

Universidade Federal de São Carlos – UFSCar
Centro de Ciências Exatas e de Tecnologia – CCET
Programa de Pós-Graduação em Engenharia Mecânica – PPGEMec

Mateus Keniti Nakashima Sinzato

**INTELIGÊNCIA ARTIFICIAL APLICADA À
PREPARAÇÃO E APLICAÇÃO DE INSERTOS DE METAL
DURO**



São Carlos
2024

Mateus Keniti Nakashima Sinzato

INTELIGÊNCIA ARTIFICIAL APLICADA À PREPARAÇÃO E APLICAÇÃO DE INSERTOS DE METAL DURO

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de São Carlos, para obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. João Vitor de Carvalho Fontes

Coorientador: Prof. Dr. Armando Ítalo Sette Antonialli

São Carlos

2024



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Mateus Keniti Nakashima Sinzato, realizada em 30/10/2024.

Comissão Julgadora:

Prof. Dr. João Vitor de Carvalho Fontes (UFSCar)

Prof. Dr. Amauri Hassui (UNICAMP)

Prof. Dr. Sidney Bruce Shiki (UFSCar)

Dedico este trabalho à minha família e amigos por tanto me apoiarem.

AGRADECIMENTOS

À Universidade Federal de São Carlos e ao Programa de Pós-Graduação em Engenharia Mecânica pelo apoio institucional e estrutural. À Fundação de Amparo à Pesquisa Científica (FAPESP) pelo apoio financeiro para a realização desta pesquisa com bolsa de estudos, – Projeto nº 2022/01711-7 e Projeto nº 2023/06179-4 (Bolsa Estágio de Pesquisa no Exterior - BEPE) – além do apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, e do apoio financeiro do Programa de Apoio à Pós-Graduação (ProAP).

Agradecimentos também aos processos FAPESP nº 2022/15409-0, nº 2015/15622-2, nº 2017/12309-7, nº 2017/12304-5, e nº 2022/01965-9, que auxiliaram para a realização do projeto. À Oerlikon Balzers por auxiliar na produção de revestimentos dos insertos utilizados durante a BEPE.

Agradeço à minha família, e todos que me apoiaram durante todo o tempo do mestrado. Agradeço ao meu orientador Prof. Dr. João Vitor de Carvalho Fontes e co-orientador Prof. Dr. Armando Ítalo Sette Antonialli pelo acompanhamento durante todo o desenvolvimento do mestrado, com uma orientação humana e qualificada, em que, mesmo nos momentos de maior dificuldade acadêmica e social, buscaram orientar com maestria.

Agradecimentos ao Prof. Dr. Joël Rech, supervisor responsável durante a Bolsa Estágio de Pesquisa no Exterior - BEPE, por ter fornecido todo o apoio, acompanhamento e ensinamentos durante todo o período de estágio realizado. Além de agradecimentos a *École nationale d'ingénieurs de Saint-Étienne* (ENISE) e ao *Laboratoire de Tribologie et Dynamique des Systèmes* (LTDS) por fornecer o apoio estrutural, e todos os técnicos e pesquisadores que auxiliaram com sugestões e auxílios durante a pesquisa.

Agradeço ao Prof. Dr.-Ing. Carlos Eiji Hirata Ventura pelas instruções quanto ao escopo do processamento do projeto, além de orientações sobre as melhores maneiras de realizar o planejamento experimental, além de ajudar na retificação dos insertos utilizados na pesquisa. Agradeço ao Msc. Ueliton Carvalho Alves pela ajuda com a preparação dos insertos.

Agradeço a todos os professores do Departamento de Engenharia Mecânica (DEMec) que ajudaram de alguma forma no projeto e aos técnicos de laboratório do Departamento de Engenharia Mecânica (DEMec) pelo auxílio com o desenvolvimento do projeto.

Continue a nadar, continue a nadar.";

Dory - Procurando Nemo

RESUMO

A retificação é um processo abrasivo comumente empregado em operações de acabamento por conferir tolerâncias dimensionais e geométricas estreitas, bem como reduzida rugosidade. Além dos aços endurecidos, que frequentemente passam por operações de acabamento com rebolo, outros materiais também são objetos da retificação, como os cermetos: compósitos com partículas cerâmicas e matriz metálica. Conhecidos popularmente como metais duros, esses materiais constituídos majoritariamente de carbeto de tungstênio e cobalto têm larga aplicação como ferramentas para usinagem. Nesse caso, a retificação é um dentre os diferentes processos abrasivos que podem ser aplicados para a preparação das arestas cortantes; mas se verifica uma certa falta de publicações a esse respeito quando é considerado a sua relação com a inteligência artificial, ainda que em crescente número nos últimos anos. Esta pesquisa propõe utilizar algoritmos de inteligência artificial (IA) como recurso de otimização para a retificação de insertos de metal duro considerando a velocidade de corte, velocidade de avanço e penetração de trabalho como fatores de influência e características geométricas dos produtos, tal qual as rugosidades (R_a e R_z), como variáveis de resposta. Ademais, como estudo de caso complementar, também estudou-se a utilização da IA para a otimização do torneamento longitudinal realizado com ferramentas de arestas cortantes com dois chanfros produzidos pela retificação, sendo avaliados o avanço, o raio de ponta da ferramenta e o fator de forma (K), e suas influências sobre as rugosidades R_a e R_z e a tensão residual geradas sobre uma liga de aço 4142. Um modelo preliminar foi amparado na metodologia de Taguchi além de análise de variância (ANOVA) para complementar o método; após isto, foi implementado modelos de otimização utilizando sistema artificial de inferência *Neuro-Fuzzy* (ANFIS) e rede neural artificial (ANN). Os resultados demonstraram que o modelo ANN apresentou melhores capacidades de predição quando comparados ao ANFIS, possuindo maiores capacidades de se tornar uma ferramenta de otimização.

Palavras-chave: Usinagem. Metal duro. Metodologia de Taguchi. Preparação de Aresta.

ABSTRACT

Grinding is an abrasive process often employed in finishing operations due to the possibility of obtaining narrow dimensional and geometric tolerances, besides low surface roughness. Besides hardened steels, that usually undergo finishing operations with grinding wheels, other materials may also be ground, like cermets: composites with ceramic particles and metallic matrix. Popularly known as hard metals, these materials mainly constituted by tungsten carbides and cobalt have wide application as machining tools. In this case, grinding is one among several abrasive processes that can be applied to the preparation of cutting edges; but it is verified a lack of publications on this purpose when related to the artificial intelligence, although their increasing number in the last few years. This work proposes to apply artificial intelligence (AI) algorithms as an optimization tool for carbide inserts grinding considering cutting speed, feed rate and radial depth of cut as input factors and geometric features of the products, such as surface roughness (R_a e R_z), as response outputs. Besides, as a complementar study, the IA application on the optimization of the straight turning was studied, using tools with two-chamfer cutting edges produced by grinding, which were evaluated the feed rate, tool nose radius and form factor (K), and their influences over the roughness R_a e R_z and residual stress generated on the 4142 alloy steel. A preliminary model was developed using the Taguchi methodology in addition to the analysis of variance (ANOVA) to complement the methodology; afterwards, it was developed optimization models using artificial Neuro-Fuzzy inference system (ANFIS) and artificial neural networks (ANN). The results demonstrated that the ANN model presented better prediction capability compared to the ANFIS model, obtaining higher capacities of becoming an optimization tool.

Keywords: Machining. Carbide. Taguchi Methodology. Edge Preparation.

LISTA DE FIGURAS

Figura 1 – Esquema de construção em blocos da inteligência artificial.	15
Figura 2 – Frequência de utilização de IA para processos abrasivos.	16
Figura 3 – Uso de IA em monitoramento e modelagem de diferentes processos abrasivos.	16
Figura 4 – Panorama de publicações relacionadas ao tema de pesquisa no ScienceDirect.	17
Figura 5 – Panorama de publicações relacionadas ao tema de pesquisa no Scopus.	18
Figura 6 – Representação da rugosidade R_a	21
Figura 7 – Representação da rugosidade R_z	21
Figura 8 – Variação da rugosidade média R_a	21
Figura 9 – Princípio do processo abrasivo.	22
Figura 10 – Esquema representativo de micro e macro desgaste na ferramenta.	24
Figura 11 – Efeito da velocidade de corte no processamento.	25
Figura 12 – Representação dos parâmetros da micro geometria.	29
Figura 13 – Modelo aplicado aos dados.	31
Figura 14 – Relação entre rede neural e <i>Machine Learning</i>	32
Figura 15 – Esquema de inferência Fuzzy.	35
Figura 16 – Modelo de neurônio artificial <i>Perceptron</i>	36
Figura 17 – Camada estruturada de nós.	37
Figura 18 – Esquema do <i>Back-propagation</i>	38
Figura 19 – Representação da divisão dos dados na validação.	39
Figura 20 – Fluxograma do projeto.	43
Figura 21 – Representação da retificação dos insertos.	45
Figura 22 – Caracterização geométrica por microscópio: (a) equipamento e (b) exemplo de imagem obtida.	46
Figura 23 – Exemplo de medição de rugosidade realizada no Alicona.	47
Figura 24 – Esquema das magnitudes do perfil de tensão residual.	50
Figura 25 – Médias (a) e SN_S (b) do valor R_a	53
Figura 26 – Médias (a) e SN_S (b) do valor R_z	54
Figura 27 – Dados dos valores médios de R_a versus velocidade de corte.	55
Figura 28 – Dados dos valores médios de R_a versus sobremetal e velocidade de avanço.	55
Figura 29 – Dados dos valores médios de R_z versus velocidade de corte.	55
Figura 30 – Dados dos valores médios de R_z versus velocidade de corte e velocidade de avanço.	56
Figura 31 – Gráfico das superfícies de resposta para as três variáveis; (a) $V_c = 12$ m/s, (b) $V_c = 36$ m/s e (c) $V_c = 60$ m/s.	57
Figura 32 – Valores de rugosidade R_a e R_z	61

Figura 33 – Gráfico de Influência para o R_a (a) raio de ponta, (b) K ; e R_z (c) raio de ponta e (d) K	62
Figura 34 – Dados ajustados a curva teórica de rugosidade.	63
Figura 35 – Forças médias (a) força de corte, (b) força de avanço e (c) força passiva. . .	63
Figura 36 – Gráficos de influência para o raio de ponta (a) força de corte, (b) força de avanço e (c) força passiva.	64
Figura 37 – Gráficos de influência para o K (a) força de corte, (b) força de avanço e (c) força passiva.	65
Figura 38 – Perfis de tensão residual para direção circunferencial: (a) $f = 0,10$ mm, (b) $f = 0,15$ mm e (c) $f = 0,20$ mm.	66
Figura 39 – Perfis de tensão residual para direção radial: (a) $f = 0,10$ mm, (b) $f = 0,15$ mm e (c) $f = 0,20$ mm.	67
Figura 40 – Comparativo de curvas de tensão residual para raio de ponta 0,4 mm.	68
Figura 41 – Dados discretizados na direção circunferencial para raio de ponta 0,4 mm. .	69
Figura 42 – Dados discretizados na direção radial para raio de ponta 0,4 mm.	69
Figura 43 – Exemplo de R-valor encontrado para previsão de resultado de rugosidade. .	72
Figura 44 – Exemplo de R-valor encontrado para previsão de resultado para a tensão residual.	72
Figura 45 – Teste de Tukey para R_a	89
Figura 46 – Teste de Tukey para R_z	91
Figura 47 – Dados de Rugosidade.	92
Figura 48 – Dados de Força.	92
Figura 49 – Diagrama de efeitos principais para as rugosidades e forças.	93
Figura 50 – Diagrama de efeitos principais para a tensão residual.	94
Figura 51 – Dados da ANOVA para rugosidade e forças.	94
Figura 52 – Dados da ANOVA para tensão residual.	95

LISTA DE TABELAS

Tabela 1 – Variáveis de entrada mais importantes dos artigos.	27
Tabela 2 – Variáveis de saída mais importantes dos artigos.	28
Tabela 3 – Arquitetura de Redes Neurais.	37
Tabela 4 – Condições experimentais dos insertos utilizados na análise por metodologia de Taguchi.	47
Tabela 5 – Fatorial completo de todas as condições das arestas de folga.	48
Tabela 6 – Características nominais da micro geometria dos insertos.	49
Tabela 7 – Condições experimentais do torneamento.	49
Tabela 8 – Condições experimentais do sistema de difração de raios-X	49
Tabela 9 – Condições de maior compressão residual.	51
Tabela 10 – Quadro ANOVA das medidas de R_a	53
Tabela 11 – Quadro ANOVA das medidas de R_z	54
Tabela 12 – Resultados do teste de Chauvenet para R_a	58
Tabela 13 – Resultados do teste de Chauvenet para R_z	58
Tabela 14 – Resultados da Predição com modelo ANN para as rugosidades na retificação com dados conjuntos.	59
Tabela 15 – Resultados da Predição com modelo ANFIS para as rugosidades na retificação.	60
Tabela 16 – Resultados da Predição com modelo ANN para rugosidade no torneamento.	71
Tabela 17 – Resultados da Predição com modelo ANN para as tensões residuais no torneamento.	73
Tabela 18 – Resultados da Predição com modelo ANFIS para as tensões residuais no torneamento.	74
Tabela 19 – Valores de Rugosidade R_a da superfície de folga dos insertos	89
Tabela 20 – Valores de Rugosidade R_z da superfície de folga dos insertos	90
Tabela 21 – Legenda	90

LISTA DE ABREVIATURAS E SIGLAS

ANOVA	Análise de Variância
ABNT	Associação Brasileira de Normas Técnicas
ANN	Rede Neural Artificial
ANFIS	Sistema de Inferência Artificial Neuro-Fuzzy
IA	Inteligência Artificial
DR	Desvio-Padrão

LISTA DE SÍMBOLOS

V_c	Velocidade de Corte
V_f	Velocidade de Avanço
a_e	Sobremetal
V_{fad}	Velocidade Axial do dressador
f	Taxa de Avanço
a_p	Profundidade de Usinagem
F_c	Força de Corte
F_t	Força de Avanço
F_p	Força Passiva
SN	Sinal-ruído
K	Fator de Forma
λ_s	Inclinação da Aresta de Corte
γ_n	Ângulo Ortogonal
Δr	<i>Profile Flattening</i>
φ	<i>Apex Angle</i>

SUMÁRIO

1	INTRODUÇÃO	14
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Retificação dos metais duros	20
2.2	Preparação de geometria da aresta por retificação e o torneamento . . .	28
2.3	Inteligência Artificial	30
2.3.1	Teoria dos conjuntos <i>FUZZY</i> E ANFIS	31
2.3.2	Redes Neurais	36
2.3.3	Inteligência artificial aplicada aos processos de retificação e torneamento . .	39
3	MATERIAIS E MÉTODOS	43
3.1	Metodologia de Taguchi e ANOVA	43
3.2	Retificação de superfície de folga	45
3.3	Torneamento com inserto de dois chanfros	48
3.4	Programação do Matlab® em ANN e ANFIS para os estudos	51
4	RESULTADOS E DISCUSSÕES	52
4.1	Retificação de Superfície de folga dos insertos	52
4.2	Torneamento de liga de aço 4142 com insertos de metal duro com arestas de corte retificadas	60
5	CONCLUSÃO	75
5.1	Contribuições pontuais	76
5.2	Trabalhos Futuros	77
	REFERÊNCIAS	78
	APÊNDICE A – RESULTADOS DE RUGOSIDADE E TESTES DE TUKEY PARA R_a E R_z NA SUPERFÍCIE DE FOLGA DOS INSERTOS	89
	APÊNDICE B – DADOS DO TORNEAMENTO DE LIGAS DE AÇO 4142	92

1 INTRODUÇÃO

Os cermetos, também conhecidos como metais duros, são materiais constituídos essencialmente de carbeto de tungstênio e cobalto de larga aplicação na preparação de ferramentas de usinagem. A alta dureza dos grãos cerâmicos combinada com um ligante metálico dúctil proporciona excelentes propriedades mecânicas a esse material compósito (HEGEMAN; De Hosson; de With, 2001).

A estrutura rígida dos metais duros e a sua propriedade de manter superfícies acabadas em condições com variados parâmetros de processamento permite a sua utilização em diversas aplicações. Ademais, a sua combinação de propriedades mecânicas, tais como alta dureza, resistência mecânica, refratariedade e resistência a deformação compressiva e atrito, permitem que o material compósito seja mais aplicado em ferramentas de corte e usinagem de metais em altas velocidades (BONNY et al., 2009).

De acordo com Jha e Jha (2019), a usinagem com ferramentas de geometria definida não é adequada para estes materiais, de elevada dureza. A dificuldade está na usinagem de formas complexas com a devida acuracidade; sendo assim, a retificação é uma das soluções para a preparação destes materiais.

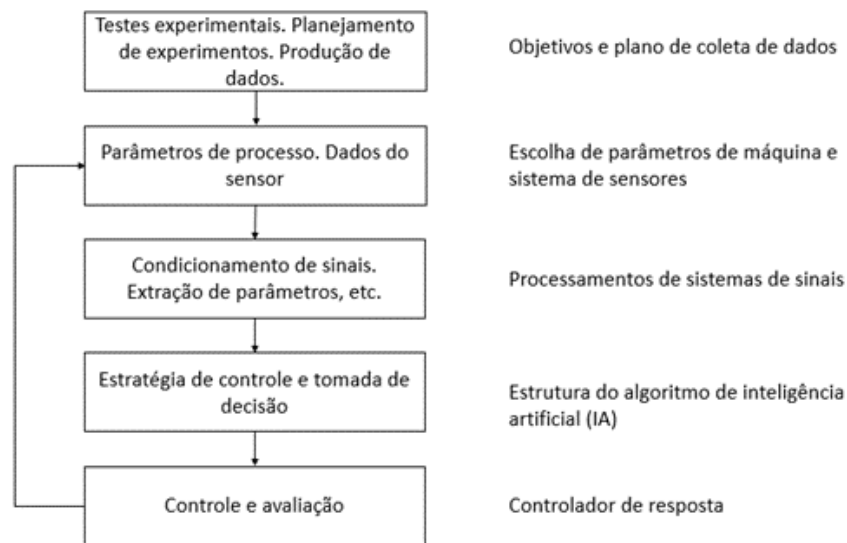
Segundo Pandiyan et al. (2020), os processos de retificação devem seguir rígidas tolerâncias de produção, com monitoramento de variáveis de entrada e saída. Com tais variáveis, é possível garantir qualidade, produtividade, segurança e lucratividade. Nesse sentido, pode-se alcançar a completa automatização quando algoritmos de inteligência artificial são empregados para aprender com o processo. Na Figura 1, podem-se observar todos os elementos necessários para aplicar e otimizar o processo por meio da inteligência artificial (IA) gerando a integração que permite automonitoramento e capacidade de tomada de decisão.

Para tanto, a implementação deve ser iniciada com o plano de coleta de dados e objetivos, com experimentos iniciais do projeto. Após isso, é necessária a escolha dos parâmetros de processo e dos sensores, seguido do processamento dos mesmos. Nas etapas finais, é realizado o esquema algorítmico da IA associando o processo e os softwares, finalizando com o controle ou não do processo; sendo que a falha retorna à implementação a partir da análise dos parâmetros e sensores utilizados.

Segundo Oliveira e Dornfeld (2001) e Prakasam e Subbiah (2013), os métodos de monitoramento usando técnicas limiares em sensores nos processos de usinagem, com identificação dos limites dos sistemas, podem identificar fenômenos simples como a quebra da ferramenta em tempo real. Contudo, isso funciona apenas para quando existe um padrão de funcionamento, em que mudanças drásticas são facilmente notadas.

Porém, tais técnicas falham para um mecanismo complexo com funcionamento não-

Figura 1 – Esquema de construção em blocos da inteligência artificial.



Fonte: adaptado de (PANDIYAN et al., 2020).

linear sem previsibilidade. Para isso, deve-se realizar a decodificação dos dados-padrão dos sensores, com mecanismos de *Machine Learning* (ML) e *Deep Learning* (DL) adequados. Segundo Abellan-Nebot (2010), diversas técnicas de ML, como Redes Neurais (ou ANN do inglês *Artificial Neural Networks*) e inferência *Fuzzy*, estão sendo utilizados para a modelagem e monitoramento dos sistemas de usinagem, principalmente no que se refere aos processos abrasivos.

Processos abrasivos, como a retificação, estão em crescente utilização como operações de acabamento, promovendo elevadas qualidade superficial e precisão geométrica, já que apresentam maiores repetibilidade e acuracidade. Tais processos conseguem atingir qualidade superficial mais refinada. Além disso, processos abrasivos de retificação geram menores tensões internas, zonas termicamente afetadas e cavacos finos são gerados, garantindo que as deformações se concentrem em pequenas regiões determinadas, resultando em maior energia específica para usinar materiais mais resistentes (MACHADO et al., 2015).

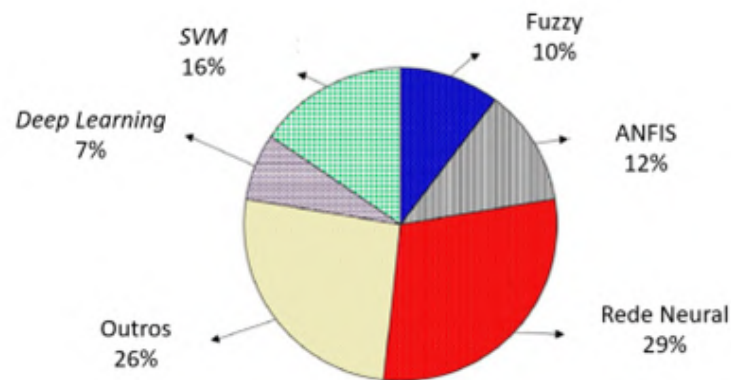
No caso da retificação de metal duro, a remoção de material ocorre por meio da interação de pontas de grãos orientados aleatoriamente com o material do inserto. Isto resulta na remoção de uma fração dos carbetos, sendo que o aumento das componentes da força de usinagem faz com que os grãos se atritem, provocando sua regeneração e afiação. Assim, o processo é majoritariamente estável, sendo que possíveis falhas da aresta de corte não resultam em efeitos significativos, como dito por Inasaki, Tönshoff e Howes (1993).

Correlacionando as variáveis do processo de retificação de metal duro por meio de inteligência artificial, seria possível predeterminar as respostas em termos de força de usinagem e rugosidade do produto, por exemplo. Alexandre et al. (2018) conseguiu prever as condições

topográficas de um rebolo em tempo real usando análise de frequência dominante e sistema Fuzzy. Ademais, a determinação de eventos indesejáveis, como a queima, pôde ser determinada pela associação da inteligência ANN baseada nos dados dos sensores de emissão acústica.

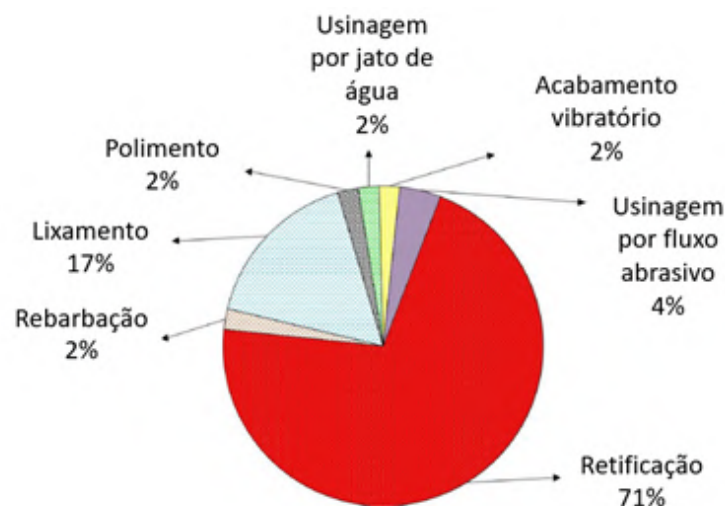
Além de ANN, outros algoritmos vêm sendo utilizados para monitorar os processos abrasivos. Dentre os sistemas mais utilizados destacam-se o sistema de inferência Neuro-Fuzzy (ANFIS), como apresentado na Figura 2. Como pode ser visto na Figura 3, Pandiyan et al. (2020) observou que a imensa maioria dos trabalhos está relacionada, de fato, a processos de retificação que aparecem em número maior do que quaisquer outros processos abrasivos.

Figura 2 – Frequência de utilização de IA para processos abrasivos.



Fonte: adaptado de (PANDIYAN et al., 2020).

Figura 3 – Uso de IA em monitoramento e modelagem de diferentes processos abrasivos.

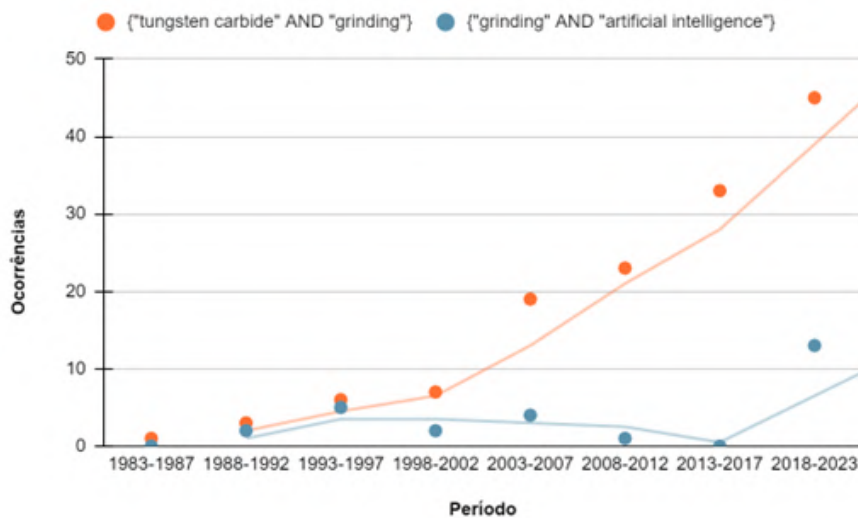


Fonte: adaptado de (PANDIYAN et al., 2020).

A pesquisa referente a esta dissertação de mestrado insere-se em um campo importante, sendo que uma busca na base de dados ScienceDirect utilizando a string {"tungsten carbide" AND "grinding"} no campo "Title, abstract or author-specified keywords" retornou 164 resultados.

Por sua vez, com a string {"grinding"AND "artificial intelligence"}, 27 resultados; porém, com {"tungsten carbide"AND "grinding"AND "artificial intelligence"}, não se obtém qualquer resultado em Junho de 2023. A Figura 4 ilustra um panorama de evolução das publicações com essas strings ao longo dos últimos quarenta anos, em que se vê a tendência crescente da string {"tungsten carbide"AND "grinding"} e uma estagnação da string {"grinding"AND "artificial intelligence"}. As linhas de tendência representam a média móvel.

Figura 4 – Panorama de publicações relacionadas ao tema de pesquisa no ScienceDirect.



Fonte: Elaborado pelo autor.

Realizando a mesma pesquisa na base Scopus, a busca utilizando a string {"tungsten carbide"AND "grinding"} no campo "Title, abstract or author-specified keywords" retornou 722 resultados, e a string {"grinding"AND "artificial intelligence"}, 229 resultados. A Figura 5 apresenta o panorama do Scopus com comportamento semelhante quanto a tendência de publicações da base do ScienceDirect, com as linhas de tendência representando a média móvel.

Em vias de validar o campo de pesquisa estudado, realizando pesquisas em ambas as bases com outros termos similares ou da mesma área de pesquisa, observa-se os mesmos cenários de crescimento do assunto abordado para a base de dados ScienceDirect e Scopus:


(a): Modificando o termo AND por OR, pesquisas relacionadas à retificação ou inteligência artificial possuem tendência de crescimento abaixo aos metais duros e retificação;

(b): Utilizando arquiteturas de IA diferentes em conjunto (uso de termo AND) com a retificação ou com metais duros, nota-se que as análises para os cermetos tem menor tendência a crescimento de pesquisas correlacionadas com IAs do que com retificação;

(c): Elevado crescimento das pesquisas em IAs, com crescimento expoente com relação aos cermetos e a retificação;

Ou seja, existe uma crescente para os estudos que envolvem a retificação conjuntamente

Figura 5 – Panorama de publicações relacionadas ao tema de pesquisa no Scopus.



Fonte: Elaborado pelo autor.

aos cermetos, porém a estagnação, com certa crescente no número de artigos, dos estudos de inteligência artificial com a retificação apresenta-se como um campo a ser estudado. Desta maneira, torna-se interessante ser verificado quanto a viabilidade de uso das IA's no processo de retificação.

Ademais, a retificação também possui papel vital sobre a definição e determinação de aplicação da ferramenta, a qual é utilizada nos processos de usinagem. Em vias disso, um dos estudos para verificar a aplicação dos mesmos ocorreria por meio da análise detalhada sobre a influência da micro geometria da aresta de corte, produzidas a partir da retificação nas ferramentas, sobre a usinagem por torneamento.

