

UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO  
EM ENGENHARIA DE PRODUÇÃO

**PREVISÃO E INTERPRETAÇÃO DO DESGASTE  
DA FERRAMENTA NO TORNEAMENTO DO AÇO  
AISI 52100 ENDURECIDO POR MEIO DE ANÁLISE  
DE VIBRAÇÃO E APRENDIZADO DE MÁQUINA  
EXPLICÁVEL**

LUCAS RIBEIRO ALVES COSTA

ITAJUBÁ, DEZEMBRO DE 2025

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO

EM ENGENHARIA DE PRODUÇÃO

LUCAS RIBEIRO ALVES COSTA

**PREVISÃO E INTERPRETAÇÃO DO DESGASTE  
DA FERRAMENTA NO TORNEAMENTO DO AÇO  
AISI 52100 ENDURECIDO POR MEIO DE ANÁLISE  
DE VIBRAÇÃO E APRENDIZADO DE MÁQUINA  
EXPLICÁVEL**

Dissertação submetida ao programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do Título de Mestre em Ciências em Engenharia de Produção.

Área de Concentração: Engenharia de Produção

Orientador: Prof. Dr. Matheus Brendon Francisco

Coorientador: Prof. Dr. Sebastião Simões da Cunha Junior

ITAJUBÁ, DEZEMBRO DE 2025

## Resumo

O torneamento é um dos principais processos de usinagem utilizados na fabricação de componentes metálicos com alta precisão dimensional e bom acabamento superficial. A eficiência desse processo depende diretamente do estado da ferramenta de corte, cujo desgaste influencia a qualidade da peça, o tempo de ciclo e os custos de produção. Nesse contexto, o monitoramento e a previsão do desgaste de ferramenta tornam-se fundamentais para garantir produtividade e confiabilidade nos sistemas de manufatura. Este trabalho teve como objetivo prever o desgaste da ferramenta no processo de torneamento do aço AISI 52100 por meio da análise de sinais de vibração, utilizando técnicas de Inteligência Artificial (IA). Os sinais foram coletados por dois sensores distintos — um vibrômetro a laser e um acelerômetro tridimensional —, possibilitando a aquisição precisa das respostas dinâmicas do sistema durante o processo de usinagem. A partir dos sinais brutos, foram extraídas características relevantes nos domínios do tempo e da frequência, como amplitude, energia, curtose, assimetria e frequência dominante, compondo o conjunto de variáveis para a modelagem. Foram avaliados diversos modelos de aprendizado de máquina, incluindo Redes Neurais Artificiais (MLP), Support Vector Regression (SVR), Extra Trees e XGBoost, bem como técnicas de aprendizado em conjunto (ensemble learning). O modelo combinado por stacking apresentou o melhor desempenho, alcançando  $R^2 = 0,88$  e  $MSE = 0,00552$ , superando as abordagens individuais. A análise de importância das variáveis, realizada por meio do método SHAP (SHapley Additive exPlanations), evidenciou que a energia e a curtose dos sinais de vibração possuem maior influência sobre o desgaste, confirmando a coerência física do modelo. Além disso, foi implementada uma interface interativa em Python (Gradio) integrando o modelo preditivo com um modelo de linguagem de grande porte (LLM), capaz de gerar recomendações automáticas de parâmetros de corte e interpretações em linguagem natural. Essa integração amplia a explicabilidade dos resultados e demonstra o potencial da IA aplicada à usinagem inteligente, alinhando-se aos princípios da Manufatura 4.0 e da Explainable Artificial Intelligence (XAI). Os resultados obtidos confirmam a viabilidade da proposta para o monitoramento preditivo e assistido do desgaste de ferramentas, indicando caminhos promissores para a aplicação industrial de sistemas inteligentes de apoio à decisão no contexto da manufatura avançada.

**Palavras-chave:** Ensemble Learning; Desgaste de ferramentas; Inteligência Artificial; SHAP; Explainable AI; Manufatura 4.0.

