



Pontifícia Universidade Católica de Minas Gerais

Campus de Poços de Caldas

Curso de Engenharia de Produção

Lucas Borges Reis; Wiliam Regone

Modelagem Preditiva da Rugosidade Superficial em Processos de Usinagem Utilizando Random Forest Regressor

Projeto de Iniciação Científica apresentado no curso de Engenharia da Produção da Pontifícia Universidade Católica de Minas Gerais, Campus de Poços de Caldas EDITAL FIP Nº 067/2023.

Número do Projeto: FIP 2024 / 30842

Orientador(a): Dr. Wiliam Regone

Orientando(a): Lucas Borges Reis

Poços de Caldas

2025

Modelagem Preditiva da Rugosidade Superficial em Processos de Usinagem Utilizando Random Forest Regressor

Lucas Borges Reis; Wiliam Regone

PUC MINAS - campus Poços de Caldas

Curso de Engenharia de Produção

Av. Pe. Cletus Francis Cox, 1.661 – Jardim Country Club

37.714-620 – Poços de Caldas – Minas Gerais

wiliamregone@gmail.com; lucasbreisxx@gmail.com

Resumo: A aplicação de aprendizado de máquina, especificamente o Random Forest Regressor (RFR), na previsão da rugosidade superficial (R_a) em processos de usinagem foi realizada considerando os principais parâmetros de corte (profundidade de corte, velocidade de corte e avanço por rotação) e as forças de usinagem (F_x , F_y , F_z e força resultante F). A metodologia envolveu a coleta de um conjunto de 612 dados experimentais, distribuídos entre Experimento 1 (Ferramenta Nova) e Experimento 2 (Ferramenta Desgastada), seguida por análises estatísticas, incluindo a correlação de Pearson, para avaliar as relações entre as variáveis. O modelo foi treinado e validado utilizando métricas estatísticas amplamente aplicadas em problemas de regressão, além de visualizações gráficas que auxiliam na interpretação do seu desempenho preditivo. O algoritmo de previsão obteve altos coeficientes de determinação (R^2), sendo 0.9534 para o Experimento 1 e 0.9643 para o Experimento 2, e apresentou baixos erros preditivos, com MAE de 0.0406 (Exp1) e 0.0271 (Exp2), além de MAPE de 6,43% (Exp1) e 4,63% (Exp2). A avaliação do desempenho do modelo foi realizada por meio de gráficos de dispersão, que demonstraram forte alinhamento entre os valores preditos e os valores reais da rugosidade, e histogramas dos erros residuais, que apresentaram distribuição aproximadamente normal e centrada em zero, indicando um modelo bem ajustado e sem vieses significativos. Além disso, a análise da importância das variáveis revelou que o avanço por rotação (f) foi o fator de maior influência na previsão da rugosidade, especialmente no Experimento 1, onde representou 58,08% da contribuição total do modelo. No Experimento 2, devido ao desgaste da ferramenta, a influência do avanço foi reduzida para 38,16%, enquanto as forças de usinagem, especialmente F_y (17,45%) e F_z (16,44%), passaram a ter maior impacto na rugosidade final. Os resultados evidenciam que o Random Forest Regressor é uma ferramenta eficaz para prever a rugosidade superficial.

Palavras-Chave: Usinagem, Random Forest Regressor, Rugosidade Superficial.

1. Introdução

A usinagem é um processo essencial na manufatura, permitindo a produção de peças com alta precisão e qualidade superficial. Esse processo é amplamente utilizado em setores como o automotivo, aeroespacial e médico, onde a precisão dimensional e o acabamento superficial são fundamentais. As principais variáveis envolvidas na usinagem incluem a profundidade de corte (ap), a velocidade de corte (vc) e o avanço por rotação (f), que influenciam diretamente as forças de corte, o desgaste da ferramenta e a rugosidade superficial (SILVA et al., 2019).

Com a evolução da Indústria 4.0, a inteligência artificial tem sido cada vez mais aplicada aos processos de fabricação. Técnicas de aprendizado de máquina, como o Random Forest Regressor (RFR), vêm sendo exploradas para prever variáveis críticas da usinagem, otimizando parâmetros de corte e reduzindo custos operacionais. Apesar de sua aplicação ainda estar em fase inicial na indústria, essa abordagem já demonstra impactos positivos na eficiência produtiva e no controle de qualidade das peças usinadas (HUANG et al., 2023).

A crescente digitalização dos processos produtivos reforça a importância dos dados na indústria. A coleta e análise sistemática de informações permitem a implementação de estratégias preditivas que minimizam desperdícios, previnem falhas e aumentam a confiabilidade dos processos. A utilização de aprendizado de máquina não apenas melhora a precisão das previsões, mas também promove um ambiente industrial baseado em dados, garantindo maior competitividade e inovação no setor manufatureiro (AGGARWAL C. C., 2018).

Os parâmetros de corte são determinantes para o desempenho da usinagem e afetam diretamente as forças de corte e a rugosidade superficial. A variável (ap) representa a profundidade de corte, ou seja, a espessura da camada de material removida em cada passagem da ferramenta. Valores maiores de (ap) resultam em maiores forças de corte e podem gerar vibrações indesejadas, enquanto valores menores promovem um acabamento de melhor qualidade, mas aumentam o tempo de usinagem. A velocidade de corte (vc) indica a velocidade da ferramenta em relação à peça, medida em metros por minuto (m/min). Velocidades muito baixas podem aumentar o atrito e o desgaste da ferramenta, enquanto velocidades muito altas reduzem sua vida útil e elevam a temperatura do processo (SILVA et al., 2019). O avanço por rotação (f) define a distância percorrida pela ferramenta ao longo do eixo da peça a cada rotação. Esse parâmetro é um dos principais influenciadores da rugosidade, pois avanços baixos geram superfícies mais suaves, mas aumentam o tempo de usinagem, enquanto avanços elevados aumentam a taxa de remoção de material, porém podem causar rugosidade excessiva e defeitos no acabamento. Quanto maior a remoção de material, maior a influência sobre a força de corte e a rugosidade final da peça. Peças que exigem maior remoção podem demandar ajustes nos parâmetros de corte para evitar defeitos ou desgaste excessivo da ferramenta (OLIVEIRA et al. 2021).

As forças de usinagem indicam a resistência que a ferramenta encontra ao remover material e são representadas por três componentes ortogonais: F_x (força de corte na direção X), F_y (força de avanço na direção Y) e F_z (força passiva na direção Z). A força de corte (F_x) é geralmente a principal força envolvida no processo, sendo diretamente relacionada ao consumo de potência da máquina. Se esse valor for muito elevado, pode indicar aumento do desgaste da ferramenta. A força de avanço (F_y) afeta a estabilidade da peça, e um aumento excessivo pode indicar problemas de fixação ou vibrações indesejadas. Já a força passiva (F_z) está relacionada à rigidez da peça e da máquina, podendo influenciar a deflexão da peça, especialmente em materiais menos rígidos (FERREIRA et al., 2020).

A força resultante (F) é calculada a partir da soma vetorial das três forças anteriores e representa a carga total exercida sobre a ferramenta. Valores elevados de F indicam maior esforço da ferramenta, podendo causar deformação plástica da peça e aumentar sua rugosidade.