O torneamento é um processo de usinagem e um dos fatores responsáveis pela geração de tensões residuais na peça de trabalho. Esse processo é aplicado no processo de fabricação de peças com tempo de vida limitada (LI et al., 2022).

Davim et al. (2008) revisaram as investigações sobre tensões residuais em superfícies usinadas. De acordo com os autores, este tópico tem sido investigado desde os anos 50, desenvolvendo dados de *handbooks* baseados em abordagens experimentais, demonstrando a sua importância. Desde então, têm sido utilizados novos métodos para a previsão de tensões residuais, por exemplo, os métodos de elementos finitos na usinagem e métodos que combinam modelos experimentais, analíticos e numéricos. Estes modelos de previsão forneceram uma abordagem aplicável para aplicações industriais.

Algo a se notar é que Abboud et al. (2016) verificaram que existe um conflito entre a tensão residual e a rugosidade da superfície, observando a variação dos parâmetros com a taxa de avanço. Como Li et al. (2022) concluíram, para o estudo da análise e previsão da tensão residual, é necessário otimizar o método de estabelecimento do modelo de previsão da tensão residual no

torneamento.

Mondelin et al. (2012) propuseram um modelo híbrido para a predição das tensões residuais induzidas no torneamento de acabamento do aço inoxidável martensítico 15-5PH. O modelo híbrido consistiu em uma aplicação de carregamento termomecânico obtido experimentalmente em um modelo numérico, onde foi deslocado para a superfície usinada para registrar o estado de tensão residual no final, aplicando simulação de elementos finitos para proporcionar uma comparação de dados.

Khoshaim et al. (2021) estudaram a aplicação de métodos baseados em IA para a previsão de tensões residuais no torneamento de ferro puro. Utilizaram modelos híbridos de IA para determinar a geração de tensões residuais nas direções circunferencial e radial, buscando uma redução das tensões residuais induzidas. Os resultados indicaram os fatores cinemáticos mais significativos e o melhor cenário para o processo de torneamento.

Desta maneira, o torneamento com ferramentas retificadas torna-se um tópico de estudo complementar para a dissertação, sendo que analisa o impacto indireto da retificação sobre o torneamento, com a preparação da aresta, além da aplicação da inteligência artificial como ferramenta de otimização para a predição dos resultados de qualidade superficial da peça usinada e a tensão residual gerada.

O objetivo geral desta dissertação de mestrado acadêmico consiste em aplicar estratégias de inteligência artificial para otimização de processos que envolvem a retificação de insertos de metais duros, seja o acabamento da superfície de folga ou a preparação das geometrias das arestas de corte. Em outras palavras, verificar os resultados obtidos experimentalmente e comparar com os resultados obtidos por meio do modelo de inteligência artificial, com a função de verificar a capacidade de previsão dos resultados, tornando-se uma ferramenta útil de otimização para a predição. O projeto envolve alguns objetivos específicos:

- Retificar insertos de metal duro seguindo planejamento experimental previamente definido de forma a avaliar a relação entre os fatores de influência e as variáveis de resposta;
- Tornear liga de aço 4142 com insertos de aresta de corte retificados, com a produção de dois chanfros, buscando verificar os fatores de influência sobre a qualidade superficial e tensão residual na peça trabalhada;
- Implementar algoritmo de inteligência artificial, com enfoque nas redes neurais e ANFIS (*Adaptive Network-Based Fuzzy Inference System*), utilizando dados obtidos experimentalmente para ambos os casos anteriores;

As próximas seções desta dissertação contêm a fundamentação teórica, seguido dos materiais e métodos, resultados e discussões, conclusões, além de sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, abordam-se conceitos relacionados a usinagem por retificação com foco na aplicação em metais duros, sobre a relação da preparação de aresta da ferramenta com o torneamento (tensão residual e qualidade superficial) e a inteligência artificial, sendo especificamente a inferência *Fuzzy*, as redes neurais e ANFIS.

A etapa de revisão bibliográfica foi fundamental para garantir o arcabouço teórico tanto sobre a retificação de metais duros e sobre o torneamento com ferramentas de arestas de corte retificadas, quanto sobre algoritmos de otimização baseados em inteligência artificial. Empregaram-se as bases de dados *ScienceDirect*.

2.1 Retificação dos metais duros


A retificação é um processo típico de acabamento superficial, sendo que, com o avanço tecnológico, tornou-se em um processo de desbaste. Além disso, a retificação também é utilizada como operação intermediária, para a geração de superfícies de referência em outros processos, porém usualmente é utilizado como última operação, de acabamento; desta maneira, possibilita a obtenção de tolerâncias estreitas e baixas rugosidades (com R_a entre 0,2 e 1,6 μm), ainda que com baixa capacidade para a remoção de cavaco (CHENG, 2009) (DINIZ; MARCONDES; COPPINI, 2014)

De acordo com Bordinassi (2006), integridade superficial pode ser definida como: “[...] uma medida da qualidade das superfícies usinadas interpretada em função de elementos que descrevem a estrutura da superfície e do substrato do material”. Neste trabalho, a análise da integridade superficial estará restrita aos termos de rugosidade.

Diversos parâmetros de rugosidade podem ser analisados. O parâmetro R_a é o valor médio aritmético para um perfil de linha de referência, por comprimento de amostra analisada, sendo importante para determinar a textura superficial, como visto na Figura 6 (DAGNALL, 1980).


A variável R_z , segundo Machado et al. (2015), é indicada para especificar a máxima rugosidade, sendo que se trata de um parâmetro sensível a possíveis irregularidades na superfície, por considerar a média das cinco alturas máximas detectadas para cada comprimento de amostragem. Cada altura é representada pela diferença do vale mais baixo (Zv_i) com pico mais alto do mesmo trecho Zp_i , como visto na Figura 7.

Figura 6 – Representação da rugosidade R_a .



Fonte: (DAGNALL, 1980).

Figura 7 – Representação da rugosidade R_z .



Fonte: (ISO.4287, 2002)

A Figura 8 apresenta a gama de rugosidades mais e menos frequentes nos processos de retificação e fresamento, sendo destacada a importância para o processamento de retificação.


O rebolo é a ferramenta utilizada nesse processo. O mesmo pode ser definido como um corpo essencialmente cilíndrico, possuindo material aglomerante para reunir muitos grãos abrasivos (quantidade elevada de arestas de corte organizadas aleatoriamente), que realizam o acabamento ao ter contato com o material a ser trabalhado e que penetram sequencialmente na peça, como pode ser visto na Figura 9.

Figura 8 – Variação da rugosidade média R_a .

Processo de fabricação	Rugosidade média R_a (μm)												
	50	25	12,5	6,3	3,2	1,6	0,8	0,4	0,2	0,1	0,05	0,025	0,012
Fresar													
Retificar													

Fonte: (SILVA et al., 2000).

Figura 9 – Princípio do processo abrasivo.



Fonte: adaptado de (PANDIYAN et al., 2020).

A retificação é um método de processamento por deslocamento ou com posição controlada em que o excesso de material é removido pelo uso de uma ferramenta abrasiva. As vantagens deste processo de usinagem quanto a outros incluem melhor acabamento superficial (PAN et al., 2021). Os rebolos costumam ser definidos por: material do grão abrasivo, dureza e estrutura do rebolo, e o tipo de ligante aglomerante (DINIZ; MARCONDES; COPPINI, 2014):

- **Material do grão abrasivo:** Dentre os superabrasivos, temos o nitreto de boro cúbico (CBN) e o diamante policristalino (PCD). Este último possui aplicação em metais duros, na qual os grãos frágeis, irregulares e friáveis são utilizados em metais duros com rebolos com liga resinóide;
- **Dureza:** Trata-se do índice de resistência com que o grão abrasivo permanece retido no material aglutinante. Em maiores coesões, maiores as capacidades de resistir a esforços de retificação que retiram os grãos da ferramenta, e, assim, classifica-se como duro;
- **Estrutura:** Trata-se da concentração volumétrica dos grãos abrasivos do rebolo. Os rebolos de estrutura mais aberta geram acabamentos mais grosseiros que a estrutura fechada;
- **Ligante:** Componente que mantém os grãos abrasivos unidos, sendo que podem ser vitrificadas, resinóides ou metálicas. As resinóides são compostas por resinas orgânicas, em que é uma liga de resistência e resiliência elevada;

Tal processo possui quatro principais diferenças com relação aos processos de usinagem com ferramenta de geometria definida, sendo estas (CHENG, 2009):

- Grãos abrasivos, por estarem posicionados de maneira desordenada e possuírem tamanhos irregulares, fazem com que a ação de corte de cada um dos grãos ocorra de maneira diferente, tornando necessária a análise estatística para o seu estudo;

- A profundidade de usinagem não-deformada de cada grão ou a aresta de corte da retificação é fina, em níveis submicrométricos. Esta característica permite que o processamento tenha elevada acuracidade e baixas rugosidades superficiais; no entanto, isto exige uma energia específica elevada para a remoção do material;
- A velocidade de corte é elevada, sendo dez vezes maior que dos outros processos de usinagem. Isto promove um aumento na taxa de remoção de material, porém apresenta problemas quanto a altas temperaturas de trabalho e a necessidade de resfriamento;
- O rebolo possui ação de regeneração e afiação. O desgaste de um grão individual pode não ter efeito sobre o desempenho da retificação, porém o desgaste aumenta a força aplicada nos grãos, gerando novos e afiadas arestas de corte ou promove a retirada da superfície do rebolo, permitindo que um grão de uma camada inferior participe do processamento. Isto permite que a retificação ocorra em materiais de dureza similares;

No processamento, alguns fatores são importantes para a correta seleção do rebolo. O material da peça a ser usinada influi na escolha do abrasivo, da dureza do rebolo e no tamanho de grão. O volume de material removido influi quanto ao acabamento superficial, sendo que o tamanho de grão (os menores grãos visam a menor remoção de material e melhor acabamento, devido a presença de mais grãos ativos no corte) e o ligante (a resínóide, associada a grande velocidade periférica da ferramenta, promove melhor acabamento) a serem utilizados são determinantes quanto a qualidade superficial (DINIZ; MARCONDES; COPPINI, 2014) (KLOCKE; KUCHLE, 2009).

Os fluidos de corte afetam a dureza do rebolo. Quando refrigerado eficientemente, os rebolos de dureza elevada não são afetados quanto a estrutura superficial da peça; se afetados superficialmente, denomina-se de processo de “queima”. Com a mudança da coloração da região afetada na peça, por exemplo pela formação de interface entre camada de martensita e de martensita revenida, provoca a formação de uma região sujeita a trincas (MACHADO et al., 2015) (DINIZ; MARCONDES; COPPINI, 2014).

Os metais duros, produzidos a partir da metalurgia do pó, possuem como propriedades físicas a excelente combinação de resistência ao desgaste, tenacidade e resistência mecânica. Devido às suas características mecânicas, a retificação é aplicada utilizando-se rebolos de grãos de diamante, para assegurar o custo-benefício da usinagem, além da precisão dimensional e a qualidade superficial necessária (MACHADO et al., 2015) (KOPAC; KRAJNIK, 2006).

Para a realização da produção dos metais duros, realiza-se a moagem dos carbonetos e a secagem por spray, seguido da compressão a frio da mistura em matrizes, com a utilização de ceras lubrificantes (removida durante o tratamento térmico de sinterização, em etapa posterior) para facilitar a secagem. Realizada a prensagem, a mistura no seu formato final segue para o tratamento de sinterização, onde a peça sofre uma redução de tamanho em até 18%. A retificação é aplicada nos metais duro devido à necessidade de afiação do inserto e da adequação aos


padrões dimensionais, uma vez que os tratamentos térmicos aplicados na produção podem causar alterações dimensionais e defeitos superficiais. Para ser comercializado, esta deve ser retificada a fim de confeccionar os raios de ponta e melhoria na precisão dimensional (MACHADO et al., 2015).

Segundo Denkena e Biermann (2014), o tempo de vida da ferramenta é influenciado pelos recobrimentos, tecnologias de preparação de pré-recobrimento, material e a macrogeometria. As cargas mecânicas e térmicas também determinam a propagação do desgaste da aresta de corte, sendo dependentes das microgeometrias. Desta maneira, a geometria e a qualidade superficial influenciam na resistência da ferramenta ao desgaste, o atrito envolvido no processamento, a possibilidade de falhas estruturais (tais como a geração de trincas).

Diversos fatores podem influenciar no desempenho da retificação e na qualidade superficial gerada na peça. O aumento do avanço ou da penetração de trabalho promovem o aumento da força de corte na retificação, resultando em cavacos de maior espessura e aumento na cinemática de corte das arestas. Isso ocorre devido ao fato de aumentar a área de secção do cavaco, provocando um aumento na carga aplicada sobre cada grão do rebolo, gerando o aumento das forças (GÜHRING, 1967) (KLOCKE; KUCHLE, 2009).

O desgaste do rebolo dependerá da quantidade de material removida da peça. Em pequenas taxas de remoção, microdesgastes se formam devido às altas tensões mecânicas e energia térmica específica, provocando o amaciamento da ponta do grão de corte. Isso pode gerar a superfícies lisas nos grãos, reduzindo a capacidade de corte. Na Figura 10 pode-se observar a completa quebra do grão quando a taxa de remoção se torna elevada, devido ao surgimento de macrodesgastes (KLOCKE; KUCHLE, 2009).

Figura 10 – Esquema representativo de micro e macro desgaste na ferramenta.



Fonte: adaptado de (KLOCKE; KUCHLE, 2009).

Alterações nas qualidades geométricas ocorrem na retificação primordialmente devido a elevadas forças de corte e desgaste do rebolo, que varia dependendo do mecanismo. A acuracidade

de perfil é afetada por possíveis erros no arredondamento de aresta, de desgastes e de forças de corte. Desta maneira, torna-se importante a análise dos parâmetros responsáveis por alterações nos resultados, além das interdependências entre eles (KLOCKE; KUCHLE, 2009).

A rugosidade, fator importante na determinação da qualidade superficial, é afetada devido a fatores ligados a formação do cavaco. O aumento na penetração de trabalho ou do avanço, afetam o acabamento superficial, devido ao aumento da espessura dos cavacos gerados e a maior taxa de remoção de material (KLOCKE; KUCHLE, 2009).

Outro fator importante é a velocidade de corte. Variados fatores são afetados por esse parâmetro, influenciando as forças de corte, a qualidade superficial e o desgaste. Usualmente, o aumento na velocidade de corte promove efeitos positivos sobre o processamento, porém o aumento excessivo (normalmente utilizado em métodos de alto desempenho) pode gerar maiores tensões térmicas e necessidade de medidas de segurança (KLOCKE; KUCHLE, 2009).

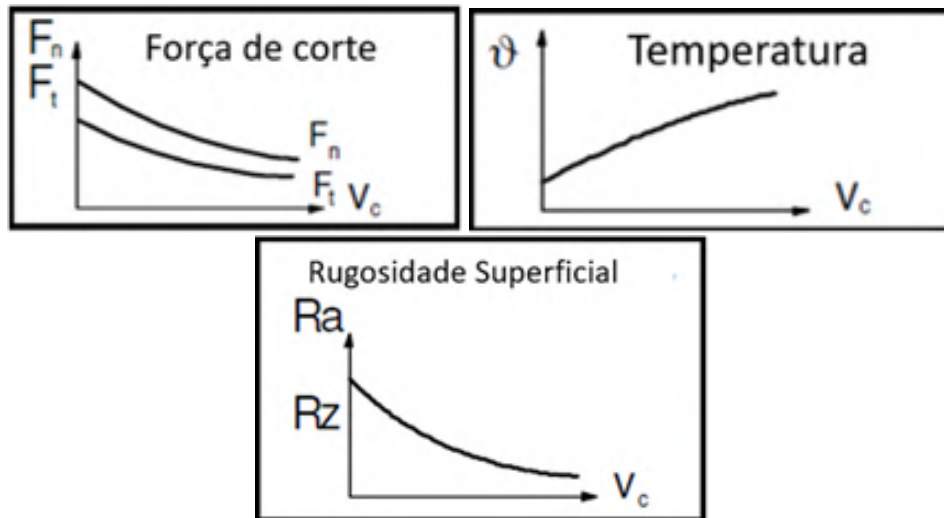
Maiores valores de velocidade de corte geram menores desgastes radiais e de aresta. Devido à redução da área seccional do cavaco, menores tensões mecânicas são geradas. Quanto menor for o tempo e a frequência de contato, menores serão as pressões de contato e durações de aplicações, aumentando o tempo de vida da ferramenta. Em alguns casos, o desgaste do rebolo pode aumentar devido à alta tensão térmica quando determinada velocidade é excedida, ocorrendo em ferramentas ligadas com resina sintética (KÖNIG; WERNER; YOUNIS, 1971) (KLOCKE; KUCHLE, 2009).

Caso o aumento da velocidade seja realizado mantendo uma taxa constante de remoção de material, as forças de corte são reduzidas, menores erros conformativos da geometria de corte e menores valores de rugosidade. No entanto, caso a remoção seja variável, ocorre aumento nas forças e na energia térmica da peça, como visto na Figura 11. Observa-se a importante influência deste parâmetro para critérios de acabamento superficial (SPENCER, 1970) (KLOCKE; KUCHLE, 2009).

A remoção de material também possui interdependência com as forças e com as rugosidades médias. Em situações quase estacionárias, em que a rugosidade superficial efetiva do rebolo é maior que o esperado, ocorre a redução da rugosidade até um estado estacionário com aumento da remoção devido ao desgaste dos grãos do rebolo que aumenta o número de arestas de corte, gerando melhores acabamentos superficiais. O oposto ocorre com as forças, de maneira que as mesmas aumentem até atingir o mesmo estado estacionário (KLOCKE; KUCHLE, 2009).

De maneira a sintetizar e abordar as variáveis de maior relevância para o estudo em questão, o resultado da pesquisa com os termos “grinding” AND “carbide” AND “surface integrity” para os anos de 2001 a 2024 no ScienceDirect está organizado em função das variáveis de entrada e saída, conforme apresentado nas Tabelas 1 e 2, respectivamente. Como pode ser observado na Tabela 1, variáveis cinemáticas, como a velocidade de corte e avanço, possuem importância para o processo de retificação, além da penetração de trabalho sendo amplamente

Figura 11 – Efeito da velocidade de corte no processamento.



Fonte: adaptado de (KLOCKE; KUCHLE, 2009).

investigadas. Quanto às variáveis de saída na Tabela 2, observa-se a análise crítica de fatores relacionadas a integridade superficial e de valores de força. Ademais, nota-se a existência de pesquisas relacionadas com a inteligência artificial. Em vias de verificar artigos que não foram abordados pelos termos, também analisou-se os trabalhos comentados em artigo de revisão elaborado por Zeng et al. (2023) sobre os últimos desenvolvimentos tecnológicos envolvendo a retificação, nos últimos cinco anos.

Tabela 1 – Variáveis de entrada mais importantes dos artigos.

Artigos \ Variáveis de Entrada	Velocidade de corte	Velocidade de avanço do rebolo	Penetração de trabalho	Avanço	Granulometria	IA
(AGARWAL; RAO, 2010)	X		X	X		
(AGARWAL, 2016)			X	X	X	X
(GOPAL; RAO, 2003)					X	X
(LI et al., 2019)			X	X		
(MARTÍNEZ et al., 2003)	X					
(QU et al., 2019)			X			
(ROY; BHATTACHARYYA; BANERJEE, 2007)	X					
(SINHA et al., 2016)	X		X			
(STEPHENSON et al., 2001)		X	X	X		
(STEPHENSON; HEDGE; CORBETT, 2002)		X				
(VENTURA et al., 2021)	X		X	X	X	
(XU; SHEN; SHIH, 2006)		X		X		
(ZHANG et al., 2022)		X	X	X		
(ZHANG et al., 2022)	X	X	X		X	X
(WEI et al., 2022)		X	X	X	X	
(WEI et al., 2022)		X	X	X	X	
(XIONG et al., 2021)		X				
(MONIER et al., 2022)	X		X	X		
(MAENG et al., 2020)			X	X		
(SAHATA, 2022)	X			X		
(ZHANG et al., 2023)	X		X		X	
(GAO et al., 2024)			X			
(WANG et al., 2024)					X	
(YIN et al., 2023)		X	X	X		
(PAKNEJAD et al., 2024)	X		X		X	
(GUO et al., 2023)	X					
(CHENG et al., 2023)	X					
(CHENG et al., 2024)	X		X	X		

Tabela 2 – Variáveis de saída mais importantes dos artigos.

Artigos \ Variáveis de Saída	Variáveis de Força	Parâmetros de Superfície	Rugosidade
(AGARWAL; RAO, 2010)	X		X
(AGARWAL; RAO, 2013)	X		X
(AGARWAL, 2016)			X
(BONNY et al., 2009)			X
(CASAS et al., 2004)			X
(CASAS; TORRES; LLANES, 2006)			X
(DELGADO et al., 2013)		X	
(FANG et al., 2019)		X	X
(GOPAL; RAO, 2003)	X		X
(GUAN; ZHAO, 2022)			X
(LI et al., 2019)	X		
(LLANES et al., 2001)			X
(NOVOVIC et al., 2016)		X	
(QU et al., 2019)	X	X	
(ROY; BHATTACHARYYA; BANERJEE, 2007)			X
(SINHA et al., 2016)	X		
(STEPHENSON et al., 2001)			X
(STEPHENSON; HEDGE; CORBETT, 2002)			X
(VENTURA et al., 2021)			X
(WU; ZHANG; YANG, 2021)	X		
(XU; SHEN; SHIH, 2006)	X		X
(YANG et al., 2014)			X
(ZHANG et al., 2022)	X		X
(ZHANG et al., 2022)	X		
(XIONG et al., 2021)	X		
(MONIER et al., 2022)		X	
(MAENG et al., 2020)	X		X
(WU et al., 2019)	X		
(SAIATA, 2022)	X	X	
(ZHANG et al., 2023)		X	
(GAO et al., 2024)	X	X	
(WANG et al., 2024)	X		X
(YIN et al., 2023)	X		X
(PAKNEJAD et al., 2024)	X		X
(GUO et al., 2023)		X	
(CHENG et al., 2023)	X		X
(CHENG et al., 2024)	X		X

2.2 Preparação de geometria da aresta por retificação e o torneamento

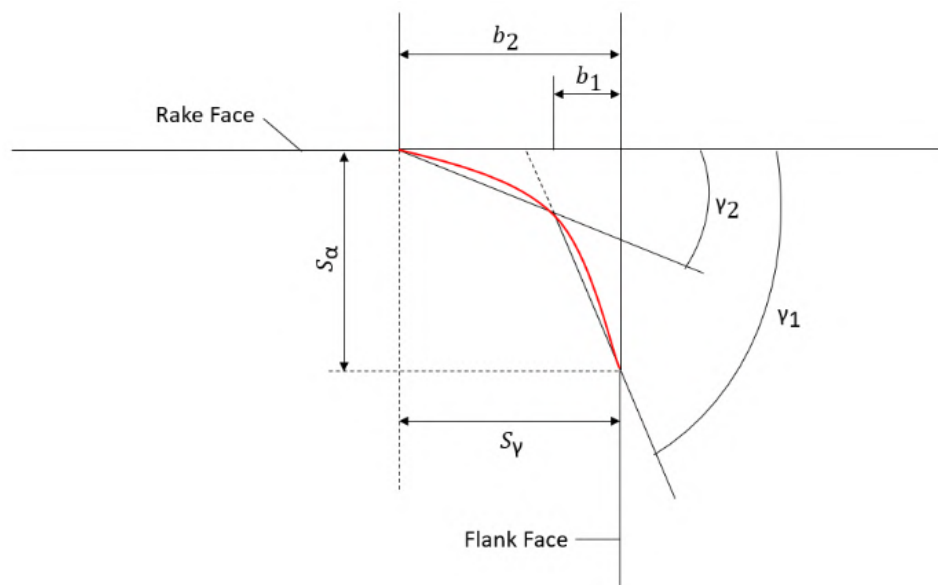
A retificação possui papel importante na preparação da micro geometria das ferramentas a serem utilizadas na usinagem, especialmente as arestas de corte. A geometria possui influência sobre o tempo de vida, afetando a integridade superficial da peça de trabalho, com modificações

na rugosidade e mudanças microestruturais, incluindo a tensão residual (BROWN; SCHOOP, 2020).

A micro geometria da aresta foi objeto de estudo extenso de Denkena e Biermann (2014). Para os autores, a preparação da aresta de corte aprimora a estabilidade de corte, com maior resistência ao desgaste, aumentando a resistência mecânica da ferramenta. Sabendo disto, Byrne, Dornfeld e Denkena (2003) propuseram uma descrição adequada da aresta para a micro geometria. Introduziram quatro novos parâmetros de caracterização: Δr (*profile flattening*), φ (*apex angle*), $S\gamma$ e $S\alpha$.

Os parâmetros $S\gamma$ e $S\alpha$ foram definidos pela distância entre o ponto de intersecção das tangentes da superfície de folga e de saída, além do ponto de separação das respectivas tangentes do perfil da aresta de corte. A razão entre $S\gamma$ e $S\alpha$, denominado de fator de forma K , determina a tendência da aresta para a folga ($K < 1$) ou para a saída ($K > 1$). A Figura 12 apresenta um esquema identificando os parâmetros micro geométricos da aresta.

Figura 12 – Representação dos parâmetros da micro geometria.



Fonte: Elaborado pelo autor.

Maiores forças foram obtidas por maiores valores de $S\alpha$, já que o comprimento de contato foi aumentado (VENTURA et al., 2017). O parâmetro $S\alpha$ demonstrou influencia primordial sobre as cargas térmicas na ferramenta de corte. O aumento da área de contato e maiores atritos na superfície de folga promoveram maiores forças (DENKENA; LUCAS; BASSETT, 2011).

De acordo com Brown e Schoop (2020), o raio de ponta também possui influência na integridade da superfície. Para um determinado avanço, a diminuição do raio de ponta aumentaria a rugosidade; por outro lado, em avanços baixos, os raios de ponta maiores pioravam a qualidade superficial.

Benlahmidi et al. (2017) observou aspectos que envolviam o avanço na usinagem de aço

AISI H11 endurecido. Os resultados demonstraram que, com a redução da taxa de avanço, a rugosidade superficial seguiu o mesmo comportamento. Ademais, arestas mais afiadas podiam produzir maiores rugosidades na peça de trabalho, detalhado por Denkena, Lucas e Bassett (2011).

Meyer, Köhler e Denkena (2012) e Sharman, Hughes e Ridgway (2015) investigaram os efeitos do raio de ponta no torneamento de Inconel 718TM e descobriram que o aumento da força passiva enquanto o raio de ponta aumentava, devido ao aumento da interação entre a superfície de folga e a peça de trabalho, conjuntamente com a redução do ângulo de folga e aumento do arredondamento de geometria, promovendo maiores atritos e geração de calor. As forças de corte também foram afetadas; no entanto, o força de avanço não foi afetada na mesma intensidade que os outros.

Já quanto às tensões residuais, Liu, Takagi e Tsukuda (2004) estudaram a variação da tensão residual circunferencial para diferentes raios de ponta. Menores raios de ponta promoveram maiores tensões compressivas sub superficiais devido a menor fricções, maiores forças e maiores temperaturas. Para Dahlman, Gunnberg e Jacobson (2004), maiores taxas de avanço aumentaram a tensão compressiva para o torneamento de aço AISI 52100.

Menores forças afetaram o aumento da tensão residual na peça de trabalho. Ventura, Breidenstein e Denkena (2018) estudaram a tensão residual produzida por geometria de três chanfros com cinco diferentes micro geometrias e observaram que o aumento na força de corte provocava o aumento na tensão compressiva subsuperficial, o que promove maior tempo de vida da ferramenta e resistência à fadiga. A força passiva foi o principal responsável pela variação, o que ocorreu devido a diferentes comprimentos de contato entre ferramenta e peça de trabalho, modificando a deformação dos cavacos e a energia de atrito. Concluíram sobre a relação direta nas forças de corte, comprimento de contato e tensão residual, afetado por cargas mecânicas presentes na peça.

