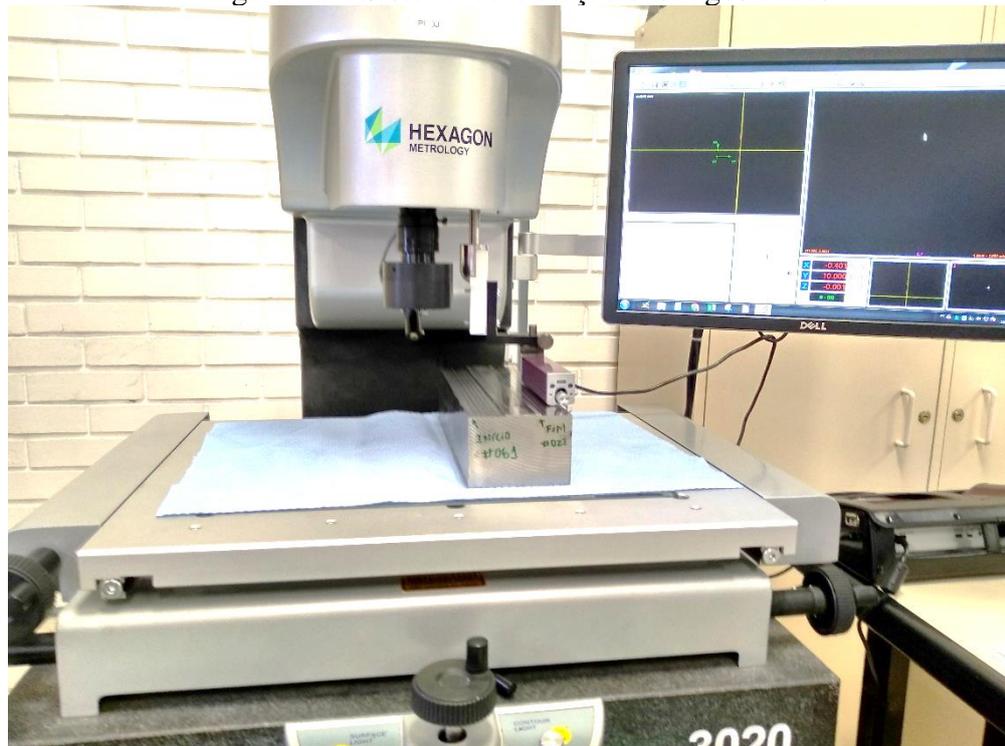


Fonte: Autor (2023).

Com base nisso, foi deixado 10 mm da borda final, conforme indicado pela norma ABNT NBR ISO 4288, e foi coletado um ponto a cada 0,4 mm de deslocamento lateral, que é o valor de a_e . Assim, o primeiro ponto foi em L menos 10 mm, o segundo ponto $2L$ menos 10

mm, ou seja, em 242 mm, 494mm, e assim por diante. Para esse posicionamento do apalpador inicial e deslocamentos laterais para coleta de dados, o apalpador do rugosímetro foi acoplado em uma mesa graduada. Desta forma, primeiramente, o corpo de prova é alinhado na mesa com um esquadro e o apalpador é zerado em x e y iguais a zero, depois é deslocado -10 mm, para deixar os 10 mm de distância da borda final e a cada medição é feito um deslocamento lateral de 0,4. O sistema de medição é mostrado na Figura 22 a seguir.

Figura 22 – Sistema de medição das rugosidades



Fonte: Autor (2023).

A aquisição destes valores de R_a , R_z e R_t foi feita por meio de um rugosímetro SJ-301, da marca Mitutoyo, que possui as especificações detalhadas na Tabela 4.

Tabela 4 – Especificações rugosímetro Mitutoyo

Curso eixo z	350 μm
Curso eixo x	12,5 mm
Resolução / faixa de medição	0,4 μm /350 μm
	0,1 μm /100 μm
	0,05 μm /50 μm
	0,01 μm /10 μm
Apalpador	Diamante tipo estilete
Raio de ponta do apalpador	5 μm
Conicidade do apalpador	90°
Força de medição	4mN
Velocidade de avanço	0,25 até 0,5 mm/s
Velocidade de retorno	0,8 mm/s

Fonte: Autor (2023).

Para definição do cut-off foi realizada uma primeira medida de R_a para identificar a faixa correspondente ao cut-off que deverá ser utilizado, conforme já referenciado na Tabela 1. Este comprimento é subdividido para evitar desvios de forma na avaliação da rugosidade.

Foram realizadas medições em todos os ensaios, desta forma, foram adquiridos dados de rugosidade para o teste e para as duas réplicas, portanto considerou-se os valores de rugosidade médio destes 3 valores coletados para cada um dos parâmetros (R_a , R_z e R_t).

3.1.3 Pré-processamento e avaliações prévias

Com os dados coletados foi estruturado o conjunto de dados para cada condição de gume. Desta forma, dois modelos de predição são propostos, em ambos a entrada (x) foi o comprimento usinado e em um deles a saída (y) foi desgaste ($VB_{\text{máx}}$) médio das 3 amostras e no outro as saídas foram os valores de rugosidades, também médios das amostras, R_a , R_z e R_t .

Com o intuito de deixar o intervalo equivalente entre as medições de rugosidade e desgaste, para os pontos faltantes de medição do desgaste da ferramenta, que foi medido de 2520 em 2520 mm, foi realizada a interpolação para obter os valores do comprimento usinado faltantes. Como a rugosidade é sempre medida a 10 mm da borda final, os valores equivalentes de desgaste terão 10 mm usinados a mais, que são considerados equivalentes. Por exemplo, a medida do desgaste de 2520 mm foi considerada a mesma para 2510 mm, devida a pouca

variação, para conseguir o mesmo intervalo de dados e respeitar os 10 mm da borda final para aquisição da rugosidade. No Quadro 2 a seguir está ilustrado o intervalo de dados conforme o comprimento usinado, os valores de coleta de desgaste e quais foram coletados e os valores de coleta dos parâmetros de rugosidade.

Quadro 2 – Estruturação do conjunto de dados

Comprimento usinado (mm)	Desgaste (mm)	R _a (μm)	R _z (μm)	R _t (μm)
10	0	Medição	Medição	Medição
242	Interpolação	Medição	Medição	Medição
494	Interpolação	Medição	Medição	Medição
746	Interpolação	Medição	Medição	Medição
998	Interpolação	Medição	Medição	Medição
1250	Interpolação	Medição	Medição	Medição
1502	Interpolação	Medição	Medição	Medição
1754	Interpolação	Medição	Medição	Medição
2006	Interpolação	Medição	Medição	Medição
2258	Interpolação	Medição	Medição	Medição
2510	Medição	Medição	Medição	Medição
...
Fim da vida	Medição	Medição	Medição	Medição

Fonte: Autor (2023).

Após a estruturação destes dados, são plotados os gráficos das rugosidades e do desgaste para cada condição em função do comprimento usinado para avaliar o comportamento do desgaste e das rugosidades ao longo da vida da ferramenta, analisar padrões e verificar, comparando a condição padrão com as duas condições de polimento, se os desgastes e os valores de rugosidades aumentaram ou diminuíram com os polimentos. Além disso, foi investigado as informações que cada parâmetro de rugosidade pode trazer sobre o processo, relacionando-os também entre si.

3.1.4 Modelagem e ajustes dos modelos

Com os dados estruturados, nesta etapa, foram treinados os modelos de regressão nos dados. Os modelos ajustados aos dados, por meio da biblioteca *scikit-learn* foram *Linear Regression*, *Random Forest*, *XGBoost*, *Gradient Boost*, *Ada Boost*, *Support Vector Regressor* (SVR), *Nu Support Vector Regressor* (NuSVR) e *Extra Tree*. Com as bibliotecas *Keras* e *Tensorflow*, foi implementada a previsão com o modelo de Rede Neural Artificial, do inglês *Artificial Neural Network* (ANN).

Os algoritmos citados neste trabalho e análises foram implementados na linguagem *Python*. Rossum (1998) definiu a linguagem como uma linguagem de programação interpretada, orientada a objetos e de alto nível, com semântica dinâmica. Suporta módulos e pacotes, incentivando a modularidade do programa e reutilização dos códigos, sendo de fácil compreensão. O interpretador e a extensa biblioteca padrão estão disponíveis na forma de código-fonte ou binário sem custo para os principais sistemas operacionais e podem ser distribuídos livremente.

3.1.5 Pós-processamento

Com a implementação dos modelos foi calculado para cada uma das predições o RMSE e o MAE, comparando-se os métodos a fim de escolher o de melhor desempenho para retornar os valores de rugosidade e desgaste do processo de fresamento para cada uma das condições. As duas métricas de erro foram calculadas pelas funções *mean_squared_error* e *mean_absolute_error* da biblioteca *SKlearn*.

Foi também aplicada a Validação Cruzada para avaliação da repetibilidade dos modelos para novos dados, diminuindo o risco de *overfitting* nos dados, com múltiplas divisões em k-folds alternam-se os conjuntos de teste e validação e estimam-se os melhores valores para os hiperparâmetros dos modelos. Para isso utilizou-se a função *GridSearchCV* da biblioteca *SKlearn*, baseada em Validação Cruzada para busca dos valores para os hiperparâmetros. Os hiperparâmetros são parâmetros exigidos para implementação dos modelos de forma manual, no caso indicará o percentual de dados que foi utilizado para teste e parâmetros particulares de cada modelo, que são detalhados nos resultados.

Por fim, foram comparados os resultados das métricas de cada modelo e foi escolhido o melhor modelo para prever cada um dos parâmetros de rugosidade e o melhor modelo para prever desgaste dentro dos diferentes cenários de polimento de gume.

4. RESULTADOS

Nesta seção são discutidos os resultados do trabalho, mostrando os dados coletados, as análises prévias, as predições e o pós-processamento com as avaliações finais.

4.1 COLETA DE DADOS

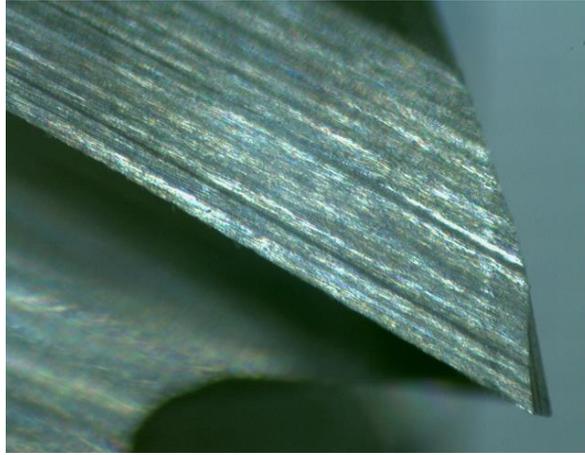
Na etapa de coleta de dados, após as etapas de definir o material e as ferramentas e fabricar as ferramentas, foi realizada a caracterização dos gumes antes e depois dos polimentos. Desta forma, mostra-se os resultados das caracterizações realizadas para diferenciar os gumes com e sem polimento, assim como os resultados dos ensaios, com as medições dos desgastes das ferramentas e das rugosidades do material usinado.

4.1.1 Caracterização das ferramentas

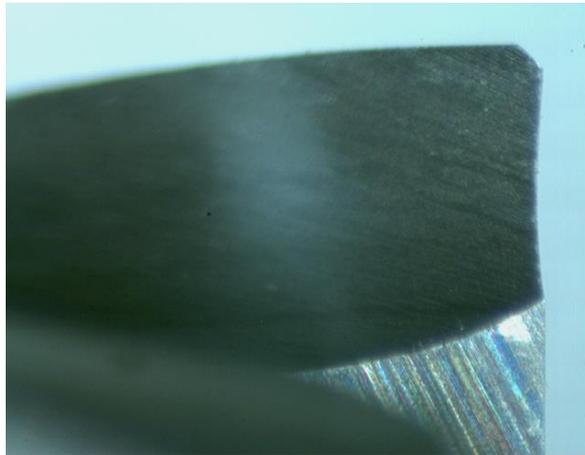
As avaliações prévias realizadas foram com o estereoscópio binocular TNE-10B, com ampliação de 30 vezes, para garantir que o estado inicial da ferramenta não possuía falhas de fabricação ou lascamentos provenientes do manuseio. Assim, foi avaliado as superfícies de flanco, face e topo, conforme exemplo do Quadro 3 a seguir.

Quadro 3 – Avaliação prévia das ferramentas

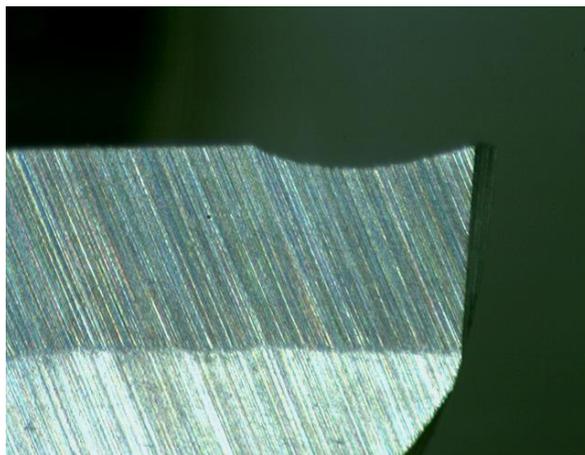
Flanco do gume



Face do gume



Topo do gume



Fonte: Autor (2023).