A rugosidade média (R_a) é um dos parâmetros mais críticos para avaliar a qualidade do acabamento superficial. Essa variável representa a média aritmética dos desvios da superfície em relação à linha média, medida em micrômetros (μm). Baixos valores de R_a indicam um acabamento mais suave, enquanto valores altos podem evidenciar desgaste excessivo da ferramenta ou parâmetros de corte agressivos. A rugosidade depende diretamente do avanço (f), das forças de corte (F_x , F_y , F_z) e da condição da ferramenta. Portanto, entender como essas variáveis interagem é essencial para otimizar o processo de usinagem e garantir peças com melhor acabamento e maior precisão dimensional (MARTINS et al., 2023).

A correlação de Pearson é uma métrica estatística utilizada para quantificar a relação linear entre duas variáveis contínuas. Seu coeficiente varia de -1 a 1. Valores próximos de 1 indicam uma forte correlação positiva (quando uma variável aumenta, a outra também tende a aumentar). Valores próximos de -1 indicam uma forte correlação negativa (quando uma variável aumenta, a outra tende a diminuir). Valores próximos de 0 indicam uma correlação fraca ou inexistente. Na análise da rugosidade superficial, a correlação de Pearson pode ser utilizada para identificar relações diretas entre os parâmetros de corte e a rugosidade medida, ajudando a entender a influência de cada variável no acabamento da peça (JOHNSON et al. 2020).

A previsão da rugosidade da superfície em processos de usinagem é fundamental para garantir a qualidade do acabamento e a otimização dos parâmetros de corte. Entre os modelos de aprendizado de máquina, RFR destaca-se por sua robustez, capacidade de generalização e boa interpretação dos resultados. Esta técnica vem sendo amplamente empregado na previsão da rugosidade da superfície devido à sua capacidade de lidar com dados não lineares e sua resistência a ruídos nos dados, características essenciais para aplicações industriais (AYYASWAMY et al., 2022).

O RFR opera com base em quatro princípios principais. Primeiro, ele cria múltiplas árvores de decisão a partir de amostras aleatórias dos dados de treinamento, utilizando o método de bootstrap aggregation (bagging) para reduzir a variância e aumentar a estabilidade do modelo (ZHOU et al., 2019). Em seguida, a seleção aleatória de atributos garante que cada nó de decisão dentro de uma árvore seja dividido com base em um subconjunto aleatório das variáveis de entrada, promovendo diversidade entre as árvores e reduzindo o risco de superajuste (overfitting). A previsão final do modelo é obtida por meio da agregação dos resultados, ou seja, a média das previsões individuais de todas as árvores, o que assegura uma estimativa mais estável e precisa (CHEN et al., 2021). Além disso, o algoritmo avalia a importância das variáveis, identificando quais fatores do processo de usinagem exercem maior impacto na rugosidade média (LIU et al., 2023). Esse recurso é essencial para a tomada de decisões na otimização dos parâmetros de corte.

Para avaliar a eficácia do modelo RFR na previsão da rugosidade, são empregadas diversas técnicas de análise dos resultados. Três métodos fundamentais se destacam nesse processo: o gráfico de dispersão, o histograma dos erros residuais e a importância das variáveis no modelo.

O gráfico de dispersão é uma ferramenta essencial para visualizar o desempenho do modelo, comparando os valores reais da rugosidade com os valores preditos. Quando o modelo apresenta alta precisão, os pontos tendem a se alinhar à linha de referência de 45° , indicando previsões próximas dos valores reais. Quanto maior a dispersão dos pontos em relação a essa linha, maior é a magnitude dos erros do modelo. Além disso, a presença de padrões sistemáticos nos erros pode sugerir a

necessidade de ajustes nos hiperparâmetros ou na escolha das variáveis preditoras (NGUYEN et al., 2020).

O histograma dos erros residuais exhibe a distribuição dos desvios entre os valores reais e preditos, permitindo a identificação de possíveis vieses e a avaliação da qualidade das previsões do modelo. Um modelo bem ajustado deve apresentar erros simétricos e centrados próximos de zero. Caso haja assimetria ou padrões irregulares na distribuição dos erros, isso pode indicar que o modelo está subajustado (*underfitting*) ou superajustado (*overfitting*). Para mitigar esses problemas, é possível ajustar hiperparâmetros, como o número de árvores e a profundidade máxima das árvores individuais (SINGH et al., 2022).

A análise da importância das variáveis é crucial para interpretar o modelo e compreender quais fatores mais influenciam a previsão da rugosidade. Normalmente, essa análise é representada por um gráfico de barras, no qual as variáveis com maior peso no modelo são consideradas mais relevantes para o controle e otimização do processo de usinagem. Além disso, a eliminação de variáveis pouco significativas pode reduzir a complexidade do modelo e melhorar sua interpretabilidade (ALMEIDA et al., 2018). Essa análise fornece informações para o aprimoramento dos parâmetros de corte, auxiliando engenheiros e operadores na otimização dos processos industriais.

2. Metodologia

O conjunto de dados foi obtido na dissertação de mestrado de André Dorigueto Canal. Esses dados contêm informações detalhadas sobre os experimentos de usinagem, incluindo variáveis que vão desde a identificação do experimento até as forças de usinagem e a rugosidade superficial. Cada variável desempenha um papel essencial na análise do desempenho do processo e na qualidade do acabamento da peça.

2.1. Explicação das Variáveis do conjunto de dados

O conjunto de dados contém um total de 612 entradas distribuídas em 12 colunas, representando a concatenação dos dados dos experimentos Exp1 (Ferramenta Nova) e Exp2 (Ferramenta Desgastada). Esse conjunto de dados está estruturado para fornecer informações sobre os parâmetros de corte, forças de usinagem, medições de rugosidade e dimensões da peça, além da condição da ferramenta (CANAL, 2022).

A estrutura dos dados inclui colunas essenciais para a análise dos experimentos. A identificação do experimento é feita pela variável "Experiment", distinguindo os testes realizados com ferramenta nova (Exp1) e ferramenta desgastada (Exp2). Os parâmetros de corte são representados por *ap* (profundidade de corte), *vc* (velocidade de corte) e *f* (avanço por rotação), fatores determinantes no comportamento da usinagem. As forças de usinagem incluem F_x , F_y e F_z , além da força resultante F , que expressa a magnitude combinada dessas componentes. A rugosidade média (R_a) fornece uma métrica fundamental para a qualidade superficial, enquanto as colunas *Init_diameter* e *Final_diameter* indicam as dimensões da peça antes e depois do processo de usinagem. A variável *TCond* está relacionada à condição da ferramenta, indicando seu nível de desgaste.