2.3 Inteligência Artificial

Segundo Norvig e Russell (2014), as seis disciplinas que compõem parte da inteligência artificial seriam:

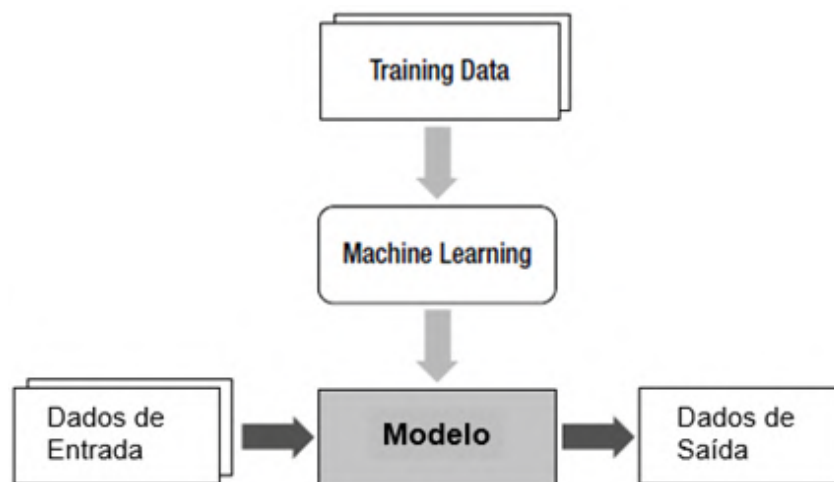
- Processamento de linguagem natural: permite a comunicação com sucesso em idioma natural;
- Representação de conhecimento: armazenamento das informações;
- Raciocínio automatizado: Uso das informações armazenadas para responder questões e elaborar novas conclusões;
- Aprendizado de máquina: adaptação a novas circunstâncias, detecção e extrapolação de novos padrões;

- Visão computacional: percepção de objetos;
- Robótica: manipulação e movimentação de objetos;

Estas seis capacidades fazem parte do teste de Turing (proposto por Alan Turing em 1950), criado para fornecer a definição operacional satisfatória de inteligência (NORVIG; RUSSELL, 2014).

A inteligência artificial está relacionada com o *Machine Learning*. Trata-se de um grupo específico de tecnologias de IA, sendo uma técnica de modelamento dos dados recebidos (também denominados de *training data*). A capacidade do *Machine Learning* é útil para os problemas que envolvem a inteligência artificial. A Figura 13 demonstra a maneira como ocorre a geração do modelo, em que o fluxograma horizontal apresenta o processo de treinamento enquanto o horizontal apresenta o modelo definido (KIM, 2017).

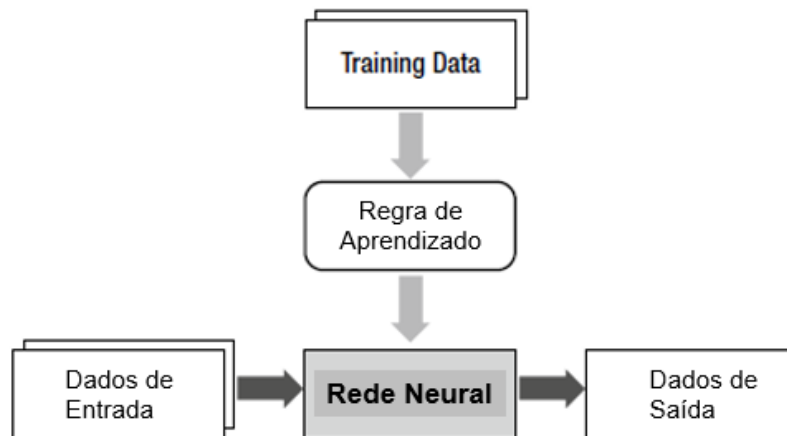
Figura 13 – Modelo aplicado aos dados.



Fonte: adaptado de (KIM, 2017).

Existem três técnicas do *Machine Learning*, sendo: *Supervised Learning*, *Unsupervised Learning* e *Reinforcement Learning*. O *Supervised Learning* é similar ao aprendizado humano, sendo que cada conjunto de dados de treinamento deve consistir em dados de entrada e seus corretos valores de saída. Estes valores corretos são os quais o modelo deve produzir para determinada entrada. A IA utiliza-se do *Machine Learning* para o desenvolvimento de soluções dos problemas, possuindo a maneira de aplicação similares. Como exemplo, as redes neurais artificiais podem ser definidas a partir do fluxograma da Figura 14 (KIM, 2017).

Desta maneira, esta importante ferramenta é aplicada para solucionar o problema de predição da rugosidade superficial a partir de diversas ferramentas de IA, dentre elas: *Artificial Neural Network* (ANNs), *Fuzzy Expert Systems* (FES) e suas derivações. As aplicações destes sistemas são viáveis para solucionar tais situações de previsão da qualidade superficial, por meio de simplificação dos métodos tradicionais (PAN et al., 2021).

Figura 14 – Relação entre rede neural e *Machine Learning*.

Fonte: adaptado de (KIM, 2017).

2.3.1 Teoria dos conjuntos *FUZZY* E ANFIS

A teoria dos conjuntos de *Fuzzy* e lógica *Fuzzy* tratam de situações nas quais as incertezas surgem quando os contornos das classes dos objetos não são bem definidos. Os conceitos teóricos e práticos de *Fuzzy* são aplicados para a produção de sistemas capazes de reproduzir o raciocínio humano automaticamente, sendo necessário o estudo matemático básico desta teoria (NGUYEN; WALKER; WALKER, 2018).

A teoria foi elaborada por Zadeh (1965) com finalidade de obter ferramental matemático para tratamento de informações imprecisas. *Fuzzy* foi determinado por meio de conceitos estabelecidos na lógica clássica, com operadores semelhantes aos tradicionais e outros introduzidos com o tempo, de caráter prático. A teoria clássica prediz que, como exemplo, “dado um conjunto A em universo X, os elementos deste universo simplesmente pertencem ou não pertencem àquele conjunto”; pode ser representada pela Equação 1 (TANSCHKEIT, 2004):

$$f_A(x) = \begin{cases} 1 & \text{se e somente se } x \in A \\ 0 & \text{se e somente se } x \notin A \end{cases} \quad (1)$$

Zadeh elaborou a função de modo que pudesse assumir infinitos valores no intervalo [0,1]. O conjunto *Fuzzy* A em universo X é definido por uma função de pertinência em que $\mu_A(x) : X \rightarrow [0, 1]$, representado por: $A = \{\mu_A(x)/x \mid x \in X\}$; sendo que $\mu_A(x)$ indica o grau de pertinência, determinando o quanto x é compatível com o conjunto A. Para conjuntos *Fuzzy*, por não seguirem a lógica Booleana, determinado elemento por pertencer a mais de um conjunto *Fuzzy*, com diferentes graus de pertinência (ZADEH, 1965).

Zadeh (1965) propôs as seguintes definições e operações que envolvem a lógica *Fuzzy* (SOUZA; MESQUITA, 2010) (ZADEH, 1965):

- Definição 1: Considerando U o universo de discurso e F o subconjunto *Fuzzy* de U, a

função pré-fixada dada pela Equação 2:

$$\mu_F(x) \rightarrow [0, 1] \quad (2)$$

Trata-se da função de pertinência do subconjunto Fuzzy F (também denominados de subconjunto *crisp*), sendo que valores iguais a 1 indicam a pertinência completa ao conjunto F (U), sendo este o conjunto de todos os subconjuntos *Fuzzy* de U.

- Definição 2: Sejam os subconjuntos *Fuzzy* A e B de U, a união, a intersecção e o complementos são funções dadas pelas Equações 3, 4 e 5:

$$\mu_{(A \cup B)}(x) = \max\{\mu_A(x), \mu_B(x)\}, \forall x \in U \quad (3)$$

$$\mu_{(A \cap B)}(x) = \min\{\mu_A(x), \mu_B(x)\}, \forall x \in U \quad (4)$$

$$\mu_{(A)}(x) = 1\mu_A(x), \forall x \in U \quad (5)$$

- Definição 3: O subconjunto clássico de U em que $\text{supp}_F = \{x \in U : \mu_F(x) > 0\}$ é denominado de suporte F, possuindo grau de importância maior do que zero. Esta definição é importante para correlacionar a teoria dos conjuntos clássicos com a Fuzzy.
- Definição 4: Seja A um subconjunto Fuzzy de U e $\alpha \in [0, 1]$. O α -nível de A é o subconjunto clássico de U definido por $[A]^\alpha = \{x \in U : \mu > \alpha\}$, se $0 < \alpha < 1$. O nível zero de um subconjunto *Fuzzy* de A é definido como sendo o menor subconjunto fechado de U que contém o conjunto suporte de A.
- O subconjunto *Fuzzy* A é chamado de número *Fuzzy* quando:
 1. Todos os α -níveis de A são não-vazios, com $\{0 \leq \alpha \leq 1\}$;
 2. Todos os α -níveis são intervalos fechados de R ;
 3. $\text{supp}_F = \{x \in U : \mu_F(x) > 0\}$ é limitado;

Os números *Fuzzy* podem possuir característica quanto a sua função de pertinência triangular, trapezoidal e em forma de sino;

- Definição 6: A relação *Fuzzy* R é definida pela função de pertinência $\mu_R : U_1 \times U_2 \times \dots \times U_n \rightarrow [0, 1]$, onde U_n é qualquer subconjunto *Fuzzy*. Desta maneira, apresenta o grau em que os elementos de x estão relacionados segundo a relação R.
- Definição 7: O produto cartesiano *Fuzzy* é uma função de pertinência dado pela Equação 6.

$$\mu_{(A_1 \times A_2 \times \dots \times A_n)}(x_1, x_2, \dots, x_n) = \mu_{(A_1)}(x_1) \wedge \mu_{(A_2)}(x_2) \wedge \dots \wedge \mu_{(A_n)}(x_n) \quad (6)$$

Em que A_n representa os subconjuntos de U , além de \wedge representar o mínimo. Esta função é pertinente para designar e correlacionar dois subconjuntos distintos, mas que possuem resultados que podem ser obtidos a partir de ambos, tal como a temperatura de certo elemento.

- Definição 8: Considerando a composição de relações, existe a composição max-min. Seja R e S duas relações *Fuzzy* binárias, em universos $U \times V$ e $V \times W$, a composição $R \circ S$ é relação *Fuzzy* binária em $U \times W$, com função de pertinência dado por:

$$\mu_{R \circ S}(x, z) = \sup_{y \in V} [\min(\mu_R(x, y), \mu_S(y, z))] \quad (7)$$

A composição max-min é obtido por meio de multiplicação de matrizes, substituindo o produto pelo mínimo e a soma pelo máximo. Destas afirmações, obtêm-se a regra de composição de inferência.

- Definição 9: a regra de composição de inferência considera dois conjuntos em universos U e V , sendo $F(U)$ e $F(V)$ as classes dos subconjuntos *Fuzzy* de U e V , e R a relação binária de $U \times V$. R definirá um funcional na qual cada elemento de $S \in F(U)$ corresponde ao elemento $B \in F(V)$, com função de pertinência dado por:

$$\mu_B = \mu_{R \circ S}(y) = \sup_{x \in U} [\min(\mu_R(x, y), \mu_S(x))] \quad (8)$$

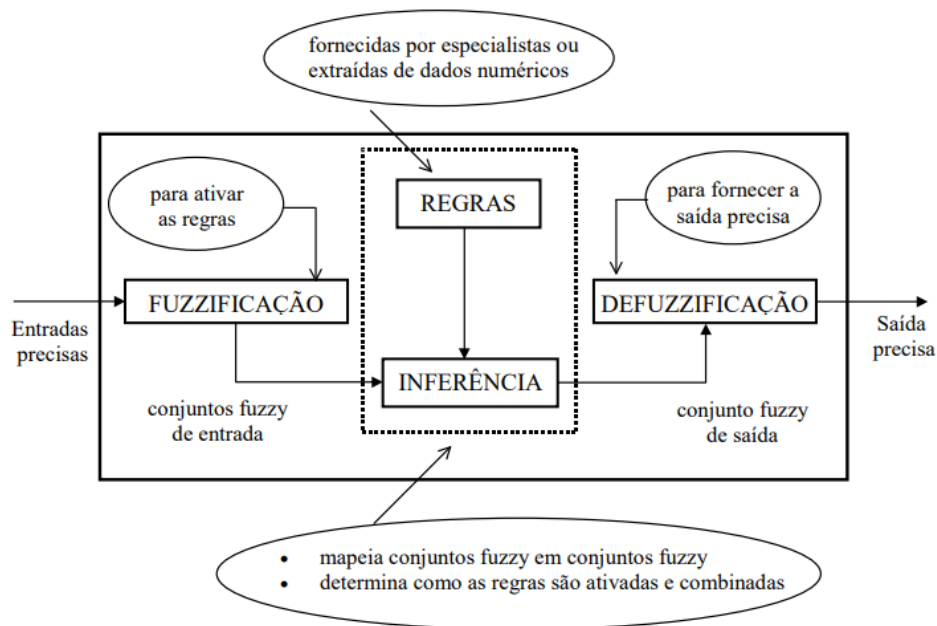
- Definição 10: Para a obtenção de conclusões de premissas incertas, utiliza-se o raciocínio aproximado, baseado principalmente em variáveis linguísticas. Variável linguística são variáveis pertencentes aos subconjuntos *Fuzzy* de U . A variável linguística é um substantivo, com valores sendo adjetivos representados por *Fuzzy*, que apresenta o quanto x está em concordância com o conjunto total de *Fuzzy*. A exemplo, “temperatura” é uma variável linguística que pode assumir valores de “frio” ou “quente”.

Uma maneira da utilização de conjuntos *Fuzzy* para desenvolver os processos mecânicos e promover o controle destes, promove-se a utilização de sistemas e controladores *Fuzzy*, buscando aplicar o método de inferência. Na Figura 15 é possível observar o processo de utilização do método de inferência (TANSCHKEIT, 2004).

As medidas não-*Fuzzy* são consideradas como entradas precisas no sistema, sendo desenvolvidas por medições ou conjunto de dados, que são direcionados aos conjuntos *Fuzzy* de entrada, realizando a *fuzzyficação* dos dados. O módulo de *fuzzificação* consiste em uma etapa em que as entradas são modeladas a partir de conjuntos *Fuzzy* com seus respectivos domínios, e com suas funções características (SOUZA; MESQUITA, 2010).

Após esta etapa, ocorre a ativação de regras, fornecidas por especialistas em sentenças linguísticas da forma causa e consequência, sendo parte do núcleo do controlador *Fuzzy*. As

Figura 15 – Esquema de inferência Fuzzy.



Fonte: (TANSCHKEIT, 2004).

variáveis e classificações linguísticas são catalogadas e modeladas por conjuntos *Fuzzy* ou em funções de pertinência, que podem ser obtidas por apelos intuitivos, interpolações ou redes neurais, tornando a geração automática de regras (TANSCHKEIT, 2004).

A inferência traduz em valores as proposições *Fuzzy*, ocorrendo as principais operações do núcleo. Após isto, aplica-se a *defuzzificação*, como uma interpretação das informações, obtendo-se saídas precisas. Os métodos de *defuzzificação* incluem o centro de gravidade e a média dos máximos (SOUZA; MESQUITA, 2010) (TANSCHKEIT, 2004).

O centro de gravidade estabelece a saída a partir dos valores do universo que dividem a área sob a curva de pertinência em duas partes iguais. Já a média dos máximos define como a média entre os dois elementos extremos do universo, correspondendo aos maiores valores da função de pertinência (SOUZA; MESQUITA, 2010) (TANSCHKEIT, 2004).

Alguns pesquisadores utilizaram a lógica *Fuzzy* com a rede neural, aplicando o sistema de inferência *Fuzzy* adaptado a rede neural (ANFIS, Adaptive Network-Based Fuzzy Inference System), com alta habilidade de auto-aprendizado. Neste modelo, a ANN é utilizada para determinar os diversos parâmetros dos sistemas *Fuzzy*, permitindo a criação ou a melhoria automática do modelo de inferência (AGRAWAL; YADAVA, 2013) (HORIKAWA; FURUHASHI; UCHIKAWA, 1992).

O ANFIS, segundo Jang (1993), possui arquitetura de cinco camadas de redes neurais associadas a lógica *Fuzzy*. De acordo com Zhang et al. (2023), o ANFIS é conhecido como um dos métodos de *Machine Learning* mais eficazes para a modelagem de problemas complexos de

regressão. As configurações do modelo ANFIS são importantes, sendo a quantidade de regras *Se-Então* um ponto crítico do algoritmo, as quais são relacionadas ao número de variáveis de entrada (2^k , sendo k o número de variáveis de entrada).

Em vias de organizar as regras, os dados de entrada e saída são divididos em diferentes categorias por métodos de clusterização, sendo que estes podem ser: *grid partitioning (GP)*, *subtractive clustering (SC)* e *fuzzy c-means (FCM)*. O *grid partitioning* é um dos métodos mais comuns para situações em que o número de variáveis de entrada é limitado. Neste sistema, os dados de entrada são divididos em sub-espacos retangulares com processo de particionamento para formar a base das áreas *Fuzzy* utilizando funções de pertinência. Para cada um dos sub-espacos, uma função de pertinência é associado. O número de regras para cada dado de entrada a um determinado intervalo, dependendo da quantidade de pontos de dados.

2.3.2 Redes Neurais

As ANNs, também denominadas de Redes Neurais Artificiais, podem ser classificadas como um sistema que realize a simulação do funcionamento do cérebro humano. As redes neurais priorizam o processo de aprendizagem por meio da experiência; ou seja, gera-se sistemas inteligentes capazes de realizar classificações, reconhecer padrões, processar imagens, além do processamento e previsão de resultados (GONÇALVES, 2009).

McCulloch, Pitts e McCulloch (2016) desenvolveram um modelo de neurônio artificial, como apresentado na Figura 16, denominado de rede “Perceptron”. Neste modelo, os sinais de entrada e saída assumem valores binários, sendo que os neurônios podem assumir a Equação 9.

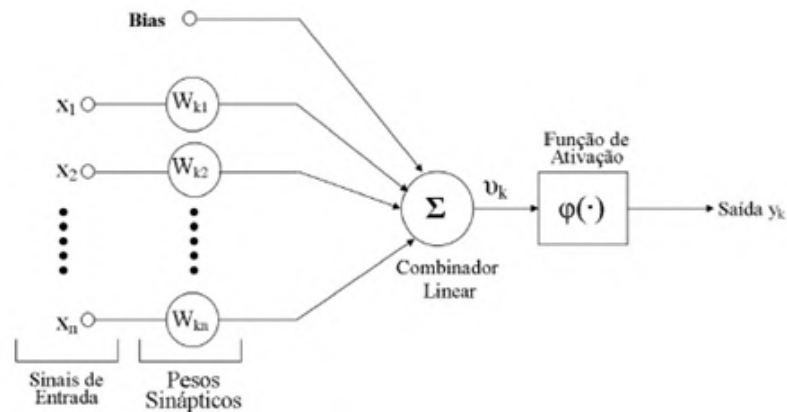
$$\mu_k = \sum_{j=1}^m w_{kj} * x_j \quad (9)$$

Sendo que m é o número de sinais de entrada que agem no neurônio k e ativados pela função $\phi(u_k)$.

Este modelo inicial de rede neural era capaz de computar funções lógicas e aritméticas, sendo a Bias a responsável por ajustar os pesos e os dados, de maneira a agir como uma constante para desenvolvimento do sistema, como visto na Figura 16 (MCCULLOCH; PITTS; MCCULLOCH, 2016).

A rede neural usual é composta por conjunto de neurônios interligados, em que cada participante do sistema influencia no outro, gerando um sistema capaz de armazenar informações adquiridos por dados brutos e realizar novas inferências. Segundo Kim (2017), as redes neurais imitam o mecanismo do cérebro. Tal como o cérebro é composto por conexões de diversos neurônios, as ANNs são construídas por conexões dos *nós* (tradução livre de *nodes*), além de simular a conexão dos neurônios por meio dos pesos ajustados para a tomada de decisões corretas em novas situações, por meio do algoritmo de aprendizagem (GONÇALVES, 2009).


Figura 16 – Modelo de neurônio artificial *Perceptron*.



Fonte: (MCCULLOCH; PITTS; MCCULLOCH, 2016).

As ANNs possuem uma diversidade de maneiras para serem construídas. A mais comum utilizada aplica estruturas em camadas de nós, tal como pode ser visto na Figura 17. A primeira camada, denominada de *Camada de Entrada* e representada por quadrados, atua como transmissor dos sinais dos dados de entrada para os próximos nós, não possuindo a função de ativação e o *Bias*. A *Camada de Saída* representa os resultados da rede neural, além de estar presente as *Camadas Ocultas*, denominadas desta maneira por não serem acessíveis fora da rede neural

Figura 17 – Camada estruturada de nós.



Fonte: adaptado de (KIM, 2017).

As redes neurais se iniciaram a partir das *Single Layer Neural Networks*, compostas por arquitetura simplificada com apenas as camadas de entrada e de saída. Com a adição das camadas ocultas, criou-se as *Multi-layer Neural Networks*, sendo que as que continham apenas uma camada oculta eram denominadas de *Shallow Neural Network/Vanilla Neural Network* e quando possuíam duas ou mais camadas ocultas, *Deep Neural Network*. A Tabela 3 apresenta resumidamente cada uma das arquiteturas de rede (KIM, 2017).

Existem quatro características importantes para a utilização de ANNs, sendo elas (PAN et al., 2021):

Tabela 3 – Arquitetura de Redes Neurais.

Rede Neural de Camada Única		Camada de Entrada - Camada de Saída
Rede Neural de Múltiplas Camadas	Shallow Neural Network	Camada de Entrada - Camada Oculta - Camada de Saída
	Deep Neural Network	Camada de Entrada - Camadas Ocultas - Camada de Saída

Fonte: adaptado de (KIM, 2017).

- Estrutura: Trata-se de um modelo estrutural, com diversos neurônios artificiais interconectados, com a saída de um neurônio conectado a entrada de outro, com pesos adequados aplicados;
- Habilidade de auto adaptação e auto-aprendizado: Os modelos de ANNs definem conexões internas entre as entradas e saídas por treinamento com os dados brutos, sem depender de conhecimentos prévios e de regras para o desenvolvimento do aprendizado, além de adaptabilidade as situações;
- Os modelos de ANNs processam dados novos e obter regras a partir deles. Ademais, podem gerar previsões precisas em dados incertos e com erros de medições;
- Não-linearidade: ANNs alcançam mapeamentos não-lineares entre variáveis múltiplas;


Estas características são importantes para a sua utilização na determinação da aplicabilidade na predição de rugosidades superficiais. Nestas situações, as redes neurais, a partir de dados de entrada, como parâmetros de processo, ajustam os pesos e a *Bias* e desenvolvem o treinamento do sistema para obter valores de predição da rugosidade superficial (PAN et al., 2021).

O fluxo dos dados no modelo de ANN possui variações de acordo com o sistema escolhido. No processo denominado de *feed-forward*, o dado de entrada da rede neural atravessa a camada de entrada, oculta e de saída; enquanto isso, no algoritmo do *Back-propagation algorithm*, o fluxo se inicia na camada de saída e se desloca até a camada de entrada, realizando o caminho reverso, porém o sinal ainda propaga através das linhas de conexões, com a multiplicação dos pesos. Todo o processo que envolve o treinamento e o fluxo dos dados está representado na Figura 18 (GUPTA et al., 2019) (KIM, 2017).

As redes neurais necessitam de um processo de validação. Este é feito de forma a evitar o processo de *overfitting*, situação em que o modelo gerado possui baixa generalização devido a possíveis ruídos. A validação é feita reservando parte dos dados de treinamento e utilizando para monitorar a performance, sendo que os dados não são utilizados durante o treinamento. A Figura 19 representa a validação (KIM, 2017).


Ademais, outro aspecto importante para as redes neurais são o treinamento aplicado aos dados implementados, sendo que podem ser: *Levenberg-Marquardt*, *Bayesian Regularization* e

Figura 18 – Esquema do *Back-propagation*.



Fonte: adaptado de (GUPTA et al., 2019).

Figura 19 – Representação da divisão dos dados na validação.



Scaled Conjugate Gradient. O treinamento *Levenberg-Marquardt* é o padrão utilizado, sendo que é recomendado para a maioria dos problemas. Utiliza da Jacobiana para os cálculos, o que assume que o desempenho é a média ou a soma dos erros quadráticos. O *Bayesian Regularization* é utilizado para obter uma solução melhor a custo de maior tempo, sendo que se trata de uma função que minimiza a combinação dos erros quadráticos e pesos, além de modificar a combinação linear para que ao final do treinamento exista qualidades gerais adequadas; por fim, o *Scaled Conjugate Gradient* é aplicado em problemas de maior escala devido ao cálculo em gradiente (MATLAB, 2022).

2.3.3 Inteligência artificial aplicada aos processos de retificação e torneamento

Tais estratégias de inteligência artificial possuem potencial para serem utilizados como ferramentas de predição de resultados tanto nos processos de retificação quanto no torneamento. Em artigo de revisão elaborado por Ullrich et al. (2024), os autores abordam o estado da arte na aplicação de diversos métodos de otimização e de inteligência artificial voltadas à processamentos

de usinagem. Para os autores, a qualidade superficial prepondera sobre os outros resultados a serem obtidos pelos algoritmos, uma vez que é considerada a característica mais crítica do processo.

Para processos que envolvam a velocidade de corte, avanço, profundidade de usinagem ou geometria da ferramenta, os dados de saída calculados avaliam a rugosidade e a tensão superficial, além de outros como a dureza e a tolerância geométrica. As estratégias de inteligência artificial utilizadas para tais parâmetros envolvem a ANN e o ANFIS, tanto para a retificação quanto para o torneamento (ULLRICH et al., 2024).

Entre os trabalhos que envolvem a IA conjuntamente a retificação, têm-se o estudo de Nakai et al. (2015), que avaliaram o uso de modelos neurais para a previsão de desgaste da ferramenta em retificação de cerâmicas avançadas. Com uso de dados de entrada utilizando as emissões acústicas, criou-se um modelo de ANN com uma a três camadas ocultas, variando o número de neurônios de 5 a 40. Para o ANFIS, aplicou-se de duas a nove funções de pertinência, mas que não causou grandes variações no resultado. Os resultados demonstraram baixa diferença em torno do erro absoluto (cerca de 1%), porém o ANN demonstrou-se com maior repetibilidade e melhores resultados para algumas condições de processamento fixadas.

Ichida, Zouaghi e Kishi (1994) desenvolveram um método de ANN para o reconhecimento de padrões de retificação e predição de qualidade da superfície em nitreto de silício. Kumar e Choudhury (2007) se basearam na ANN para prever resultados de rugosidade das superfícies usinadas e desgaste de rebolo durante o processo de retificação por meio de descargas elétricas, sendo que desenvolveu uma relação entre os parâmetros de entrada (corrente, velocidade do rebolo, razão de trabalho e densidade do rebolo) e de saída (desgaste do rebolo e rugosidade superficial). Aplicaram ANN de camada oculta única com 12 neurônios, com uso de 100 dados para treinamento e 20 para a validação, obtendo um erro percentual máximo de 4,1% para os valores de saída, demonstrando a confiabilidade sobre o modelo.

Agrawal e Yadava (2013) desenvolveram a relação entre parâmetros de corrente, ciclos, velocidade do rebolo, velocidade de avanço e profundidade de usinagem, com os parâmetros de taxa de remoção de material e rugosidade superficial, sendo que observou que a rugosidade superficial é beneficiada com aumento da corrente, da razão de trabalho, profundidade de usinagem e velocidade de avanço, porém diminui com aumento da velocidade da ferramenta. Aplicando arquitetura de *Back-propagation* de camada oculta única (29 neurônios) com 18 dados para implementação, obteve R-valor acima de 0,90 e variação no erro percentual absoluto variando entre 1,17% a valores mais elevados de 25,65%.

Em estudo de Siddartha Varma et al. (2021), os autores verificaram a aplicação conjunta da metodologia de Taguchi e da ANN para otimização dos parâmetros de entrada (profundidade de usinagem, avanço e velocidade) na retificação de aço EN31AM. Aplicou-se o ANN com *Back-propagation* e treinamento *Levenberg-Marquardt*, obtendo resultados de predição próximos de rugosidade e taxa de remoção de material, comparando-os com os resultados experimentais e

determinando a validade do método de Taguchi.

Comparando as estratégias ANN e ANFIS, Sudheer Kumar Varma et al. (2017) avaliaram a capacidade preditiva para rugosidade e taxa de remoção de material em retificação cilíndrica de aço AISI 1040, com dados de entrada de velocidade de corte, avanço e profundidade de usinagem. Com uso de 27 dados de entrada e 8 para a validação, sendo que ambos demonstraram possuir desempenho satisfatório, com erro percentual absoluto encontrando-se na faixa dos 10%.

No torneamento, em pesquisa levantada por Umbrello et al. (2010), observou-se um crescimento de técnicas de ANN para modelar e realizar a predição de valores de tensão residual e de rugosidade, enquanto que os algoritmos de ANFIS concentraram-se em estudos relacionados a rugosidade. Especificamente, as ANNs foram extensivamente aplicadas em modelos de conformação metálica. Um destes usos foi realizado por Paturi et al. (2021), em análise de modelagem dos dados por ANN para estimar o desgaste da ferramenta. Observaram que, por meio de uma arquitetura com treinamento *Levenberg-Marquardt*, *Back-propagation* e uso de 27 condições experimentais, conseguiram gerar uma predição com maior valor de erro percentual absoluto de 11,7%, além de R-valor próximos à 1, demonstrando concordância entre os valores experimentais e o modelo obtido.