Com a análise de cada um dos 4 gumes da ferramenta é possível identificar falhas de fabricação ou lascamentos e substituir por outras da mesma condição com os gumes

preservados. A segunda avaliação foi feita no equipamento IF-SensorR25, onde foram medidos os raios dos gumes de 3 ferramentas de cada condição de gume (padrão, HSC 1/300 e H 4/400) para melhor distinguir suas características, o que contribui para as avaliações seguintes, onde compara-se as 3 condições. Os valores medidos estão apresentados na Tabela 5.

Tabela 5 – Medições dos raios das ferramentas

Ferramentas	Raio 1 (μm)	Raio 2 (μm)	Raio 3 (μm)	Média (μm)
Padrão	4,4	4,7	5,3	4,8
HSC 1/300	9,8	10,7	9,2	9,9
H 4/400	9,8	9,6	9,9	9,8

Fonte: Autor (2023).

Com base nas medidas, verifica-se que os raios dos gumes das ferramentas com os polimentos possuem valores muito próximos, em média 9,9 μm e 9,8 μm , já a ferramenta padrão, sem qualquer polimento, possui um raio menor, quase metade das outras, em média de 4,8 μm .

4.1.2 Medição dos desgastes

Durante os ensaios de desgaste das ferramentas, elas trabalharam até alcançar o desgaste $VB_{\text{máx}}$ de 0,3 mm, como critério de fim de vida da ferramenta. Os valores de $VB_{\text{máx}}$ foram medidos de 2520 em 2520 mm, ou seja, de 10 em 10 passes. Com a utilização do estereoscópio e da câmera acoplada, foram fotografados os flancos de cada um dos 4 gumes da ferramenta e realizada a medição em escala real, conforme já detalhado anteriormente. Após estas medições foram feitas as médias para os 4 gumes e depois as médias entre o teste e as duas réplicas para cada condição.

Na Tabelas 6 a seguir mostram-se os desgastes das ferramentas para as ferramentas padrões, HSC 1/300 e H 4/400.

Tabela 6 – Medições dos desgastes das ferramentas

Ferramentas padrões				
Comprimento usinado (mm)	Desgaste Ferramenta 1 (mm)	Desgaste Ferramenta 2 (mm)	Desgaste Ferramenta 3 (mm)	Média (mm)
0	0	0	0	0
2510	0,11	0,16	0,14	0,14
5030	0,17	0,20	0,21	0,19
7550	0,27	0,24	0,29	0,27
10070	0,33	0,33	0,36	0,34
Ferramentas HSC 1/300				
0	0	0	0	0
2510	0,12	0,12	0,12	0,12
5030	0,18	0,18	0,18	0,18
7550	0,23	0,23	0,22	0,23
10070	0,27	0,29	0,28	0,28
Ferramentas H 4/400				
0	0	0	0	0
2510	0,12	0,11	0,09	0,11
5030	0,20	0,18	0,17	0,18
7550	0,23	0,22	0,21	0,22
10070	0,28	0,27	0,25	0,27

Fonte: Autor (2023).

Nota-se que, para um comprimento usinado de 10070 mm, as ferramentas que tiveram menor desgaste foram as polidas com a média H 4/400, com desgaste médio de 0,27 mm, em seguida aquelas polidas com a média HSC 1/300 e, por fim, as ferramentas sem polimento, onde registrou-se um desgaste médio de 0,34 mm.

4.1.3 Medição das rugosidades

A medição dos valores de R_a , R_z e R_t foi realizada com o sensor do rugosímetro (carro de medida) acoplado em uma mesa graduada, deslocando lateralmente 0,4 mm, que é o valor de a_e . O comprimento de amostragem foi definido por meio de uma medição de R_a inicial no corpo de prova, conforme a faixa referenciada na Tabela 1, que foi de 0,8 mm.

Para cada uma das condições de gumes (Padrão, HSC 1/300 e H 4/400), foi medido R_a , R_z e R_t para 3 ferramentas, o teste e as duas réplicas. Portanto resultou-se em um conjunto de dados com 27 colunas e 47 linhas. Por essa razão, é mostrado na próxima seção, nas Tabelas 7,

8 e 9, as médias das rugosidades e também dos desgastes, simplificando-se a visualização dos dados.

4.2 PRÉ-PROCESSAMENTO E AVALIAÇÕES PRÉVIAS

Nesta seção detalha-se sobre a estruturação do conjunto de dados para modelagem e ajuste dos modelos. O comprimento usinado é a entrada (x) e a saída (y) poderá ser o valor médio do $VB_{máx}$, R_a , R_z ou R_t . Destacando-se dois pontos importantes desta etapa, onde os pontos faltantes de medição do desgaste da ferramenta, que foi medido de 2520 em 2520 mm, foi realizada a interpolação para obter os valores do comprimento usinado faltantes. E, como a rugosidade é sempre medida a 10 mm da borda final, os valores equivalentes de desgaste terão 10 mm usinados a mais, que são considerados equivalentes.

Nas Tabelas 7, 8 e 9 a seguir estão os conjuntos de dados estruturados nesta etapa com os dados de rugosidades e desgastes médios para as ferramentas padrões, HSC 1/300 e H 4/400.

Tabela 7 – Rugosidades e desgaste médios das ferramentas padrões

Comprimento usinado [mm]	Ra médio Padrão [μm]	Rz médio Padrão [μm]	Rt médio Padrão [μm]	Desgaste médio Padrão [mm]
0,00	0,44	2,91	3,58	0,00
242,00	0,47	3,04	3,81	0,01
494,00	0,43	2,75	3,25	0,03
746,00	0,37	2,44	2,86	0,04
998,00	0,38	2,45	3,50	0,05
1250,00	0,31	2,11	2,78	0,07
1502,00	0,29	2,13	2,66	0,08
1754,00	0,28	2,04	2,42	0,09
2006,00	0,30	2,11	2,62	0,11
2258,00	0,30	2,02	2,50	0,12
2510,00	0,42	2,73	3,20	0,13
2762,00	0,34	2,34	2,90	0,14
3014,00	0,31	2,23	2,91	0,14
3266,00	0,32	2,31	3,31	0,15
3518,00	0,33	2,38	3,01	0,16
3770,00	0,32	2,19	2,76	0,16
4022,00	0,27	2,02	2,49	0,17
4274,00	0,25	1,76	2,36	0,17
4526,00	0,26	1,87	2,86	0,18
4778,00	0,26	1,82	2,33	0,18
5030,00	0,30	1,94	2,55	0,19
5282,00	0,28	1,83	2,28	0,20

5534,00	0,28	1,84	2,33	0,20
5786,00	0,26	1,72	2,31	0,21
6038,00	0,27	1,95	2,52	0,22
6290,00	0,33	2,12	2,85	0,23
6542,00	0,32	2,23	2,67	0,23
6794,00	0,29	1,90	2,25	0,24
7046,00	0,25	1,69	2,27	0,25
7298,00	0,27	1,71	2,34	0,26
7550,00	0,36	2,53	3,35	0,26
7802,00	0,33	2,28	2,95	0,27
8054,00	0,29	1,93	2,72	0,28
8306,00	0,27	1,79	2,41	0,29
8558,00	0,27	1,86	2,41	0,29
8810,00	0,25	1,68	2,33	0,30
9062,00	0,23	1,58	2,06	0,31
9314,00	0,23	1,57	2,14	0,32
9566,00	0,25	1,78	2,47	0,32
9818,00	0,23	1,65	1,85	0,33
10070,00	0,26	1,90	2,50	0,34
10322,00	0,27	1,92	2,53	0,34
10574,00	0,25	1,71	2,18	0,35
10826,00	0,25	1,84	2,69	0,36
11078,00	0,25	1,72	2,43	0,36
11330,00	0,27	1,91	2,47	0,37
11582,00	0,25	1,89	2,58	0,38

Fonte: Autor (2023).

Tabela 8 – Rugosidades e desgaste médios das ferramentas HSC 1/300

Comprimento usinado [mm]	Ra médio 1-300 [μm]	Rz médio 1-300 [μm]	Rt médio 1-300 [μm]	Desgaste médio 1-300 [mm]
0,00	0,27	1,56	2,00	0,00
242,00	0,28	1,86	2,21	0,01
494,00	0,18	1,15	1,45	0,02
746,00	0,16	1,17	1,61	0,03
998,00	0,20	1,37	1,66	0,05
1250,00	0,20	1,30	1,70	0,06
1502,00	0,17	1,20	1,61	0,07
1754,00	0,14	1,07	1,47	0,08
2006,00	0,17	1,17	1,41	0,09
2258,00	0,15	0,98	1,12	0,10
2510,00	0,21	1,41	1,65	0,12
2762,00	0,23	1,29	1,86	0,12
3014,00	0,16	1,01	1,40	0,13
3266,00	0,22	1,21	1,67	0,14

3518,00	0,14	0,95	1,33	0,14
3770,00	0,18	1,22	1,57	0,15
4022,00	0,22	1,52	1,86	0,15
4274,00	0,13	0,81	0,97	0,16
4526,00	0,23	1,45	1,84	0,17
4778,00	0,20	1,34	1,60	0,17
5030,00	0,13	0,79	1,03	0,18
5282,00	0,15	0,89	1,24	0,18
5534,00	0,17	0,95	1,72	0,19
5786,00	0,24	1,60	2,04	0,19
6038,00	0,20	1,39	1,86	0,20
6290,00	0,24	1,57	2,07	0,20
6542,00	0,15	0,95	1,26	0,21
6794,00	0,23	1,21	1,80	0,21
7046,00	0,24	1,66	2,06	0,22
7298,00	0,28	1,85	2,38	0,22
7550,00	0,20	1,80	2,20	0,23
7802,00	0,23	1,44	1,94	0,23
8054,00	0,19	1,44	1,93	0,24
8306,00	0,20	1,38	2,08	0,24
8558,00	0,25	1,70	2,33	0,25
8810,00	0,25	1,77	2,19	0,25
9062,00	0,22	1,54	2,16	0,26
9314,00	0,22	1,64	2,41	0,26
9566,00	0,35	2,17	2,73	0,27
9818,00	0,22	1,55	2,20	0,28
10070,00	0,29	2,13	2,72	0,28
10322,00	0,28	1,88	2,82	0,29
10574,00	0,17	1,25	1,86	0,29
10826,00	0,19	1,29	1,89	0,30
11078,00	0,23	1,59	1,96	0,30
11330,00	0,32	1,79	2,68	0,31
11582,00	0,16	1,01	1,51	0,32

Fonte: Autor (2023).

Tabela 9 – Rugosidades e desgaste médios das ferramentas H 4/400

Comprimento usinado [mm]	Ra médio 4-400 [μm]	Rz médio 4-400 [μm]	Rt médio 4-400 [μm]	Desgaste médio 4-400 [mm]
0,00	0,32	2,00	2,41	0,00
242,00	0,31	2,14	2,58	0,01
494,00	0,26	1,78	2,55	0,02
746,00	0,25	1,50	1,84	0,03
998,00	0,26	1,70	2,26	0,04
1250,00	0,15	1,04	1,29	0,05
1502,00	0,17	1,12	1,33	0,06
1754,00	0,14	1,01	1,30	0,07
2006,00	0,19	1,27	1,61	0,08
2258,00	0,15	0,97	1,11	0,09
2510,00	0,21	1,16	1,30	0,10
2762,00	0,19	1,33	1,84	0,11
3014,00	0,18	1,19	1,44	0,12
3266,00	0,18	1,22	1,60	0,13
3518,00	0,20	1,22	1,57	0,13
3770,00	0,19	1,27	1,58	0,14
4022,00	0,19	1,25	1,65	0,15
4274,00	0,18	1,20	1,58	0,16
4526,00	0,19	1,12	1,53	0,17
4778,00	0,22	1,37	2,03	0,17
5030,00	0,22	1,14	1,65	0,18
5282,00	0,25	1,57	2,00	0,18
5534,00	0,20	1,29	1,71	0,19
5786,00	0,25	1,54	2,00	0,19
6038,00	0,23	1,39	1,87	0,20
6290,00	0,18	1,18	1,49	0,20
6542,00	0,18	1,23	1,68	0,20
6794,00	0,20	1,32	1,84	0,21
7046,00	0,19	1,20	1,62	0,21
7298,00	0,26	1,98	2,65	0,21
7550,00	0,26	1,85	2,43	0,22
7802,00	0,24	1,67	2,25	0,22
8054,00	0,27	1,67	2,25	0,23
8306,00	0,34	2,06	2,93	0,23
8558,00	0,26	1,72	2,27	0,24
8810,00	0,27	1,77	2,52	0,24
9062,00	0,29	1,74	2,46	0,25
9314,00	0,29	1,80	2,36	0,25
9566,00	0,27	1,70	2,36	0,26
9818,00	0,31	2,11	2,88	0,26
10070,00	0,27	1,84	2,59	0,27
10322,00	0,35	2,33	3,20	0,27

10574,00	0,30	1,93	2,90	0,28
10826,00	0,35	2,07	2,74	0,29
11078,00	0,33	2,00	2,76	0,30
11330,00	0,30	2,10	2,68	0,30
11582,00	0,38	2,50	3,65	0,31

Fonte: Autor (2023).