## Abstract

Turning is one of the main machining processes used in the manufacture of metallic components with high dimensional accuracy and good surface finish. The efficiency of this process directly depends on the condition of the cutting tool, whose wear affects the quality of the workpiece, the cycle time, and production costs. In this context, monitoring and predicting tool wear are essential to ensure productivity and reliability in manufacturing systems. This work aimed to predict tool wear in the turning process of AISI 52100 steel through the analysis of vibration signals using Artificial Intelligence (AI) techniques. The signals were collected by two different sensors — a laser vibrometer and a three-axis accelerometer — allowing precise acquisition of the system's dynamic responses during machining. From the raw signals, relevant features were extracted in both time and frequency domains, such as amplitude, energy, kurtosis, skewness, and dominant frequency, composing the set of variables used for modeling. Several machine learning models were evaluated, including Artificial Neural Networks (MLP), Support Vector Regression (SVR), Extra Trees, and XGBoost, as well as ensemble learning techniques. The stacking ensemble model achieved the best performance, reaching  $R^2 = 0.88$  and  $MSE = 0.00552$ , surpassing the individual approaches. The variable importance analysis performed using the SHAP (SHapley Additive exPlanations) method revealed that the energy and kurtosis of the vibration signals exert the greatest influence on wear, confirming the physical consistency of the model. In addition, an interactive interface was implemented in Python (Gradio), integrating the predictive model with a Large Language Model (LLM) capable of automatically generating cutting parameter recommendations and natural language interpretations. This integration enhances the explainability of the results and demonstrates the potential of AI applied to intelligent machining, in line with the principles of Industry 4.0 and Explainable Artificial Intelligence (XAI). The results confirm the feasibility of the proposed approach for predictive and assisted monitoring of tool wear, indicating promising paths for the industrial application of intelligent decision-support systems within the context of advanced manufacturing.

**Keywords:** Ensemble Learning; Tool life; Artificial Intelligence; SHAP; Explainable AI; Industry 4.0.

## LISTA DE FIGURAS

Figura 1 – Exemplo esquemático torneamento	1
Figura 2 – Exemplo de uma regressão linear	17
Figura 3 – Exemplo de uma <i>extra trees regressor</i>	19
Figura 4 – Exemplo de uma <i>random forest regressor</i>	20
Figura 5 – Exemplo de uma <i>gradient boosting regressor</i>	22
Figura 6 – Exemplo de uma <i>adaboost regressor</i>	23
Figura 7 – Exemplo de uma <i>support vector machine</i>	25
Figura 8 – Exemplo de uma rede neural	26
Figura 9 – Exemplo de uma <i>stacking ensemble</i>	29
Figura 10 – Montagem para a aquisição dos sinais de vibração	33
Figura 11 – Extração de Características domínio do tempo	37
Figura 12 - Extração de Características domínio da frequência	37
Figura 13 - Valores reais x valores previstos SVR	44
Figura 14 - Valores reais x valores previstos Redes Neurais	44
Figura 15 - Valores reais x valores previstos Ensemble	45
Figura 16 - Importância das variáveis para a previsão da rugosidade superficial obtida pelo método SHAP	47
Figura 17 - Interface inteligente de recomendação desenvolvida em Python (Gradio)	49

## LISTA DE TABELAS

Tabela 1 - Resumo de estudos relevantes sobre revisão em usinagem utilizando <i>Machine Learning</i> .	2
Tabela 2 – Trabalhos sobre a Influência da Vibração no Processo de Usinagem	14
Tabela 3 – Matriz experimental	33
Tabela 4 – Dados experimentais do torneamento	34
Tabela 5 – Correlação com o desgaste	35
Tabela 6 - Hiperparâmetros Otimizados dos Modelos de Regressão	39
Tabela 7 - Desempenho dos modelos de aprendizado de máquina na previsão da vida útil da ferramenta.	44