Quanto às tensões residuais, Umbrello et al. (2007) desenvolveu um sistema híbrido de ANN conjuntamente com modelos de elementos finitos para a determinação de curvas de tensão residual em aço 52100. A aplicação conjunta gerou um modelo de ANN com erro de predição entre 4% e 10%. Khoshaim et al. (2021) elaborou algoritmos de ANN (estrutura de *Levenberg-Marquardt* e *Back-propagation*) na predição de tensão residual em torneamento de ferro puro, a partir de 20 condições (divididas em 70% para o treinamento, 30% para testes e validação) estabelecidas com velocidade de corte, profundidade de usinagem e avanço, alcançando valores de R-valor entre 0,65 e 0,82.

Aplicando o ANFIS, Lee, Ho e Ho (2005) utilizaram para a predição de rugosidade superficial em torneamento de aço S55C, sendo que buscou estabelecer a relação entre a rugosidade e aspectos texturais da imagem superficial. A partir de 55 dados envolvendo características de imagem (nível de área cinza, frequência) e rugosidade, treinou um modelo de ANFIS, conseguindo um erro percentual médio de 4,12%. Com dados de entrada de profundidade de usinagem, velocidade de corte e avanço, Ho et al. (2002) elaborou a relação da rugosidade e aspectos texturais por uso de 57 dados, com um erro percentual abaixo de 4,6%.

Tanikić (2020) aplicou os modelos de ANFIS e ANN para calcular a temperatura de corte e a rugosidade média em processo de torneamento de liga de aço 4140, em parâmetros de corte previamente otimizados por ANOVA e algoritmo genético (GA), com uso de 192 dados experimentais. Para o ANN, o autor utilizou arquitetura de única camada oculta, com variação de 5 a 500 neurônios na camada oculta, aplicando 70% dos dados para o treinamento, 15% para validação e 15% para testes, obtendo R-valores melhores e com predições mais próximas aos experimentais quando aplicado menos de 20 neurônios. Para o ANFIS, aplicou a mesma divisão

dos dados, com uso de 81 regras com três funções de pertinência para cada variável de entrada (dureza, profundidade de usinagem, avanço e velocidade de corte), obtendo resultados próximos aos experimentais.

Utilizando 27 dados, Harsha et al. (2018) buscou prever a rugosidade e o desgaste de ferramenta no torneamento de liga Ti_6Al_4V utilizando ANN e ANFIS. Com dados de entrada de velocidade de corte, tempo de corte e taxa de avanço, o modelo de ANN utilizado aplicou (estrutura de *Levenberg-Marquardt* e *Back-propagation*) com camada oculta única de 10 neurônios. Para o sistema ANFIS, utilizou os mesmos conjunto de dados com uso de três funções de pertinência para cada parâmetro. Comparativamente, os resultados de predição demonstraram que ANFIS teve melhor desempenho que ANN, com maior proximidade aos resultados experimentais. Tal conclusão corrobora com estudo desenvolvido por Özkan e İnal (2014), na qual comparou ambos os modelos e determinou que o ANFIS possui melhor desempenho em análise de problemas que envolvam múltiplos critérios de decisão.

Porém, em trabalho desenvolvido por Neto et al. (2013) sobre modelos neurais para predição de diâmetros de furo na furação de ligas de Ti_6Al_4V , observou-se o contrário. Comparando ANN e ANFIS, os autores obtiveram maior precisão com as redes neurais artificiais, dispondo de menor erro percentual médios. Para a ANN, utilizaram três camadas ocultas (10-5-10 neurônios) com 80% dos dados utilizados no treinamento e 20% para validação e testes. A estrutura do ANFIS foi utilizado algoritmo existente no MATLAB®.

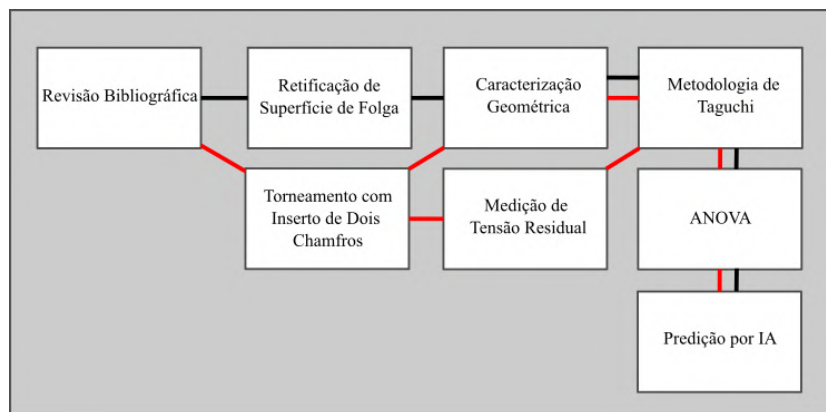
Em outros processos, também encontra-se pesquisas similares aplicando a IA, tal como Sivatte-Adroer et al. (2016) que propôs um modelo indireto baseado nas ANNs para a modelagem de processos de furação, sendo que testaram os efeitos de diferentes números de camadas neurais, diversos neurônios e tipos de funções de ativação nas camadas ocultas (camadas em que o processamento dos dados ocorre) para verificar o desempenho das redes neurais. Além disto, verificaram a melhor configuração para a rede neural por meio da metodologia de Taguchi.

Para este projeto de mestrado, o enfoque foi dado às redes neurais e ANFIS, denotado pela quantidade de estudos que aplicam tais estratégias, além da quantidade de dados experimentais a serem utilizados. O processamento de retificação e de torneamento estudado apresentaram aspectos de não-linearidade, com a predominância de variáveis que influenciam nos aspectos de acabamento superficial da peça trabalhada, tornando os modelos neurais (ANN e ANFIS) analisadas para o estudo. Desta maneira, estudando ambas as formas de inteligência artificial, gerando possíveis comparativos de resultados, denotaria uma validação de qual seria a melhor metodologia a ser aplicada para as situações de estudo, conjuntamente aos métodos estatísticos para verificação de influência.

3 MATERIAIS E MÉTODOS

A Figura 20 contém um fluxograma com as principais atividades realizadas e o desenvolvimento da pesquisa, para os dois casos estudados sendo retificação em superfície de folga e torneamento, com identificação das etapas de cada processo identificados pelas cores preta e vermelha, respectivamente. Nesta seção, também são apresentados o planejamento experimental aplicado, sendo a Metodologia de Taguchi e análise de variância (ANOVA), além dos métodos empregados para alcançar os objetivos e das informações de programação da inteligência artificial do ANFIS e ANN realizada no software MATLAB®.

Figura 20 – Fluxograma do projeto.



Fonte: Elaborada pelo autor.

3.1 Metodologia de Taguchi e ANOVA

O planejamento experimental realizou-se por meio da Metodologia de Taguchi e da análise de variância (ANOVA). O planejamento é utilizado para estudar o desempenho dos processos e dos sistemas. O experimento envolve a combinação de diversas operações e métodos para determinar as variáveis de influência, otimizar resultados, minimizar a variabilidade de resultados e de influência de variáveis incontroláveis. O planejamento experimental adequado é necessário para que se reduzam os números de ensaios necessários, obtendo um fatorial adequado, possibilitando o estudo de diversas variáveis e seus efeitos, determinando resultados qualitativos dos resultados (BUTTON, 2005) (MONTGOMERY, 2017).

Diversos autores aplicaram tal metodologia para estudos que envolvam a retificação. Liu et al. (2005) estudou o desenvolvimento de um sistema de retificação automática com controlador de forças em um centro de usinagem CNC (Controle Numérico por Computador). O método de Taguchi foi necessário para determinar as combinações ideais de taxa de avanço horizontal e valores desejáveis de força.

Saravanakumar et al. (2018) empregou uma matriz L_{18} para estudar o efeito de três parâmetros de usinagem na retificação plana de um aço de baixo teor de carbono sobre a sua rugosidade média, concluindo que a profundidade de usinagem é a variável de maior influência, seguida pela sua interação com o avanço.

Em estudos realizados por Saglam, Unsacar e Yaldiz (2005) nos efeitos dos parâmetros de retificação nos erros do arredondamento de aresta e de rugosidade superficial, determinou-se a influência da velocidade de trabalho, taxa de avanço e profundidade de usinagem, sendo que as matrizes de Taguchi, conjuntamente com ANOVA e a análise de dados experimentais, demonstraram que a velocidade e a profundidade de usinagem possuíam influência sobre o processamento, com taxa de avanço abaixo do limite permitido.

Já Shaji e Radhakrishnan (2003) analisou os efeitos dos parâmetros de processo como a velocidade, taxa de avanço, dressagem e penetração nas variáveis de componentes de força e da rugosidade superficial baseado na metodologia de Taguchi. A análise por ANOVA foi uma das ferramentas utilizadas para determinar a melhor combinação dos parâmetros.

Ademais, Routara et al. (2010) propôs um método de otimização integrada utilizando análise ponderada de componentes principais combinadas com o método de Taguchi para otimizar os parâmetros da retificação cilíndrica. Os parâmetros de processo determinados foram a velocidade da peça, avanço longitudinal e radial, na qual determinou-se que em menores velocidades, o acabamento superficial foi incrementado devido a redução das vibrações.

Chen, Cheung e Zhang (2018) propôs experimento teórico e prático para a geração de superfícies durante a retificação de ultra precisão de materiais dúcteis e frágeis. Nesta pesquisa, o método de Taguchi demonstrou que a taxa de avanço e a distância transversal de avanço foram as variáveis mais influentes sobre os resultados de geração de superfícies, possibilitando a criação de um modelo capaz de prever a rugosidade e a geração de espirais superficiais.

O método de Taguchi propõe três objetivos principais, sendo a projeção de processos robustos com relação as condições ambientais, minimização da variabilidade em torno de valor nominal e desenvolvimento de produtos robustos à variabilidade dos componentes (MONTGOMERY, 2017).

A Metodologia de Taguchi é um método de análise e de projeto experimental, na qual o princípio trata do uso de experimentos ortogonais para o processamento dos dados e a obtenção de uma combinação otimizada de parâmetros, determinando variáveis principais e secundárias de influência no processamento. A análise dos resultados realiza-se em conjunto com método estatístico, tal como a ANOVA (denominado de análise de variância), que é aplicado em experimentos de múltiplos fatores que necessitam de mais ou igual a dois níveis de testes.

A matriz apropriada a ser escolhida é definida a partir dos números de fatores e níveis. Considerando um cenário em que três fatores seriam selecionados, com três níveis para cada, o fatorial completo envolveria 3^3 experimentos, totalizando 27. Com a metodologia de Taguchi,

determina-se os efeitos de fatores de processos individualmente, e, com a matriz L_9 , em 9 experimentos é possível realizar a otimização dos fatores e tornando o planejamento mais eficiente (PAN et al., 2021).

O método de Taguchi é uma ferramenta viável para análise adequada e categorizada das variáveis de processo. Este método prevê a verificação da resposta média dos conjuntos de dados, sendo a variabilidade indicada por meio da razão sinal-ruído (SN) apropriado, sendo que são três: melhor nominal (SN_T) para reduzir variações em torno do valor nominal, maior melhor (SN_L) para a maximização de resultados e, finalmente, a menor melhor (SN_S) para minimização deles (BUTTON, 2005).


3.2 Retificação de superfície de folga

A preparação da superfície de folga dos inserts foi realizada com a retificadora CNC Agathon Dom Plus que dispõe de quatro eixos, 16 kW de potência e até 3.400 rpm, disponível no Laboratório de Processos de Fabricação do Departamento de Engenharia Mecânica da Universidade Federal de São Carlos (LPF/DEMec/UFSCar).

Utilizou-se no processamento por retificação um rebolo de diamante do tipo copo, com ligante resinoide, de granulometria D46, concentração C100 e óleo mineral como fluido de corte, com representação demonstrada na Figura 21. Para a preparação da superfície de folga, variaram-se os parâmetros de corte cinemáticos, velocidade de corte e a velocidade de avanço, além de variar a medida de remoção de material, o sobremetal da operação.

Para a dressagem do rebolo, foi utilizado rolo dressador #180 de tipo copo, de alumina (Al_2O_3), que realizam a limpeza do cavaco no rebolo e a remoção de grãos de diamante sem linha de corte.

Figura 21 – Representação da retificação dos inserts.



Fonte: adaptado de (CRUZ, 2021)


Os inserts de metal duro utilizados foram os de classe HW K10, disponível comercialmente, em formato quadrado. Conforme a norma ISO.513 (2012), trata-se de um metal duro sem cobertura, à base de carboneto de tungstênio em matriz de cobalto, de elevada resistência ao

desgaste. O grupo de aplicação preferencial é o de ferros fundidos em condições de acabamento, mas seu desempenho deve ser também satisfatório na usinagem de ligas de alumínio (N10) ou ainda superligas de cobalto, níquel ou titânio (S10).

Os insertos tiveram suas superfícies de saída retificadas antes da preparação da superfície de folga, nas seguintes condições: velocidade de corte em 20 m/min e velocidade de avanço em 4 mm/min, com espessura de 4,76 cm.

Para permitir a avaliação de diferentes parâmetros de rugosidade na superfície retificada dos insertos, bem como de aspectos geométricos e de integridade das arestas cortantes, empregou-se o microscópio para análise tridimensional de imagens Alicona InfiniteFocus SL (Figura 22), também presente no LPF/DEMec/UFSCar.

Figura 22 – Caracterização geométrica por microscópio: (a) equipamento e (b) exemplo de imagem obtida.




A análise microscópica da rugosidade e aspectos geométricos de todos os insertos foi feito utilizando 200 perfis e com lente objetiva de ampliação de 10x, com direção perpendicular a retificação da superfície de folga e paralela à superfície de saída, sendo que a análise foi feita após a retificação ter terminada (a medição não foi realizada *in-situ*), tal como é apresentado na Figura 23.

Neste estudo em questão, a razão menor melhor, apresentado na Equação 10 foi utilizada, em vias de estabelecer os parâmetros que conferem a menor rugosidade (BUTTON, 2005).

$$SN_s = -10 \cdot \log \left(\frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (10)$$

Conduziu-se uma abordagem inicial a partir de um arranjo ortogonal reduzido (uma matriz L_9) para a obtenção de resultados para a elaboração da análise por meio da Metodologia de Taguchi e, posteriormente, ensaios definitivos para a análise do fatorial completo, com 27

Figura 23 – Exemplo de medição de rugosidade realizada no Alicona.



Fonte: Elaborado pelo autor.

Tabela 4 – Condições experimentais dos insertos utilizados na análise por metodologia de Taguchi.

Inserto	Velocidade de corte (m/s)	Velocidade de avanço (mm/min)	Sobremetal (mm)
1	12	2	0,05
2	12	12	0,1
3	12	25	0,2
4	36	2	0,1
5	36	12	0,2
6	36	25	0,05
7	60	2	0,2
8	60	12	0,05
9	60	25	0,1

Fonte: Elaborado pelo autor.

experimentos ao todo para a análise de variância (ANOVA), com os resultados de rugosidade R_a e R_z apresentados no Apêndice A. As Tabelas 4 e 5 apresentam os experimentos aplicados para a Metodologia de Taguchi e o fatorial completo abordado, respectivamente. Todos as condições e resultados experimentais podem ser visualizadas no Apêndice A.

Ademais, realizou-se a análise de variância de diversos fatores (ANOVA), a fim de determinar os parâmetros que influenciam no processamento de retificação quanto ao acabamento e qualidade superficial, sendo analisado os valores de rugosidade do fatorial completo.

A fim de verificar a normalidade do fatorial completo e garantir a confiabilidade dos dados, também realizou-se o procedimento de Chauvenet, que, segundo Button (2005), é uma maneira de rejeitar ou manter os resultados da amostra. O critério consiste no cálculo do desvio-

Tabela 5 – Fatorial completo de todas as condições das arestas de folga.

Níveis / Variáveis	Intensidade Baixa	Intensidade Média	Intensidade Alta
Velocidade de corte (v_c)(m/s)	12	36	60
Velocidade de avanço (v_f)(mm/min)	2	12	25
Sobremetal (a_e) (mm)	0,05	0,1	0,2

Fonte: Elaborado pelo autor.

padrão DR em cada componente y_i da amostra, e depois comparar os resultados com a Razão Padrão (DR_0), sendo que, para o caso de quatro repetições, o valor é igual a 1,54. Caso o valor de $DR < DR_0$, o componente é mantido, mantendo a normalidade. A Equação 11 apresenta o cálculo de DR .

$$DR = \frac{(y_i - \bar{y})}{S} \quad (11)$$

O teste de Tukey foi implementado em seguida, sendo este teste, segundo Montgomery e St (2022), utilizado para determinar os intervalos dos níveis de confiança em porcentagem para os níveis avaliados, realizando a diferença das médias dos diferentes tratamentos. A Equação 12 apresenta a forma de cálculo, em que se baseia no intervalo estatístico de Student (para esta pesquisa, foi aplicado ao nível de 5% de probabilidade).

$$q = \frac{\bar{y}_{max} - \bar{y}_{min}}{\sqrt{\frac{MSE}{n}}}; \quad (12)$$

MSE representa o erro quadrático médio, n o número de tratamentos realizado, \bar{y} como a média do tratamento escolhido.

3.3 Torneamento com inserto de dois chanfros

Insertos de classe HW K10 foram previamente retificados pela CNC Agathon Dom Plus na superfície de saída e de folga para melhorar a qualidade superficial. A retificação foi realizado com velocidade de corte (v_c) de 36 m/s, velocidade de avanço de 12 mm/min e velocidade rotacional do inserto em 70°/s, com rebolo de diamante do tipo copo, com ligante resinóide, de granulometria C100 e concentração C100, com óleo mineral de fluído de corte. A superfície de corte foi retificada com velocidade de corte de 20 m/s, taxa de avanço de 4 mm/min e dressagem com rebolo de Al_2O_3 (velocidade axial do dressador v_{fad} de 3 μ m, percurso de dressagem de 15 μ m e velocidade de corte de 10 m/s).

Nove diferentes micro geometrias de chanfro duplo na aresta foram produzidas, com revestimento PVD (deposição física de vapor) TiAlN providos pela Oerlikon Balzers (Balinit®LATUMA), sendo estas baseadas no método de discretização de arestas arredondadas por meio de chanfros proposto por Denkena, Köhler e Ventura (2013), com representação esquemática na Figura 12. A Tabela 6 apresentam as micro geometrias (fator de forma K), sendo que os

valores nominais não foram alcançados com uma diferença média de 13%. A Tabela 7 apresenta as condições de raio de ponta e avanço.

Tabela 6 – Características nominais da micro geometria dos insertos.

K	$S\alpha$ (mm)	$S\gamma$ (mm)
0,5	100	50
1	50	50
2	50	100

Fonte: Elaborado pelo autor.

Tabela 7 – Condições experimentais do torneamento.

Dados	K	Raio de ponta (mm)	Avanço (mm)
Teste 1	0,5	0,4	0,10
Teste 2	2,0	0,8	0,10
Teste 3	1,0	1,2	0,10
Teste 4	1,0	0,4	0,15
Teste 5	0,5	0,8	0,15
Teste 6	2,0	1,2	0,15
Teste 7	2,0	0,4	0,20
Teste 8	1,0	0,8	0,20
Teste 9	0,5	1,2	0,20

Fonte: Elaborado pelo autor.

As etapas seguintes foram realizadas na Ecole d'ingénieurs en Génie Mécanique (ENISE - Saint-Étienne). O torneamento longitudinal foi realizado em CNC CMZ TC 25 Y de três eixos com potência máxima de 35W e máxima velocidade de rotação de 400 rot/min. As forças de corte foram medidas com dinamômetro Kistler de três componentes 9129AA, acoplado a unidade de taxa de aquisição de 1 kHz. A velocidade de corte v_c 100 m/min e a profundidade de usinagem 0,8 mm foi mantido constante, sendo utilizado porta-ferramenta DSBNL 2525M 12. A inclinação da aresta de corte foi $\lambda_s = -6^\circ$ e ângulo ortogonal $\gamma_n = -6^\circ$. A rugosidade (R_a e R_z) da peça usinada foi determinada por ferramenta de medição Marsurf PS 10 com cut-off de 2,5 mm.

O material de trabalho utilizado foi a liga de aço 4142. As peças usinadas foram analisadas em dois sistemas de difração de raios-X (DRX) da Proto e MXR Rays. A Tabela 8 resume os aspectos dos equipamentos e parâmetros.

Os perfis de tensão residual foram caracterizados em quatro magnitudes, sendo estas: tensão superficial, intensidade de compressão do vale, posição de compressão e zona afetada. A Figura 24 representa os pontos de caracterização. No entanto, os dois últimos não foram profundamente avaliados uma vez que a determinação do ponto na curva tornou-se imprecisa, já que algumas curvas de tensão não apresentaram um "formato de gancho" claro.

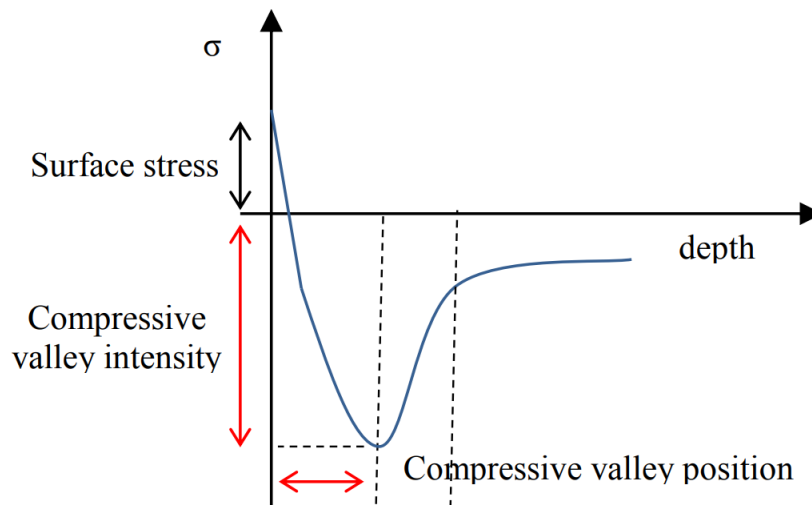
Para o estudo do torneamento, a razão menor melhor, apresentado na Equação 10 foi utilizada, em vias de estabelecer os parâmetros que conferem o menor valor de rugosidade

Tabela 8 – Condições experimentais do sistema de difração de raios-X

	Proto System	MXR Rays System
Condição de Difração	Radiação Cr K α com 18 kV, 4 mA	Radiação Cr K α com 20 kV, 4 mA
Comprimento de Onda	2,291 nm	2,291 nm
-S1 (v/E)	0,00124/GPa	0,00128/GPa
S2/2 (1+v)/E	0,00501/GPa	0,00583/GPa
Plano <i>hkl</i>	211	211
Ângulo de Bragg	156,08°	156,08°
Polimento	Eletropolimento	Eletropolimento

Fonte: Elaborado pelo autor.

Figura 24 – Esquema das magnitudes do perfil de tensão residual.



Fonte: (HAN et al., 2022)

R_a , R_z e tensão superficial (BUTTON, 2005). A razão maior-melhor, abordado na Equação 13, foi aplicado para a intensidade de compressão do vale, em vias de determinar as condições de maior compressão residual sobre a peça. Com os testes de Taguchi, elaborou-se uma análise de variância (ANOVA) abordando os valores das médias e das SN_s , avaliando a influência dos parâmetros sobre a rugosidade, forças (força de corte F_c , força de avanço F_t e força passiva F_p , além da tensão residual).

$$SN_s = -10 \cdot \log \left(\frac{\sum \left(\frac{1}{y^2} \right)}{n} \right) \quad (13)$$

Após os nove testes da Metodologia de Taguchi, três novas condições foram elaboradas visando os melhores parâmetros para comportamento compressivo da tensão residual. Estes foram comparados com dados dos testes anteriores com condições similares, a fim de verificar a influência dos parâmetros escolhidos sobre o acabamento superficial e tensão residual da peça, principalmente o impacto da micro geometria K , representados na Tabela 9.

Tabela 9 – Condições de maior compressão residual.

Teste	Avanço (mm)	Raio de ponta (mm)	Fator de forma (K)
Teste 10	0,20	0,4	0,5
Teste 11	0,20	0,4	1
Teste 12	0,20	0,8	2

Fonte: Elaborado pelo autor.

Para cada condição, foi repetido o torneamento três vezes, em vias de confirmar a confiabilidade dos dados gerados com o comparativo das medições de força e de rugosidade, com medição única de perfil de tensão residual para cada condição (totalizando 36 medidas de rugosidade e força, e geração de 12 perfis de tensão residual). Os dados de rugosidade R_a , R_z e forças são apresentados no Apêndice B.

3.4 Programação do Matlab® em ANN e ANFIS para os estudos

Realizou-se a implementação de algoritmo de inteligência artificial para a otimização para ambos os casos, verificando a capacidade de predição dos resultados experimentais, em ambiente de programação interpretada, com o Matlab®, buscando aplicar as ferramentas de redes neurais e ANFIS.

A rede neural artificial (ANN) baseou-se em uma rede *Shallow Feed Forward* e de *Back-Propagation*, aplicando a função de treinamento de Levenberg-Marquardt. Ademais, variou-se o número de neurônios utilizados na camada oculta, utilizando de 8 a 12 neurônios, a fim de verificar a capacidade de predição e possibilidade de uso para otimização, avaliando a diferença comparativa com os resultados experimentais. Avaliou-se como dados de saída os valores de rugosidade R_a e R_z , além dos dados de tensão residual para a peça usinada.

Os dados de entrada e saída implementados na ANN foram distribuídos da seguinte forma: 70% para treinamento, 15% para validação e 15% para os testes. Em vias de realizar a comparação da predição, dados foram retirados da quantidade total para verificar a capacidade de inferência da ferramenta. Exemplificando, para a retificação, um dado de rugosidade (dado de saída experimental) junto aos seus dados de entrada foram retirados (das 27 condições observados, permaneceram 26 para implementação no algoritmo); assim, com os dados de entrada desta condição, foi obtido o seu respectivo dado de saída calculado pela ANN, conseguinte a sua comparação com o valor de saída experimental. Em vias de conferir confiabilidade sobre os resultados, repetiu-se o cálculo por três vezes para os respectivos números de neurônios.

Para o sistema artificial de inferência *Neuro-Fuzzy* (ANFIS), seguiu-se a mesma metodologia, aplicando o *grid partitioning* com duas funções de pertinência para cada entrada (nível baixo e alto). Os dados implementados foram distribuídos em 75% para treinamento e 25% para validação, com prévia retirada de dados para comparação.

4 RESULTADOS E DISCUSSÕES

A seguir, estão apresentados os resultados experimentais relacionados a análise estatística dos dados da retificação da superfície de folga e do torneamento de liga 4142 com ferramentas de arestas retificadas, além da verificação da capacidade preditiva da inteligência artificial (ANN e ANFIS) associado a cada um dos estudos.

4.1 Retificação de Superfície de folga dos insertos

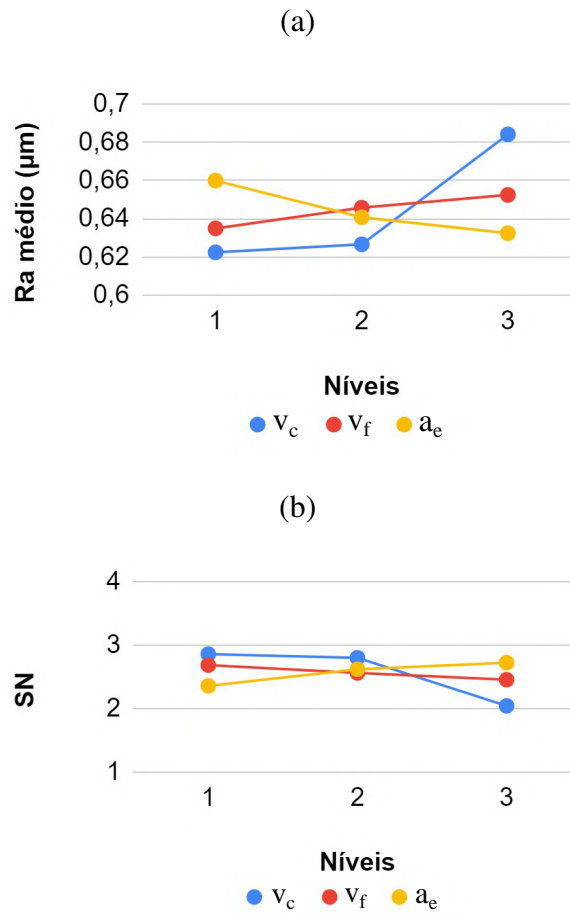
Com os resultados de rugosidade R_a obtidos na superfície de folga dos insertos, foi possível a determinação dos gráficos de valores médios e das razões SN_S . O gráfico representado na Figura 25 demonstrou que a influência da velocidade de corte prepondera sobre as outras variáveis, sendo que os valores de SN_S tenderam a variar mais para este parâmetro. Desta maneira, verificou-se que a redução da velocidade de corte do rebolo provoca a redução da rugosidade, melhorando o acabamento superficial. Isto contradiz com o resultado obtido por Klocke e Kuchle (2009), em que maiores velocidades reduzem a rugosidade, porém efeitos dinâmicos ou vibrações poderiam ter alterado os resultados, tal como a remoção variável de material, que pode ter resultado na variação térmica.