Com estes valores, foram analisadas algumas estatísticas dos valores encontrados nos parâmetros das rugosidades. Pode-se notar na Tabela 10, comparando as métricas das ferramentas padrões com as ferramentas polidas, que os valores médios e medianos de cada parâmetro foram maiores para as ferramentas padrões, assim como para os valores máximos e mínimos encontrados nos pontos medidos. Esta comparação, junto com o fato de que as ferramentas padrões tiveram valores maiores para R_z e R_t , pode-se notar menor regularidade superficial, onde as distâncias entre picos e vales da rugosidade foram maiores. A dispersão dos dados em relação à média no desvio padrão foi semelhante entre as três condições.

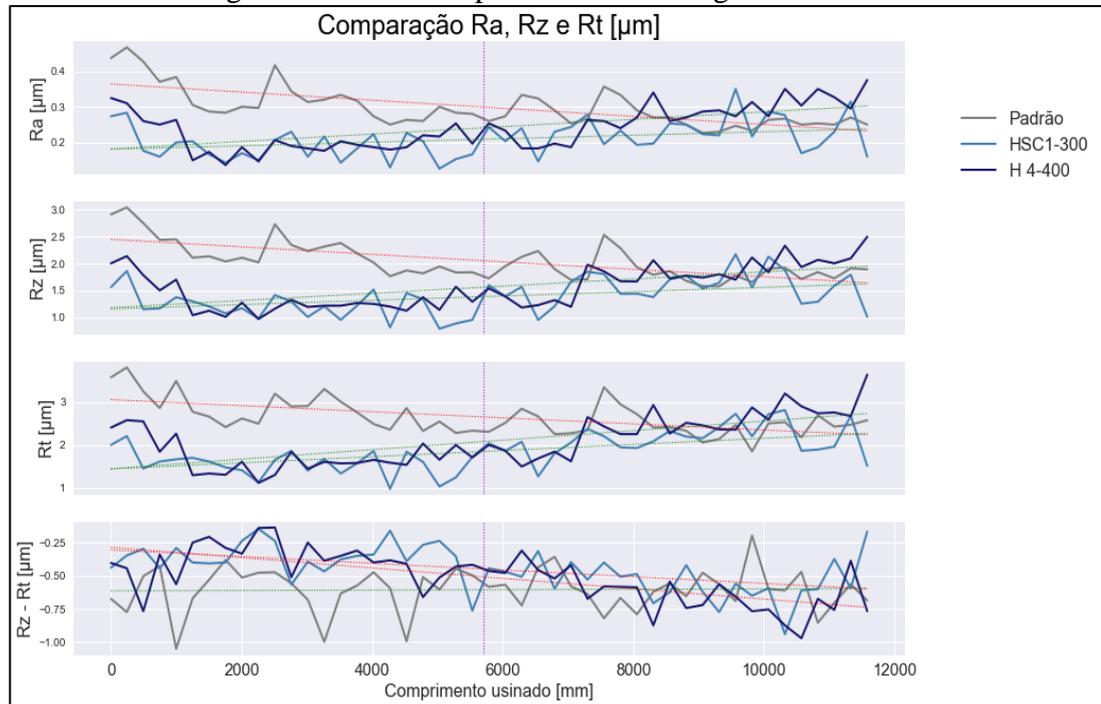
Tabela 10 – Avaliações das rugosidades

Rugosidades por condição	Média	Mediana	Desvio padrão	Máx.	Mín.
R_a médio Padrão [μm]	0,30	0,28	0,06	0,47	0,23
R_z médio Padrão [μm]	2,05	1,93	0,34	3,04	1,57
R_t médio Padrão [μm]	2,65	2,53	0,41	3,81	1,85
R_a médio 1-300 [μm]	0,21	0,20	0,05	0,35	0,13
R_z médio 1-300 [μm]	1,39	1,38	0,33	2,17	0,79
R_t médio 1-300 [μm]	1,85	1,86	0,44	2,82	0,97
R_a médio 4-400 [μm]	0,24	0,25	0,06	0,38	0,14
R_z médio 4-400 [μm]	1,56	1,54	0,39	2,50	0,97
R_t médio 4-400 [μm]	2,09	2,00	0,58	3,65	1,11

Fonte: Autor (2023).

Em seguida, foram realizadas as avaliações prévias para cada condição do gume, comparando-os entre si. Primeiro, analisou-se as rugosidades das ferramentas ao longo do comprimento usinado. Na Figura 23 a seguir estão os gráficos utilizados para a análise.

Figura 23 – Gráficos para análise das rugosidades



Fonte: Autor (2023).

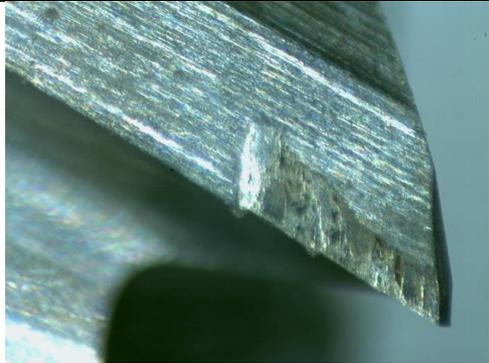
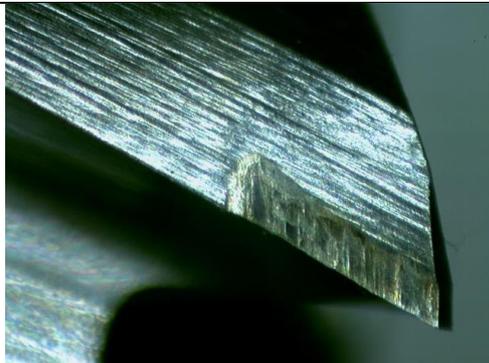
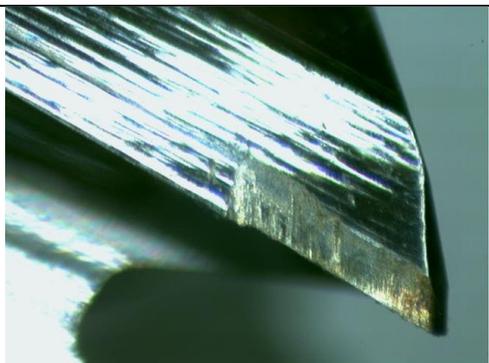
No gráfico acima, utilizou-se o comprimento usinado, em mm, como o eixo horizontal e nos eixos verticais, foram utilizados os valores, em μm , de R_a , R_z , R_t e a diferença entre R_z e R_t . Esta diferença representa a estabilidade do processo, de forma que, conforme esta diferença aumenta, aumenta-se também a instabilidade ou não homogeneidade do processo.

Analisando-se isoladamente os parâmetros de rugosidade, pode-se verificar, pelas linhas de tendência geradas, que os parâmetros para a ferramenta padrão tendem a diminuir no decorrer da vida útil, enquanto para as ferramentas com polimentos, tendem a aumentar. Isso acontece, pois as ferramentas sem polimento iniciam o processo com um raio menor, aproximadamente a metade, conforme o desgaste aumenta, o raio também aumenta e a rugosidade diminui. Já as ferramentas com polimento, já iniciam com raio maior, a rugosidade tende a aumentar no decorrer do desgaste da ferramenta, mas tendem a ser mais estáveis.

Pode-se confirmar esta estabilidade, por meio da análise do último gráfico das diferenças entre os parâmetros R_z e R_t , que para as ferramentas com polimento, essa diferença tende a diminuir e possui menos variação no decorrer da vida útil, enquanto as ferramentas sem polimento, essa diferença tende a aumentar. Desta forma, podemos confirmar o melhor desempenho das ferramentas com polimento, já que o aumento desta diferença representa maior instabilidade e não homogeneidade do processo.

Outro ponto relevante, é que entre 5000 mm e 6000 mm usinados, a diferença entre os valores para as ferramentas com ou sem polimento são menores e os valores se aproximam. Nesta etapa, é onde os desgastes aumentam de forma mais acelerada, os raios dos gumes já apresentam uma alteração causada pelo desgaste que passam a afetar, de forma mais acentuada, a qualidade das rugosidades das peças usinadas. No Quadro 4 estão as imagens dos flancos e das faces dos gumes no final da vida útil, onde pode-se verificar os desgastes das ferramentas nas 3 condições de preparação de gume.

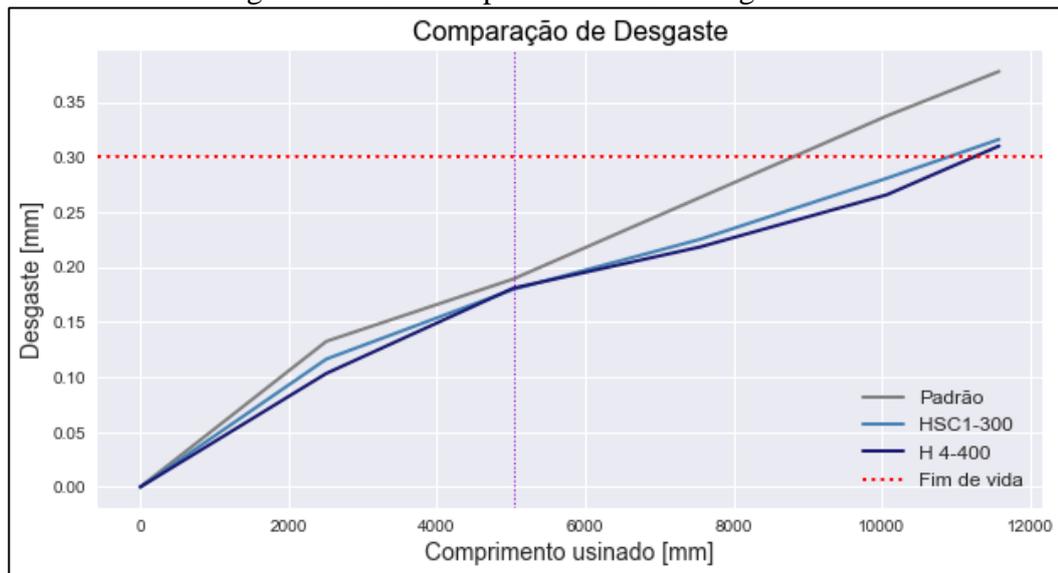
Quadro 4 – Flancos e faces dos gumes no final da vida útil

Preparação do gume	Flanco do Gume	Face do gume
Padrão (Sem preparação)		
HSC 1/300		
H 4/400		

Fonte: Autor (2023).

A partir das medições dos desgastes em escala real, considerando as 3 amostras de cada condição, foi possível obter os valores médios durante o decorrer de toda vida útil da ferramenta. Analisando-se estes valores, podemos observar o comportamento da vida útil na Figura 24.

Figura 24 – Gráfico para análise dos desgastes



Fonte: Autor (2023).

Neste gráfico, é possível analisar o comportamento dos valores medidos para os desgastes das ferramentas, nas 3 condições, no decorrer do comprimento usinado. Pode-se verificar qual das condições atingiu o fim de vida com $VB_{\text{máx}}$ de 0,3 mm antes, representado pela linha pontilhada horizontal em vermelho. A linha pontilhada na vertical, em aproximadamente 5000 mm usinados, mostra um início de acréscimo acentuado nos desgastes, após uma região de estabilização, que é no mesmo intervalo de comprimento usinado onde começou-se a notar um padrão semelhante nas rugosidades, onde os valores das três condições ficaram semelhantes.

As ferramentas com maior vida útil foram as com polimento H 4/400, com 11080 mm usinados, depois as ferramentas com polimento HSC 1/300, que usinaram 10826 mm, e por fim, as ferramentas padrões, sem polimento, que usinaram 8810 mm. Ou seja, as ferramentas com polimento H 4/400 e HSC 1/300 possuem uma vida útil 20,49% e 18,62% maior, respectivamente, comparando-as às ferramentas sem polimento.

4.3 MODELAGEM E AJUSTE DOS MODELOS

Nesta etapa, para cada uma das condições dos gumes, foi estruturada em linguagem python a predição dos valores médios de $VB_{\text{máx}}$, R_a , R_z e R_t , no decorrer do comprimento usinado. Para isso, foram testados os modelos da biblioteca *SKlearn: Linear Regression, Random Forest, XGBoost, Gradient Boost, Ada Boost, Suport Vector Regressor (SVR), Nu Suport Vector Regressor (NuSVR) e Extra Tree*. Com as bibliotecas *Keras e Tensorflow*, foi implementada a previsão com ANN.

Para realizar a previsão, foi atribuído para a variável x os valores, em mm, do comprimento usinado e para a variável y os valores da variável que seria predita naquele momento, $VB_{\text{máx}}$, R_a , R_z ou R_t , na sua unidade correspondente.