A análise estatística do conjunto de dados revela que a rugosidade média (R_a) apresenta variações entre os experimentos. Para Exp1 (ferramenta nova), R_a varia entre 0.21 μm e 1.81 μm ,

com uma média de 0.72 μm . Já para Exp2 (ferramenta desgastada), Ra oscila entre 0.14 μm e 1.68 μm , resultando em uma média de 0.65 μm . Nota-se que Exp1 apresenta uma maior dispersão nos valores de rugosidade, enquanto Exp2 demonstra menor variação. As forças de usinagem apresentam variações significativas, com a força de corte Fx oscilando entre 49.2 N e 289.6 N, resultando em uma média de 136.8 N. As componentes Fy e Fz também apresentam variações consideráveis, sugerindo que diferentes condições de corte afetam significativamente o comportamento das forças. Fy oscila entre 41.6 N e 243.7 N, com uma média de 93.1 N. Fz varia entre 18.9 N e 227.5 N, resultando em uma média de 88.3 N. A força resultante F, combinando essas componentes, varia entre 69.3 N e 362.9 N, com uma média de 193.4 N, evidenciando a influência dos parâmetros de corte na magnitude do esforço total aplicado à peça. Os parâmetros de corte demonstram variações relevantes, com a profundidade de corte (ap) situando-se entre 0.25 mm e 0.80 mm, a velocidade de corte (vc) variando de 310 a 390 m/min e o avanço (f) oscilando entre 0.07 e 0.13 mm/rev. As colunas Init_diameter e Final_diameter indicam as dimensões da peça antes e depois do processo de usinagem. O diâmetro inicial da peça varia entre 76.6 mm e 94.0 mm, com uma média de 88.5 mm. Após o processo, o diâmetro final oscila entre 75.6 mm e 93.5 mm, resultando em uma média de 87.6 mm, indicando a remoção de material ao longo da usinagem (CANAL, 2022).

A combinação desses fatores determina o comportamento da usinagem e pode fornecer informações importantes para a otimização do processo. A partir dessas informações, análises detalhadas podem ser conduzidas para identificar padrões, otimizar parâmetros de corte e melhorar a eficiência do processo de usinagem. A comparação entre os experimentos Exp1 e Exp2 pode fornecer informações valiosas sobre a influência do desgaste da ferramenta na qualidade final da peça e no consumo energético da máquina. A análise desses dados pode contribuir para o entendimento da influência dos parâmetros operacionais sobre a qualidade final da peça e a eficiência da usinagem. A comparação entre as condições de ferramenta nova e desgastada pode ser utilizada para desenvolver estratégias que aumentem a produtividade e reduzam custos, maximizando a vida útil da ferramenta sem comprometer a qualidade do processo.

2.2. Metodologia Utilizada no Código

O código desenvolvido tem como objetivo prever a rugosidade média (Ra) de peças usinadas a partir dos parâmetros de corte e forças de usinagem, utilizando o modelo RFR. Para garantir uma análise detalhada, os dados passam por um processo estruturado de pré-processamento e modelagem, permitindo que o impacto do desgaste da ferramenta na qualidade do acabamento seja avaliado. A metodologia empregada pode ser dividida em cinco etapas principais: carregamento e pré-processamento dos dados, treinamento e avaliação do modelo, validação dos resultados, visualização dos dados preditivos e explicabilidade do modelo (ZHOU et al., 2019).

Inicialmente, os dados são carregados a partir de um arquivo Excel e organizados em um DataFrame do Pandas, possibilitando manipulações estatísticas. A variável categórica "Experiment", que identifica se a ferramenta utilizada é nova ou desgastada, é convertida para valores numéricos, facilitando o processamento pelos modelos de regressão. Para uma análise comparativa mais precisa, os dados são então divididos em dois conjuntos distintos: Experimento 1, que representa a ferramenta nova, e Experimento 2, que se refere à ferramenta desgastada. Essa separação permite avaliar de forma independente os efeitos do desgaste da ferramenta sobre a rugosidade final da peça.

O treinamento e avaliação do modelo, onde é aplicada a regressão com RandomForestRegressor para prever a rugosidade média da peça usinada. O conjunto de dados de cada experimento é separado em variáveis independentes (X) e variável alvo (Ra), sendo

posteriormente dividido em 80% para treinamento e 20% para teste, garantindo que o modelo possa generalizar bem para novos dados. Em seguida, são normalizados utilizando a técnica StandardScaler, preparando-os para a aplicação de algoritmos de aprendizado de máquina. O modelo é configurado com 100 árvores de decisão ($n_estimators=100$), utilizando um estado aleatório fixo para garantir a reprodutibilidade dos resultados. O uso da Random Forest é vantajoso por sua capacidade de lidar com relações complexas entre variáveis, reduzir o risco de overfitting e proporcionar previsões mais confiáveis (CHEN et al., 2021).

Os resultados do modelo são validados por meio de métricas estatísticas que permitem avaliar a precisão da previsão em relação aos dados reais. São utilizadas métricas como o Erro Absoluto Médio (MAE), que mede a diferença média entre os valores previstos e reais, o Erro Quadrático Médio (MSE) e a Raiz do Erro Quadrático Médio (RMSE), que penalizam erros maiores. Além disso, são calculados o Erro Percentual Médio Absoluto (MAPE), que expressa o erro como uma porcentagem dos valores reais, e o Coeficiente de Determinação (R^2), que indica o quanto o modelo consegue explicar a variação dos dados. A Variância Explicada é analisada para verificar o nível de precisão do modelo na previsão da rugosidade (LIU et al., 2023).

Posteriormente tem-se a etapa que se concentra na visualização dos resultados preditivos, permitindo uma interpretação mais clara do desempenho do modelo. São gerados gráficos que mostram a relação entre os valores reais e preditos da rugosidade média, evidenciando a precisão do modelo na previsão. Além disso, são analisadas as distribuições dos erros residuais, permitindo identificar possíveis padrões de viés ou dispersão nos dados. Outro aspecto fundamental é a análise da importância das variáveis preditoras, onde o modelo indica quais parâmetros de corte e forças de usinagem possuem maior influência na rugosidade final da peça. Isso possibilita ajustes no processo de usinagem para melhorar a qualidade do acabamento e otimizar as condições operacionais (NGUYEN et al., 2020).

O TreeExplainer, uma ferramenta otimizada para modelos baseados em árvores como o Random Forest, é empregado para quantificar a influência de cada variável na decisão do modelo. Essa abordagem contribui para a transparência do modelo, auxiliando engenheiros e operadores a entenderem quais ajustes no processo de usinagem podem levar a melhores resultados em termos de qualidade da superfície usinada. Assim, a metodologia implementada possibilita uma análise aprofundada do comportamento da rugosidade em diferentes condições de ferramenta, promovendo maior controle e eficiência no processo de fabricação (HUANG et al., 2023).

3. Resultados

A análise dos resultados desempenha um papel fundamental na compreensão dos efeitos dos parâmetros de corte e das forças de usinagem sobre a rugosidade superficial da peça usinada. Com base na metodologia previamente descrita, os resultados apresentados têm como objetivo investigar a correlação entre as variáveis do processo, permitindo identificar padrões e tendências que possam auxiliar na otimização da usinagem. A abordagem adotada inclui tanto análises estatísticas tradicionais de correlação, além da aplicação de um modelo preditivo baseado em Random Forest para avaliar a importância relativa de cada variável na previsão da rugosidade.

3.1. Matriz De Correlação Pearson

A Figura 1 apresentada exibe a matriz de correlação das variáveis experimentais para os dois conjuntos de dados analisados: Exp1 (Ferramenta Nova) e Exp2 (Ferramenta Desgastada). Cada célula representa o coeficiente de correlação de Pearson entre duas variáveis, variando de -1 a 1, onde valores próximos de 1 indicam correlação positiva forte, valores próximos de -1 indicam correlação negativa forte e valores próximos de 0 sugerem ausência de correlação significativa.