A mesma análise pode ser observada com a medição da rugosidade R_z na Figura 26 similar aos gráficos de R_a . Ademais, observando os valores médios nos gráficos das Figuras 25 e 26, determinou-se que os níveis ótimos para minimizar a rugosidade R_a (observando os valores médios de ambas as rugosidades, notando a aplicação da regra de menor-melhor) segundo o método de Taguchi seriam: velocidade de corte baixa, velocidade de avanço baixa e sobremetal alta. Algo importante a se denotar é que a variável de sobremetal foi identificado com o símbolo de penetração de trabalho (a_e).

Posteriormente, realizou-se a análise de variância (ANOVA) para verificar a influência das três variáveis isoladamente e as suas interações, sendo utilizado os valores de rugosidade R_a e R_z do fatorial completo. Os resultados para a variância obtidos são observados nas Tabela 10 e Tabela 11, além dos valores das funções F_0 , na qual aborda os fatores de influência em distribuição F para um intervalo de confiança de 95%. Os resultados de rugosidade R_a e R_z podem ser observados no Apêndice A. Os valores demonstram as variáveis que influenciam nos valores de rugosidade R_a e R_z , devido ao seu valor ser inferior à porcentagem de 5% (considerando o intervalo de confiança de 95%).

Pode-se notar que, para os valores de R_a , a velocidade de corte, a interação entre velocidade de avanço e sobremetal, além da interação entre os três, possuíram influência sobre os resultados, uma vez que o P-valor encontrado têm valores inferiores a 5%. Desta maneira, foram estabelecidos os gráficos com os valores médios de rugosidade para os fatores de influência,

Figura 25 – Médias (a) e SN_S (b) do valor R_a .



Fonte: Elaborado pelo autor.

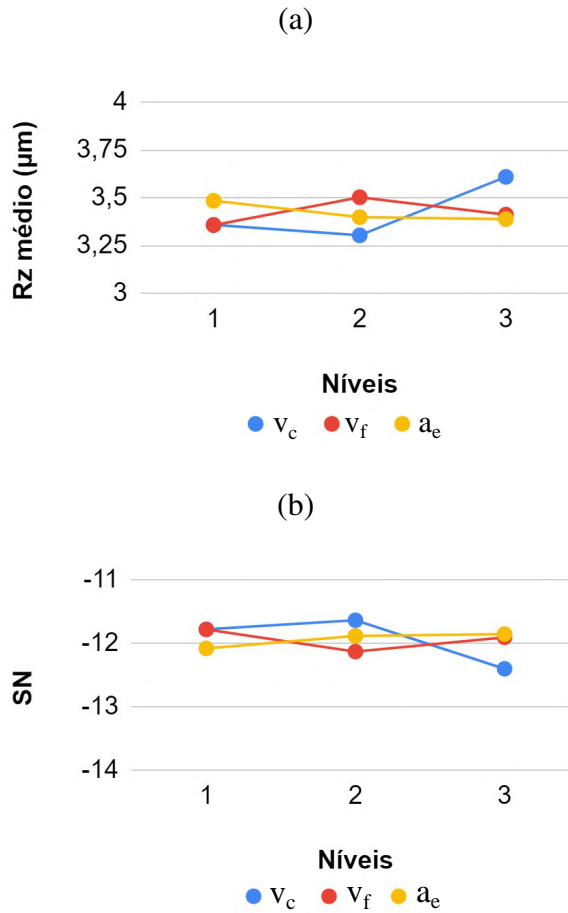
Tabela 10 – Quadro ANOVA das medidas de R_a .

ANOVA R_a	SS	GL	MS	Intervalo de Confiança	
				F0	F 0,5
Totais	0,2351	107			
v_c	0,0233	2	0,0116	7,3174	0,001
v_f	0,0061	2	0,0031	1,9202	0,15
a_e	0,0038	2	0,0019	1,1864	0,31
$v_c \times v_f$	0,0140	4	0,0035	2,1980	0,08
$v_c \times a_e$	0,0109	4	0,0027	1,7132	0,16
$v_f \times a_e$	0,0221	4	0,0055	3,4787	0,01
$v_c \times v_f \times a_e$	0,0262	8	0,0033	2,0582	0,05
Erro	0,1288	81	0,0016		

Fonte: Elaborado pelo autor.

apresentados nas Figuras 27 e 28, e se confirmou a sensibilidade de R_a quanto aos fatores especificados anteriormente, devido a interação entre as curvas de linha de tendência de grau polinomial 2.

Figura 26 – Médias (a) e SN_S (b) do valor R_z .



Fonte: Elaborado pelo autor.

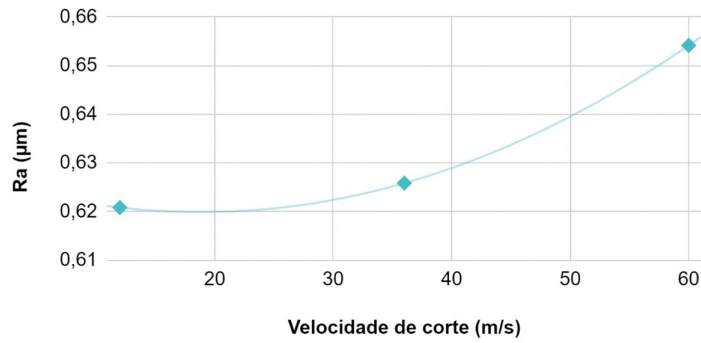
Tabela 11 – Quadro ANOVA das medidas de R_z .

ANOVA R_z	SS	GL	MS	Intervalo de Confiança	
				F0	P-valor
Totais	8,9585	107	0,3119		
v_c	0,6238	2	0,1106	4,8924	0,01
v_f	0,2213	2	0,0298	1,7355	0,18
a_e	0,0596	2	0,2355	0,4675	0,63
$v_c \times v_f$	0,9420	4	0,1006	3,6942	0,01
$v_c \times a_e$	0,4024	4	0,1293	1,5780	0,19
$v_f \times a_e$	0,5171	4	0,1286	2,0278	0,10
$v_c \times v_f \times a_e$	1,0284	8	0,0638	2,0164	0,05
Erro	5,1639	81	0,3119		

Fonte: Elaborado pelo autor.

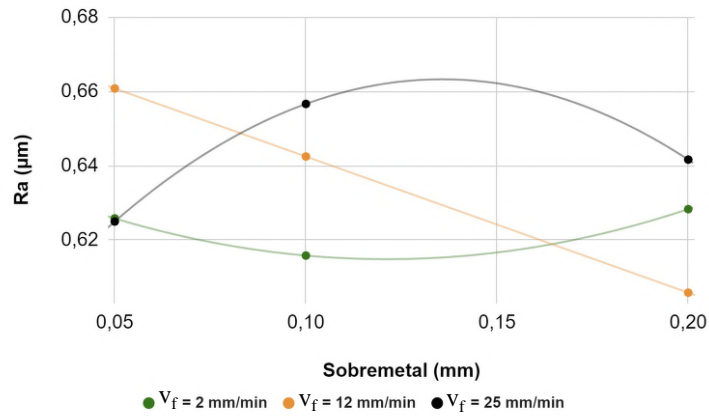
Quanto aos valores de R_z , notou-se que a velocidade de corte, a interação entre este com o sobremetal, além da correlação entre os três parâmetros (obtiveram valor próximo a 5%) possuíam influência para R_z , como se confirmou com as Figuras 29 e 30, com linhas de tendência

Figura 27 – Dados dos valores médios de R_a versus velocidade de corte.



Fonte: Elaborado pelo autor.


Figura 28 – Dados dos valores médios de R_a versus sobremetal e velocidade de avanço.



Fonte: Elaborado pelo autor.

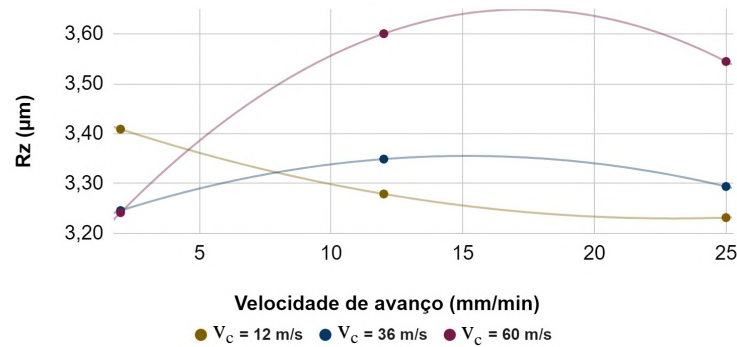
de tipo polinomial de grau 2.

Figura 29 – Dados dos valores médios de R_z versus velocidade de corte.



Fonte: Elaborado pelo autor.

Quanto a influência dos três fatores, observou-se que não foi possível adequar linhas de tendência aos dados, uma vez que se tratou de um processamento não-linear, ou seja, com heterogeneidade quanto a previsibilidade dos resultados. A Figura 31 exemplifica as superfícies

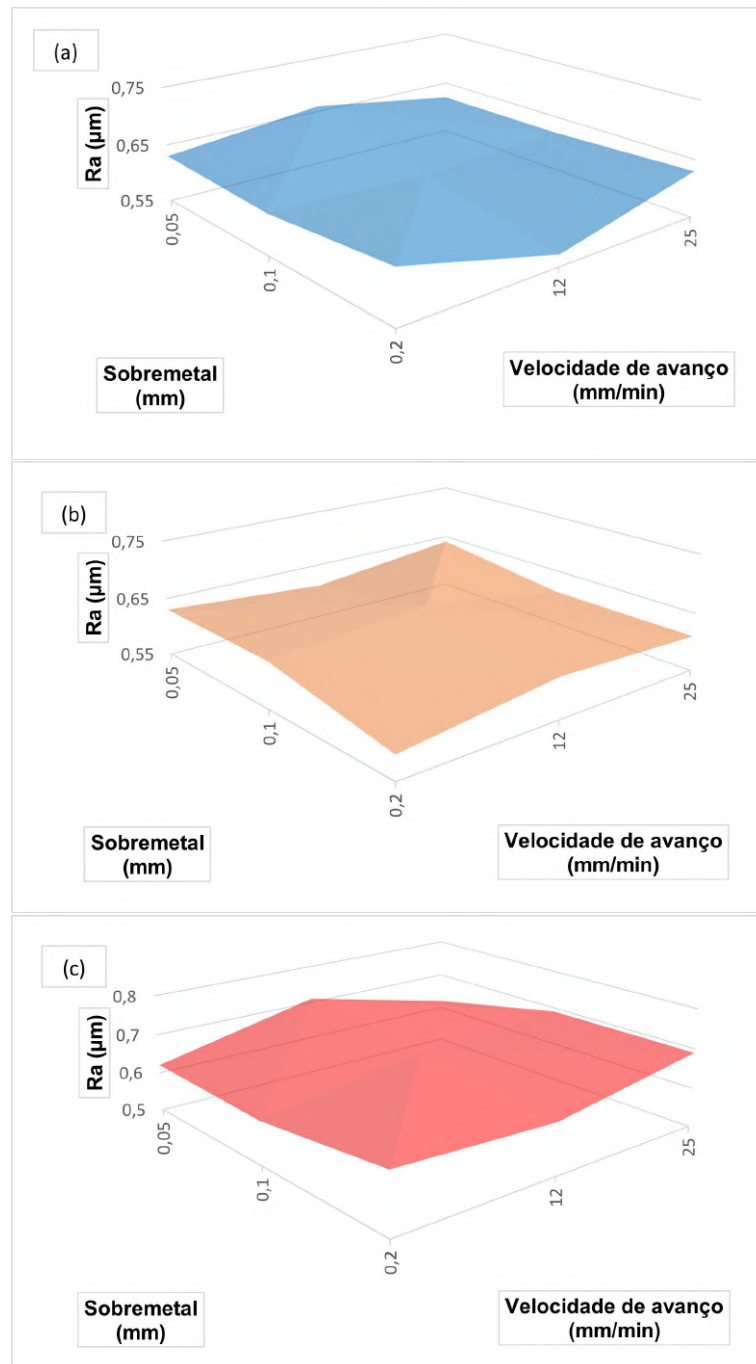
Figura 30 – Dados dos valores médios de R_z versus velocidade de corte e velocidade de avanço.

Fonte: Elaborado pelo autor.

de resposta dos dados de rugosidade R_a , com a variação do comportamento de acordo com a velocidade de corte, de forma a demonstrar a condição heterogênea observada.

Notou-se que a velocidade de corte, a interação velocidade de corte/sobremetal e a interação velocidade de avanço/velocidade de corte, são influentes nos resultados de rugosidade. Em vias de confirmar a normalidade dos testes e verificar a confiabilidade nos resultados, realizou-se o teste de Chauvenet para ambos os parâmetros, demonstrados na Tabela 12 e 13. Notou-se que nenhum dos valores ultrapassou o valor da Razão Padrão ($DR_0 = 1,54$), mantendo-se todos os resultados.

Figura 31 – Gráfico das superfícies de resposta para as três variáveis; (a) $V_c = 12$ m/s, (b) $V_c = 36$ m/s e (c) $V_c = 60$ m/s.



Fonte: Elaborado pelo autor.

Tabela 12 – Resultados do teste de Chauvenet para R_d .

IDRl	f1						f2						f3					
	d1		d2		d3		d1		d2		d3		d1		d2		d3	
V1	0,73	0,98	1,13	1,31	0,81	1,43	0,26	1,31	1,38	0,11	0,78	0,26	1,13	0,08	1,17	0,50	0,84	1,40
	0,98	0,73	0,09	0,09	0,06	0,56	0,78	0,78	0,74	0,74	0,78	1,31	0,23	1,29	0,83	0,83	0,56	0,00
V2	0,10	1,30	0,13	0,90	0,66	1,45	0,66	1,45	1,48	0,39	1,02	0,15	0,77	0,49	0,24	0,24	0,89	0,05
	1,10	0,30	1,48	0,39	0,66	0,13	0,66	0,13	0,39	0,70	1,32	0,44	0,21	1,46	1,20	1,20	1,41	0,47
V3	0,63	0,21	0,63	1,05	1,16	0,39	1,45	0,15	0,56	0,47	0,95	1,40	0,48	1,43	0,56	1,12	1,49	0,42
	1,47	0,63	0,63	1,05	0,39	1,16	0,55	0,75	1,07	1,15	0,07	0,37	0,86	0,10	0,84	0,84	0,65	0,42

Fonte: Elaborado pelo autor.

Tabela 13 – Resultados do teste de Chauvenet para R_z .

IDRl	f1						f2						f3					
	d1		d2		d3		d1		d2		d3		d1		d2		d3	
V1	0,32	1,21	1,29	1,13	0,76	1,22	0,50	1,10	1,37	0,55	0,27	0,09	1,11	0,15	1,40	0,56	0,50	1,50
	1,16	0,27	0,26	0,10	0,87	0,41	0,45	1,15	0,90	0,08	1,11	1,29	0,32	1,28	0,02	0,85	0,59	0,41
V2	0,05	1,39	0,14	0,83	0,79	0,63	1,08	1,31	1,37	0,01	1,26	0,52	0,34	0,65	0,47	0,39	0,78	0,03
	0,37	0,96	0,94	0,47	0,02	1,40	0,33	0,09	0,97	0,41	1,03	0,30	0,50	1,49	0,63	1,49	1,40	0,65
V3	0,49	0,60	1,13	0,80	0,01	0,51	1,06	1,34	0,16	0,48	0,72	0,84	0,77	0,77	1,08	0,61	1,46	0,69
	1,50	0,41	0,88	0,55	0,89	1,39	0,02	0,30	1,45	0,80	1,00	0,88	1,34	0,19	0,98	0,70	0,16	0,60

Fonte: Elaborado pelo autor.

Em seguida, para conferir os níveis em que existiram diferenças nos resultados, em que poderiam ser considerados significativos ou não, realizou-se os testes de Tukey, demonstrados no Apêndice A. Comparou-se média a média, sendo observado que para os valores de R_a apenas quatro condições demonstraram possuir diferença significativa, na qual estas situações estão preenchidas com a coloração verde (coloração vermelha indica que não houve diferença significativa). No entanto, quando observados os valores de R_z , notou-se diferença para 64% das situações apresentadas, demonstrando confiabilidade nas diferenças dos resultados. Ademais, a ANOVA e os diagramas de efeitos principais apresentadas para ambas as rugosidades foram similares quanto às conclusões, portanto não foi influenciado os resultados já analisados.

Com as informações obtidas, aplicou-se os modelos de inteligência artificial para os resultados de retificação (Tabela 14 e Tabela 15), sendo que foi retirado uma condição otimizada obtida pelas análises estatísticas e por Taguchi, sendo um dado de saída de rugosidade (R_a e R_z) e um dado de entrada (velocidade de corte, velocidade de avanço e sobremetal), a fim de determinar a capacidade preditiva final dos modelos. O dado experimental retirado foi:

- Rugosidade $R_A = 0,6425 \mu\text{m}$ e $R_z = 3,4300$

Tabela 14 – Resultados da Predição com modelo ANN para as rugosidades na retificação com dados conjuntos.

Número de Neurônios	Modelo de Predição ANN		Diferença Média Absoluta Percentual
	Rugosidade R_a (um)	Rugosidade R_z (um)	
8	0,6071	3,2021	6%
	0,6315	3,1833	
	0,6024	3,0545	
9	0,6100	3,3452	4%
	0,6787	3,2567	
	0,6332	3,5621	
10	0,5578	3,6542	7%
	0,6142	3,2951	
	0,6124	3,1337	
11	0,6015	3,0263	8%
	0,5676	3,1250	
	0,6718	3,1337	
12	0,6078	3,3371	8%
	0,6146	3,0773	
	0,5186	3,3038	

Fonte: Elaborado pelo autor.

O modelo de ANN obteve valores acima de 0,90 para o R-valor. Observou-se que o modelo de ANN possuiu melhor capacidade preditiva que o ANFIS, assim como já citado na

Tabela 15 – Resultados da Predição com modelo ANFIS para as rugosidades na retificação.

Rugosidade R_a (μm)			Rugosidade R_z (μm)		
Experimental	Predição	Diferença Absoluta Percentual	Experimental	Predição	Diferença Absoluta Percentual
0,6425	0,5562	13%	3,4300	2,8187	18%

Fonte: Elaborado pelo autor.

literatura. Outro fator a se notar é que, para os dados de retificação, realizou-se a tentativa de implementação dos 27 dados para a ANN de maneira separada e conjunta dos dados experimentais obtidos, ou seja, com único dado de saída (rugosidade R_a ou rugosidade R_z) ou conjuntamente, com os dois dados de saída implementados juntos (rugosidade R_a e rugosidade R_z , observados na Tabela 14). Quando treinados separadamente, a ANN demonstrou ter pouca concordância entre valores experimentais e teóricos, com R-valor baixos, enquanto que conjuntamente obteve valores próximos a 1.

Isto demonstra a necessidade do modelo ser alimentado com as duas variáveis, sendo que ambas acabaram por se complementar e gerar melhores resultados de treinamento, o que também poderia ser explicado pelo teste de Tukey, uma vez que as diferenças entre os valores médios foram mais significativos para os valores de R_z , o que geraria mais robustez aos treinamentos.

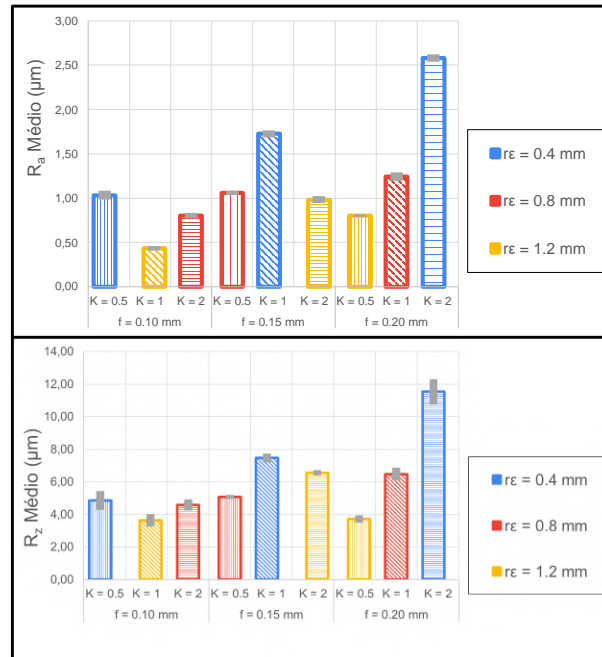
4.2 Torneamento de liga de aço 4142 com insertos de metal duro com arestas de corte retificadas

Com as nove condições iniciais estabelecidos pela Metodologia de Taguchi, obteve-se os resultados de rugosidade média apresentados em forma de gráfico na Figura 32. As hachuras indicam $K = 0,5$, horizontais $K = 2$ e linhas em 45° $K = 1$, com os desvios representados em retângulos cinzas, além das cores diferenciarem os raios de ponta aplicados. Os dados numéricos, com todos os dados de rugosidade, força e tensão residual (incluindo os dados de repetições), além dos diagramas de efeitos principais (Taguchi) e as tabelas de ANOVA, podem ser vistos no Apêndice B.

Os resultados apresentam a redução nos valores de rugosidade conforme o raio de ponta aumenta e o avanço diminui. Tal como estudado por Brown e Schoop (2020) e Denkena, Lucas e Bassett (2011), menores raios de ponta aumentavam a rugosidade, além de Benlahmidi et al. (2017) apontar a redução da rugosidade com a redução do avanço. Estabeleceu-se gráficos de influência (Figura 33), em que se fixa uma das variáveis para verificar o impacto das outras sobre o resultado final, para analisar o efeito do parâmetro K sobre a rugosidade.

Considerando as curvas, o K de 1 e 0,5 tiveram menores tendências para um aumento da rugosidade junto às outras variáveis. Realizou-se a comparação dos dados experimentais com a equação teórica de rugosidade, observados no artigo de Sinzato et al. (2024b), sendo

Figura 32 – Valores de rugosidade R_a e R_z .



Fonte: Elaborado pelo autor.

que, baseando-se na equação teórica 14, encontrou-se uma variação de 25,7% sobre os valores teóricos (Equação 15), demonstrando a influência de K . Ademais, os efeitos do raio de ponta (r_ϵ) e do avanço (f) também podem ser explicados pela relação entre as variáveis na equação teórica de rugosidade. A curva ajustada a esta equação (Figura 34), realizada em MATLAB®(algoritmo *Trust-Region* e método *Non-Linear Least Squares*) obteve um valor de R^2 de 72%.

$$R_a(\mu m) = \frac{f^2}{18000\sqrt{3}r_\epsilon} \quad (14)$$

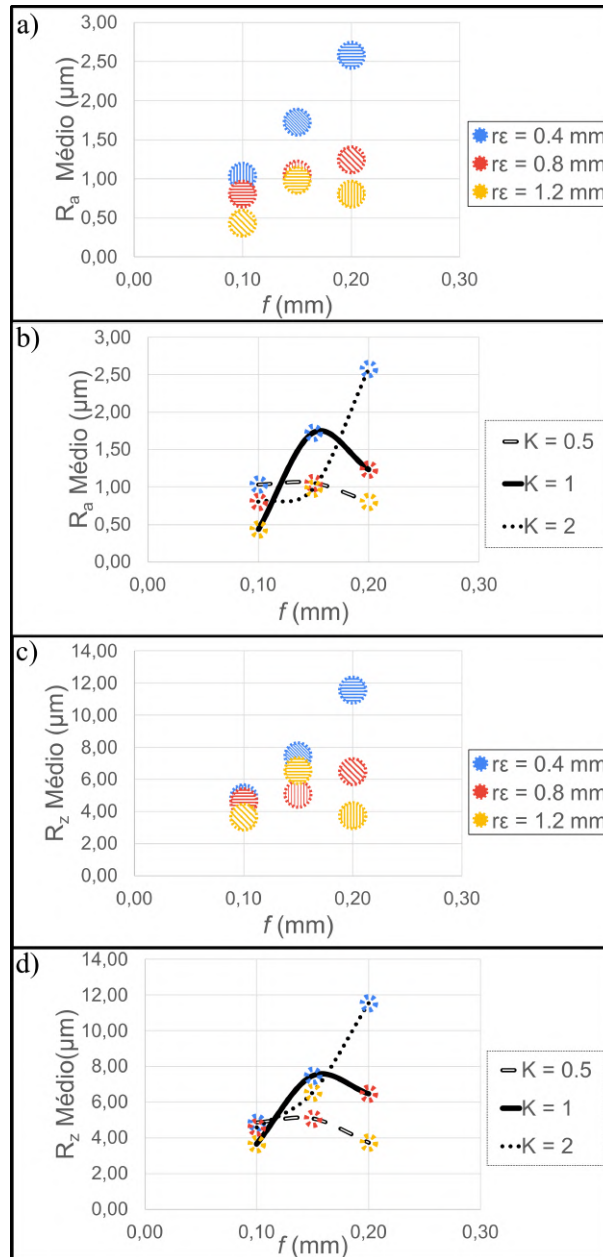
$$R_a(\mu m) = 1,257 \frac{f^2}{18000\sqrt{3}r_\epsilon} \quad (15)$$

Os resultados de força média podem ser observados na Figura 35. Os insertos com raio de ponta de 1,2 mm tiveram um comportamento diferente comparado às outras geometrias, com aumento da força passiva (F_p), tal como notou Sharman, Hughes e Ridgway (2015) com o torneamento de Inconel 718TM.

Os gráficos de influência, demonstrados na Figura 36 e Figura 37, apresentaram que quanto maior o raio de ponta, menores os valores de F_c e de F_f , com tendência de menores valores para K igual a 1, tal como observado no estudo de Ventura, Breidenstein e Denkena (2018) em que diferentes comprimentos de contato ferramenta\peça alteraram as forças, devido a atritos, cargas mecânicas e térmicas. Maiores avanços provocaram maiores forças aplicadas.

Com todos os dados de força de corte obtidos, aproximou-se os resultados para a equação do método de Kienzle (Equação 16), com a pressão específica de corte k_s . A aproximação para

Figura 33 – Gráfico de Influência para o R_a (a) raio de ponta, (b) K ; e R_z (c) raio de ponta e (d) K .




Fonte: Elaborado pelo autor.

k_{s1} e z em termos da espessura de corte h (constantes que variam com a peça de trabalho, material da ferramenta, geometria e outras condições de corte) foram, respectivamente, 1445 N/mm^2 e $0,2955$. Os números, comparando com a literatura para materiais de baixa liga temperados, são viáveis, já que os valores teóricos foram de 2500 a 2800 N/mm^2 e $0,29$ (MACHADO et al., 2015).

$$k_s = \frac{k_{s1}}{h^z} \quad (16)$$

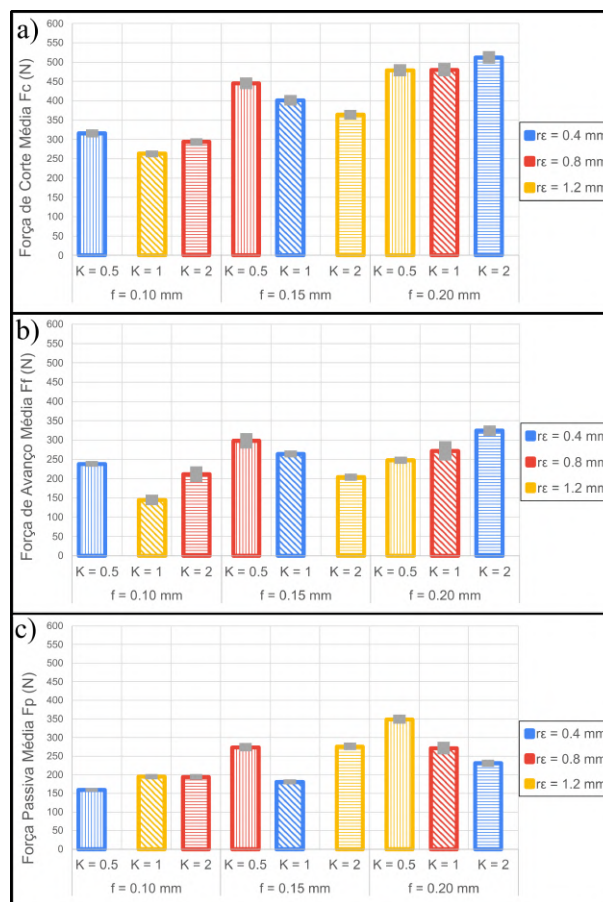
Realizando a análise por meio de Taguchi para a rugosidade e forças, encontrou-se que

Figura 34 – Dados ajustados a curva teórica de rugosidade.



Fonte: Elaborado pelo autor.

Figura 35 – Forças médias (a) força de corte, (b) força de avanço e (c) força passiva.