Após isso, esses dados foram divididos em treino e teste, pelo método de divisão de treino e teste da biblioteca *scikit-learn*, assim dividiu-se os dados em 80% para treino e 20% para teste. Ou seja, os modelos foram treinados com 80% dos dados e depois 20% dos dados foi usado para realizar a predição e calcular as métricas de erros para avaliar o desempenho de cada um dos modelos.

Depois de dividir os dados em treino e teste é feito o ajuste dos modelos. Normalmente este ajuste pelo método *fit* nos dados de teste, começa limpando atributos já armazenados nos estimadores, depois valida os parâmetros e dados, e assim estimam os atributos de entrada e armazena-os nos modelos, retornando os parâmetros de aprendizagem de cada modelo.

Em seguida, pelo método *predict*, os parâmetros aprendidos no método anterior são utilizados para realizar as previsões sobre novos pontos de dados de teste, por meio da previsão para cada instância dos dados de teste, retornando uma matriz de saída com valores preditos.

Para o modelo das Redes Neurais Artificiais, primeiro os valores das variáveis x e y foram padronizadas, nesta etapa, todos os dados tem seu valor decrescido da média e, depois, dividido pelo desvio padrão. A média do conjunto de dados fica igual a zero e o desvio padrão 1, o que evita que os valores tenham pesos maiores ou menores para o treinamento dos modelos. Depois disso, da mesma forma dos métodos anteriores, é realizado o ajuste do modelo nos dados e depois a predição dos valores. Por último, utiliza-se o método *inverse_transform*, para voltar os valores aos valores iniciais, desfazendo a padronização.

4.4 PÓS-PROCESSAMENTO

Na última etapa dos resultados, foi realizada a Validação Cruzada para todos os métodos de predição, exceto Regressão Linear, com a função *GridSearchCV* da biblioteca *SKlearn*, para avaliação da capacidade de generalização dos modelos para novos dados, diminuindo o risco de *overfitting* nas predições. Esta validação feita por meio de múltiplas divisões em 5 folds, onde alterna-se os conjuntos de teste e validação e assim estima-se os melhores valores para os hiperparâmetros dos modelos.

Os hiperparâmetros considerados para cada modelo variaram. Para o *Random Forest*, *XGBoost* foram considerados *n_estimators*, que são os números de estimadores, onde foram testados os valores de 100, 150, 200, 250 e 300 e representam o número de árvores na floresta utilizados pelo método. O parâmetro *max_depth*, que é a profundidade máxima das árvores de decisão e foram testados os valores de 1 a 5. E o *random_state*, que é o valor que controla a aleatoriedade dos conjuntos de árvores das amostras usadas na construção das árvores e a amostragem dos recursos para a divisão de cada nó, foi variado entre 10, 20 e 30. Para Ada Boost, não foi utilizado *max_depth* e Extra Tree apenas o *random_state*.

Para os modelos de vetores de suporte, NuSVR e SVR, os parâmetros foram C, que foram testados os valores de 0,1, 1, 10 e 100, este é o hiperparâmetro de regularização do modelo. O *gamma* teve os valores de 1, 0,1, 0,001 e 0,001 testados e representa o coeficiente do kernel, que utiliza como padrão o *rbf*.

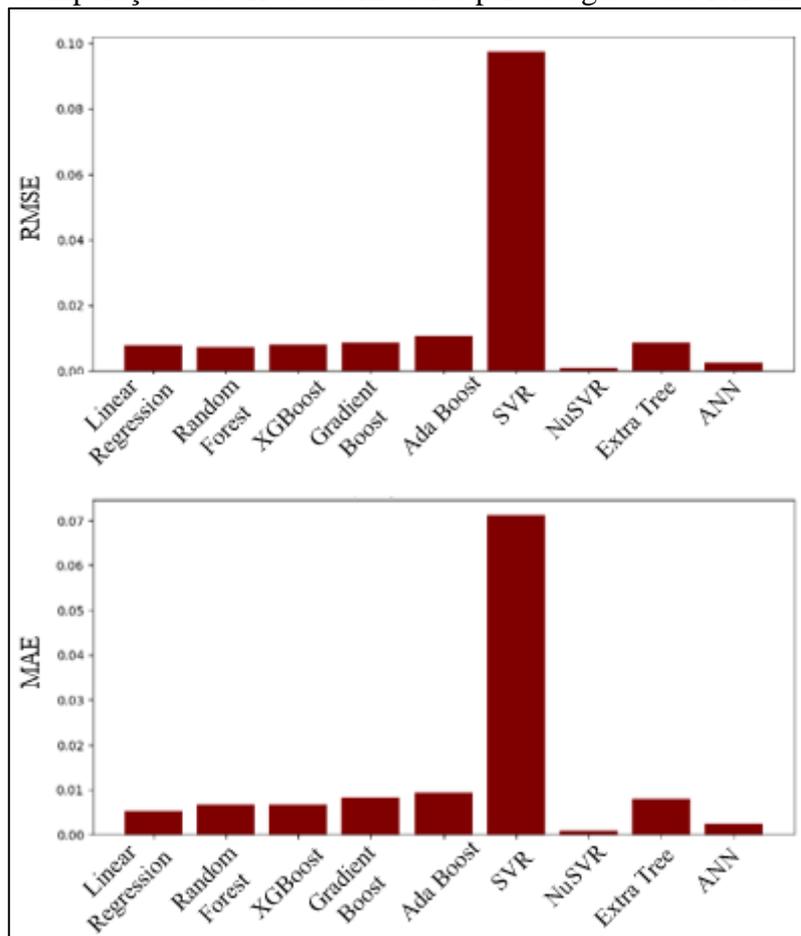
Para a implementação de ANN, foi analisado na validação cruzada os hiperparâmetros *batch_size*, que são utilizados como gradiente descendentes que controlam o número de amostras de treinamento a serem utilizadas antes que os parâmetros internos dos modelos sejam utilizados. E *epochs*, que é um hiperparâmetro também de gradiente descendente que controla o número de passagens completas pelo conjunto de dados de treinamento.

Com estes testes de hiperparâmetros durante a validação cruzada de 5 folds, utilizou-se o *clf_rf.best_params_*, que retorna os resultados dos melhores ajustes para os hiperparâmetros treinados, depois disso estes valores foram substituídos nos modelos, que antes utilizaram valores padrões para treinamento, e foram realizadas as predições. Após esta etapa de validação cruzada, foram calculadas as métricas de avaliação dos modelos RMSE e MAE para mensurar o desempenho dos modelos e selecionar o modelo de melhor desempenho para predição.

Nas Figuras 25 a 36 a seguir são mostrados os gráficos que comparam os desempenhos dos modelos por meio das métricas de erros RMSE e MAE. Foram escolhidas estas métricas, pois o MAE é o valor absoluto do erro, na unidade de medida do valor predito, porém tende a

suavizar os outliers. Já o RMSE, também está na unidade de medida do valor predito, mas penaliza os outliers, já que os valores são elevados ao quadrado. Desta forma, foram avaliados pelas duas métricas, em caso de empate ou resultados diferentes, é considerado o melhor modelo, aquele que tiver um RMSE menor.

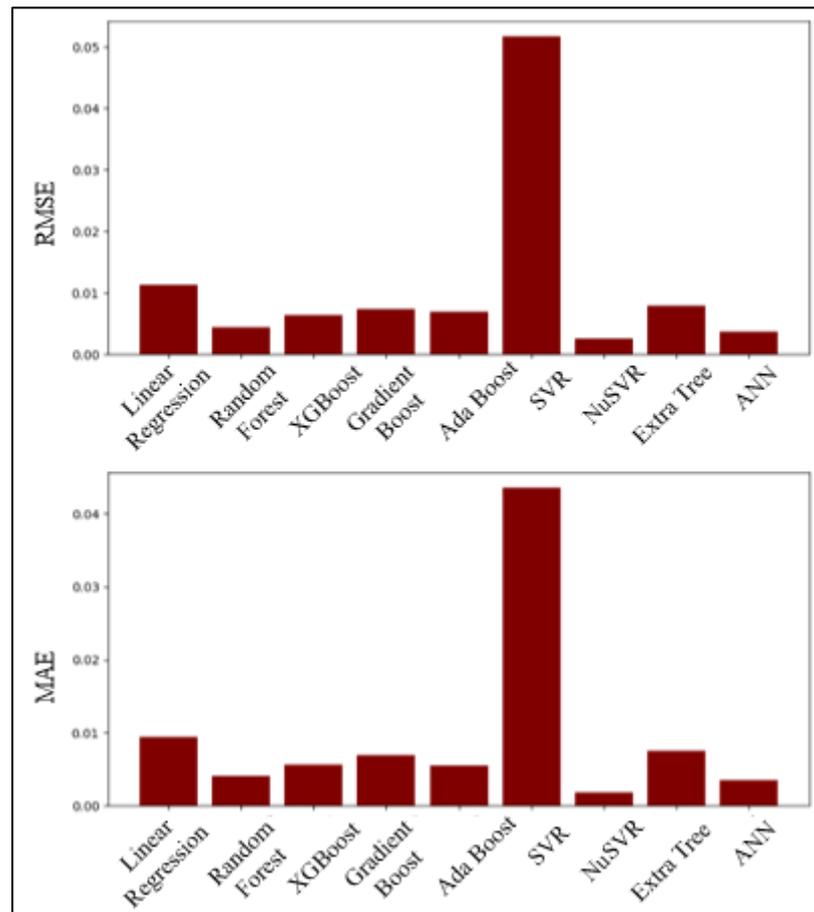
Figura 25 – Comparação dos erros dos modelos para desgaste das ferramentas padrões



Fonte: Autor (2023).

O melhor modelo para o predizer o desgaste das ferramentas padrões foi o NuSVR, com um RMSE de 0,00090 e um MAE de 0,00078.

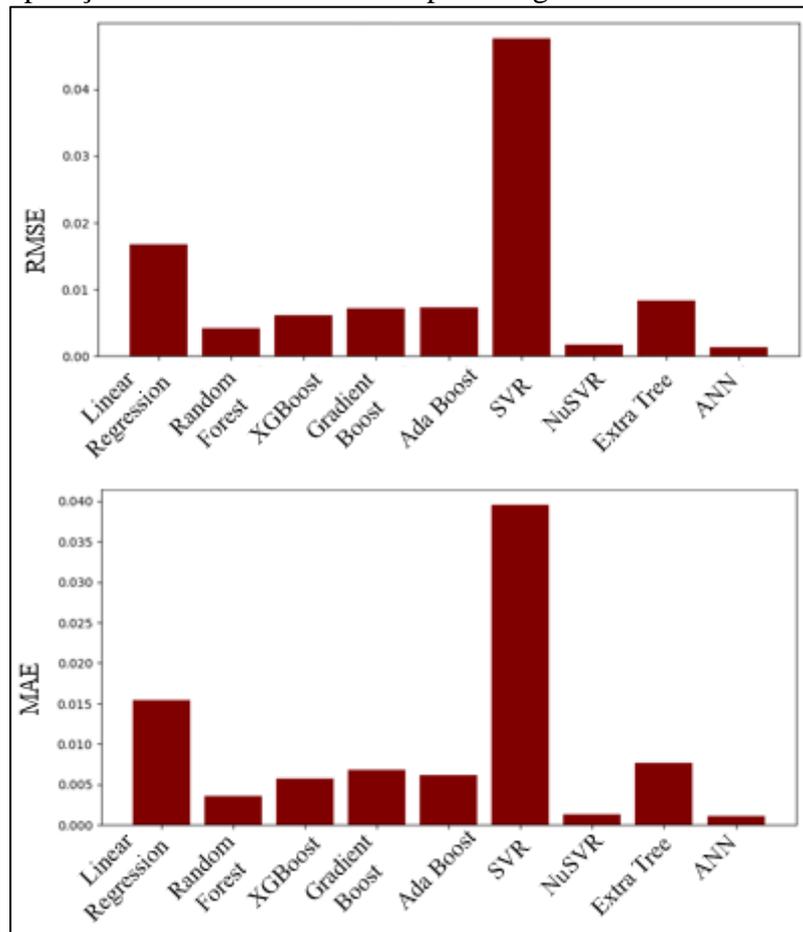
Figura 26 – Comparação dos erros dos modelos para desgaste das ferramentas HSC 1/300



Fonte: Autor (2023).