3.1.1. Análise da Correlação - Exp1 (Ferramenta Nova)

O estudo analisou a correlação entre variáveis no processo de usinagem com ferramenta nova (Exp1); Figura 1. A profundidade de corte (ap) mostrou forte correlação positiva com as forças de usinagem F_x (0.89), F_y (0.69), F_z (0.91) e F (0.90), indicando que um aumento na profundidade resulta em maiores forças de corte. A rugosidade média (R_a) teve correlação moderada com o avanço (f) (0.76), sugerindo que valores mais altos de avanço aumentam a rugosidade da superfície. Já a velocidade de corte (vc) não influenciou significativamente as forças de usinagem ou a rugosidade, pois apresentou correlação próxima de zero com essas variáveis. A condição da ferramenta (TCond) teve correlação negativa fraca com a rugosidade (-0.15), sugerindo que o desgaste inicial pode reduzir levemente a rugosidade devido ao alisamento do gume de corte. Os diâmetros inicial e final apresentaram correlação altamente positiva entre si (0.98) e correlação negativa moderada com ap (-0.37 e -0.57), indicando que maiores profundidades de corte resultam em menores diâmetros finais, como esperado pela remoção de material.

3.1.2. Análise da Correlação - Exp2 (Ferramenta Desgastada)

No experimento com ferramenta desgastada (Exp2), os padrões de correlação entre variáveis mudam significativamente em relação à ferramenta nova (Exp1); Figura 1. A profundidade de corte (ap) tem uma correlação menor com as forças de usinagem (F_x : 0.77, F_y : 0.58, F_z : 0.50, F : 0.37), indicando que o desgaste reduz a influência da profundidade sobre as forças de corte, possivelmente devido à alteração na interação entre a peça e a ferramenta. A correlação entre avanço (f) e rugosidade (R_a) também diminuiu (0.76 para 0.63), sugerindo que o avanço tem menor impacto na rugosidade quando a ferramenta está desgastada. Por outro lado, a relação entre F_x e R_a aumenta (de 0.20 para 0.47), indicando que as forças de corte exercem maior influência na rugosidade devido ao aumento do atrito e irregularidades no corte. Além disso, surge uma forte correlação negativa entre a condição da ferramenta (TCond) e os diâmetros inicial (-0.80) e final (-0.77), o que sugere que, à medida que a ferramenta se desgasta, a remoção de material se torna menos previsível, afetando o diâmetro da peça. As forças de corte continuam fortemente correlacionadas com a força resultante ($F > 0.85$), mas essas correlações são um pouco menores no Exp2, sugerindo que o desgaste altera a distribuição das forças no processo de usinagem.

3.1.3. Análise da Correlação - Comparação Geral entre Exp1 e Exp2

Na Comparação Geral entre Exp1 e Exp2 a matriz de correlação evidencia diferenças significativas entre o comportamento da usinagem com ferramenta nova e desgastada. A profundidade de corte (ap) tem um impacto menor nas forças de corte no Exp2, indicando que a ferramenta desgastada pode reduzir a eficiência da remoção de material. O avanço (f) continua sendo um fator relevante para a rugosidade, mas com menor influência no Exp2, possivelmente devido ao aumento do desgaste e irregularidade na superfície da peça. A correlação entre as forças de corte e a rugosidade aumenta no Exp2, sugerindo que o desgaste da ferramenta intensifica o impacto dessas forças na

qualidade da superfície. A condição da ferramenta (TCond) passa a ter uma relação mais evidente com os diâmetros da peça no Exp2, indicando que o desgaste pode alterar significativamente a estabilidade dimensional do processo. A velocidade de corte (vc) continua apresentando baixa correlação com as demais variáveis, sugerindo que, dentro das faixas testadas, ela não tem um impacto significativo sobre as forças ou sobre a rugosidade da peça. Esses resultados sugerem que a ferramenta desgastada altera a dinâmica da usinagem, reduzindo a eficiência do corte e aumentando a variabilidade no acabamento superficial, o que pode exigir ajustes nos parâmetros de corte para compensar essas mudanças.