# SUMÁRIO

1 INTRODUÇÃO	1
2 REFERENCIAL TEÓRICO	6
2.1 Características do processo de torneamento	6
2.2 - Coleta e Análise de Sinais de Vibração em Processos de Usinagem	8
2.2.1 - Sensores de Vibração	8
2.2.2 - Posicionamento dos Sensores	9
2.2.3 - Sistemas de Aquisição de Dados (DAQ)	10
2.2.4 - Frequência de Amostragem	11
2.2.5 - Análise no Domínio do Tempo	11
2.2.6 - Análise no Domínio da Frequência	13
2.3 - <i>Machine Learning</i> Aplicado à Previsão do Desgaste da Ferramenta	15
2.3.1 - Modelos de <i>Machine Learning</i> para Previsão do Desgaste	15
2.3.1.1 - Regressão Linear	15
2.3.1.2 - <i>ExtraTreesRegressor</i>	17
2.3.1.3 - <i>Random Forest Regressor</i>	19
2.3.1.4 - <i>Gradient Boosting Regressor</i>	21
2.3.1.5 - <i>AdaBoost Regressor</i>	22
2.3.1.6 - <i>Support Vector Regression (SVR)</i>	24
2.3.1.7 - <i>Multi Layer Perceptron</i>	26
2.3.1.8 - <i>Ensemble Methods</i>	27
2.3.2 - Explicabilidade em Modelos de Aprendizado de Máquina	29
3 METODOLOGIA	30
3.1 Entendimento do Problema e do Objeto de Estudo	31
3.2 Entendimento dos Dados	32
3.2.1 - Procedimento Experimental e Coleta de Dados	32

3.2.2 - Características dos Dados e Tratamento	35
3.3 Preparação dos Dados	37
3.4 Modelagem	38
3.4.1 Seleção e Construção dos Modelos Base	40
3.4.2 Otimização de Hiperparâmetros via <i>Grid Search</i> e Validação Cruzada	41
3.4.3 <i>Ensemble Stacking</i>	41
3.5 Avaliação	42
3.6 Implantação	43
4 RESULTADOS	43
5 CONCLUSÃO	51
6 REFERÊNCIAS	52

# 1 Introdução

O torneamento (Figura 1) é uma das técnicas de usinagem mais utilizadas na indústria, fundamental na produção de peças com geometrias diversas e elevada precisão dimensional. O processo consiste basicamente na remoção de material de uma peça giratória, utilizando ferramentas de corte que variam de acordo com as necessidades da aplicação (Campos & Muniz, 2019).




Figura 1 – Exemplo esquemático torneamento. Fonte: Autor

A eficiência do torneamento, no entanto, depende de uma série de fatores, como os parâmetros de corte (velocidade, avanço, profundidade de corte), as propriedades do material usinado (Santos *et al.*, 2023), e as características da própria ferramenta (Aleixo, 2023). Neste estudo, as variáveis investigadas foram a velocidade de corte ( $V_c$ ) e o avanço ( $f$ ), enquanto a profundidade de corte ( $a_p$ ) foi mantida constante em 0,10 mm. Essa decisão visou isolar os efeitos de  $V_c$  e  $f$  sobre o desgaste da ferramenta, simplificando a análise experimental sem comprometer a representatividade do processo. Todos esses elementos impactam diretamente no desempenho da ferramenta e no tempo em que ela permanece funcional durante o processo. Por isso, prever o desgaste da ferramenta é essencial para garantir produtividade, evitar paradas inesperadas e reduzir custos.

Neste trabalho, o desgaste da ferramenta é tratado como uma variável contínua, sendo avaliado por meio do desgaste de flanco (VB), medido em milímetros (mm), conforme práticas consolidadas na literatura e a norma ISO 3685. Ressalta-se que o objetivo do estudo não consiste na previsão futura de séries temporais, mas sim na estimativa do desgaste da ferramenta a partir de características extraídas de sinais de vibração, considerando diferentes condições de usinagem. Cada observação do conjunto de dados representa um estado específico do processo, analisado de forma independente, caracterizando um problema de regressão supervisionada.

Na prática industrial, o desgaste da ferramenta ainda costuma ser monitorado por métodos tradicionais, como inspeções visuais ou medições periódicas. Embora eficientes, essas abordagens apresentam limitações, principalmente em ambientes de produção automatizados, nos quais se espera maior integração com sistemas de monitoramento inteligentes. Neste cenário, o avanço de sensores e algoritmos de inteligência artificial (IA) tem permitido o desenvolvimento de novas soluções para prever o desgaste da ferramenta de forma mais precisa e em tempo real (Huang & Lee, 2021).