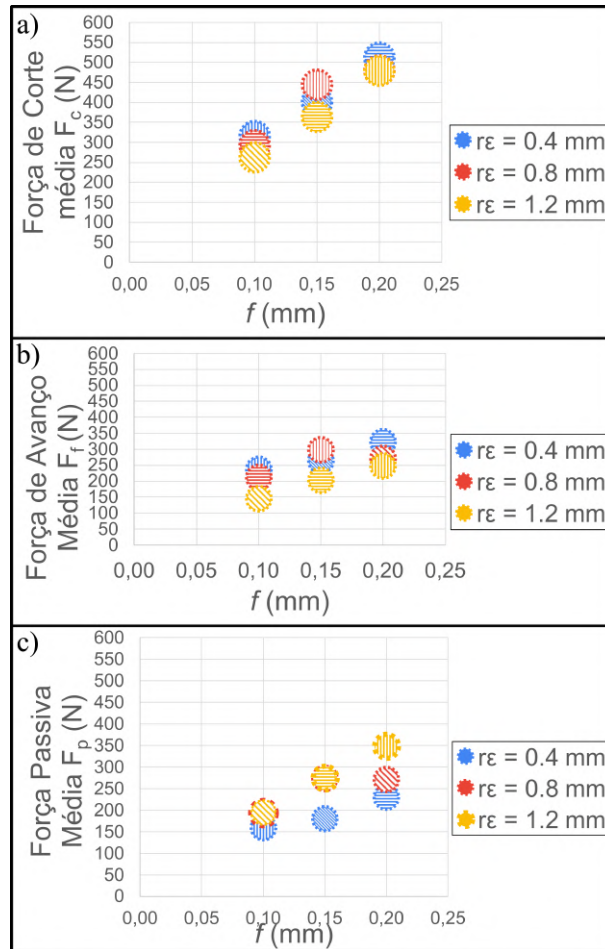


Fonte: Elaborado pelo autor.

as melhores condições para melhores acabamentos superficiais e, conseqüentemente, menores forças foram:

- Rugosidade R_a e R_z : Maiores raios de ponta, menores avanços e K menores;
- Força de corte (F_c) e força de avanço (F_f): Maiores raios de ponta, menores avanços e K igual a 1;
- Força passiva (F_p): Menores raios de ponta, menores avanços e K igual a 1;

Figura 36 – Gráficos de influência para o raio de ponta (a) força de corte, (b) força de avanço e (c) força passiva.

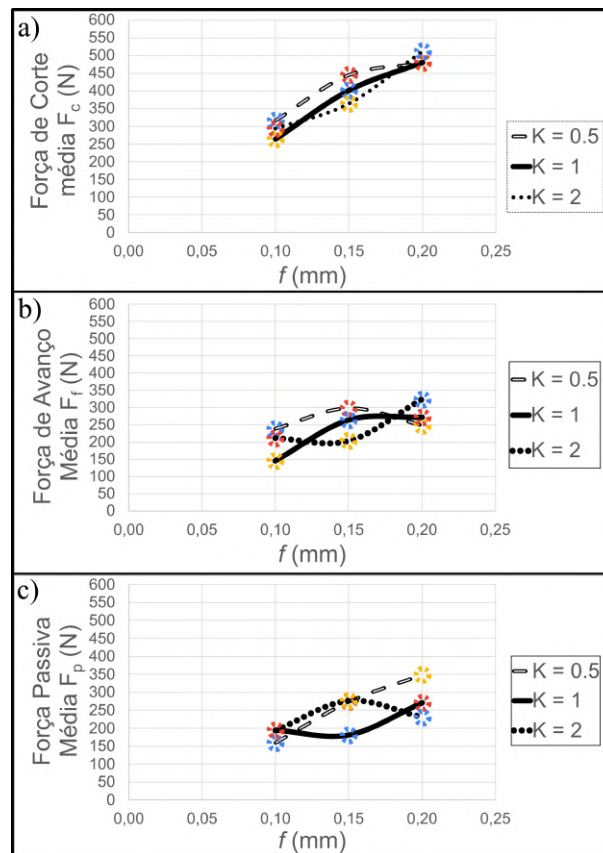


Fonte: Elaborado pelo autor.

A Análise de Variância (ANOVA) foi aplicada para os valores médios e para as razões sinal-ruído. A ANOVA dos valores médios indicam quais variáveis poderiam influenciar nos resultados, enquanto que a da razão sinal-ruído verifica a significância das variáveis quando combinadas. Os resultados encontrados, para um nível de confiança de 90%, foram os seguintes:

- Rugosidade R_a : Possível influência do raio de ponta nos valores médios, enquanto que para a razão SN, todas as variáveis tiveram influência sobre o comportamento do torneamento;
- Rugosidade R_z : Nenhuma das variáveis apresentou influência sobre os resultados de rugosidade;
- Força de corte (F_c): Avanço e raio de ponta foram significantes nos valores médios e para a razão SNs;
- Força de avanço (F_f): Avanço e raio de ponta foram significantes nos valores médios e para a razão SNs;

Figura 37 – Gráficos de influência para o K (a) força de corte, (b) força de avanço e (c) força passiva.



Fonte: Elaborado pelo autor.

- Força passiva (F_p): Avanço e raio de ponta foram significantes para os valores médios. Para a razão SNs, todas as três variáveis foram significantes no processo, incluindo o K ;

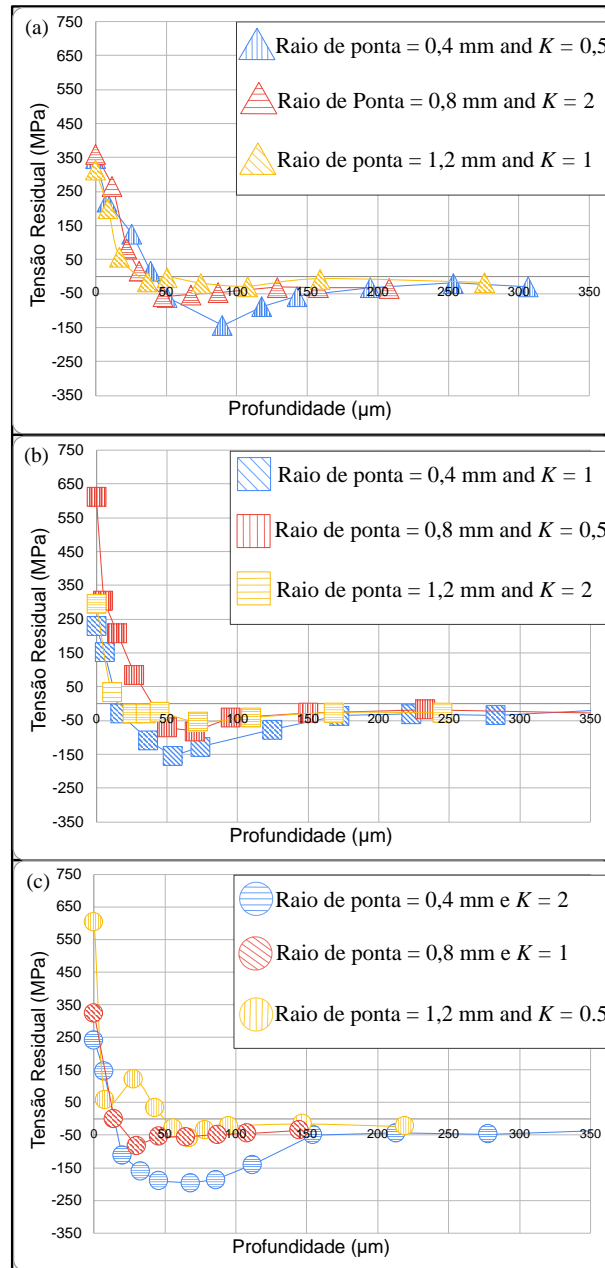
Ou seja, encontrou-se a influência das três variáveis sobre os parâmetros de rugosidade R_a , força de corte (F_c), força de avanço (F_f) e força passiva (F_p).

Quanto aos resultados de tensão residual, as análises iniciais, a partir da verificação dos perfis de tensão residual para a direção circunferencial e radial que podem ser vistos na Figura 38 e Figura 39, demonstraram que os inserts com raio de ponta 0,4 mm apresentaram maior tensão residual compressiva com menores valores de tensão trativas, similares as curvas obtidas em pesquisa realizada por Liu, Takagi e Tsukuda (2004).

Para a verificação da possível influência do K , a análise de Taguchi foi determinado com os diagramas de efeitos principais. A melhor situação para comportamento mais compressivo na peça de trabalho (aumentar a resistência à fadiga e tempo de vida), com menores tensões superficiais e maiores intensidades de compressão do vale foram:

- Direção circunferencial: Para a tensão superficial, menores raios de ponta, maiores avanços e K de 1 ou 2. Para intensidade de compressão menores raios de ponta, maiores avanços e

Figura 38 – Perfis de tensão residual para direção circunferencial: (a) $f = 0,10$ mm, (b) $f = 0,15$ mm e (c) $f = 0,20$ mm.



Fonte: Elaborado pelo autor.

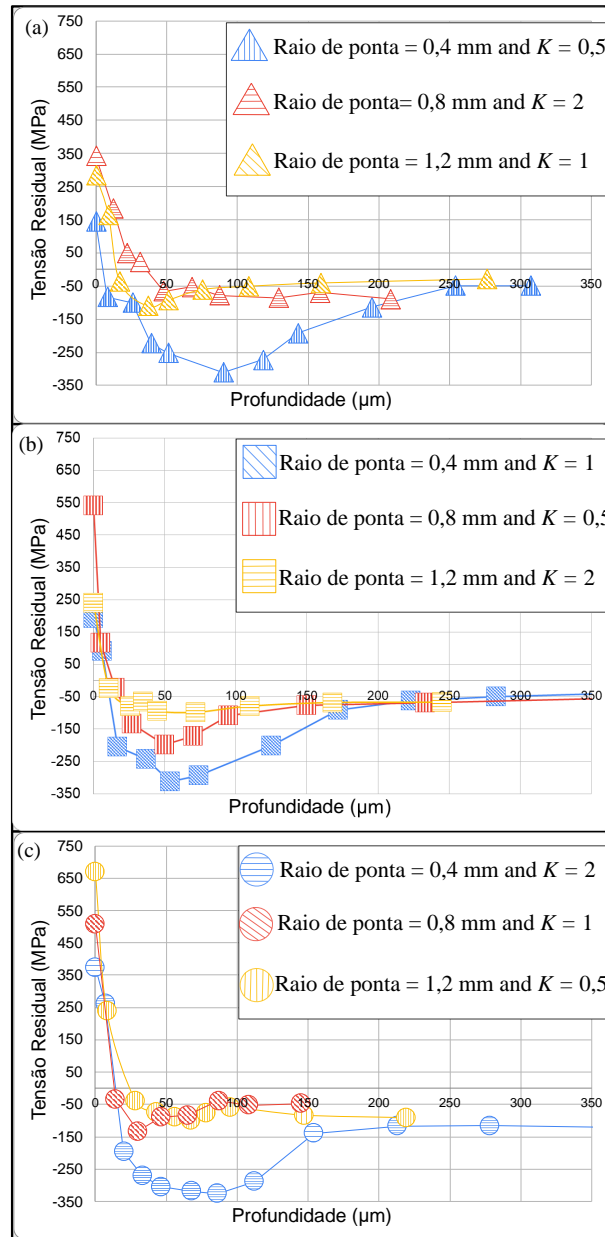
K de 0,5 ou 2;

- Direção radial: Para tensão superficial, menores raios de ponta, menores avanços e K de 0,5. Para a intensidade de compressão, menores raios de ponta, avanços intermediários e K de 0,5;

A ANOVA foi aplicada com nível de confiança de 90%, obtendo os seguintes resultados:

- Direção circunferencial: Para os valores médios, K foi significativa para a tensão superficial,

Figura 39 – Perfis de tensão residual para direção radial: (a) $f = 0,10$ mm, (b) $f = 0,15$ mm e (c) $f = 0,20$ mm.



Fonte: Elaborado pelo autor.

enquanto o raio de ponta foi significativo para a intensidade de compressão. Para os valores de SN, temos K como parâmetro significativo para a tensão superficial; avanço e raio de ponta foram significativos para a intensidade de compressão do vale;

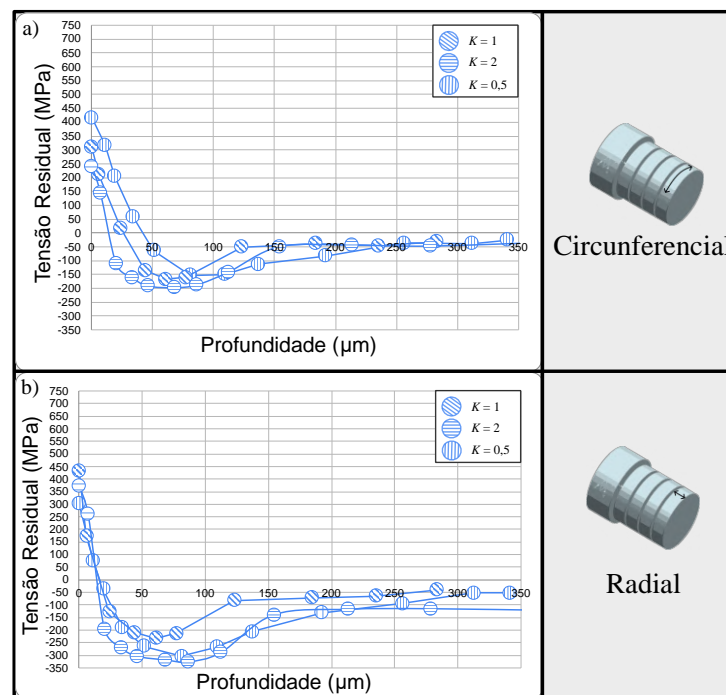
- Direção radial: Nos valores médios e SN, nenhum dos parâmetros influenciaram significativamente os resultados. Para a intensidade de compressão do vale, apenas o raio de ponta teve influência para os valores médios;

Tem-se a influência das variáveis sobre os resultados, sendo que o K influenciou apenas os resultados de tensão superficial. O raio de ponta apresentou maiores influências sobre os

parâmetros de saída tal qual o avanço. Para a completa determinação da influência dos parâmetros nos valores de tensão residual, especialmente o K que não apresentou influências na tensão compressiva, realizou-se as três condições otimizadas.

Para o raio de ponta de 0,4 mm, tivemos o comparativo apresentado na Figura 40, sendo a terceira curva a condição de raio de ponta 0,4 mm, K 2 e avanço (f) 0,20 mm. As curvas para o comparativo de raio de ponta 0,8 mm foram inconclusivos.

Figura 40 – Comparativo de curvas de tensão residual para raio de ponta 0,4 mm.



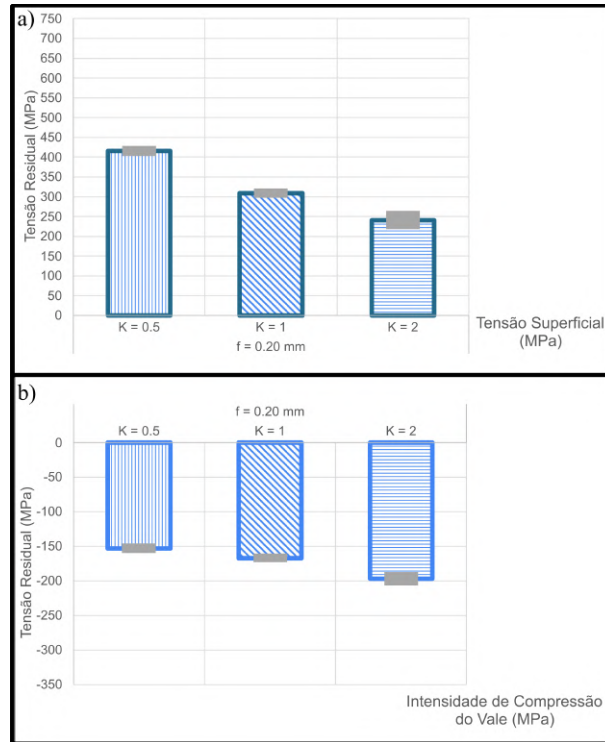
Fonte: Elaborado pelo autor.

Pelas curvas, observou-se uma possível influência do K na direção radial, em que o K igual a 1 teve menor comportamento compressivo, com maior tensão superficial e menor valor absoluto na intensidade de compressão do vale. Na direção circunferencial, as curvas não demonstraram sofrer influência. Na Figura 41 e na Figura 42 apresentou-se os dados de maneira discretizada, facilitando tal observação.

Observando todas as condições, denotou-se que a micro geometria, além dos outros parâmetros, influenciaram nos resultados de saída de tensão residual. As forças para K igual a 1 demonstraram serem menores, o que influenciou nos resultados de tensão e, conseqüentemente, de rugosidade. Isto corroborou com o estudo de Ventura, Breidenstein e Denkena (2018), em que maiores comprimentos de contato possuía maiores comportamentos compressivos.

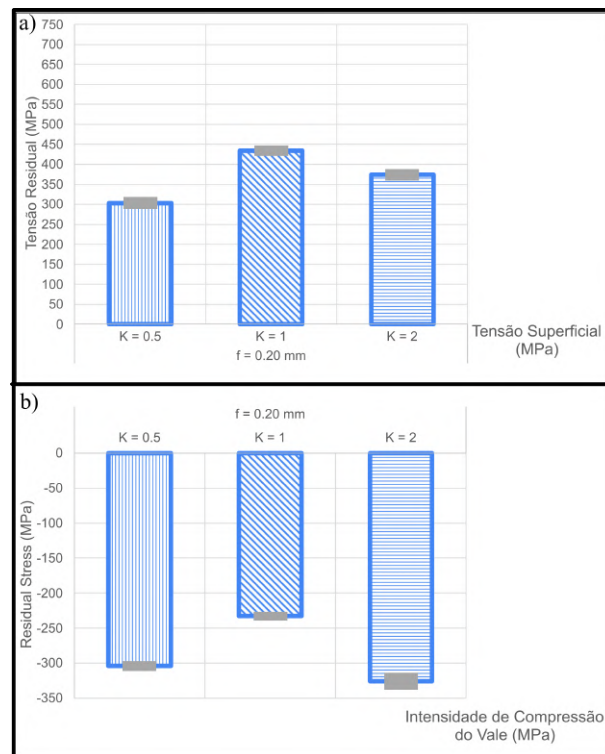
Todos os três parâmetros escolhidos tiveram influencia sobre qualidade superficial, forças e tensão residual. O efeito do raio de ponta e do avanço puderam ser observados nos primeiros nove testes, observado pelos métodos estatísticos, enquanto que o efeito do K foi confirmado pelos novos testes.

Figura 41 – Dados discretizados na direção circunferencial para raio de ponta 0,4 mm.



Fonte: Elaborado pelo autor.

Figura 42 – Dados discretizados na direção radial para raio de ponta 0,4 mm.



Fonte: Elaborado pelo autor.

Após ser realizada a análise, implementou-se os dados sobre os modelos de ANN e ANFIS. Removeu-se dois dados aleatoriamente de saída (R_a e R_z) e entrada de rugosidade (raio de ponta, avanço, K e forças) e um dado de saída (tensão superficial e intensidade de compressão do vale) e entrada de tensão residual. Com estes dados, realizou-se o comparativo demonstrado na Tabela 16 a fim de verificar a capacidade preditiva.

Os dados experimentais retirados foram:

- $R_a = 2,6190 \mu\text{m}$ e $R_z = 11,3723 \mu\text{m}$;
- $R_a = 1,2537 \mu\text{m}$ e $R_z = 6,7887 \mu\text{m}$;
- Tensão superficial Circunferencial = 309 MPa, Tensão superficial Radial = 434 MPa, Compressão do Vale Circunferencial = -167 MPa e Compressão do Vale Radial = -233 MPa.

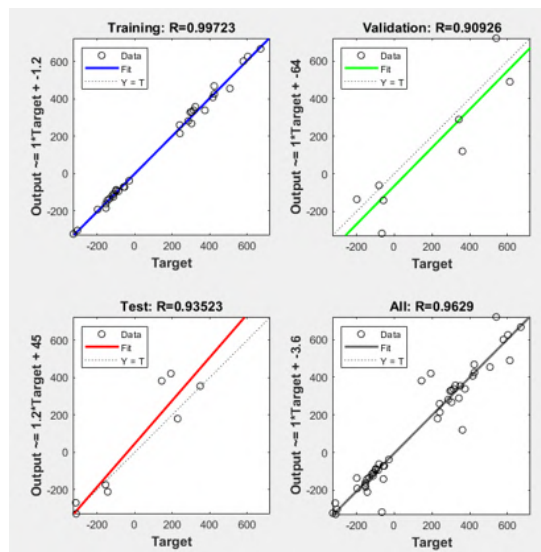
Tabela 16 – Resultados da Predição com modelo ANN para rugosidade no torneamento.

Número de Neurônios	Modelo de Predição ANN				Diferença Média Absoluta Percentual
	Rugosidade Ra (um)	Rugosidade Rz (um)	Rugosidade Ra (um)	Rugosidade Rz (um)	
8	2,4080	10,3176	1,4643	6,2694	9%
	2,6760	12,8628	1,3012	6,5944	
	2,4232	11,2872	1,6235	6,4115	
9	2,4592	10,9541	1,6057	6,1959	8%
	2,5977	11,9997	1,2198	6,385	
	2,6943	11,9484	1,4387	6,3597	
10	2,5565	10,9316	1,2534	7,2442	11%
	2,1237	12,4013	1,5150	8,2680	
	3,1951	13,6789	1,34	7,04	
11	1,4930	8,9806	2,0150	8,1780	21%
	2,1566	9,8400	1,3992	8,4458	
	2,8837	12,7730	1,3426	6,0488	
12	2,3966	10,3016	1,74	7,4756	8%
	2,7702	11,8743	1,2442	7,2376	
	2,5514	11,0564	1,2564	6,4483	

Fonte: Elaborado pelo autor.

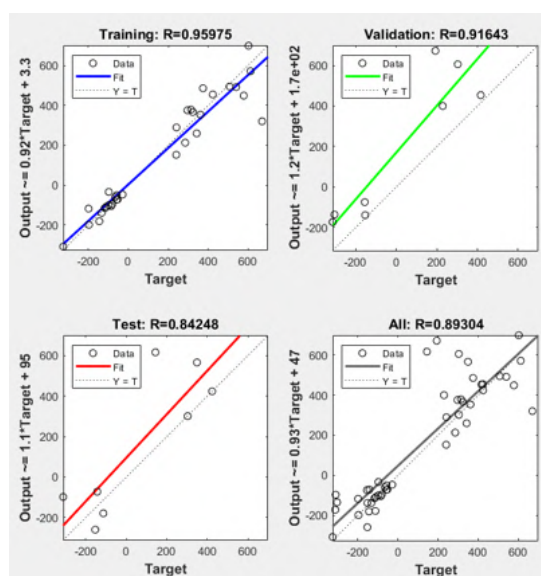
Notou-se boa capacidade preditiva, uma vez que alcançou valores de diferença abaixo de 10%, além de R-valores acima de 0,90, tal como é exemplificado na Figura 43. No entanto, ao se aplicar o modelo sobre os valores de tensão residual (Tabela 17), encontrou-se valores de diferença acima de 20%, o que pode ter ocorrido devido a menor quantidade de dados comparativamente aos de rugosidade (34 dados de rugosidade contra 12 dados de tensão residual). Porém, mesmo com baixa compatibilidade de valores, apresentou R-valor acima de 0,90 tal como na rugosidade (Figura 44).

Figura 43 – Exemplo de R-valor encontrado para previsão de resultado de rugosidade.



Fonte: Elaborado pelo autor.

Figura 44 – Exemplo de R-valor encontrado para previsão de resultado para a tensão residual.



Fonte: Elaborado pelo autor.

Tabela 17 – Resultados da Predição com modelo ANN para as tensões residuais no torneamento.

Número de Neurônios	Modelo de Predição ANN				Diferença Média Absoluta Percentual
	Intensidade de Compressão do Vale (Circunferencial)	Tensão Superficial (Circunferencial)	Intensidade de Compressão do Vale (Radial)	Tensão Superficial (Radial)	
8	-157	149	-182	587	29%
	-114	259	-304	146	
	-157	489	-262	501	
9	-176	237	-340	101	24%
	-197	219	-336	403	
	-145	354	-257	420	
10	-185	230	-275	537	24%
	-177	506	-244	568	
	-217	289	-326	326	
11	-41	314	-205	755	32%
	-161	236	-252	553	
	-182	124	-342	254	
12	-220	263	-381	217	29%
	-91	334	-159	440	
	-153	316	-398	499	

Fonte: Elaborado pelo autor.

Desta maneira, para estudar a aplicação do modelo ANFIS, realizou-se o estudo com os resultados de tensões residuais, para verificação dos resultados. No entanto, como observado na Tabela 18, não se obteve resultados de predição melhores aos já obtidos no ANN, sendo que as funções de pertinência e as regras obtidas a partir do modelo não foram conclusivas.

Tabela 18 – Resultados da Predição com modelo ANFIS para as tensões residuais no torneamento.

Intensidade de Compressão do Vale (Circunferencial)			Tensão Superficial (Circunferencial)		
Experimental	Predição	Diferença Absoluta Percentual	Experimental	Predição	Diferença Absoluta Percentual
-167	-271,9	63%	309	-77,7	125%

Intensidade de Compressão do Vale (Radial)			Tensão Superficial (Radial)		
Experimental	Predição	Diferença Absoluta Percentual	Experimental	Predição	Diferença Absoluta Percentual
-233	-243,1	4%	434	57,3	87%

Fonte: Elaborado pelo autor.

Com isto, verificou-se que, tal como o verificado por estudo de Neto et al. (2013), as redes neurais artificiais obtiveram maior precisão, mesmo que com a utilização de poucos dados e apenas uma camada oculta. Ademais, o estudo sobre o torneamento verificou que a quantidade de dados alimentados de rugosidade e tensão residual foram suficientes para o treinamento adequado do modelo (R-valor próximos a 1).

Desta forma, a ANN tornou-se o modelo mais adequado para a quantidade de dados experimentais obtidos, possuindo melhores capacidades preditivas e maiores precisões relativas. Esta se torna uma ferramenta importante para a realização da otimização ao possibilitar a previsão dos resultados de maneira satisfatória.

5 CONCLUSÃO

Neste trabalho foram abordados tópicos relacionados a retificação, sendo a retificação de superfície de folga e o torneamento de ligas de aço 4142 por insertos com aresta de corte retificadas em dois chanfros, buscando realizar análise estatística e por meio da Metodologia de Taguchi para verificar as possíveis melhores condições de ensaios para os estudos, e verificar a capacidade da IA se tornar uma ferramenta de predição e, conseqüentemente, otimização.

Para a retificação das superfícies de folga, denotou-se a não-linearidade dos resultados. Assim, verificou-se a influência dos parâmetros, escolhidos após vasta revisão bibliográfica, sobre os resultados por meio da análise estatística, assim como da possível melhor situação de acabamento superficial, com exploração estatística mais aprofundada que no torneamento em vias de conferir a confiabilidade dos experimentos. Os testes de Chauvenet e Tukey demonstraram que os testes estavam normalizados, além de ter diferença significativa quando observado os valores de rugosidade R_z em 64%, mas com pouca diferença nas rugosidades R_a ; porém não alterariam os resultados da análise de ANOVA e Taguchi já que ambos tiveram comportamentos semelhantes nestas análises.

Para o torneamento, demonstrou-se a importância da preparação da micro geometria do inserto para ser utilizado como ferramenta de corte, sendo que o parâmetro de micro geometria K foi importante para influenciar as forças passivas, além da rugosidade R_a . Verificou-se o efeito das variáveis escolhidas (raio de ponta, avanço e fator de forma K), notando-se a sua influência por meio da análise estatística por análise de variância, além da observação dos melhores cenários possíveis para se garantir o melhor acabamento superficial e de maior comportamento de tensão compressiva na peça torneada, garantindo a sua confiabilidade nos testes por meio das repetições dos experimentos.

Avaliados estatisticamente e por Metodologia de Taguchi as melhores condições, ambos os estudos foram avaliados quanto a possibilidade de aplicação das inteligências artificiais que otimizem os processos, sendo isto viabilizado pela possibilidade de uso para a determinação e predição de resultados de qualidade superficial ou tensão residual próximos as melhores condições determinadas, por elaboração, desenvolvimento e utilização de modelos de ANN e o ANFIS, para se tornarem uma ferramenta útil para o processamento mecânico da retificação.

Os estudos no torneamento tornaram-se peças-chave para o entendimento inicial do comportamento dos modelos neurais, uma vez que pode ser avaliado duas situações diferentes, sendo o acabamento superficial e as tensões residuais, verificando a capacidade de predição com dados escolhidos aleatoriamente para verificar o comportamento e capacidade de predição. Com isto avaliado, foi possível a aplicação nos dados de retificação das superfícies de folga com conhecimento das arquiteturas mais viáveis, pautado sobre o conhecimento experimental

e teóricos, analisando a predição de condições que reduzissem a rugosidade determinados por Taguchi e ANOVA.