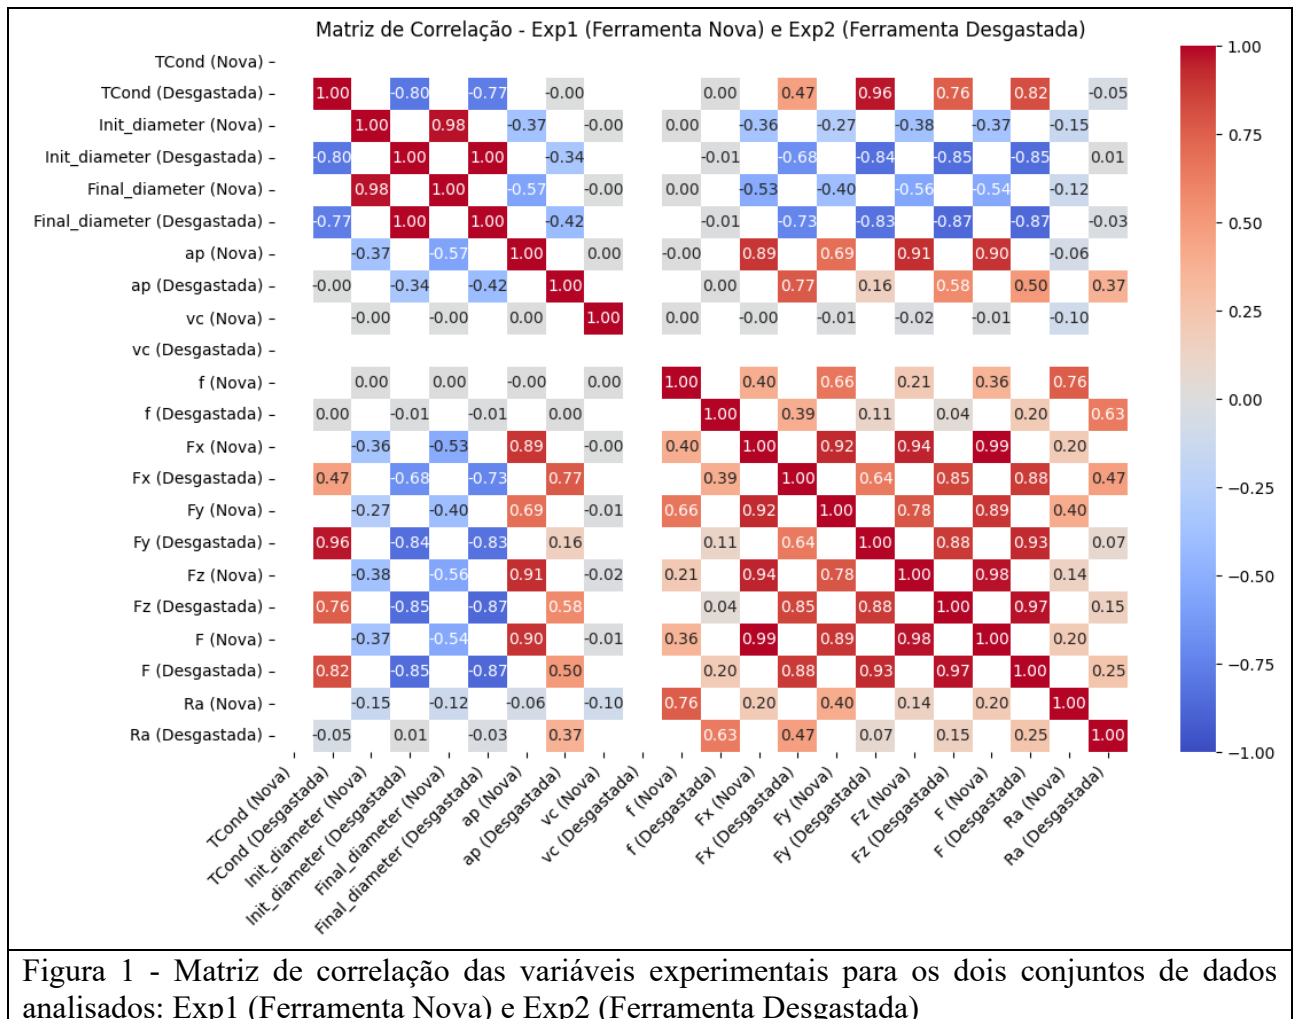


Figura 1 - Matriz de correlação das variáveis experimentais para os dois conjuntos de dados analisados: Exp1 (Ferramenta Nova) e Exp2 (Ferramenta Desgastada)

3.2. Modelagem Preditiva da Rugosidade Superficial

A análise preditiva da rugosidade média (Ra) foi realizada por meio da aplicação de um Random Forest Regressor, permitindo estimar os valores de rugosidade com base nos parâmetros de corte e nas forças de usinagem. Para garantir uma avaliação mais precisa, o modelo foi treinado e testado separadamente para os dois experimentos analisados: Exp1 (Ferramenta Nova) e Exp2 (Ferramenta Desgastada). A validação do modelo foi realizada utilizando métricas estatísticas e visualizações gráficas, que auxiliam na interpretação do seu desempenho preditivo. Para avaliar a eficácia do Random Forest Regressor na previsão da rugosidade superficial, foram empregadas métricas estatísticas amplamente utilizadas em problemas de regressão. Os resultados obtidos para os experimentos com ferramenta nova e ferramenta desgastada estão apresentados na Tabela 1.

Tabela 1 - Avaliação do desempenho do modelo preditivo.

Métrica	Experimento 1 (Ferramenta Nova)	Experimento 2 (Ferramenta Desgastada)
Coeficiente de Determinação (R^2)	0.9534	0.9643
Variância Explicada (%)	95,54%	96,43%
Erro Absoluto Médio (MAE)	0.0406	0.0271
Raiz do Erro Quadrático Médio (RMSE)	0.0752	0.0396
Erro Percentual Médio Absoluto (MAPE)	6,43%	4,63%

Os resultados da Tabela 1 indicam que o modelo RFR apresentou alta capacidade de generalização e precisão na previsão da rugosidade superficial em ambas as condições de usinagem. No Experimento 1 (Ferramenta Nova), o coeficiente de determinação (R^2) de 0.9534 indica que aproximadamente 95,34% da variabilidade da rugosidade pode ser explicada pelas variáveis preditoras, evidenciando um forte ajuste do modelo aos dados experimentais. A variância explicada de 95,54% reforça a confiabilidade da previsão, enquanto o MAE de 0.0406 e o RMSE de 0.0752 indicam um baixo desvio médio entre os valores reais e os valores previstos pelo modelo. O MAPE de 6,43% revela que a margem de erro percentual nas previsões é relativamente pequena, sugerindo boa estabilidade do modelo.

No Experimento 2 (Ferramenta Desgastada), observa-se um desempenho ainda mais preciso do modelo. O coeficiente de determinação R^2 de 0.9643 demonstra que 96,43% da variação na rugosidade superficial pode ser explicada pelos parâmetros de entrada. Além disso, a redução nos valores do MAE (0.0271) e do RMSE (0.0396) reforça a acurácia do modelo, enquanto o MAPE de 4,63% indica um erro percentual inferior ao do Experimento 1. Esses resultados sugerem que, mesmo com a ferramenta desgastada, o modelo foi capaz de capturar os padrões da rugosidade com alta precisão, possivelmente devido a uma distribuição mais consistente dos dados experimentais.

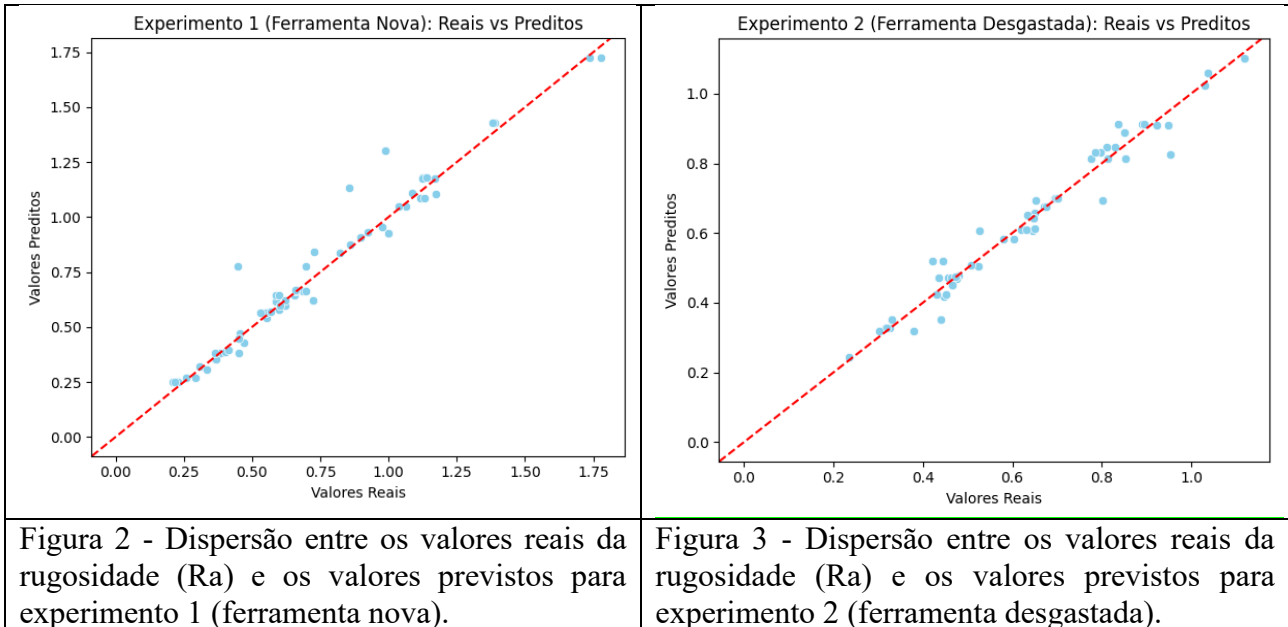
A comparação entre os dois experimentos indica que a modelagem preditiva baseada no Random Forest Regressor é altamente eficaz na previsão da rugosidade superficial em processos de usinagem. O melhor desempenho observado no Experimento 2 pode estar relacionado à estabilização dos parâmetros de corte devido ao desgaste progressivo da ferramenta, resultando em menor variabilidade nas medições de rugosidade. Esses dados reforçam o potencial do aprendizado de máquina para otimizar o monitoramento e controle de qualidade em processos industriais, permitindo ajustes mais precisos dos parâmetros de corte e promovendo maior eficiência na produção.