Entre as alternativas disponíveis, destacam-se métodos baseados em diferentes tipos de sinais, como emissão acústica, força de corte, corrente do motor e vibração. Dentre esses, a análise de sinais de vibração tem se mostrado particularmente promissora, pois tais sinais carregam informações importantes sobre o estado da ferramenta e do processo, quando combinados com modelos de aprendizado de máquina, tornam possível identificar padrões relacionados ao desgaste. Com isso, torna-se viável antecipar falhas e otimizar as trocas de ferramentas, alinhando-se aos princípios da manutenção preditiva.

Nos últimos anos, diversos estudos têm aprofundado essa linha de pesquisa. Shantisagar *et al.* (2019) aplicaram lógica fuzzy e árvores de decisão para monitorar ferramentas com base em sinais de vibração. Zhou *et al.* (2020) propuseram uma abordagem que combina sensores de temperatura e vibração com modelos de aprendizado profundo. Já Segreto *et al.* (2020) integraram o uso de *wavelets* e aprendizado de máquina para aprimorar a extração de características em sinais transitórios.

Estudos recentes reforçam a importância do uso de algoritmos de *machine learning* no monitoramento de desgaste de ferramentas. Baig *et al.* (2021) utilizaram redes neurais artificiais para prever o desgaste com base em sinais de vibração durante o torneamento de

aços, obtendo previsões precisas mesmo sob diferentes velocidades de corte. *Zabala et al.* (2023), por sua vez, integraram vibração e temperatura em um modelo de aprendizado supervisionado para estimar tensões residuais, mostrando que a fusão de múltiplas variáveis físicas aumenta a robustez das predições.

*Tabaszewski* (2022) comparou diversos métodos de *machine learning* aplicados ao torneamento de ferro fundido cinzento EN-GJL-250, destacando que algoritmos baseados em vibração conseguem discriminar com alta acurácia diferentes níveis de desgaste e identificar o momento ideal para troca da ferramenta. *Liu et al.* (2022) avançaram ao propor uma arquitetura híbrida *CNN-LSTM*, capaz de extrair automaticamente padrões temporais e espectrais dos sinais de vibração, superando modelos tradicionais em termos de erro médio quadrático e estabilidade de generalização.

Seguindo essa tendência de modelos mais complexos, *Gajewski et al.* (2023) integraram múltiplos sensores (vibração, força de corte e corrente de *spindle*) a uma rede profunda de aprendizado, demonstrando que a combinação de diferentes domínios de medição reduz falsos positivos na detecção de falhas. Já *Cardoz et al.* (2023) exploraram uma abordagem multimodal, combinando sinais de vibração e imagens de alta resolução da ferramenta para alimentar um classificador baseado em *random forest*, atingindo acurácia superior a 95 % na identificação automática da condição da aresta de corte.

Além disso, *Xie et al.* (2023) desenvolveram uma estratégia de *meta-learning* voltada à generalização do modelo de predição de desgaste para diferentes materiais e parâmetros de corte, reduzindo a necessidade de re-treinamento em novos cenários experimentais. *Li et al.* (2024) aplicaram *Support Vector Machine (SVM)* na previsão da vida útil da ferramenta durante a usinagem de compósitos MMC com vibração ultrassônica e eletroerosão, demonstrando que a integração de múltiplos tipos de excitação mecânica pode aprimorar a precisão das estimativas de desgaste.

Por sua vez, *Shah et al.* (2023) aplicaram *machine learning* sobre sinais de vibração e emissão acústica, utilizando transformadas no domínio da frequência para melhorar a sensibilidade à evolução do desgaste. Os autores verificaram que a integração dessas fontes de dados reduz significativamente o erro de previsão quando comparada a abordagens baseadas em um único tipo de sensor.

Esses trabalhos, embora distintos em metodologia e domínio experimental, convergem para a constatação de que a análise combinada de vibração e técnicas de aprendizado supervisionado constitui uma alternativa eficaz para o monitoramento preditivo da vida útil de ferramentas. No presente estudo, adota-se essa premissa, expandindo-a por meio da integração de múltiplos modelos e do uso de *ensemble stacking* para aumentar a robustez e interpretabilidade das previsões. A Tabela 1 resume os principais estudos revisados, destacando materiais, variáveis analisadas, fontes de dados e algoritmos empregados.