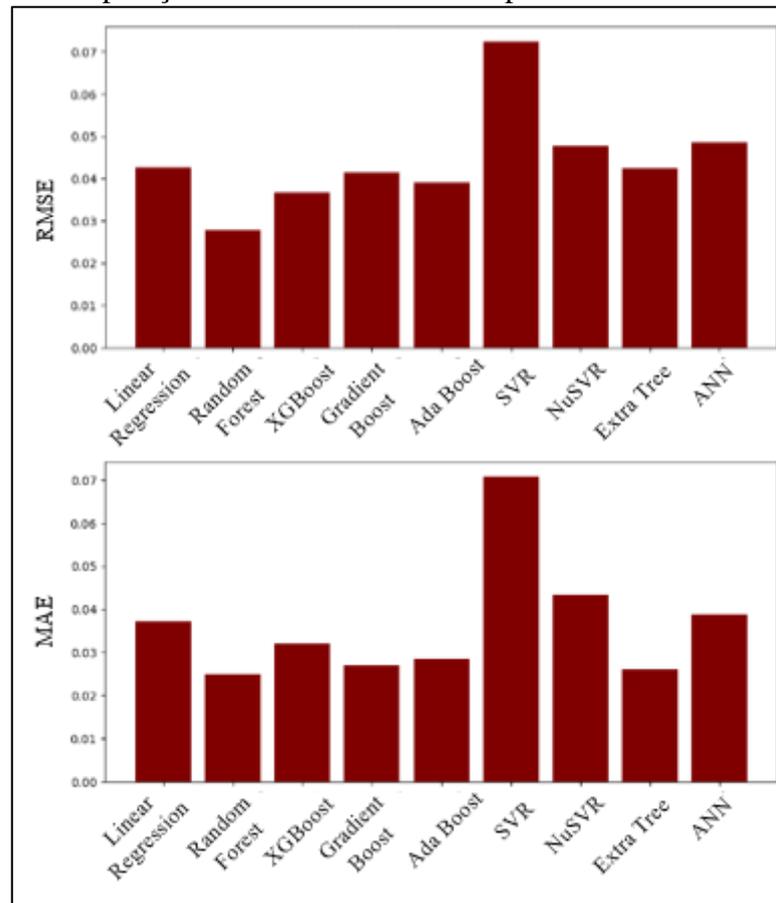
Para o desgaste das ferramentas com polimento HSC 1/300, o melhor modelo também foi o NuSVR, com um RMSE de 0,00253 e um MAE de 0,00182.

Figura 27 – Comparação dos erros dos modelos para desgaste das ferramentas H 4/400



Fonte: Autor (2023).

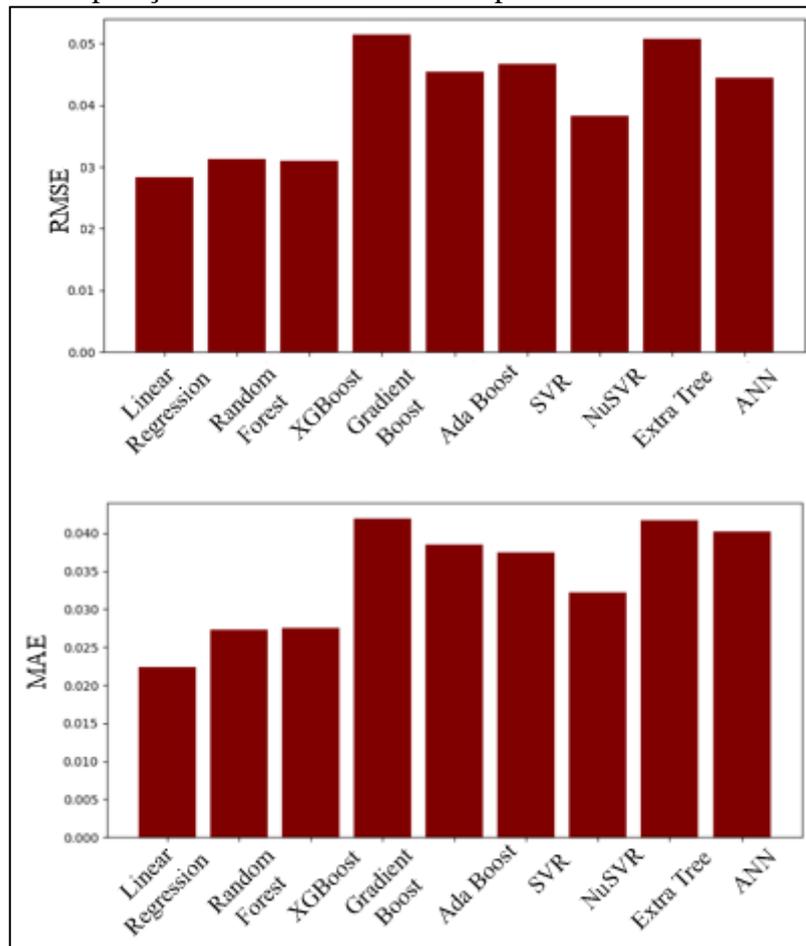
Já para o desgaste das ferramentas com polimento H 4/400, o melhor modelo foi o de ANN, com um RMSE de 0,00129 e um MAE de 0,00106. O NuSVR também teve um desempenho bom com o RMSE de 0,00166 e MAE de 0,00127.

Figura 28 – Comparação dos erros dos modelos para R_a das ferramentas padrões

Fonte: Autor (2023).

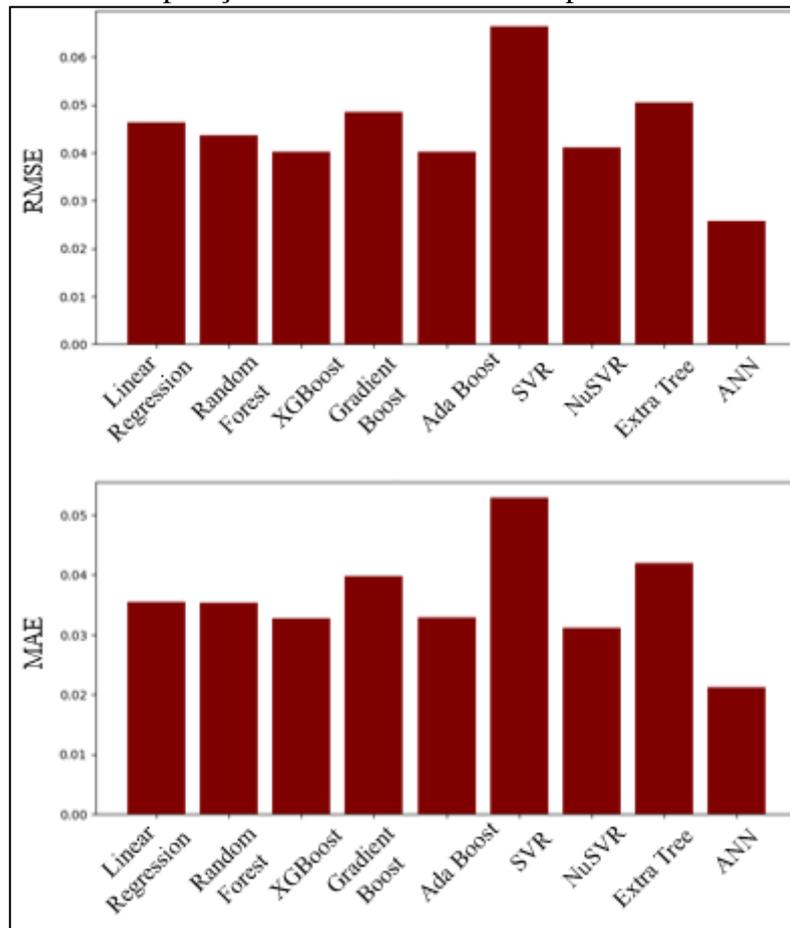
Avaliando os erros dos modelos para predição de R_a , observa-se que o melhor modelo foi o *Random Forest*, que apresentou um RMSE de 0,02778 e MAE de 0,02479.

Figura 29 – Comparação dos erros dos modelos para Ra das ferramentas HSC 1/300



Fonte: Autor (2023).

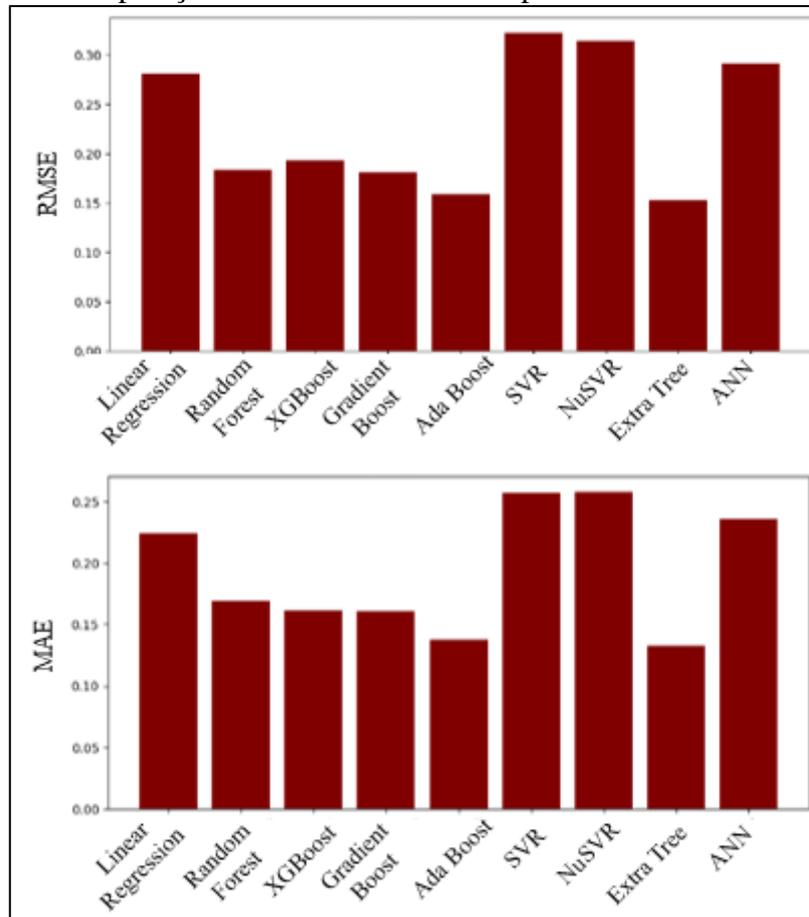
Já para as ferramentas com polimento HSC 1/300, devido ao comportamento linear dos dados, em média a Regressão linear apresentou um melhor resultado, comparando-se aos outros modelos, o valor de RMSE foi 0,02828 e MAE foi de 0,02237.

Figura 30 – Comparação dos erros dos modelos para R_a das ferramentas H 4/400

Fonte: Autor (2023).

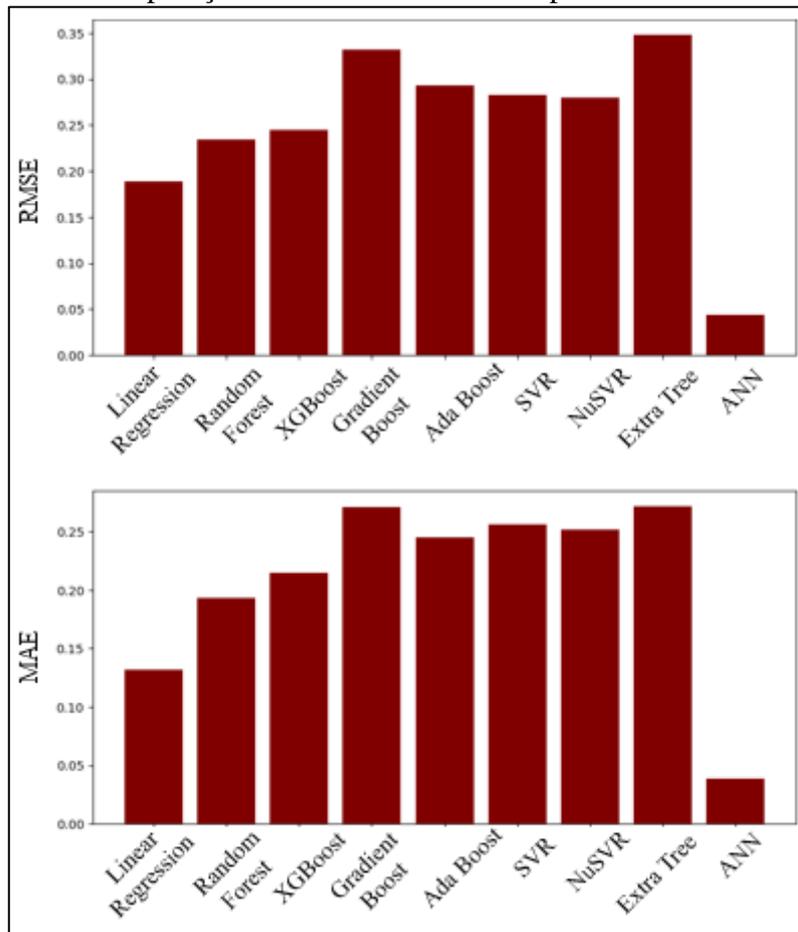
E para as ferramentas com polimento H 4/400, o modelo que apresentou menor erro foi ANN, o valor foi 0,02563 para RMSE e 0,02256 para MAE.

Figura 31 – Comparação dos erros dos modelos para R_z das ferramentas padrões



Fonte: Autor (2023).