Verificou-se que, em situações para menores quantidades de dados como neste projeto, o ANN apresentou-se como uma arquitetura mais viável nas condições apresentadas, sendo que seu erro absoluto percentual aos valores experimentais foram menores que o apresentado pelo ANFIS, contrariando os resultados de alguns autores mas pautado por estudos de outros.

Demonstrou-se que as condições de acabamento superficial eram melhores previstas quando analisadas conjuntamente. Quando implementados as rugosidades R_a e R_z de maneira separada nos modelos neurais (como única variável de saída), o treinamento foi prejudicado, afetando a concordância entre os valores experimentais e os modelos obtidos. Quando conjuntamente aplicados (ou seja, como duas variáveis de saída), os modelos obtinham melhores treinamentos e compatibilidades.

Desta maneira, desenvolveu-se um modelo de rede artificial neural adequado para os processamentos de conformação com menores quantidades de dados, com boa capacidade preditiva em consonância com os baixos valores de diferença percentual absoluta.

Esta dissertação apresenta como colaboração uma análise bibliográfica para os processamentos mecânicos de retificação e torneamento, além de abordagem sobre os modelos aplicados de inteligência artificial baseados no ANN e ANFIS, com revisão sobre a aplicação dos mesmos sobre as conformações. Ademais, desenvolveu-se um modelo da IA para ser utilizado como ferramenta para otimização, a ser utilizado para a predição dos resultados com confiabilidade nos resultados gerados artificialmente. Os modelos desenvolvidos tornaram-se versões iniciais que poderiam ser aprimorados em futuros desenvolvimentos de novas pesquisas e obtenção de maiores quantidades de dados.

5.1 Contribuições pontuais

- CBECIMat 2022: Apresentação de dados da revisão bibliográfica de retificação de superfície de folga dos insertos para a determinação de variáveis de entrada dos modelos de inteligência artificial (SINZATO; FONTES; ANTONIALLI, 2022);
- COBEF 2023: Revisão de escrita de artigo denominado "Projeto e avaliação de um porta-ferramentas especial para fresamento", buscando auxiliar na correção de fundamentos teóricos e textuais (ROSA et al., 2023);
- PROCEDIA CIRP 2024: Artigo publicado sobre os resultados obtidos no torneamento de ligas de aço 4142 com insertos retificados, especificamente rugosidade e força (SINZATO et al., 2024b);
- SBPMat 2024: Apresentação de aplicação de modelos neurais em dados de torneamento de ligas 4142 com insertos retificados (SINZATO et al., 2024a);

5.2 Trabalhos Futuros

Como sugestões de trabalhos futuros, tem-se os seguintes:

- Aplicação do modelo em outros projetos que envolvam a retificação, para entender o campo de estudo em que os modelos de inteligência artificial podem ser aplicados;
- Aplicação de ANN com mais de uma camada, em vias de verificar a sua capacidade de predição, além do uso de mais variações dos neurônios;
- Uso de outras ferramentas de inteligência artificial para determinar se outras arquiteturas poderiam ser aplicadas;
- Estudos mais aprofundados do ANFIS, com a utilização de mais dados, para verificar a sua possível aplicabilidade;
- Alteração de variáveis de entrada e saída, verificando o comportamento da inteligência artificial.

REFERÊNCIAS

- ABBOUD, E. et al. Residual stresses and surface integrity of ti-alloys during finish turning – guidelines for compressive residual stresses. *Procedia CIRP*, v. 45, p. 55–58, 2016. ISSN 2212-8271. 3rd CIRP Conference on Surface Integrity. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212827116003516>>. Citado na página 18.
- AGARWAL, S. Optimizing machining parameters to combine high productivity with high surface integrity in grinding silicon carbide ceramics. *Ceramics International*, v. 42, n. 5, p. 6244–6262, 2016. ISSN 0272-8842. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0272884216000365>>. Citado 2 vezes nas páginas 27 e 28.
- AGARWAL, S.; RAO, P. V. Grinding characteristics, material removal and damage formation mechanisms in high removal rate grinding of silicon carbide. *International Journal of Machine Tools and Manufacture*, Elsevier, v. 50, n. 12, p. 1077–1087, 2010. Citado 2 vezes nas páginas 27 e 28.
- AGARWAL, S.; RAO, P. V. Predictive modeling of force and power based on a new analytical undeformed chip thickness model in ceramic grinding. *International Journal of Machine Tools and Manufacture*, Elsevier, v. 65, p. 68–78, 2013. Citado na página 28.
- AGRAWAL, S. S.; YADAVA, V. Modeling and prediction of material removal rate and surface roughness in surface-electrical discharge diamond grinding process of metal matrix composites. *Materials and Manufacturing Processes*, Taylor & Francis, v. 28, n. 4, p. 381–389, 2013. Citado 2 vezes nas páginas 35 e 40.
- ALEXANDRE, F. et al. Tool condition monitoring of aluminum oxide grinding wheel using ae and fuzzy model. *The International Journal of Advanced Manufacturing Technology*, v. 96, 04 2018. Citado na página 15.
- BENLAHMIDI, S. et al. Design optimization of cutting parameters when turning hardened aisi h11 steel (50 hrc) with cbn7020 tools. *Int J Adv Manuf Technol*, v. 89, p. 803–820, 2017. Citado 2 vezes nas páginas 29 e 60.
- BONNY, K. et al. Influence of electrical discharge machining on the reciprocating sliding friction and wear response of wc–co cemented carbides. *International Journal of Refractory Metals and Hard Materials*, v. 27, n. 2, p. 350–359, 2009. ISSN 0263-4368. International Conference on the Science of Hard Materials - 9. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S026343680800108X>>. Citado 2 vezes nas páginas 14 e 28.
- BORDINASSI Éd C. *Contribuição ao estudo da integridade superficial de um aço inoxidável super-duplex após usinagem*. Dissertação (Tese (Doutorado em Engenharia Mecânica de Projeto de Fabricação) - Escola Politécnica) — Universidade de São Paulo, São Paulo, 2006. Citado na página 20.
- BROWN, I.; SCHOOP, J. The effect of cutting edge geometry, nose radius and feed on surface integrity in finish turning of ti-6al4v. *Procedia CIRP*, v. 87, p. 142–147, 2020. ISSN 2212-8271. 5th CIRP Conference on Surface Integrity (CSI 2020). Disponível em:

- <<https://www.sciencedirect.com/science/article/pii/S2212827120301414>>. Citado 2 vezes nas páginas 29 e 60.
- BUTTON, S. T. Metodologia para planejamento experimental e análise de resultados. *São Paulo*, p. 4, 2005. Citado 5 vezes nas páginas 43, 45, 46, 47 e 50.
- BYRNE, G.; DORNFELD, D.; DENKENA, B. Advancing cutting technology. *CIRP Annals*, v. 52, n. 2, p. 483–507, 2003. ISSN 0007-8506. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0007850607602005>>. Citado na página 29.
- CASAS, B. et al. Mechanical strength improvement of electrical discharge machined cemented carbides through pvd (tin, tialn) coatings. *Thin Solid Films*, Elsevier, v. 447, p. 258–263, 2004. Citado na página 28.
- CASAS, B.; TORRES, Y.; LLANES, L. Fracture and fatigue behavior of electrical-discharge machined cemented carbides. *International Journal of Refractory Metals and Hard Materials*, Elsevier, v. 24, n. 1-2, p. 162–167, 2006. Citado na página 28.
- CHEN, S. S.; CHEUNG, C. F.; ZHANG, F. H. An experimental and theoretical analysis of surface generation in the ultra-precision grinding of hard and brittle materials. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 97, p. 2715–2729, 2018. Citado na página 44.
- CHENG, K. *Machining Dynamics: Fundamentals, Applications and Practices*. [S.l.: s.n.], 2009. ISBN 978-1-84628-367-3. Citado 2 vezes nas páginas 20 e 22.
- CHENG, Q. et al. Undeformed chip thickness with composite ultrasonic vibration-assisted face grinding of silicon carbide: Modeling, computation and analysis. *Precision Engineering*, v. 86, p. 48–65, 2024. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0141635923002052>>. Citado 2 vezes nas páginas 27 e 28.
- CHENG, Y. et al. Ultrasonic surface rolling strengthening and its parameter optimization on bearing raceway. *Materials & Design*, v. 232, p. 112156, 2023. ISSN 0264-1275. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0264127523005713>>. Citado 2 vezes nas páginas 27 e 28.
- CRUZ, D. C. *Avaliação da integridade superficial de insertos retificados da liga WC-Co para ferramentas de corte*. Dissertação (Tese (Doutorado)) - Universidade Federal de São Carlos — Universidade Federal de São Carlos, São Carlos, 2021. Citado na página 45.
- DAGNALL, H. *Exploring Surface Texture*. Rank Taylor Hobson, 1980. ISBN 9780901920034. Disponível em: <<https://books.google.com.br/books?id=xqeZAAAACAAJ>>. Citado 2 vezes nas páginas 20 e 21.
- DAHLMAN, P.; GUNNBERG, F.; JACOBSON, M. The influence of rake angle, cutting feed and cutting depth on residual stresses in hard turning. *Journal of Materials Processing Technology*, v. 147, n. 2, p. 181–184, 2004. ISSN 0924-0136. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924013603010811>>. Citado na página 30.
- DAVIM, J. P. et al. Workpiece surface integrity. *Machining: fundamentals and recent advances*, Springer, p. 59–96, 2008. Citado na página 18.

- DELGADO, Y. P. et al. Influence of wire-edm on high temperature sliding wear behavior of wc10co (cr/v) cemented carbide. *International Journal of Refractory Metals and Hard Materials*, Elsevier, v. 41, p. 198–209, 2013. Citado na página 28.
- DENKENA, B.; BIERMANN, D. Cutting edge geometries. *CIRP Annals*, v. 63, n. 2, p. 631–653, 2014. ISSN 0007-8506. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0007850614001917>>. Citado 2 vezes nas páginas 24 e 29.
- DENKENA, B.; KÖHLER, J.; VENTURA, C. Customized cutting edge preparation by means of grinding. *Precision Engineering*, v. 37, n. 3, p. 590–598, 2013. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0141635913000093>>. Citado na página 48.
- DENKENA, B.; LUCAS, A.; BASSETT, E. Effects of the cutting edge microgeometry on tool wear and its thermo-mechanical load. *CIRP Annals*, v. 60, n. 1, p. 73–76, 2011. ISSN 0007-8506. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0007850611000990>>. Citado 2 vezes nas páginas 29 e 60.
- DINIZ, A.; MARCONDES, F.; COPPINI, N. *Tecnologia da usinagem dos materiais*. [S.l.]: ArtLiber, 2014. Citado 3 vezes nas páginas 20, 22 e 23.
- FANG, S. et al. Surface integrity assessment of laser treated and subsequently coated cemented carbides. *International Journal of Refractory Metals and Hard Materials*, Elsevier, v. 83, p. 104982, 2019. Citado na página 28.
- GAO, X. et al. Ductile-brittle transition mechanism of sic particle-reinforced al-mmc's under ultrasonic assisted grinding with single grain. *Journal of Materials Research and Technology*, v. 28, p. 3655–3669, 2024. ISSN 2238-7854. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2238785423033173>>. Citado 2 vezes nas páginas 27 e 28.
- GONÇALVES, A. R. *Redes Neurais Artificiais*. 2009. Disponível em: <www.dca.fee.unicamp.br/~andreric>. Citado 2 vezes nas páginas 36 e 37.
- GOPAL, A. V.; RAO, P. V. Selection of optimum conditions for maximum material removal rate with surface finish and damage as constraints in sic grinding. *International Journal of Machine Tools and Manufacture*, Elsevier, v. 43, n. 13, p. 1327–1336, 2003. Citado 2 vezes nas páginas 27 e 28.
- GUAN, J.; ZHAO, Y. Non-contact grinding/thinning of silicon carbide wafer by pure edm using a rotary cup wheel electrode. *Precision Engineering*, Elsevier, v. 74, p. 209–223, 2022. Citado na página 28.
- GÜHRING, K. *Hochleistungsschleifen: eine Methode zur Leistungssteigerung der Schleifverfahren durch hohe Schnittgeschwindigkeiten*. [S.l.]: na, 1967. Citado na página 24.
- GUO, S. et al. Microstructural evolution in ultra-precision grinding of al/sicp metal matrix composites. *Precision Engineering*, v. 83, p. 12–21, 2023. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0141635923000909>>. Citado 2 vezes nas páginas 27 e 28.
- GUPTA, T. et al. Prediction of mechanical properties of rubberised concrete exposed to elevated temperature using ann. *Measurement*, p. 106870, 07 2019. Citado na página 38.

HAN, S. et al. Residual stress profiles induced by machining of two types of 27mncr5 hardened steels. *Procedia CIRP*, v. 108, p. 282–286, 2022. ISSN 2212-8271. 6th CIRP Conference on Surface Integrity. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212827122005376>>. Citado na página 50.

HARSHA, N. et al. Prediction of machinability characteristics of ti6al4v alloy using neural networks and neuro-fuzzy techniques. *Materials Today: Proceedings*, v. 5, n. 2, Part 2, p. 8454–8463, 2018. ISSN 2214-7853. International Conference on Emerging Trends in Materials and Manufacturing Engineering (IMME17), March 10-12, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785317328146>>. Citado na página 41.

HEGEMAN, J.; De Hosson, J.; de With, G. Grinding of wc-co hardmetals. *Wear*, v. 248, n. 1, p. 187–196, 2001. ISSN 0043-1648. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0043164800005615>>. Citado na página 14.

HO, S.-Y. et al. Accurate modeling and prediction of surface roughness by computer vision in turning operations using an adaptive neuro-fuzzy inference system. *International Journal of Machine Tools and Manufacture*, v. 42, n. 13, p. 1441–1446, 2002. ISSN 0890-6955. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0890695502000780>>. Citado na página 41.

HORIKAWA, S.-i.; FURUHASHI, T.; UCHIKAWA, Y. On fuzzy modeling using fuzzy neural networks with the back-propagation algorithm. *IEEE Transactions on Neural Networks*, v. 3, n. 5, p. 801–806, 1992. Citado na página 35.

ICHIDA, Y.; ZOUAGHI, N.; KISHI, K. Analysis of ductile mode ground surface of optical glass by atomic force microscopy. In: USUI, E. (Ed.). *Advancement of Intelligent Production*. Amsterdam: Elsevier, 1994. p. 491–496. ISBN 978-0-444-81901-7. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780444819017500967>>. Citado na página 40.

INASAKI, I.; TöNSHOFF, H.; HOWES, T. Abrasive machining in the future. *CIRP Annals*, v. 42, n. 2, p. 723–732, 1993. ISSN 0007-8506. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0007850607625359>>. Citado na página 15.

ISO.4287. *Rugosidade: Método do perfil—termos, definições e parâmetros da rugosidade*. Rio de Janeiro: ABNT, 2002. Citado na página 21.

ISO.513. *ISO 513: 2012. Classification and Application of Hard Cutting Materials for Metal Removal with Defined Cutting Edges—Designation of the Main Groups and Groups of Application*. [S.l.]: The International Organization for Standardization Geneva, Switzerland, 2012. Citado na página 45.

JANG, J.-S. Anfis adaptive-network-based fuzzy inference system. *Systems, Man and Cybernetics, IEEE Transactions on*, v. 23, p. 665 – 685, 06 1993. Citado na página 35.

JHA, J. K.; JHA, S. K. Assessment of surface integrity in diamond grinding – based hybrid machining of tungsten free carbide based hard metal. *Journal of Physics: Conference Series*, IOP Publishing, v. 1240, n. 1, p. 012057, jul 2019. Disponível em: <<https://dx.doi.org/10.1088/1742-6596/1240/1/012057>>. Citado na página 14.

KHOSHAIM, A. B. et al. Prediction of residual stresses in turning of pure iron using artificial intelligence-based methods. *Journal of Materials Research and Technology*, v. 11, p. 2181–2194, 2021. ISSN 2238-7854. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S223878542100168X>>. Citado 2 vezes nas páginas 19 e 41.

KIM, P. *MATLAB Deep Learning*. [S.l.]: Apress, 2017. Citado 5 vezes nas páginas 31, 32, 36, 37 e 38.

KLOCKE, F.; KUCHLE, A. *Manufacturing Processes 2: Grinding, Honing, Lapping*. Springer Berlin Heidelberg, 2009. (RWTHedition). ISBN 9783540922599. Disponível em: <<https://books.google.com.br/books?id=rHiNm-OISN8C>>. Citado 5 vezes nas páginas 23, 24, 25, 26 e 52.

KOPAC, J.; KRAJNIK, P. High-performance grinding—a review. *Journal of Materials Processing Technology*, v. 175, n. 1, p. 278–284, 2006. ISSN 0924-0136. Achievements in Mechanical & Materials Engineering. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924013605004000>>. Citado na página 23.

KUMAR, S.; CHOUDHURY, S. Prediction of wear and surface roughness in electro-discharge diamond grinding. *Journal of Materials Processing Technology*, v. 191, n. 1, p. 206–209, 2007. ISSN 0924-0136. Advances in Materials and Processing Technologies, July 30th - August 3rd 2006, Las Vegas, Nevada. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924013607002749>>. Citado na página 40.

KÖNIG, W.; WERNER, G.; YOUNIS, M. A. Entwicklung von parametern zur darstellung des arbeitsergebnisses beim schleifen. *Industrie Anzeiger*, v. 93, p. 763–767, 12 1971. Citado na página 25.

LEE, K.-C.; HO, S.-J.; HO, S.-Y. Accurate estimation of surface roughness from texture features of the surface image using an adaptive neuro-fuzzy inference system. *Precision Engineering*, v. 29, n. 1, p. 95–100, 2005. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S014163590400056X>>. Citado na página 41.

LI, G. et al. Analysis and prediction of residual stresses based on cutting temperature and cutting force in rough turning of ti-6al-4v. *Heliyon*, v. 8, n. 11, p. e11661, 2022. ISSN 2405-8440. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405844022029498>>. Citado na página 18.

LI, Y. et al. Study of material removal mechanisms in grinding of c/sic composites via single-abrasive scratch tests. *Ceramics International*, Elsevier, v. 45, n. 4, p. 4729–4738, 2019. Citado 2 vezes nas páginas 27 e 28.

LIU, C. et al. Grinding force control in an automatic surface finishing system. *Journal of Materials Processing Technology*, Elsevier, v. 170, n. 1-2, p. 367–373, 2005. Citado na página 43.

LIU, M.; TAKAGI, J. ichiro; TSUKUDA, A. Effect of tool nose radius and tool wear on residual stress distribution in hard turning of bearing steel. *Journal of Materials Processing Technology*, v. 150, n. 3, p. 234–241, 2004. ISSN 0924-0136. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S092401360400233X>>. Citado 2 vezes nas páginas 30 e 65.

LLANES, L. et al. Influence of electrical discharge machining on the sliding contact response of cemented carbides. *International Journal of Refractory Metals and Hard Materials*, Elsevier, v. 19, n. 1, p. 35–40, 2001. Citado na página 28.

MACHADO, R. et al. *Teoria da usinagem dos materiais*. [S.l.]: Edgard Blücher, 2015. Citado 5 vezes nas páginas 15, 20, 23, 24 e 62.

MAENG, S. et al. An analytical model for grinding force prediction in ultra-precision machining of wc with pcd micro grinding tool. *Int. J. of Precis. Eng. and Manuf.-Green Tech.*, v. 7, p. 1031–1045, 2020. Disponível em: <<https://link.springer.com/article/10.1007/s40684-020-00199-2>>. Citado 2 vezes nas páginas 27 e 28.

MARTÍNEZ, E. et al. Diamond coatings on electrical-discharge machined hardmetals. *Diamond and related materials*, Elsevier, v. 12, n. 3-7, p. 762–767, 2003. Citado na página 27.

MATLAB. *MATLAB version: (R2019a)*. Natick, Massachusetts, United States: The MathWorks Inc., 2022. Disponível em: <<https://www.mathworks.com>>. Citado na página 39.

MCCULLOCH, W. S.; PITTS, W. H.; MCCULLOCH, W. A logical calculus of the ideas immanent in nervous activity. *Embodiments Mind*, p. 19–38, 2016. Citado na página 36.

MEYER, R.; KÖHLER, J.; DENKENA, B. Influence of the tool corner radius on the tool wear and process forces during hard turning. *Int J Adv Manuf Technol*, v. 58, p. 933–940, 2012. Citado na página 30.

MONDELIN, A. et al. Hybrid model for the prediction of residual stresses induced by 15-5ph steel turning. *International Journal of Mechanical Sciences*, v. 58, n. 1, p. 69–85, 2012. ISSN 0020-7403. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020740312000598>>. Citado na página 19.

MONIER, A. et al. Modeling and simulation of the advanced structured surfaces machined by specially patterned grinding wheels via the structuring grinding process. *Int J Adv Manuf Technol*, v. 119, p. 3321–3342, 2022. Disponível em: <<https://link.springer.com/article/10.1007/s00170-021-08296-5>>. Citado 2 vezes nas páginas 27 e 28.

MONTGOMERY, D. *Montgomery: design and analysis of experiments*. John Willy & Sons, 2017. Citado 2 vezes nas páginas 43 e 44.

MONTGOMERY, D.; ST, C. *Design and Analysis of Experiments, 9th Edition*. [S.l.]: John Wiley & Sons, Inc., 2022. ISBN 9781119113478 (PBK) ; 9781119299455 (EVALC). Citado na página 48.

NAKAI, M. E. et al. Evaluation of neural models applied to the estimation of tool wear in the grinding of advanced ceramics. *Expert Systems with Applications*, v. 42, n. 20, p. 7026–7035, 2015. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417415003280>>. Citado na página 39.

NETO, F. et al. Neural models for predicting hole diameters in drilling processes. *Procedia CIRP*, v. 12, p. 49–54, 2013. ISSN 2212-8271. Eighth CIRP Conference on Intelligent Computation in Manufacturing Engineering. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212827113006513>>. Citado 2 vezes nas páginas 41 e 74.

NGUYEN, H. T.; WALKER, C.; WALKER, E. A. *A first course in fuzzy logic*. [S.l.]: Chapman and Hall/CRC, 2018. Citado na página 31.

NORVIG, P.; RUSSELL, S. *Inteligência artificial: Tradução da 3a Edição*. Elsevier Brasil, 2014. ISBN 9788535251418. Disponível em: <<https://books.google.com.br/books?id=BsNeAwAAQBAJ>>. Citado na página 30.

NOVOVIC, D. et al. The effect of surface and subsurface condition on the fatigue life of ti-25v-15cr-2al-0.2 c% wt alloy. *CIRP Annals*, Elsevier, v. 65, n. 1, p. 523–528, 2016. Citado na página 28.

OLIVEIRA, J. Gomes de; DORNFELD, D. Application of ae contact sensing in reliable grinding monitoring. *Cirp Annals-manufacturing Technology - CIRP ANN-MANUF TECHNOL*, v. 50, p. 217–220, 12 2001. Citado na página 14.

PAKNEJAD, M. et al. Laser-assisted surface grinding of innovative superhard sic-bonded diamond (dsic) materials. *Ceramics International*, v. 50, n. 11, Part A, p. 18391–18407, 2024. ISSN 0272-8842. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0272884224008459>>. Citado 2 vezes nas páginas 27 e 28.

PAN, Y. et al. New insights into the methods for predicting ground surface roughness in the age of digitalisation. *Precision Engineering*, v. 67, p. 393–418, 2021. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0141635920309764>>. Citado 5 vezes nas páginas 22, 31, 37, 38 e 45.

PANDIYAN, V. et al. Modelling and monitoring of abrasive finishing processes using artificial intelligence techniques: A review. *Journal of Manufacturing Processes*, v. 57, p. 114–135, 09 2020. Citado 4 vezes nas páginas 14, 15, 16 e 22.

PATURI, U. M. R. et al. Modeling of tool wear in machining of aisi 52100 steel using artificial neural networks. *Materials Today: Proceedings*, v. 38, p. 2358–2365, 2021. ISSN 2214-7853. International Conference & Exposition on Mechanical, Material and Manufacturing Technology (ICE3MT). Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785320350744>>. Citado na página 40.

PRAKASAM, P. K.; SUBBIAH, S. Analysis of 1d abrasive vibratory finishing using acoustic emission. Volume 1: Processing, 2013. Disponível em: <<https://doi.org/10.1115/MSEC2013-1210>>. Citado na página 14.

QU, S. et al. Grinding characteristics and removal mechanisms of unidirectional carbon fibre reinforced silicon carbide ceramic matrix composites. *Ceramics International*, Elsevier, v. 45, n. 3, p. 3059–3071, 2019. Citado 2 vezes nas páginas 27 e 28.

ROSA, E. B. L. et al. Projeto e avaliação de um porta-ferramentas especial para fresamento. *Proceedings COBEF 2023*, 2023. Disponível em: <<https://abcm.org.br/proceedings/view/COF23/0207>>. Citado na página 76.

ROUTARA, B. C. et al. Combined quality loss (cql) concept in wpc-a-based taguchi philosophy for optimization of multiple surface quality characteristics of uns c34000 brass in cylindrical grinding. *The International Journal of Advanced Manufacturing Technology*, Springer, v. 51, p. 135–143, 2010. Citado na página 44.

ROY, S.; BHATTACHARYYA, A.; BANERJEE, S. Analysis of effect of voltage on surface texture in electrochemical grinding by autocorrelation function. *Tribology international*, Elsevier, v. 40, n. 9, p. 1387–1393, 2007. Citado 2 vezes nas páginas 27 e 28.

SAGLAM, H.; UNSACAR, F.; YALDIZ, S. An experimental investigation as to the effect of cutting parameters on roundness error and surface roughness in cylindrical grinding. *International journal of Production research*, Taylor & Francis, v. 43, n. 11, p. 2309–2322, 2005. Citado na página 44.

SARAVANAKUMAR, A. et al. Analysis of process parameters in surface grinding process. *Materials Today: Proceedings*, Elsevier, v. 5, n. 2, p. 8131–8137, 2018. Citado na página 44.

SAIATA, M. The analysis of the influence of technological parameters on the grinding temperature in the single-pass grinding process of solid carbide end mill flutes. *Advances in Science and Technology Research Journal*, v. 16, n. 1, p. 190–202, 2022. ISSN 2080-4075. Disponível em: <<https://doi.org/10.12913/22998624/143483>>. Citado 2 vezes nas páginas 27 e 28.

SHAJI, S.; RADHAKRISHNAN, V. Analysis of process parameters in surface grinding with graphite as lubricant based on the taguchi method. *Journal of Materials Processing Technology*, Elsevier, v. 141, n. 1, p. 51–59, 2003. Citado na página 44.

SHARMAN, A.; HUGHES, J.; RIDGWAY, K. The effect of tool nose radius on surface integrity and residual stresses when turning inconel 718™. *Journal of Materials Processing Technology*, v. 216, p. 123–132, 2015. ISSN 0924-0136. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924013614003355>>. Citado 2 vezes nas páginas 30 e 61.

Siddartha Varma, K. et al. Withdrawn: Experimental investigation and optimization of surface grinding on en31 steel using taguchi and ann. *Materials Today: Proceedings*, 2021. ISSN 2214-7853. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785321005861>>. Citado na página 40.

SILVA, A. et al. *Desenho técnico moderno*. [S.l.]: Grupo Gen-LTC, 2000. Citado na página 21.

SINHA, M. K. et al. An investigation on surface burn during grinding of inconel 718. *Journal of Manufacturing Processes*, Elsevier, v. 21, p. 124–133, 2016. Citado 2 vezes nas páginas 27 e 28.

SINZATO, M. K. N. et al. Artificial neural network (ann) applied for surface integrity prediction on 4142 alloy steel after straight turning. *SBPMat 2024*, 2024. Citado na página 76.

SINZATO, M. K. N. et al. Surface integrity after hard turning using specially ground cemented carbides. *Procedia CIRP*, v. 123, p. 101–106, 2024. ISSN 2212-8271. 7th CIRP Conference on Surface Integrity. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2212827124002245>>. Citado 2 vezes nas páginas 60 e 76.

SINZATO, M. K. N.; FONTES, J. V. de C.; ANTONIALLI, A. Ítalo S. Uma abordagem para otimização do processo de retificação de insertos empregando inteligência artificial. *Congresso Brasileiro de Engenharia e Ciência dos Materiais*, 2022. Citado na página 76.

SIVATTE-ADROER, M. et al. Indirect model for roughness in rough honing processes based on artificial neural networks. *Precision Engineering*, v. 43, p. 505–513, 2016. ISSN 0141-6359. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0141635915001658>>. Citado na página 42.

SOUZA, O. N.; MESQUITA, M. E. R. V. *Introdução à Teoria dos Conjuntos Fuzzy*. Dissertação (Relatório Final de Iniciação Científica) — Universidade Estadual de Londrina, Londrina, 2010. Citado 3 vezes nas páginas 32, 34 e 35.