3.3. Desempenho do Modelo para o Experimento 1 (Ferramenta Nova) e o Experimento 2 (Ferramenta Desgastada): Comparação entre Valores Reais e Preditos e Análise dos Erros Residuais

A seguir, são apresentadas as principais visualizações utilizadas para avaliar o desempenho do modelo RFR aplicado ao Experimento 1 (Ferramenta Nova) e ao Experimento 2 (Ferramenta Desgastada). As Figuras 2 e 3 mostram a relação entre os valores reais e os valores preditos da rugosidade média (R_a), enquanto as Figuras 4 e 5 apresentam a distribuição dos erros residuais, permitindo verificar a precisão do modelo e identificar possíveis tendências nos erros.

3.3.1. Análise do Gráfico de Dispersão: Valores Reais vs Preditos

As Figura 2 e 3 exibem a relação entre os valores reais da rugosidade (R_a) e os valores preditos pelo modelo. Cada ponto azul representa uma observação do conjunto de teste, enquanto a linha vermelha tracejada representa a linha ideal 1:1, onde as previsões do modelo seriam idênticas aos valores reais.



Observa-se na Figura 2 que a maioria dos pontos se encontra muito próxima da linha de referência, indicando que o modelo conseguiu prever os valores de rugosidade com alta precisão. A distribuição dos pontos ao longo da diagonal sugere uma forte correlação entre os valores reais e os valores preditos. No entanto, há alguns pontos com ligeira dispersão, principalmente para valores mais altos de rugosidade. Essa pequena dispersão pode indicar que, para certos níveis de rugosidade, o modelo apresenta uma leve subestimação ou superestimação dos valores.

Observa-se na Figura 3 que os pontos estão bem alinhados à linha de referência, indicando uma forte correlação entre os valores reais e os valores preditos pelo modelo. Essa aderência sugere que o modelo conseguiu capturar bem os padrões do experimento, gerando previsões altamente precisas. No entanto, há uma pequena dispersão nos valores mais altos de rugosidade, o que pode indicar uma leve dificuldade do modelo em prever valores extremos com a mesma precisão que os valores intermediários.

3.3.2. Análise do Histograma dos Erros Residuais

As Figura 4 e 5 exibem a distribuição dos erros residuais, que representam a diferença entre os valores reais e os valores preditos ($\text{Erro Residual} = \text{Valor Real} - \text{Valor Predito}$). A curva azul representa a densidade da distribuição dos erros, ajudando a visualizar a tendência da dispersão dos erros.

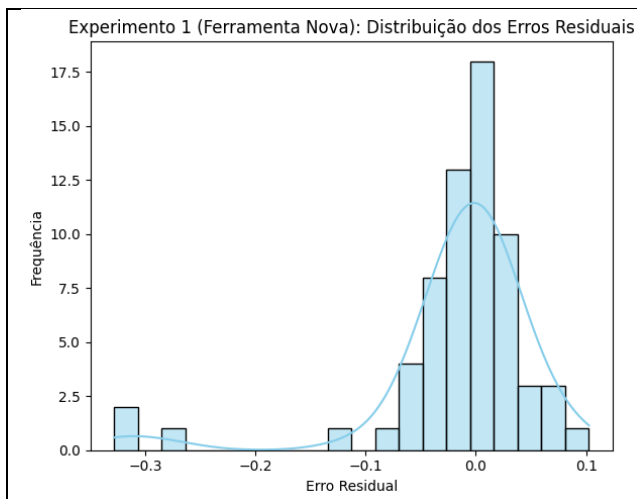


Figura 4 - Distribuição dos erros residuais para experimento 1 (ferramenta nova).

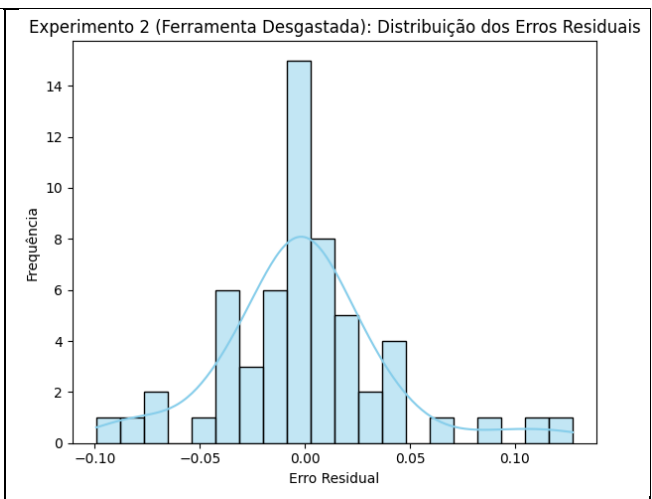


Figura 5 – Distribuição dos erros residuais para experimento 2 (ferramenta desgastada).

A maior parte dos erros, Figura 4 está concentrada próxima de zero, o que sugere que o modelo não apresenta viés significativo. Além disso, a distribuição dos erros possui um formato aproximadamente normal, o que é um indicativo positivo de um modelo bem ajustado. Entretanto, observa-se a presença de alguns valores residuais mais negativos (abaixo de -0.3), o que sugere que, em algumas instâncias, o modelo pode estar superestimando a rugosidade real, resultando em previsões ligeiramente mais altas do que os valores reais. Apesar disso, a frequência desses erros extremos é baixa, o que indica que o modelo mantém uma boa estabilidade preditiva na maioria dos casos.

A distribuição dos erros, Figura 5 se aproxima de uma curva normal centrada em zero, indicando que o modelo não apresenta viés significativo e que os erros estão distribuídos de maneira simétrica. Isso é um indicativo de um modelo bem ajustado, pois sugere que as previsões não estão sistematicamente subestimando ou superestimando os valores reais. A maior parte dos erros está concentrada entre -0.05 e 0.05, demonstrando que o erro médio das previsões é pequeno e que o modelo apresenta baixa variabilidade nos erros. Além disso, não há evidência de outliers significativos, o que reforça a estabilidade do modelo. A análise do gráfico indica que o modelo RFR apresentou excelente desempenho na previsão da rugosidade (R_a) para o Experimento 2 (Ferramenta Desgastada). O alinhamento dos pontos no gráfico de dispersão confirma que os valores preditos são altamente coerentes com os valores reais, e a distribuição normal dos erros residuais sugere que não há desvios sistemáticos nas previsões.

Esses resultados reforçam que o modelo pode ser utilizado de forma confiável para antecipar a rugosidade superficial da peça, permitindo ajustes nos parâmetros do processo de usinagem. Além disso, o bom desempenho preditivo no Experimento 2, mesmo com a ferramenta desgastada, sugere que o modelo é capaz de lidar com condições de corte mais desafiadoras, mantendo um nível elevado de precisão.