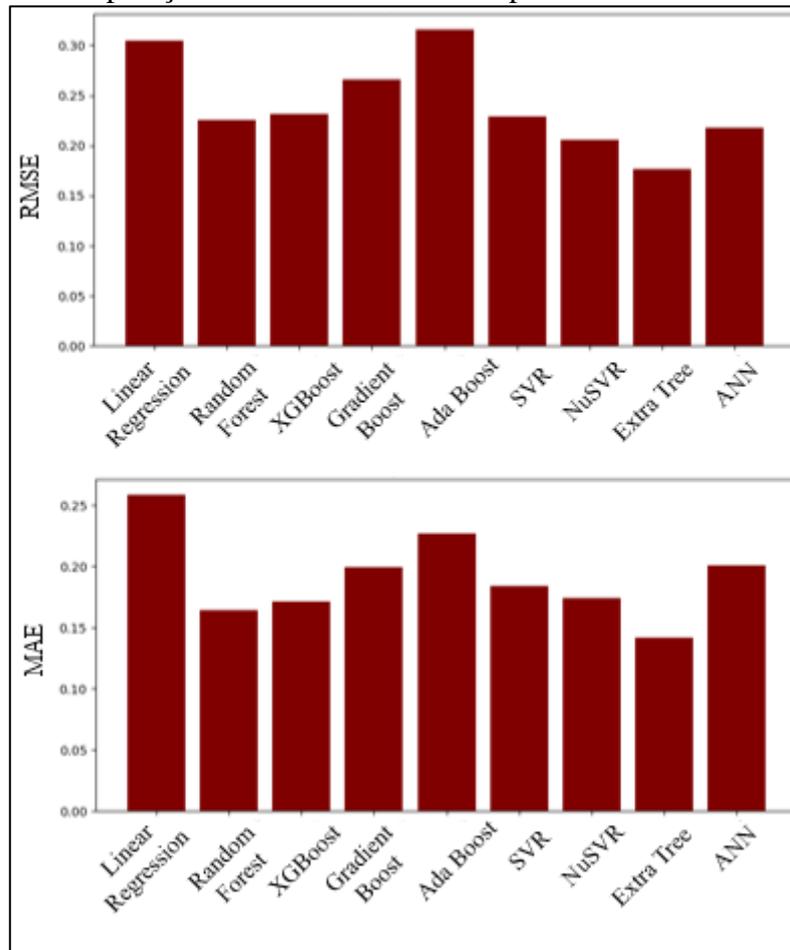
Na predição de R_z para as ferramentas padrões, o *Extra Tree* teve um desempenho melhor com um RMSE de 0,15298 e MAE de 0,13264. O *Ada Boost* teve desempenho similar com RMSE e MAE de 0,15865 e 0,13732, respectivamente.

Figura 32 – Comparação dos erros dos modelos para R_z das ferramentas HSC 1/300

Fonte: Autor (2023).

ANN foi o melhor modelo para predição do parâmetro de rugosidade R_z , com valores dos erros do RMSE de 0,04346 e do MAE de 0,03895.

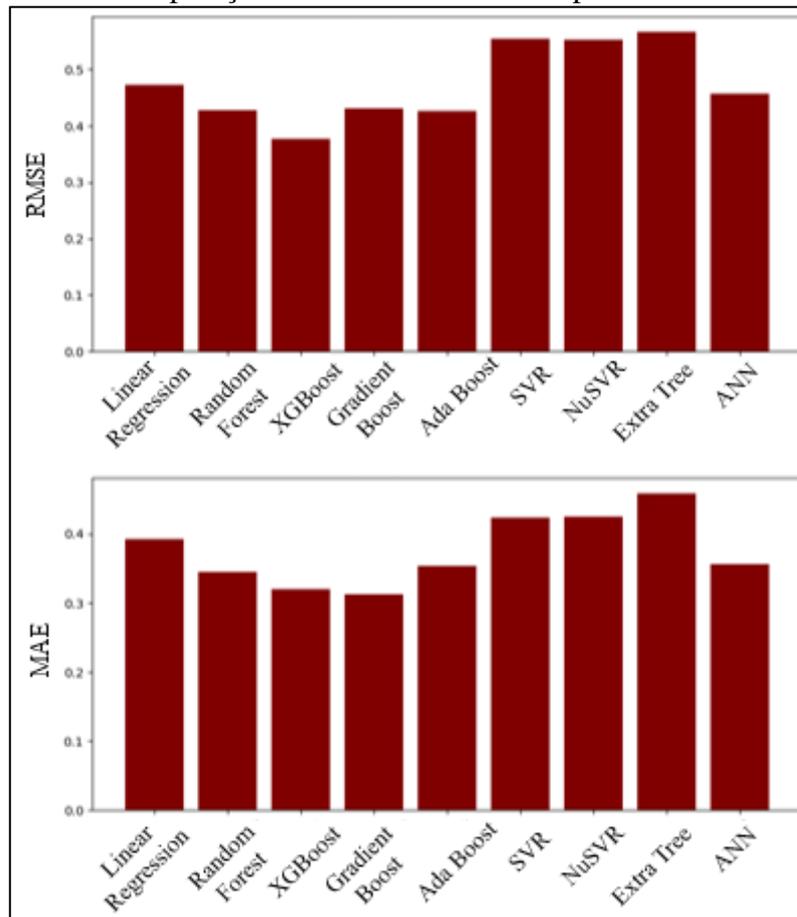
Figura 33 – Comparação dos erros dos modelos para R_z das ferramentas H 4/400



Fonte: Autor (2023).

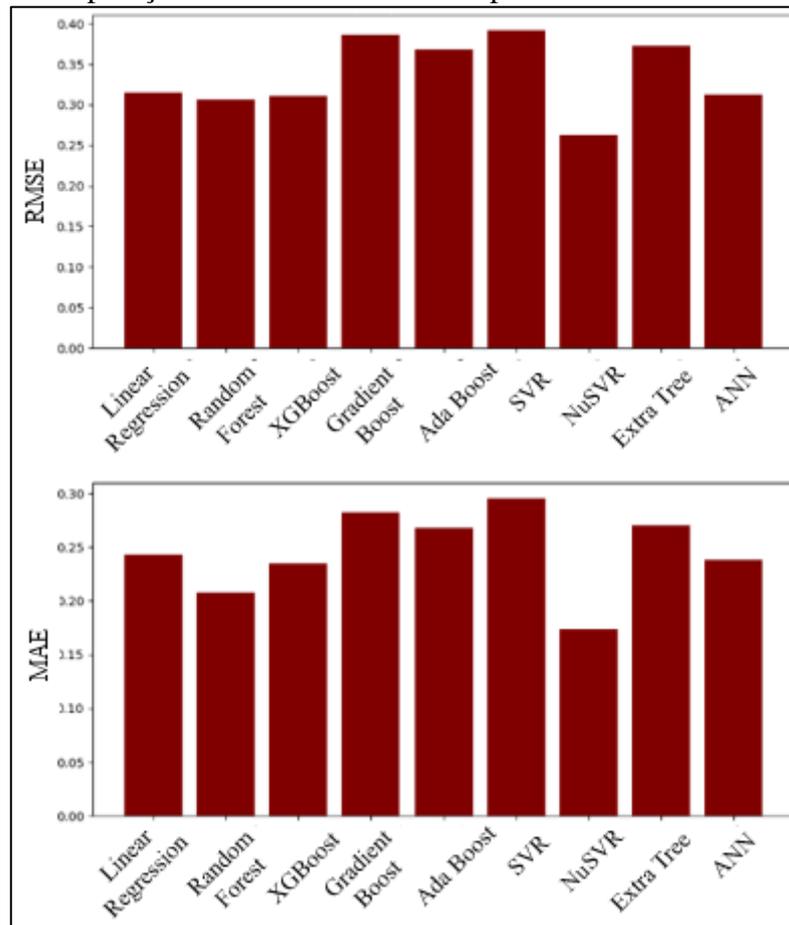
Assim como as ferramentas padrões, para as ferramentas com polimento H 4/400, o melhor modelo para predição de R_z foi o *Extra Tree*, com as métricas de erros com resultado de 0,17648 e 0,14133 para RMSE e MAE, respectivamente.

Figura 34 – Comparação dos erros dos modelos para R_t das ferramentas padrões



Fonte: Autor (2023).

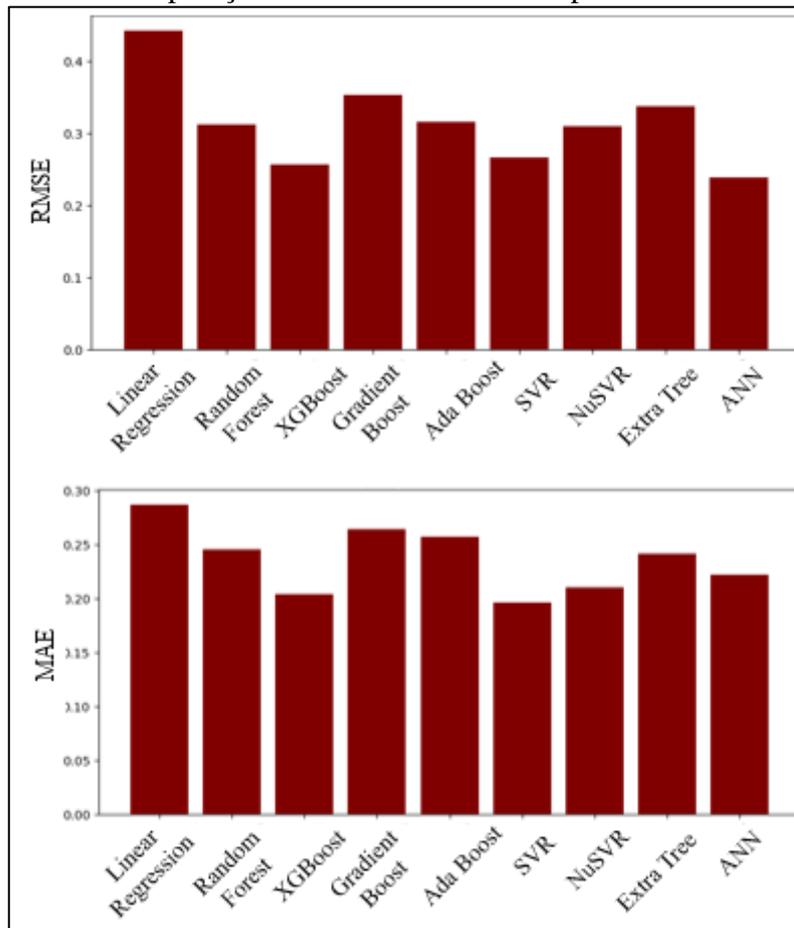
Na predição de R_t para as ferramentas padrões, os modelos *XGBoost* e *Gradient Boost* tiveram desempenho próximo analisando-se o MAE, porém por penalizar outliers, foi considerado o RMSE como mais relevante para apontar o melhor modelo. Desta forma, o modelo que apresentou melhor desempenho foi o *XGBoost* com RMSE e MAE de 0,37631 e 0,31929, respectivamente. O *Gradient Boost* teve um RMSE igual a 0,43138 e MAE igual a 0,31170.

Figura 35 – Comparação dos erros dos modelos para R_t das ferramentas HSC 1/300

Fonte: Autor (2023).

O NuSVR foi o melhor modelo para prever o R_t das ferramentas polidas com HSC 1/300, onde o RMSE foi de 0,26239 e o MAE de 0,17374.

Figura 36 – Comparação dos erros dos modelos para R_t das ferramentas H 4/400



Fonte: Autor (2023).

E, por fim, para as ferramentas H 4/400, ANN foi o melhor método para prever R_t , pois teve o menor valor para RMSE de 0,23899 e MAE de 0,22172.

Com base nas avaliações dos erros, foi possível elencar o método de melhor desempenho para prever os parâmetros de rugosidade e desgaste médios das ferramentas nas três condições analisadas. No Quadro 5 a seguir é apresentado o resumo do resultado final das análises, apontando o melhor modelo para cada aplicação.

Quadro 5 – Resultados dos melhores modelos

Parâmetros	Padrão	HSC 1/300	H 4/400
Desgaste	NuSVR RMSE = 0,00090 MAE = 0,00078	NuSVR RMSE = 0,00253 MAE = 0,00182	ANN RMSE = 0,00129 MAE = 0,00106
R _a	<i>Random Forest</i> RMSE = 0,02778 MAE = 0,02479	Regressão Linear RMSE = 0,02828 MAE = 0,02237	ANN RMSE = 0,02563 MAE = 0,02256
R _z	<i>Extra Tree</i> RMSE = 0,15298 MAE = 0,13264	ANN RMSE = 0,04346 MAE = 0,03895	<i>Extra Tree</i> RMSE = 0,17648 MAE = 0,14133
R _t	<i>XGBoost</i> RMSE = 0,37631 MAE = 0,31929	NuSVR RMSE = 0,26239 MAE = 0,17374	ANN RMSE = 0,23899 MAE = 0,22172

Fonte: Autor (2023).

Observa-se que, para os desgastes, os erros médios absolutos para as ferramentas padrões e com polimentos HSC 1/300 e H 4/400 foram de 0,00078, 0,00182 e 0,00106, respectivamente, em torno de 0,1%. Para R_a os erros médios absolutos para as 3 condições foram 0,02479, 0,02237 e 0,2256, que representam em torno de 2,3%. Analisando R_z, pode-se avaliar erros médios absolutos de 0,13264, 0,03895 e 0,14133, que resulta em um erro percentual em torno de 10,4%. E, para o parâmetro R_t, os erros médios absolutos das mesmas 3 condições foram 0,31929, 0,17374 e 0,22172, com erro percentual absoluto médio em torno de 23,8%.