SPENCER, L. Abrasives and their application in metal finishing, metal finish. *Metal Finish*, p. 41–51, 1970. Citado na página 25.

STEPHENSON, D.; HEDGE, J.; CORBETT, J. Surface finishing of ni–cr–b–si composite coatings by precision grinding. *International Journal of Machine Tools and Manufacture*, Elsevier, v. 42, n. 3, p. 357–363, 2002. Citado 2 vezes nas páginas 27 e 28.

STEPHENSON, D. J. et al. Ultra-precision grinding of hard steels. *Precision Engineering*, Elsevier, v. 25, n. 4, p. 336–345, 2001. Citado 2 vezes nas páginas 27 e 28.

Sudheer Kumar Varma, N. et al. Neural network and fuzzy logic based prediction of surface roughness and mrr in cylindrical grinding process. *Materials Today: Proceedings*, v. 4, n. 8, p. 8134–8141, 2017. ISSN 2214-7853. International Conference on Advancements in Aeromechanical Materials for Manufacturing (ICAAMM-2016): Organized by MLR Institute of Technology, Hyderabad, Telangana, India. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214785317314517>>. Citado na página 40.

TANIKIĆ, D. Computationally intelligent optimization of metal cutting regimes. *Measurement*, v. 152, p. 107358, 2020. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224119312229>>. Citado na página 41.

TANSCHKEIT, R. Sistemas fuzzy. *Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro*, p. 338–353, 2004. Citado 3 vezes nas páginas 32, 34 e 35.

ULLRICH, K. et al. Ai-based optimisation of total machining performance: A review. *CIRP Journal of Manufacturing Science and Technology*, v. 50, p. 40–54, 2024. ISSN 1755-5817. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1755581724000105>>. Citado na página 39.

UMBRELLO, D. et al. An ann approach for predicting subsurface residual stresses and the desired cutting conditions during hard turning. *Journal of Materials Processing Technology*, v. 189, n. 1, p. 143–152, 2007. ISSN 0924-0136. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924013607000362>>. Citado na página 41.

UMBRELLO, D. et al. A clustering approach for determining the optimal process parameters in cutting. *J Intell Manuf*, v. 21, p. 787–795, 2010. Disponível em: <<https://link.springer.com/article/10.1007/s10845-009-0254-1>>. Citado na página 40.

VENTURA, C. et al. Effect of the grinding process on the wear of a cemented tungsten carbide cutting insert during turning. *Procedia CIRP*, Elsevier, v. 101, p. 174–177, 2021. Citado 2 vezes nas páginas 27 e 28.

VENTURA, C. E.; BREIDENSTEIN, B.; DENKENA, B. Influence of customized cutting edge geometries on the workpiece residual stress in hard turning. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, v. 232, n. 12, p. 2132–2139, 2018. Citado 3 vezes nas páginas 30, 61 e 68.

VENTURA, C. E. H. et al. The influence of the cutting tool microgeometry on the machinability of hardened aisi 4140 steel. *Int J Adv Manuf Technol*, v. 90, p. 2557–2565, 2017. Citado na página 29.

WANG, T. et al. Effect of abrasive on tribological behavior and polishing effect of β -ga₂o₃(100) substrate. *Materials Science in Semiconductor Processing*, v. 172, p. 108059, 2024. ISSN 1369-8001. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1369800123007527>>. Citado 2 vezes nas páginas 27 e 28.

WEI, L. et al. Analysis of large edge breakage of wc-co cemented carbide tool blades emerging in precision grinding process. *Journal of Materials Research and Technology*, v. 19, p. 3916–3929, 2022. ISSN 2238-7854. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2238785422009644>>. Citado na página 27.

WU, W. et al. Specific energy and g ratio of grinding cemented carbide under different cooling and lubrication conditions. *Int. J. of Precis. Eng. and Manuf.-Green Tech.*, v. 105, p. 67–82, 2019. Disponível em: <<https://link.springer.com/article/10.1007/s40684-020-00199-2>>. Citado na página 28.

WU, Z.; ZHANG, L.; YANG, S. Effect of abrasive grain position patterns on the deformation of 6h-silicon carbide subjected to nano-grinding. *International Journal of Mechanical Sciences*, Elsevier, v. 211, p. 106779, 2021. Citado na página 28.

XIONG, Q. et al. The effects of grinding process parameters of a cemented carbide micro-drill on cutting edge burr formation. *Int J Adv Manuf Technol*, v. 117, p. 3041–3051, 2021. Disponível em: <<https://link.springer.com/article/10.1007/s00170-021-07662-7>>. Citado 2 vezes nas páginas 27 e 28.

XU, L.; SHEN, B.; SHIH, A. J. Vitreous bond silicon carbide wheel for grinding of silicon nitride. *International Journal of Machine Tools and Manufacture*, Elsevier, v. 46, n. 6, p. 631–639, 2006. Citado 2 vezes nas páginas 27 e 28.

YANG, J. et al. Grinding effects on surface integrity and mechanical strength of wc-co cemented carbides. *Procedia CIRP*, Elsevier, v. 13, p. 257–263, 2014. Citado na página 28.

YIN, J. et al. Fabrication of pcd face grinding wheel with positive rake angle by femtosecond laser and its performance evaluation in cemented carbide grinding. *Diamond and Related Materials*, v. 139, p. 110418, 2023. ISSN 0925-9635. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925963523007434>>. Citado 2 vezes nas páginas 27 e 28.

ZADEH, L. A. Fuzzy sets. *Information and control*, Elsevier, v. 8, n. 3, p. 338–353, 1965. Citado na página 32.

ZENG, K. et al. A comprehensive review on the cutting and abrasive machining of cemented carbide materials. *Journal of Manufacturing Processes*, v. 108, p. 335–358, 2023. ISSN 1526-6125. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S152661252300988X>>. Citado na página 26.

ZHANG, F. et al. A low temperature nano-lubrication method for enhancing machinability in ultra-precision grinding of binderless tungsten carbide (wc). *CIRP Annals*, v. 72, n. 1, p. 273–276, 2023. ISSN 0007-8506. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0007850623001142>>. Citado 2 vezes nas páginas 27 e 28.

ZHANG, M. et al. Understanding the machining characteristic of plain weave ceramic matrix composite in ultrasonic-assisted grinding. *Ceramics International*, Elsevier, v. 48, n. 4, p. 5557–5573, 2022. Citado 2 vezes nas páginas 27 e 28.

ZHANG, Z. et al. Optimized anfis models based on grid partitioning, subtractive clustering, and fuzzy c-means to precise prediction of thermophysical properties of hybrid nanofluids. *Chemical Engineering Journal*, v. 471, p. 144362, 2023. ISSN 1385-8947. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1385894723030930>>. Citado na página 35.

ZHANG, Z. et al. Residual stress of grinding cemented carbide using mos2 nano-lubricant. *Int J Adv Manuf Technol*, v. 119, p. 5671–5685, 2022. Disponível em: <<https://link.springer.com/article/10.1007/s00170-022-08660-z>>. Citado 2 vezes nas páginas 27 e 28.

ÖZKAN, G.; İNAL, M. Comparison of neural network application for fuzzy and anfis approaches for multi-criteria decision making problems. *Applied Soft Computing*, v. 24, p. 232–238, 2014. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494614003068>>. Citado na página 41.


APÊNDICE A – RESULTADOS DE RUGOSIDADE E TESTES DE TUKEY PARA R_a E R_z NA SUPERFÍCIE DE FOLGA DOS INSERTOS

Tabela 19 – Valores de Rugosidade R_a da superfície de folga dos insertos

Medidas	f1						f2						f3					
	d1		d2		d3		d1		d2		d3		d1		d2		d3	
V1	0,60	0,67	0,65	0,58	0,61	0,70	0,65	0,60	0,64	0,61	0,59	0,56	0,54	0,62	0,58	0,60	0,60	0,68
	0,59	0,66	0,62	0,62	0,64	0,62	0,70	0,70	0,59	0,59	0,59	0,53	0,60	0,70	0,64	0,64	0,61	0,63
V2	0,63	0,66	0,63	0,66	0,58	0,62	0,62	0,58	0,70	0,64	0,6	0,62	0,61	0,62	0,66	0,67	0,65	0,61
	0,60	0,62	0,57	0,64	0,58	0,59	0,62	0,61	0,64	0,63	0,64	0,61	0,63	0,69	0,69	0,64	0,54	0,63
V3	0,65	0,63	0,59	0,63	0,62	0,66	0,64	0,72	0,70	0,64	0,60	0,68	0,61	0,66	0,71	0,73	0,82	0,65
	0,55	0,65	0,62	0,58	0,64	0,68	0,74	0,75	0,73	0,60	0,63	0,62	0,60	0,62	0,66	0,66	0,63	0,65

Fonte: Elaborado pelo autor

Figura 45 – Teste de Tukey para R_a .



Fonte: Elaborado pelo autor.

Tabela 20 – Valores de Rugosidade R_z da superfície de folga dos insertos

Medidas	f1						f2					f3							
	d1		d2		d3		d1		d2		d3	d1	d2	d3					
V1	3,35	3,66	3,74	3,07	3,30	3,64	3,50	3,38	3,59	3,16	3,00	2,94	2,69	3,26	2,74	3,28	3,32	3,55	
	3,18	3,47	3,31	3,41	3,28	3,50	3,69	3,83	3,08	3,30	3,14	2,74	3,05	3,77	3,12	3,36	3,31	3,33	
V2	3,24	3,51	3,43	3,62	3,00	3,02	3,44	2,93	3,72	3,43	3,24	3,48	3,18	3,14	3,51	3,50	3,50	3,20	
	3,18	3,07	2,99	3,52	3,10	3,27	3,28	3,19	3,22	3,34	3,55	3,37	3,16	3,41	3,53	3,26	2,69	3,45	
V3	3,36	3,39	2,85	3,31	3,38	3,27	3,51	4,20	3,46	3,34	3,26	3,71	3,50	3,50	3,91	3,81	4,24	3,26	
	2,82	3,34	3,33	2,99	3,19	3,67	3,82	3,73	4,06	3,22	3,18	3,72	3,17	3,35	3,47	3,53	3,50	3,30	

Tabela 21 – Legenda

Variável	Denominação
f	Avanço (m/s)
V	Velocidade de corte (mm/min)
d	Sobremetal (mm)

Variável	Valor
f1	2
f2	12
f3	25
v1	12
v2	36
v3	60
d1	0,05
d2	0,1
d3	0,2

Fonte: Elaborado pelo autor

Figura 46 – Teste de Tukey para R_z .

Teste de Tukey																								
3,9150																								
0,130	3,6000																							
0,210	0,08	3,6000																						
0,24	0,100	0,000	3,6760																					
0,290	0,10	0,08	0,050	3,5200																				
0,315	0,220	0,120	0,105	0,000	3,4050																			
0,360	0,23	0,16	0,120	0,07	0,0150	3,4000																		
0,380	0,20	0,17	0,140	0,09	0,0370	0,02	3,4200																	
0,395	0,200	0,170	0,145	0,090	0,04	0,020	0,000	3,4270																
0,4	0,200	0,180	0,16	0,100	0,020	0,030	0,010	0,010	3,4100															
0,400	0,27	0,19	0,160	0,11	0,0270	0,04	0,02	0,0170	0,000	3,4100														
0,400	0,20	0,21	0,180	0,13	0,0270	0,06	0,04	0,0270	0,020	0,02	3,3900													
0,420	0,2070	0,2170	0,1920	0,1370	0,030	0,0270	0,0470	0,040	0,0220	0,0270	0,0070	3,3820												
0,420	0,23	0,22	0,190	0,14	0,030	0,03	0,020	0,020	0,020	0,020	0,01	0,000	3,3800											
0,4270	0,3020	0,2220	0,1970	0,140	0,09	0,020	0,020	0,020	0,020	0,020	0,000	0,000	3,3770											
0,4370	0,3020	0,2220	0,1970	0,140	0,09	0,020	0,020	0,020	0,020	0,020	0,000	0,000	0,000	3,3770										
0,510	0,3070	0,2170	0,200	0,2070	0,100	0,0270	0,1470	0,140	0,120	0,1270	0,1070	0,1	0,0070	0,000	0,000	3,2820								
0,560	0,43	0,30	0,320	0,27	0,2170	0,2	0,10	0,1270	0,160	0,16	0,14	0,120	0,13	0,1270	0,1270	0,020	3,2600							
0,6070	0,4020	0,3220	0,3470	0,2920	0,24	0,2220	0,200	0,2	0,1070	0,1020	0,1020	0,10	0,10	0,060	0,0220	3,2270								
0,600	0,6070	0,3770	0,3020	0,2970	0,240	0,2270	0,2070	0,200	0,190	0,1070	0,1070	0,10	0,1070	0,100	0,06	0,0270	0,000	3,2220						
0,600	0,47	0,30	0,300	0,31	0,2070	0,24	0,22	0,2170	0,200	0,2	0,10	0,120	0,17	0,1070	0,1070	0,020	0,04	0,0170	0,010	3,2100				
0,600	0,47	0,30	0,300	0,31	0,2070	0,24	0,22	0,2170	0,200	0,2	0,10	0,120	0,17	0,1070	0,1070	0,020	0,04	0,0170	0,010	3,2100				
0,620	0,4070	0,4070	0,300	0,3270	0,270	0,2070	0,2270	0,2170	0,1970	0,19	0,1070	0,100	0,09	0,0070	0,020	0,03	0,0170	0,0170	3,1920					
0,690	0,60	0,40	0,400	0,4	0,3470	0,33	0,31	0,2070	0,200	0,20	0,27	0,2020	0,20	0,2070	0,2070	0,1020	0,13	0,1070	0,1020	0,09	0,09	0,020	3,1200	
0,7170	0,6020	0,6020	0,4770	0,4220	0,37	0,3020	0,320	0,33	0,3170	0,310	0,200	0,200	0,20	0,20	0,100	0,1020	0,13	0,100	0,100	0,100	0,060	0,000	3,0070	
0,80	0,720	0,640	0,62	0,600	0,610	0,490	0,470	0,4720	0,46	0,460	0,430	0,4270	0,420	0,420	0,420	0,3270	0,290	0,270	0,260	0,250	0,250	0,160	0,1420	2,9650

Fonte: Elaborado pelo autor.

APÊNDICE B – DADOS DO TORNEAMENTO DE LIGAS DE AÇO 4142

Figura 47 – Dados de Rugosidade.

Dados utilizados de Ra e Rz																			
Ra	f = 0,10 mm			f = 0,15 mm			f = 0,20 mm			Primeira Repetição	f = 0,10 mm			f = 0,15 mm			f = 0,20 mm		
	κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2		κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2
κ = 0,4 mm	1,00			1,06			1,71			2,58			2,67			2,56			2,56
κ = 0,8 mm																			
κ = 1,2 mm		0,43	0,80		1,06			0,98			0,79			1,35		1,53			0,19
κ = 0,4 mm	4,85			4,59			7,40			11,26			11,70			10,98			0,07
κ = 0,8 mm																			
κ = 1,2 mm		3,64			6,55			3,77			2,62		2,61		0,01	0,01		0,01	0,05
κ = 0,4 mm	1,09			1,01			1,39			2,00			2,00			2,61			0,05
κ = 0,8 mm																			
κ = 1,2 mm		0,72			0,83			0,81											0,04
κ = 0,4 mm	5,54			5,33			7,34			11,68			11,37			12,16			0,1
κ = 0,8 mm																			
κ = 1,2 mm		3,79			5,37			4,39		3,69			6,79		7,76				0,4
κ = 0,4 mm	1,00			1,03			1,75			2,59			2,62			2,58			0,02
κ = 0,8 mm																			
κ = 1,2 mm		0,81			0,64			0,81		1,23			1,43			0,06		0,02	0,02
κ = 0,4 mm	4,44			5,50			7,68			11,37			11,36			11,17			0,2
κ = 0,8 mm																			
κ = 1,2 mm		4,28			4,90			3,28		3,87			7,50			7,50			0,1
κ = 0,4 mm	0,01			0,01			0,01			0,01			0,01			0,01			0,01
κ = 0,8 mm																			
κ = 1,2 mm		0,02			0,02			0,02		0,02			0,02			0,02			0,02
κ = 0,4 mm	0,10			0,10			0,09			0,09			0,09			0,07			0,07
κ = 0,8 mm																			
κ = 1,2 mm		0,26			0,26			0,26		0,26			0,26			0,26			0,26
κ = 0,4 mm	0,02			0,02			0,02			0,02			0,02			0,02			0,02
κ = 0,8 mm																			
κ = 1,2 mm		0,05			0,05			0,05		0,05			0,05			0,05			0,05
κ = 0,4 mm	0,1			0,1			0,1			0,1			0,1			0,1			0,1
κ = 0,8 mm																			
κ = 1,2 mm		0,3			0,3			0,3		0,3			0,3			0,3			0,3
κ = 0,4 mm	0,02			0,02			0,02			0,02			0,02			0,02			0,02
κ = 0,8 mm																			
κ = 1,2 mm		0,02			0,02			0,02		0,02			0,02			0,02			0,02
κ = 0,4 mm	0,1			0,1			0,1			0,1			0,1			0,1			0,1
κ = 0,8 mm																			
κ = 1,2 mm		0,2			0,2			0,2		0,2			0,2			0,2			0,2

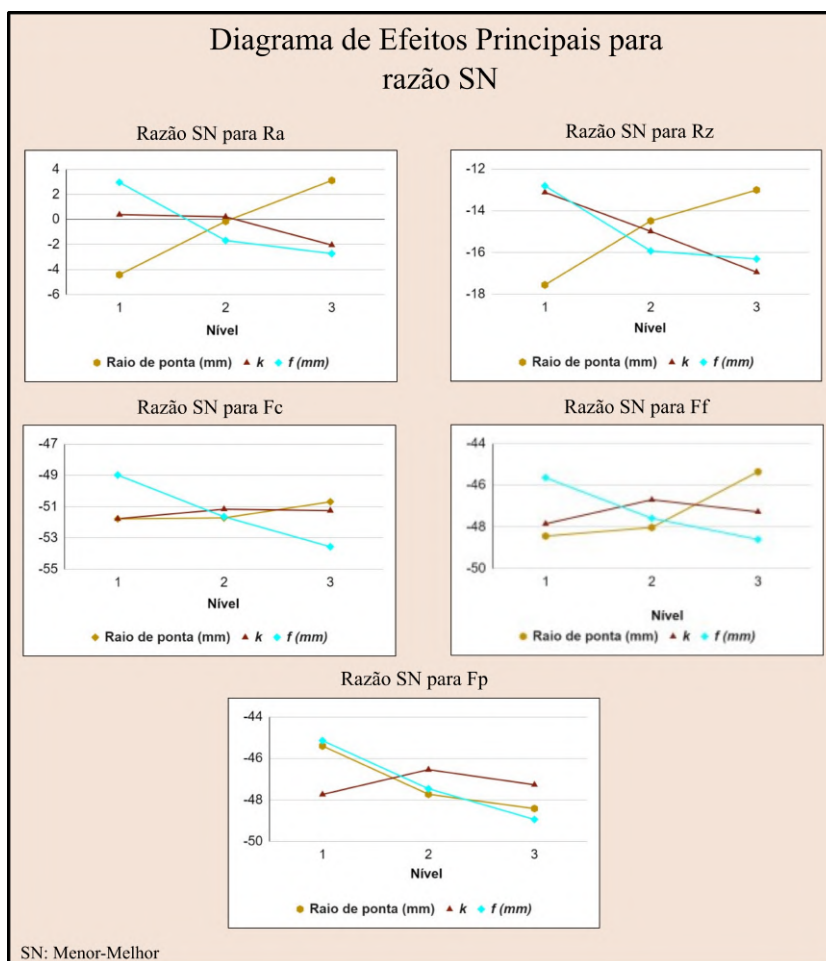
Fonte: Elaborado pelo autor.

Figura 48 – Dados de Força.

Dados utilizados de Força																			
Força de corte (N)	f = 0,10 mm			f = 0,15 mm			f = 0,20 mm			Primeira Repetição	f = 0,10 mm			f = 0,15 mm			f = 0,20 mm		
	κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2		κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2	κ = 0,5	κ = 1	κ = 2
κ = 0,4 mm	285			367			524			577			441			24		52	
κ = 0,8 mm																			
κ = 1,2 mm		231	260		351			402		284			485			5		10	
κ = 0,4 mm	220			235			342			323			276			14		26	
κ = 0,8 mm																			
κ = 1,2 mm		150	195		237			170		195			294			5		6	
κ = 0,4 mm	83			98			177			251			236			9		20	
κ = 0,8 mm																			
κ = 1,2 mm		83	100		177			271		331			286			7		3	
κ = 0,4 mm	336			445			623			511			510			19		17	
κ = 0,8 mm																			
κ = 1,2 mm		263	293		445			364		479			461			12		16	
κ = 0,4 mm	238			238			333			306			324			10		14	
κ = 0,8 mm																			
κ = 1,2 mm		195	218		264			203		240			272			3		31	
κ = 0,4 mm	83			154			250			222			231			7		16	
κ = 0,8 mm																			
κ = 1,2 mm		124	154		274			272		272			277			10		16	
κ = 0,4 mm	323			433			623			523			523			17		12	
κ = 0,8 mm																			
κ = 1,2 mm		285	299		433			366		479			465			17		16	
κ = 0,4 mm	250			221			337			306			311			12		11	
κ = 0,8 mm																			
κ = 1,2 mm		83	221		289			247		283			280			11		22	
κ = 0,4 mm	81			197			290			290			292			3		14	
κ = 0,8 mm																			
κ = 1,2 mm		197	200		273			291		290			292			23		12	
κ = 0,4 mm	0,01			0,01			0,01			0,01			0,01			0,01			
κ = 0,8 mm																			
κ = 1,2 mm		0,02			0,02			0,02		0,02			0,02			0,02			
κ = 0,4 mm	0,1			0,1			0,1			0,1			0,1			0,1			
κ = 0,8 mm																			
κ = 1,2 mm		0,3			0,3			0,3		0,3			0,3			0,3			
κ = 0,4 mm	0,02			0,02			0,02			0,02			0,02			0,02			
κ = 0,8 mm																			
κ = 1,2 mm		0,02			0,02			0,02		0,02			0,02			0,02			
κ = 0,4 mm	0,1			0,1			0,1			0,1			0,1			0,1			
κ = 0,8 mm																			
κ = 1,2 mm		0,2			0,2			0,2		0,2			0,2			0,2			

Fonte: Elaborado pelo autor.

Figura 49 – Diagrama de efeitos principais para as rugosidades e forças.



Fonte: Elaborado pelo autor.

Figura 50 – Diagrama de efeitos principais para a tensão residual.

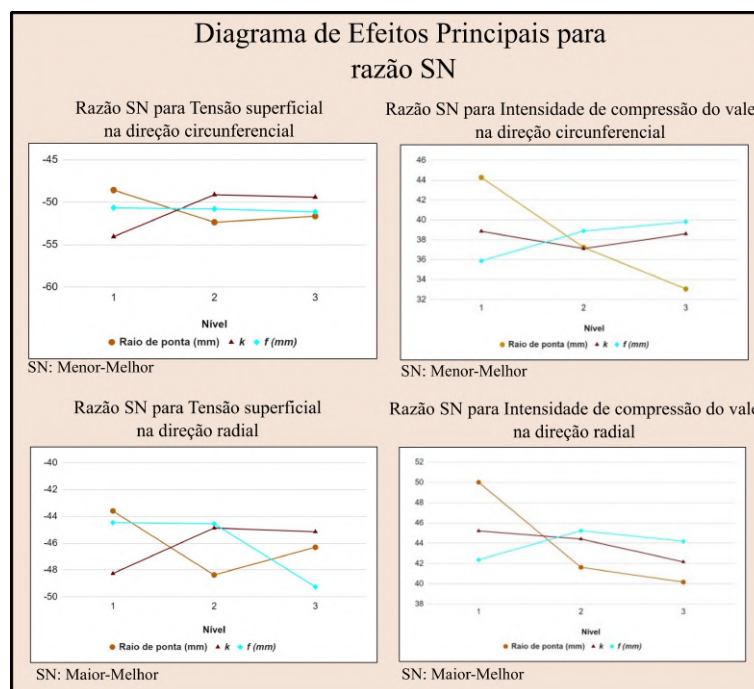


Figura 51 – Dados da ANOVA para rugosidade e forças.

Tabelas de ANOVA

	Média	SS	GL	MS	F-value	p-value	Conclusão	SNs	SS	GL	MS	F-value	p-value	Conclusão
Rugosidade Ra	Total	3,2	8					Total	151,6	8				
	f	0,9	2	0,5	7	0,13	Insignificante	f	55	2	27,5	269	0,004	Significante
	re	1,7	2	0,9	13	0,07	Significante	re	85,4	2	42,7	418	0,002	Significante
	K	0,4	2	0,2	3	0,27	Insignificante	K	11	2	5,5	54	0,018	Significante
	Erro	0,1	2	0,1				Erro	0,2	2	0,1			
Rugosidade Rz	Total	46,8	8					Total	80,2	8				
	f	12,6	2	6	4	0,19	Insignificante	f	12	2	6	0,7	0,6	Insignificante
	re	18,1	2	9	6	0,14	Insignificante	re	8,4	2	4	0,5	0,7	Insignificante
	K	13,1	2	7	4	0,19	Insignificante	K	42	2	21	2,4	0,3	Insignificante
	Erro	3	2	2				Erro	17,7	2	9			
Fc	Total	60534	8					Total	34,42	8				
	f	56392	2	28196	773	0,001	Significante	f	31,58	2	15,79	1061	0,001	Significante
	re	3641	2	1821	50	0,02	Significante	re	2,29	2	1,15	77	0,013	Significante
	K	428	2	214	6	0,146	Insignificante	K	0,52	2	0,26	17	0,055	Insignificante
	Erro	73	2	36				Erro	0,03	2	0,01			
Ff	Total	32186	8					Total	32,52	8				
	f	23189	2	11594	85,6	0,01	Significante	f	24,8	2	12,4	83	0,01	Significante
	re	8618	2	4309	31,8	0,03	Significante	re	6,92	2	3,46	23	0,04	Significante
	K	108	2	54	0,4	0,72	Insignificante	K	0,49	2	0,25	2	0,38	Insignificante
	Erro	271	2	135				Erro	0,3	2	0,15			
Fp	Total	27668	8					Total	37,31	8				
	f	14548	2	7274	66	0,02	Significante	f	20,37	2	10,186	726	0,001	Significante
	re	10649	2	5324	48	0,02	Significante	re	14,83	2	7,413	528	0,002	Significante
	K	2250	2	1125	10	0,09	Insignificante	K	2,08	2	1,039	74	0,013	Significante
	Erro	222	2	111				Erro	0,03	2	0,014			

Nível de Confiança: 90%

Fonte: Elaborado pelo autor.

Figura 52 – Dados da ANOVA para tensão residual.

Tabelas de ANOVA														
	Média	SS	GL	MS	F-value	p-value	Conclusão	SNs	SS	GL	MS	F-value	p-value	Conclusão
Tensão Superficial Circunferencial	Total	160252	8					Total	73,4	8				
	f	3753	2	1876	0	0,73	Insignificante	f	0,4	2	0,2	0	0,86	Insignificante
	rc	43226	2	21613	4	0,19	Insignificante	rc	24,4	2	12,2	11	0,09	Insignificante
	K	103229	2	51614	10	0,09	Significante	K	46,3	2	23,2	20	0,05	Significante
	Error	10045	2	5022				Erro	2,3	2	1,1			
Tensão Superficial Radial	Total	244863	8					Total	154	8				
	f	109254	2	54627	5	0,16	Insignificante	f	66	2	32,8	3,3	0,2	Insignificante
	rc	81286	2	40643	4	0,21	Insignificante	rc	63	2	31,6	3,2	0,2	Insignificante
	K	32823	2	16411	2	0,4	Insignificante	K	6	2	2,8	0,3	0,8	Insignificante
	Error	21500	2	10750				Erro	20	2	9,8			
Intensidade de Compressão do Vale Circunferencial	Total	25447,6	8					Total	225	8				
	f	1917,6	2	958,8	8	0,11	Insignificante	f	25	2	13	20	0,05	Significante
	rc	22976,9	2	11488	96	0,01	Significante	rc	193	2	96	153	0,01	Significante
	K	314,9	2	157,4	1	0,43	Insignificante	K	5	2	3	4	0,19	Insignificante
	Error	238,2	2	119,1				Erro	1	2	1			
Intensidade de Compressão do Vale Radial	Total	89952	8					Total	217	8				
	f	2538	2	1269	1	0,62	Insignificante	f	13	2	6	1	0,61	Insignificante
	rc	80678	2	40439	19	0,05	Significante	rc	170	2	85	8	0,11	Insignificante
	K	2332	2	1166	1	0,64	Insignificante	K	15	2	8	1	0,57	Insignificante
	Error	4204	2	2102				Erro	20	2	10			

Nível de Confiança: 90%

Fonte: Elaborado pelo autor.