Tabela 1 - Resumo de estudos relevantes sobre revisão em usinagem utilizando *Machine Learning*.

<b>Autor/Ano</b>	<b>Material Usinado</b>	<b>Resposta Analisada</b>	<b>Tipo de Dados de Entrada</b>	<b>Algoritmos Implementados</b>
Baig et al., 2021	Aço (torneamento)	Desgaste da ferramenta	Vibração durante o corte	<i>Artificial Neural Networks (ANN)</i>
Dalmedico et al., 2024	Liga de Alumínio 3003	Desgaste da ferramenta	Vibração (wavelets)	<i>Gradient Boosting, CNN</i>
Zabala et al., 2023	Inconel 718	Tensões residuais	Forças de corte, Temperatura, Vibração	Regressão Linear, Redes Neurais
Li et al., 2023	Compósitos MMC	Vida útil da ferramenta	Vibração ultrassônica e eletroerosão	<i>Support Vector Machine (SVM)</i>
Xie et al., 2023	Diversos materiais	Desgaste da ferramenta	Vibração, parâmetros de corte	<i>Meta-Learning</i>
Tabaszewski, 2022	Ferro fundido cinzento EN-GJL-250	Condição da ferramenta	Vibração e força de corte	<i>Machine Learning (comparativo)</i>
Gajewski et al., 2023	Aço AISI 1045	Condição da ferramenta	Múltiplos sensores (vibração, força, corrente)	<i>Deep Learning (multissensorial)</i>
Cardoz et al., 2023	Aço ferramenta rotativa	Condição/desgaste da aresta de corte	Vibração + imagem da ferramenta	<i>Random Forest</i>
Shah et al., 2023	Aços diversos	Desgaste da ferramenta	Vibração, emissão acústica,	<i>Machine Learning + transformadas no</i>

			temperatura	domínio da frequência
Liu et al., 2022	Aço AISI 1045 (endurecido)	Desgaste da ferramenta	Vibração (série temporal)	<i>CNN-LSTM</i> (rede híbrida)

Apesar desses avanços, a maior parte dos estudos concentra-se em materiais de usinagem convencional, como aços carbono e ligas de alumínio, que apresentam boa conformabilidade e menor abrasividade. Entretanto, materiais endurecidos como o aço AISI 52100 — amplamente empregado em rolamentos e reconhecido por sua alta dureza e resistência ao desgaste — impõem condições severas ao processo de corte (Makhfi et al., 2023), tornando a previsão do desgaste mais desafiadora e relevante.

Além disso, embora existam estudos aplicando Machine Learning para previsão de desgaste, ainda há lacunas importantes relacionadas à integração de múltiplos sensores, à extração conjunta de características nos domínios do tempo e da frequência e, sobretudo, à interpretação física das variáveis mais influentes no processo. Assim, o diferencial deste trabalho está na utilização de dois sensores distintos, na construção de um modelo ensemble do tipo stacking e, especialmente, na aplicação de técnicas de explicabilidade para interpretação dos resultados.

Nesse contexto, a questão de pesquisa que orienta este estudo é: é possível prever o desgaste da ferramenta de forma precisa e interpretável a partir de sinais de vibração e algoritmos de aprendizado de máquina, fornecendo explicações alinhadas aos fenômenos físicos do processo de usinagem?

Para responder a essa questão, o objetivo geral do trabalho consiste em desenvolver, avaliar e interpretar modelos de aprendizado de máquina capazes de prever o desgaste da ferramenta durante o torneamento do aço AISI 52100. Os objetivos específicos incluem extrair e selecionar características relevantes dos sinais de vibração, comparar o desempenho de diferentes algoritmos supervisionados, otimizar seus hiperparâmetros e propor um modelo integrado e explicável para aplicação em sistemas inteligentes de monitoramento industrial.

Este trabalho alinha-se aos princípios da Indústria 4.0, que busca uma usinagem mais inteligente, autônoma e conectada. A integração de sensores e algoritmos de aprendizagem

permite antecipar a evolução do desgaste da ferramenta com base em dados reais, otimizando intervenções, evitando falhas inesperadas e reduzindo desperdícios.