Estes valores representam bons resultados comparados à literatura, Lin *et al.* (2020) na predição de R_a com RNAs tiveram erros de 6,86%, sendo inferior aos resultados encontrados nas predições de R_a deste trabalho nas três condições. Thangarasu *et al.* (2020) ao predizer desgaste por meio de Árvores de Decisão e SVM obteve acuracidades de 100% e 99,86%, que representam erros em torno de 0,1%, semelhante aos resultados encontrados nos modelos aqui aplicados. Além disso, destaca-se a importância de aplicar validação cruzada para definição dos hiperparâmetros adotados nos treinamentos dos modelos, o que diminui as acuracidades encontradas, porém reduz o *overfitting* dos modelos.

Desta forma, observa-se que o modelo de ANN, apareceu com bom resultado de predição para todos os parâmetros de desgaste e de rugosidade. Um modelo potencial para

predição dos desgastes é o NuSVR. Além disso, ressalta-se os modelos baseados em árvores de decisão, principalmente *Random Forest*, *Extra Tree* e *XGBoost*, como bons modelos para predição das rugosidades. Conclui-se então, que devido ao comportamento dos dados, que o NuSVR, baseado em vetor de suporte é um bom modelo para o desgaste e os modelos baseados em árvore de decisão para prever as rugosidades, podendo ser treinados e aplicados na prática, como substituição de processos manuais para medição destes parâmetros.

5. CONCLUSÃO

Com base no objetivo desenhado para este trabalho, onde buscou-se propor modelos computacionais para predição de rugosidades e desgastes, ao longo da vida útil da ferramenta, considerando-se diferentes cenários de polimentos por arraste. Investigou-se melhor os parâmetros de avaliação para rugosidade e desgaste para o fresamento com diferentes condições de preparação de gumes. A partir disso, verificou-se na literatura quais métodos foram utilizados para predição destes parâmetros e buscou-se fazer novas explorações.

Para isso, os experimentos de aquisição dos dados foram desenhados, para que, por meio das análises destes dados fosse possível compreender melhor os efeitos destes polimentos na vida útil das ferramentas, com base no comportamento dos desgastes, e também, entender como isso afeta as rugosidades das peças usinadas com estas diferentes condições para preparação dos gumes de corte. Com estes dados, foi possível treinar diferentes modelos de Aprendizado de Máquina, para que eles fossem capazes de prever estes valores, podendo assim, após avaliação destes métodos, propor os modelos que cumpriram esta tarefa de forma efetiva.

Esta exploração dos efeitos da preparação do gume, trouxe mais discussões sobre a principal direção considerada para aprimorar o despenho das ferramentas nos processos de fresamento. Reforça-se uma fabricação mais econômica e maior durabilidade das ferramentas, reduzindo-se custos de processos de usinagem. Conciliando isso com a aplicação de métodos para predição dos parâmetros de rugosidade e desgaste, o que também contribui para redução de custos, já que evita paradas de processos para medições, e também maior controle de processo quanto aos parâmetros que estão sendo reproduzidos durante a fabricação, de forma a garantir que estejam dentro das especificações de projetos, o que corrobora com a confiabilidade da usinagem.

Com base nas análises realizadas neste trabalho, confirmou-se o poder da preparação de gume pelo processo de arraste como um bom meio para garantir um melhor desempenho das

ferramentas de fresamento. Ao comparar as rugosidades geradas por ferramentas com e sem polimento, verificou-se que o raio maior gerado no arredondamento do arraste das mídias, garantiu uma estabilidade da ferramenta e valor de rugosidades menores, com menores diferenças de picos e vales.

Além disso, ao analisar as diferenças entre os parâmetros de rugosidades R_z e R_t , confirmou-se que, para as ferramentas que não passaram pelo processo de preparação dos gumes, esta diferença entre os parâmetros aumentou no decorrer dos desgastes das ferramentas, o que representou um aumento da instabilidade ou não homogeneidade da operação de fresamento realizada por estas fresas.

Ao apurar os resultados dos desgastes obtidos nos experimentos, pode-se confirmar também a maior vida útil das ferramentas com preparação de gume. Onde, notou-se uma vida útil maior para a ferramenta com polimento H 4/400, que é a mídia mais abrasiva, que durou 20,49% a mais que uma ferramenta sem qualquer preparação. Já para as ferramentas com polimento HSC 1/300, que são mídias um pouco menos abrasivas, verificou-se um aumento da vida útil em relação às ferramentas padrões de 18,62%.

Para responder quais os melhores métodos para prever a rugosidade da peça e o desgaste da ferramenta ao longo da vida útil da ferramenta no cenário de diferentes polimentos por arraste nas condições estabelecidas neste trabalho, foram testados e comparados 9 modelos de predição diferentes, buscando-se explorar mais modelos pouco explorados na literatura para estas tarefas. Para as predições dos desgastes e rugosidades, alcançou-se erros absolutos percentuais médios para desgaste, R_a , R_z e R_t em torno de 0,1%, 2,3%, 10,4% e 23,8%, respectivamente, que foram semelhantes ou melhores que os resultados encontrados em outros trabalhos da literatura.

Ressalta-se a eficácia dos modelos baseados em árvores de decisão como *Random Forest*, *Extra Tree* e *XGBoost* para as predições de rugosidades e NuSVR para as predições de desgaste. Além da importância da comparação de diferentes métodos de predição, salienta-se a importância da aplicação da validação cruzada, que por meio dos ajustes dos hiperparâmetros, diminui o *overfitting* dos modelos e garante uma maior capacidade de generalização quando aplicados na prática para novos dados. Estes modelos propostos podem ser treinados e aplicados na prática em processos de fresamento para predição de rugosidade e desgaste, substituindo-se processos manuais de medição destes parâmetros e gerando uma compreensão melhor do processo, o que reduz custos e garante melhor aproveitamento da vida útil da ferramenta e confiabilidade das rugosidades geradas pela ferramenta.

6. SUGESTÕES PARA TRABALHOS FUTUROS

Com o desenvolvimento do trabalho e por meio das avaliações feitas, alguns pontos de melhoria surgiram e aqui estão elencados para que trabalhos futuros possam explorar. Sugere-se simplificar as análises dos cenários para validar os modelos de predição, mas utilizar mais ferramentas para o mesmo cenário. Com o mesmo número de ferramentas, 9 ferramentas, pode-se considerar a média de 3 ferramentas para treinamento, outras 3 para validação e mais 3 para teste.

Desta forma, é possível, treinar, validar e depois testar os modelos, sem utilizar os mesmos dados, evitando vazamento dos dados. Isso aumentará também o número de observações, o que diminuirá a variância dos resultados, que é a sensibilidade do algoritmo a pequenas variações nos dados de treinamento, onde memoriza ruídos aleatórios deste conjunto de treinamento.

Além disso, sugere-se aumentar a quantidade de entradas para o modelo, além do comprimento usinado, como outros parâmetros do processo, o que contribui para diminuir o viés dos modelos, que é um vício de aprender as informações erradas de forma sistemática, onde o algoritmo fica incapaz de entender a relação entre as entradas e o valor predito.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABNT NBR ISO 4287. **Termos, Definições e Parâmetros de Rugosidade**, Especificações Geométricas do produto (GPS) – Rugosidade – Método do Perfil, 18p., 2002.

ABNT NBR ISO 4288. **Regras e Procedimentos para Avaliação de Rugosidade**, Especificações Geométricas do produto (GPS) – Rugosidade – Método do Perfil, 10p., 2008.

AL HAZZA; M. H. F.; ADESTA, E. Y. T. Investigation of the effect of cutting speed on the surface roughness parameters in CNC end milling using artificial neural network, **IOP Conference Series: Materials Science and Engineering**, Vol. 53, No. 1, 2013.

ALAUDDIN, M.; BARADIE, M.A.E.; HASHMI, M.S.J. Prediction of tool life in end milling by response surface methodology. **J. Mater. Process. Technol**, Vol. 71, 456–465, 1997.

AMEEN, F. **Prediction of Surface Quality Using Artificial Neural Network for the Green Machining of Inconel 718**. Electronic Theses and Dissertations, dezembro de 2018.

AWAD, M.; KHANNA, R. **Support Vector Regression**. Efficient Learning Machines. Apress, Berkeley, CA, 2015.

AYKUT, S. Surface roughness prediction in machining castamide material using ANN. **Journal of Applied Sciences** (Acta Polytechnica Hungarica), Vol. 8, No. 2, pp. 21-32, 2011.

AZEVÊDO, L. L. A. **Métodos Estatísticos em Aprendizado de Máquinas para problemas de Classificação**. 131 f. Dissertação (Mestrado) - Curso de Estatística, Universidade de Brasília, Brasília, 2018.

BAJIĆ, D.; CELENT, L.; JOZIĆ, S. Modeling of the influence of cutting parameters on the surface roughness, tool wear and cutting force in face milling in off-line process control. **Journal of Mechanical Engineering**, Vol. 58, pp. 673-682, 2012.

BARLETTA M.; PIETROBONO F.; RUBINO G.; TAGLIAFERRI V. Drag finishing of sensitive workpieces with fluidized abrasives. **J. Manuf. Proc.**, 16 pp.494-502, 2014.

BASTOS, D. G.; NASCIMENTO, P. S.; LAURETTO, M. S. **Proposta e análise de desempenho de dois métodos de seleção de características para Random Forests**. IX Simpósio Brasileiro de Sistemas de Informação, p. 49–60, 2013.

BREIMAN, L. Arcing classifier (with discussion and a rejoinder by the author). **The Annals of Statistics**. Vol. 26, n 3, 1998.

BATISTA, G. E. d. A. P. *et al.* **Pré-processamento de dados em aprendizado de máquina supervisionado**. Tese (Doutorado) – Universidade de São Paulo, São Paulo, 2003.

BENARDOS, P. G.; VOSNIAKOS, G. C. Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments, **Robotics and Computer Integrated Manufacturing**, Vol. 18, pp. 343-354, 2002.

BIERMANN, D.; SCHUMANN, S.; KANSTEINER, M. **Umfassende Betrachtung der mechanischen Belastungen im Schleifprozess**. Forum Schneidwerkzeug Schleiftechnik, Vol. 4, 72–83, 2012.

BULLINARIA, J.A. **Introduction to neural computation**, 2014.

BURMAN, P. A comparative study of ordinary cross-validation, v-fold cross-validation and the learning-testing methods. **Biometrika**, 76: 503-514. 1989.

BYRNE, G.; DORNFELD, D.; DENKENA, B. Advancing cutting technology. **CIRP Ann Manuf Technol**, 52(2):483–507, 2003.

CARTER, M. A. **Telecurso 2000 – Metrologia – Profissionalizante – Aula 19**, Disponível em: [<www.grima.ufsc.br/capp/rugosidade/aula19_ParametrosDeRugosidade.pdf>](http://www.grima.ufsc.br/capp/rugosidade/aula19_ParametrosDeRugosidade.pdf)
Acesso em: 04/05/2022.

CHANDRASEKARAN, M.; MURALIDHAR, M.; KRISHNA, C. M.; DIXIT, U. S. Application of soft computing techniques in machining performance prediction and

optimization: a literature review. **International Journal of Advanced Manufacturing Technology**, v. 46, p. 445-464, 2010.

DENKENA, B.; BIERMANN, D. Cutting edge geometries. **CIRP Ann Manuf Technol** 63(2):631–653, 2014.

ESCALONA, P. M. **Surface Roughness Prediction when Face Milling with Square Inserts**. 296 f. Tese (Doutorado) - Curso de Mechanical Engineering, University Of Bath, Bath, 2010.

DIN 4760, Form Deviations; Concepts; Classification System, Deutches Institut Fuer Normung, e.V., 1982.

DINIZ A. E.; MARCONDES F. C.; COPPINI N. L. **Tecnologia da Usinagem dos Materiais**. MM Editora. 1999.

FACELI, K. et al. **Inteligência artificial** : uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 378 p, 2015.

FERRARESI D., **Fundamentos da usinagem dos metais**. São Paulo: E. Blucher, 3v, 1970.

FOX, D. G. Judging Air Quality Model Performance. **Bulletin of the American Meteorological Society**, v. 62, p. 599-609, 1981.

FREUND, Y.; SCHAPIRE, R. E. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting”. **Journal of Computer and System Sciences**, Vol. 55, n 1, p. 119–39, 1997.

FRIEDMAN, J. H. Stochastic gradient boosting. **Computational statistics & data analysis**, Elsevier, [S.l.], v. 38, n. 4, p. 367–378, 2002.

FRIEMUTH, T. **Herstellung Spanender Werkzeuge**. Habilitation Thesis, Universität Hannover, Hannover, Germany, 2002.

FULEMOVA, J.; ZDENĚK, J. Influence of the Cutting Edge Radius and the Cutting Edge Preparation on Tool Life and Cutting Forces at Inserts with Wiper Geometry. **Procedia Engineering**, Vol. 69, p. 565–73, 2014.