3.4. Análise das Principais Variáveis para o Experimento 1 (Ferramenta Nova) e para o Experimento 2 (Ferramenta Desgastada)

A Figura 6 apresentada compara a importância das variáveis na previsão da rugosidade média (R_a) nos dois experimentos: com ferramenta nova (Exp1) e ferramenta desgastada (Exp2), utilizando um modelo Random Forest Regressor.

No Exp1 (ferramenta nova), o avanço por rotação (f) foi a variável mais importante, com 58,08% de influência na rugosidade superficial. Esse resultado confirma que o avanço é um dos principais fatores que afetam a qualidade do acabamento da peça usinada. No Exp2 (ferramenta desgastada), a importância do avanço reduziu para 38,16%, indicando que, embora ainda seja um fator determinante, outras variáveis passaram a influenciar mais a rugosidade quando a ferramenta se desgasta.

As forças de usinagem (F_x , F_y , F_z , F) tiveram uma mudança significativa entre os experimentos. No Exp1, a força de corte F_x apresentou 14,34% de importância, enquanto F_y e F_z tiveram 8,36% e 7,39%, respectivamente. Já no Exp2, as forças de usinagem se tornaram mais influentes, com F_y aumentando para 17,45% e F_z para 16,44%. Essa mudança sugere que o desgaste da ferramenta eleva a influência das forças de corte na rugosidade, possivelmente devido ao aumento do atrito e das vibrações durante o processo.

A condição da ferramenta (TCond), que no Exp1 não teve importância (0%) por se tratar de uma ferramenta nova, passou a ter 5,02% de relevância no Exp2, evidenciando que o desgaste influencia diretamente a rugosidade da peça. Esse resultado reforça a necessidade de monitoramento do desgaste para garantir um acabamento superficial mais previsível.

Os diâmetros inicial e final tiveram baixa influência nos dois experimentos, com leve redução da importância no Exp2, sugerindo que essas dimensões não impactam significativamente a rugosidade dentro das condições experimentais. Esse comportamento indica que a variação dimensional da peça não tem correlação direta com a qualidade do acabamento superficial.

A profundidade de corte (ap) e a velocidade de corte (vc) mostraram pouca influência na rugosidade. No Exp1, a profundidade de corte teve 0,37% de importância, enquanto a velocidade de corte contribuiu com 1,08%. No Exp2, a importância da profundidade de corte caiu ainda mais para 0,06%, e a velocidade de corte tornou-se irrelevante (0%). Isso sugere que esses parâmetros não tiveram impacto significativo na rugosidade dentro das condições analisadas.

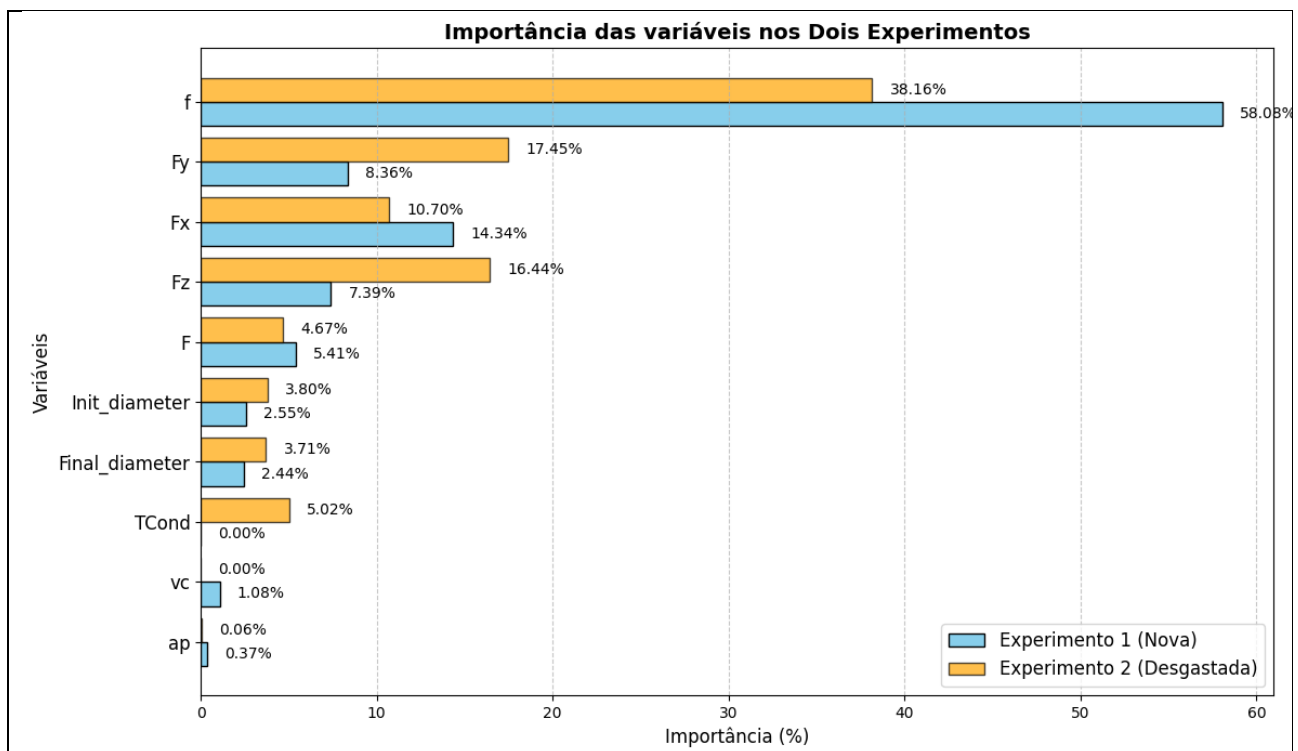


Figura 6 - Importância das variáveis na previsão da rugosidade média (R_a) nos dois experimentos: com ferramenta nova (Exp1) e ferramenta desgastada (Exp2).

Desta forma, no Exp1 (ferramenta nova), a rugosidade superficial é fortemente influenciada pelo avanço (f), enquanto as forças de corte desempenham um papel secundário. No Exp2 (ferramenta desgastada), a importância do avanço diminuiu e as forças de usinagem passaram a desempenhar um papel mais relevante, indicando que o desgaste da ferramenta altera a dinâmica do corte, tornando o processo mais instável. Dessa forma, o controle do avanço e o monitoramento das forças de corte são essenciais para minimizar a rugosidade superficial, especialmente quando a ferramenta se encontra desgastada.

4. Conclusões

As análises realizadas demonstraram que o avanço por rotação (f) é a variável mais influente na previsão da rugosidade superficial (R_a). No Experimento 1 (Ferramenta Nova), o avanço teve uma contribuição de 58,08%, enquanto no Experimento 2 (Ferramenta Desgastada) sua influência foi reduzida para 38,16%, indicando que o desgaste da ferramenta altera os fatores que afetam a rugosidade. Com o aumento do desgaste, as forças de usinagem, especialmente F_y (17,45%) e F_z (16,44%), passaram a ter maior impacto na rugosidade, reforçando a importância de um controle rigoroso dessas variáveis no processo de usinagem.