Um aspecto inovador deste estudo é o desenvolvimento de um módulo de explicabilidade automática que combina o método SHAP (SHapley Additive Explanations) com um modelo de linguagem de grande porte (Large Language Model — LLM). Há pouquíssimos trabalhos reportando essa integração na área de usinagem, o que reforça sua originalidade. O LLM permite traduzir, em linguagem natural, as contribuições de cada variável para as previsões, facilitando a interpretação para engenheiros, operadores e gestores. Dessa forma, além de prever o desgaste, o sistema fornece explicações textuais que conectam os padrões dos sinais aos mecanismos físicos do processo de corte, ampliando a transparência e o potencial de uso industrial.

O presente trabalho está estruturado da seguinte forma: a Seção 2 apresenta o referencial teórico; a Seção 3 descreve a metodologia aplicada; a Seção 4 discute os resultados obtidos; e a Seção 5 apresenta as conclusões e contribuições do estudo.

## **2 Referencial teórico**

### **2.1 Características do processo de torneamento**

O processo de torneamento é caracterizado pela remoção de material de uma peça em rotação por meio de uma ferramenta de corte de aresta única. O desempenho dessa operação depende fortemente das condições de corte, do material usinado e das propriedades da ferramenta, que influenciam diretamente o desgaste, a rugosidade superficial e a estabilidade do processo (Aleixo, 2023; Díaz Builes *et al.*, 2023; Santos *et al.*, 2023).

O processo de torneamento consiste em uma operação de corte mecânico no qual uma ferramenta de aresta única remove material de uma peça em rotação, originando o cavaco. A interação entre a ferramenta e o material da peça gera deformações plásticas intensas na zona de cisalhamento, resultando na formação de cavacos contínuos, segmentados ou descontínuos, dependendo do material, da geometria da ferramenta e das condições de corte (Diniz, Marcondes & Coppini, 2017).

A fenomenologia da formação do cavaco é fundamental para compreender o comportamento do desgaste da ferramenta, uma vez que está diretamente relacionada às tensões e

temperaturas geradas no contato peça–ferramenta. Quando o atrito é elevado e o material apresenta alta ductilidade, há maior tendência à formação de aresta postiça e desgaste de flanco, comprometendo a qualidade superficial da peça (Yaman & Tekiner, 2024).

Além disso, a vida da ferramenta é definida como o período em que se mantêm condições adequadas de corte, sendo encerrada quando o desgaste de flanco (VB) atinge aproximadamente 0,3 mm — limite amplamente utilizado pela norma ISO 3685 (1993). O conhecimento desses fenômenos é essencial para a previsão do desgaste, objetivo central deste trabalho.

Entre os parâmetros de corte, a velocidade de corte influencia diretamente a geração de calor na zona de usinagem, podendo acelerar o desgaste da ferramenta, enquanto o avanço e a profundidade de corte afetam as forças atuantes no processo, contribuindo para a intensificação dos mecanismos de desgaste (BLOUL; CHANAL; MEZIANE, 2024). Essa interação entre condições de corte e desgaste torna-se especialmente crítica em regimes de alta velocidade, nos quais os efeitos térmicos e mecânicos são acentuados. Além disso, o material usinado — neste caso, o aço AISI 52100 — apresenta elevada dureza e resistência mecânica, o que favorece mecanismos como desgaste abrasivo e deformação plástica na interface ferramenta–peça (MANE *et al.*, 2025).

O desgaste da ferramenta ocorre de forma progressiva e pode se manifestar por diferentes mecanismos, tais como abrasão, adesão, difusão e oxidação, além de reações químicas e deformações plásticas induzidas por esforços mecânicos e térmicos. A predominância de cada mecanismo depende das condições de corte, do material da peça e do material da ferramenta, variando ao longo da vida da aresta de corte (HRECHUK *et al.*, 2025). Monitorar esses mecanismos é essencial para garantir a qualidade da peça e definir o momento adequado de substituição da ferramenta.