GALVÃO, N. D.; MARIN, H. de F. **Técnica de mineração de dados**: uma revisão da literatura. *Acta Paulista de Enfermagem, Escola Paulista de Enfermagem*, v. 22, n. 5, 2009.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn and TensorFlow**. California: O'Reilly Media, 2017.

GILBERT, C.; BROWELL, J.; MCMILLAN, D. **Leveraging Turbine-Level Data for Improved Probabilistic Wind Power Forecasting**. *IEEE Trans. Sustain. Energy*, 11, 1152–1160, 2019.

HALLAK, R.; FILHO A. J. P. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de advecção e assimilação de dados. **Revista Brasileira de Meteorologia**, Vol. 26, n 4, p. 591–608, 2011.

HAYKIN, S.O. **Neural Networks: A Comprehensive Foundation** (2^a ed.). Ontario: Pearson Education. 2001.

JABBAR, H.K.; KHAN, R.Z. **Methods to Avoid Over-Fitting and Under-Fitting in Supervised Machine Learning (Comparative Study)**. 2014.

JOHARI, A.; JAVADI A. A.; HABIBAGAH, G. Modelling the mechanical behavior of unsaturated soils using a genetic algo-rithm-based neural network. **Computers and Geotechnics**, v. 38, n. 1, p. 2-13, 2001.

KALPAKJIAN, S. **Manufacturing Processes for Engineering Materials and Technology**. Vol. 157-158, p. 543-552, 2003.

KLOCKE, F. **Manufacturing Process 1 – Cutting**. Alemanha: Editora Springer, 2011.

KRIEGESKORTE, N. *Cross validation in Brain Imaging Analysis*. Medical Research Council, Cognition and Brain Sciences Unit, 2015.

LACALLE, L.; CAMPA, F.; LAMIKIZ, A. *Milling*, 2011.

Li G.C.; Zhou H.G.; Jing X.W.; Tian G.Z.; Li L. An intelligent wheel position searching algorithm for cutting tool grooves with diverse machining precision requirements. **Int J Mach Tools Manuf.** 122:149–160, 2017.

LIN, Y., *et al.* Prediction of Surface Roughness Based on Cutting Parameters and Machining Vibration in End Milling Using Regression Method and Artificial Neural Network. *Applied Sciences*, Vol. 10, n 11, p. 3941, 2020.

MACHADO, A.R.; ABRÃO, A. M.; COELHO, R. T. **Teoria da usinagem do materiais**. 3.ed. São Paulo. Editora Edgard Blücher Ltda, 2015.

MAKRIDAKIS, S.; SPILLOTIS, E.; ASSIMAKOPOULOS, V. **Statistical and Machine Learning forecasting methods: Concerns and ways forward**. PLOS ONE, México, 2018.

MALDANER, J. Verbesserung des Zerspanverhaltens von Werkzeugen mit Hartmetall-Schneidelemente durch Variation der Schleifbearbeitung. Ph.D. Thesis, Universität Kassel, Kassel, Germany, 2008.

MALKORRA, I.; SOULI, H.; SALVATORE, F.; ARRAZOLA, P.; RECH, J.; CICI, M.; MATHIS, A.; ROLET, J. Modeling of Drag Finishing—Influence of Abrasive Media Shape. *J. Manuf. Mater. Process.*, 5, 41, 2021.

MARSLAND, S. **Machine learning**: an algorithmic perspective. [S.l.]: CRC press, 2015.

MOHANRAJ, T., *et al.* Development of Tool Condition Monitoring System in End Milling Process Using Wavelet Features and Hoelder's Exponent with Machine Learning Algorithms. *Measurement*, Vol. 173, p. 108671, 2021.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. **Sistemas Inteligentes Fundamentos e Aplicações**, Manole Ltda, Barueri-SP, p. 89–114, 2003.

MONTEIRO, R. B. **Comparação de técnicas de aprendizado de máquina para predição da disponibilidade de bicicletas no projeto biciletar fortaleza**. 37 f. TCC (Graduação) - Curso de Sistemas de Informação, Universidade Federal do Ceará, Quixadá, 2018.

ORTEGA, Z.; ROCIO, L. **Estimativa da radiação solar global pelos modelos de Hargreaves e aprendizado de máquina em 11 regiões de São Paulo /Brasil**. Dissertação (Mestrado) — Universidade Estadual Paulista, 2020.

OST, C. A. **Análise da qualidade superficial no fresamento de aço P20 com diferentes tratamentos de ferramentas**. 2016. 103 f. Dissertação (Mestrado) - Dissertação (Mestrado) - Universidade de Caxias do Sul, Programa de Pós-Graduação em Engenharia Mecânica, 2016.

OTEC. **Edge Rounding and Polishing of Tools**. Apresentação, 2008.

ÖZEL, T.; HSU, T.; ZEREN, E. Effects of cutting edge geometry, workpiece hardness, feed rate and cutting speed on surface roughness and forces in finish turning of hardened AISI H13 steel. **Int. J. Adv. Manuf. Technol.** 25, 262–269, 2005.

PAUCKSH, E.; HOLSTEN, S.; LIN, M.; TIKAL F., *Zerspantechnik: Prozesse, Werkzeuge, Technologien*, 12. Vieweg-Teubner, 2008.

PEDREGOSA, F., et al. Scikit-Learn: Machine Learning in Python. **Journal of Machine Learning Research**, 12, 2825-2830, 2011.

PESTANA, M. H.; GAGEIRO, J. N. **Análise de dados para ciências sociais: a complementaridade do spss**. Sílabo Lisboa, 2003.

POKORNÝ, P.; PÄTOPRSTÝ, B.; VOPAT, T.; PETERKA, J.; MAREK, V.; VLADIMÍR, Š. Cutting edge radius preparation. **Materials Today: Proceedings**. 22. 212-218, 2020.

RAJESH, M.; MANU, R. Prediction of surface roughness of freeform surfaces using artificial neural network, **Proceedings of the 26th All India Manufacturing Technology, Design and Research Conference (AIMTDR 2014)**, IIT Guwahati, Assam, India, 2014.

Ramesh, V. **Cutting edge preparation**. Bangalore Institute of Technology. ISBN: 978-93-84209-40-7, 2014.

RASCHKA, S. **Python machine learning**. [S.l.]: Packt publishing ltd, 2015.

RIBEIRO, A. J. A. **Um método para localização e estimação das características geotécnicas dos solos da Região Metropolitana de Fortaleza-CE para 2 ins de pavimentação**. Dissertação de Mestrado, Universidade Federal do Ceará , Fortaleza, 2013.

RIBEIRO, A. J. A.; SILVA, C. A. U.; Barroso, E S. H. A. **Metodologia de baixo custo para mapeamento geotécnico aplicado à pavimentação**. Transportes (Rio de Janeiro), v. 26, n. 2, p. 84-100. DOI:10.14295/transportes.v26i2.1491, 2018.

RISSE, K. *Einflüsse von Werkzeugdurchmesser und Schneidkantenverrundung beim Bohren mit Wendelbohrern in Stahl*. Dissertação de Mestrado, RWTH Aachen, Aachen, 153p., 2006.

RODRIGUES, S. C. A. **Modelo de Regressão Linear e suas Aplicações**. Dissertação (Mestrado) — Universidade da Beira Interior, Covilhã, Portugal, 2012.

RODRÍGUEZ, C. *Cutting edge preparation of precision cutting tools by applying micro-abrasive jet machining and brushing*. Kassel university press GmbH, Kassel, 2009.

RODRÍGUEZ, J. J.; QUINTANA, G.; BUSTILLO, A.; CIURANA, J. A decision-making tool based on decision trees for roughness prediction in face milling, **International Journal of Computer Integrated Manufacturing**, 30:9, 943-957, 2017.

KOHAVI, R. *A study of cross-validation and bootstrap for accuracy estimation and model selection*. 14Th international joint conference on Artificial intelligence, 1995.

RUSSELL, S.; NORVIG, P. **Inteligência artificial**. 3. ed. Rio de Janeiro: Elsevier Editora Ltda., 988 p, 2013.

ROSSUM, G. V. **What is Python? Executive Summary**, 1998.

SAIF, Y. A. M. **Modelling and simulation of surface roughness obtain from micro milling by using artificial neural network**. Mohd Rasidi Bin Ibrahim. 2014. 68 f. Dissertação (Mestrado) - Degree of Master of Mechanical and Manufacturing Engineering, Faculty of Mechanical and Manufacturing Engineering, Universiti Tun Hussein Onn Malaysia. Malásia, 2014.

SAMEK, D.; BILEK, O. Modeling of CNC machining process – artificial neural networks approach, **Recent Advances in Automatic Control, Information and Communications**, Recent Advances in Electrical Series, Vol. 19, WSEAS, pp. 168-173, 2013.

SANTOS, A. L. B. **Metodologia via redes neurais para a estimativa da rugosidade e do desgaste de ferramentas de corte no processo de fresamento frontal**. 2001. 187 f. Tese (Doutorado) - Curso de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2001.

SHWARTZ-SHALEV, S.; BEN-DAVID, S. **Understanding Machine Learning: From theory to algorithms**. NY, USA: Cambridge University Press, 2014.

SINGH, U.; RIZWAN, M.; ALARAJ, M.; ALSAIDAN, I. A Machine Learning-Based Gradient Boosting Regression Approach for Wind Power Production Forecasting: A Step towards Smart Grid Environments. *Energies*, 14, 5196, 2021.

SITTON, J. D.; Y. ZEINALI, Y.; STORY, B.A. Rapid soil classification using artificial neural networks for use in constructing compressed earth blocks. *Construction and Building Materials*, v. 138, p. 214-221. DOI: 10.1016/j.conbuildmat.2017.02.006, 2017.

THANGARASU, S., SHANKAR, S., MOHANRAJ, T. & DEVENDRAN, K. Tool wear prediction in hard turning of EN8 steel using cutting force and surface roughness with artificial

neural network. *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 234, 329-342. 2020.

TIKAL, F.; BIENEMANN, R.; HECKMANN, L. **Schneidkantenpräparation-Ziele, Verfahren und Messmethoden. In Berichte aus Industrie und Forschung.** Universität Kassel: Kassel, Germany, 2009.

TRENT E.M.; WRIGHT P.K. **Metal cutting.** (4th edition), 'Butterworth-Heinemann', Boston, 2000". *Science of Sintering*, vol. 36, no 1, p. 54–54, 2004.

VACARO, Tiago. **Otimização do fresamento de topo esférico de planos inclinados aplicando o método de algoritmos genéticos.** 2013. 125 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Universidade de Caxias do Sul, Caxias do Sul, 2013.

VOZÁR, M., *et al.* Influence of drag finishing parameters on the cutting edge radius of solid carbide mills. **IOP Conference Series: Materials Science and Engineering**, Vol. 749, n 1, p. 012027, 2020.

XUEFENG, Z.; HUI, L.; LIN, H.; MENG, T. **Modeling and detection of the prepared tool edge radius,** 2020.

WANG, W. *et al.* Effect of Edge Preparation Technologies on Cutting Edge Properties and Tool Performance. *The International Journal of Advanced Manufacturing Technology*, vol. 106, n 5–6, p. 1823–38, 2020.

WANG, W.T.; BIERMANN, D.; AMUTH, R.; ARIF, A.F.M.; VELDHUIS, S.C. Effects on tool performance of cutting edge prepared by pressurized air wet abrasive jet machining (PAWAJM). **J Mater Process Technol**, 77, 2020.

YAZID, A.M.S. **Modelling and Simulation of Surface Roughness Obtain from Micro Milling by Using Artificial Neural Network.** Ph.D. Thesis, University Tun Hussein Onn Malaysia, Parit Raja, Malaysia, 2014.

YUE, C.; GAO, H.; LIU, X.; LIANG, S.Y. Part functionality alterations induced by changes of surface integrity in metal milling process: A review. *Appl. Sci.*, 8, 2550, 2018.

YUSSEFIAN, N. Z. **Cutting edge microgeometry modeling & electro-erosion honing.** McMaster University, 2012.

ZHAO, F.X.; HE, L.; YUAN, S.; ZHENG, W.J. Influence of edge preparation parameters on the cutting edge in drag finishing. *Key Eng. Mater.*, 693, 1067–1073, 2016.

ZHAO, S.; ZHANG, Y.; WANG, S.; ZHOU, B.; CHENG, C. **A recurrent neural network approach for remaining useful life prediction utilizing a novel trend features construction method**, 279 – 288, 2019.

ZHAO, Z.; LIU, X.; YUE, C.; LI, R.; ZHANG, H.; LIANG, S. Tool Quality Life during Ball End Milling of Titanium Alloy Based on Tool Wear and Surface Roughness Models. **Applied Sciences**, [S.L.], v. 10, n. 9, p. 3316, MDPI AG, 2020.

ZHAO, X., ZHENG, P., HE, L. *et al.* Cutting edge preparation using the discrete element software EDEM. **J Braz. Soc. Mech. Sci. Eng.** 42, 163, 2020.