A ferramenta desgastada influenciou significativamente o comportamento das forças de corte e a rugosidade, aumentando a instabilidade do processo de corte. Isso sugere que o desgaste da ferramenta causa alterações na interação entre a ferramenta e a peça, resultando em maiores forças de corte e, conseqüentemente, uma rugosidade superficial menos previsível. Dessa forma, estratégias de monitoramento da integridade da ferramenta tornam-se essenciais para manter a qualidade do acabamento superficial e minimizar defeitos no processo de usinagem.

O modelo RFR apresentou alta precisão na previsão da rugosidade, atingindo coeficientes de determinação (R^2) de 0.9534 (Exp1) e 0.9643 (Exp2). Além disso, os baixos erros preditivos, como MAE de 0.0406 (Exp1) e 0.0271 (Exp2) e MAPE de 6,43% (Exp1) e 4,63% (Exp2), reforçam sua eficácia como ferramenta para modelagem preditiva da rugosidade superficial. Os gráficos de dispersão demonstraram um forte alinhamento entre os valores preditos e reais, enquanto os histogramas dos erros residuais indicaram uma distribuição aproximadamente normal e centrada em zero, confirmando a ausência de vieses significativos no modelo.

A correlação de Pearson revelou diferenças importantes entre os experimentos, evidenciando mudanças nos fatores determinantes da rugosidade conforme o desgaste da ferramenta evoluiu. No Experimento 1, o avanço por rotação (f) apresentou correlação moderada (0.76) com a rugosidade, sugerindo que essa variável é dominante quando a ferramenta está nova. No Experimento 2, a força de corte (F_x) passou a ter maior influência, com correlação de 0.47, indicando que o aumento do atrito e das irregularidades no contato ferramenta-peça tornam a rugosidade mais dependente das forças de usinagem do que dos parâmetros de corte convencionais.

A análise do gráfico de dispersão: valores reais vs preditos evidenciou a alta precisão do modelo Random Forest Regressor na previsão da rugosidade superficial. A forte correlação observada entre os valores reais e preditos, com pontos bem distribuídos ao longo da linha de referência de 45°, indica que o modelo foi capaz de capturar os padrões do processo de usinagem com eficiência. Pequenos desvios observados em alguns pontos sugerem que variações não lineares ou efeitos

secundários podem influenciar a rugosidade em determinadas condições, mas sem comprometer significativamente a capacidade preditiva do modelo.

A análise do histograma dos erros residuais demonstrou que os erros do modelo seguem uma distribuição aproximadamente normal e centrada em zero, indicando que o modelo não apresenta viés significativo nas previsões. A simetria do histograma reforça que os erros estão distribuídos de maneira equilibrada, sem tendências sistemáticas de sub ou superestimação da rugosidade. A baixa dispersão dos erros sugere que o modelo é robusto e confiável para prever a rugosidade superficial em diferentes condições experimentais, garantindo previsões consistentes e com margens de erro reduzidas.

Na análise das principais variáveis para o Experimento 1 (Ferramenta Nova) e Experimento 2 (Ferramenta Desgastada), observou-se que, no Experimento 1, o avanço por rotação (f) foi a variável de maior influência na rugosidade, representando 58,08% da importância no modelo, seguido pela força de corte F_x (14,34%), indicando que a remoção de material e a interação entre a ferramenta e a peça são os principais fatores determinantes da rugosidade quando a ferramenta está em boas condições. No Experimento 2, a influência do avanço foi reduzida para 38,16%, enquanto as forças de corte F_y (17,45%) e F_z (16,44%) passaram a ter maior impacto na rugosidade, sugerindo que o desgaste da ferramenta altera a dinâmica do corte, tornando as forças de usinagem fatores mais críticos para o acabamento superficial. Esses resultados indicam que ajustes nos parâmetros de corte e no monitoramento das forças de usinagem são essenciais para garantir um controle eficaz da rugosidade ao longo da vida útil da ferramenta.

Os resultados confirmam que a modelagem preditiva baseada em aprendizado de máquina pode otimizar processos de usinagem, permitindo ajustes mais precisos nos parâmetros de corte. A aplicação de técnicas estatísticas e de inteligência artificial contribui para a melhoria da qualidade do acabamento superficial, maior controle de qualidade e aumento da eficiência da manufatura, minimizando defeitos e maximizando a vida útil da ferramenta. Assim, a integração de modelos preditivos na indústria pode proporcionar avanços significativos na otimização de processos produtivos, reduzindo custos operacionais e melhorando a confiabilidade da produção.

5. Referências Bibliográficas

- AGGARWAL, C. C. Neural networks and deep learning. Cham: Springer International Publishing, 2018. 512 p.
- AYYASWAMY, John Presin Kumar et al. Predictive model development in dry turning of Nimonic C263 by artificial neural networks. *Materials Today: Proceedings*, v. 59, p. 1284-1290, 2022.
- CANAL, André Dorigueto. Surface roughness analysis in turning processes using ANN. 2022. 158 f. Dissertação (Mestrado em Engenharia Aeronáutica e Mecânica) – Instituto Tecnológico de Aeronáutica, São José dos Campos, 2022.
- ALMEIDA, L., & Costa, R. (2018). Feature Selection Methods for Machining Performance Analysis. *Journal of Applied Machine Learning*, 15(4), 89-103.
- CHEN, H., Zhao, W., & Liu, M. (2021). Enhancing Predictive Accuracy of Surface Roughness Using Random Forest Regressor. *Manufacturing Science & Engineering Journal*, 58(2), 112-130.

- FERREIRA, A., Barbosa, L., & Mendes, R. (2020). Analysis of Cutting Forces in Metal Cutting Operations. *Materials & Manufacturing Processes*, 35(6), 876-890.
- HUANG, PoTsang B. et al. The development of an ANN surface roughness prediction system of multiple materials in CNC turning. *The International Journal of Advanced Manufacturing Technology*, v. 125, n. 3-4, p. 1193-1211, 2023.
- JOHNSON, R. A., & Wichern, D. W. (2020). *Applied Multivariate Statistical Analysis*. Pearson.
- LIU, Y., & Wang, Q. (2023). Machine Learning Approaches for Optimizing Machining Processes. *International Journal of Advanced Manufacturing Technology*, 105(5), 1248-1267.
- MARTINS, T., & Costa, R. (2023). Impact of Tool Wear on Surface Roughness in Machining. *Procedia CIRP*, 98, 89-104.
- NGUYEN, P., Tran, T., & Kim, D. (2020). Error Analysis in Predictive Models for Surface Roughness Estimation. *Journal of Intelligent Manufacturing*, 31(6), 1509-1524.
- OLIVEIRA, F., & Santos, P. (2021). Optimization of Machining Parameters for Surface Roughness Improvement. *International Journal of Advanced Manufacturing Technology*, 57(3), 250-267.
- SILVA, R., Souza, M., & Lima, J. (2019). Effects of Cutting Speed on Tool Wear in Machining Operations. *Journal of Manufacturing Processes*, 47, 102-118.
- SINGH, R., Verma, A., & Kaur, P. (2022). Regression Models in Manufacturing: Performance Evaluation and Optimization. *Computers in Industry*, 88, 102-118.
- ZHOU, X., Li, J., & Zhang, Y. (2019). A Study on Random Forest in Machine Learning Applications. *Journal of AI Research*, 42(3), 210-225.