O aço AISI 52100, foco deste estudo, é amplamente utilizado em componentes que exigem elevada dureza e resistência ao desgaste, como rolamentos e eixos de precisão. Essas propriedades derivam de sua composição química — com cerca de 1,0% de carbono e 1,5% de cromo — que, após tratamento térmico, promovem a formação de uma microestrutura martensítica fina e homogênea, com elevada dureza superficial e boa estabilidade dimensional (ASM International, 2020; Diniz *et al.*, 2017). À medida que a ferramenta se desgasta, padrões de vibração da máquina e da peça podem sofrer alterações devido à variação nas

forças de corte (Irino *et al.*, 2021). Esse comportamento motiva a utilização da análise de vibrações como estratégia para monitorar e prever o desgaste da ferramenta durante o torneamento deste material, com foco na previsão do parâmetro VBc (desgaste na aresta de flanco).

A avaliação do desgaste da ferramenta pode ser realizada por diferentes critérios, como o desgaste de flanco (VB), o desgaste de cratera (KT), a variação das forças de corte, a rugosidade da peça e a análise de sinais de vibração. Dentre esses parâmetros, o VB é o mais adotado, pois representa diretamente a perda de capacidade de corte e a deterioração da qualidade superficial, sendo utilizado neste estudo conforme a norma ISO 3685 (1993).

A previsão do desgaste é um fator-chave para a melhoria do desempenho do processo de usinagem. Nesse sentido, as técnicas de inteligência artificial, em especial aquelas baseadas em *machine learning* e *deep learning*, têm se mostrado eficazes na análise de dados complexos provenientes da usinagem, viabilizando soluções mais precisas e autônomas para o monitoramento e a previsão da condição da ferramenta (Ren *et al.*, 2022).

O monitoramento em processos de usinagem tem se consolidado como uma estratégia essencial da manufatura inteligente, permitindo acompanhar o estado da ferramenta e antecipar falhas com base em medições indiretas. Entre as variáveis monitoradas, destacam-se as vibrações, as forças de corte e a emissão acústica, que fornecem informações valiosas sobre o comportamento dinâmico do sistema e sobre o desgaste progressivo da ferramenta (Ren *et al.*, 2023).

## **2.2 - Coleta e Análise de Sinais de Vibração em Processos de Usinagem**

O monitoramento em processos de usinagem tem se consolidado como uma estratégia essencial da manufatura inteligente, permitindo acompanhar o estado da ferramenta e antecipar falhas com base em medições indiretas. Entre as variáveis monitoradas, destacam-se as vibrações, as forças de corte e a emissão acústica, que fornecem informações valiosas sobre o comportamento dinâmico do sistema e sobre o desgaste progressivo da ferramenta (Ren *et al.*, 2023).

Esse conjunto de técnicas fundamenta o uso da análise de vibração como abordagem deste trabalho, buscando prever o desgaste da ferramenta de forma mais precisa e autônoma, em consonância com os princípios da Indústria 4.0.

### 2.2.1 - Sensores de Vibração

A captura dos sinais de vibração é feita, na maioria dos casos, por meio de sensores específicos, sendo os acelerômetros piezoelétricos os mais comuns em aplicações industriais de monitoramento (Irino *et al.*, 2021). Esses sensores transformam a aceleração mecânica em sinais elétricos proporcionais e se destacam pela alta sensibilidade, ampla faixa de frequência e boa performance mesmo em ambientes industriais mais agressivos.

A escolha do acelerômetro mais adequado deve considerar as frequências típicas geradas no processo de torneamento, que variam de acordo com os parâmetros de corte, o material da peça e o nível de desgaste da ferramenta. Embora sensores como velocímetros ou sensores de deslocamento também possam ser utilizados em casos específicos, os acelerômetros se mostram mais versáteis por sua capacidade de captar uma gama maior de fenômenos associados à dinâmica de corte e à degradação da ferramenta (Hossain *et al.*, 2024).

Além dos sensores piezoelétricos, os acelerômetros MEMS (*Micro-Electro-Mechanical Systems*) têm ganhado espaço devido ao seu tamanho reduzido, menor custo e facilidade de integração com sistemas embarcados (Twardowski *et al.*, 2019). A escolha entre diferentes tipos de sensores depende do contexto da aplicação, considerando fatores como a faixa de frequência de interesse, a sensibilidade necessária, a robustez exigida e as limitações de custo.

Em aplicações de monitoramento de desgaste, o uso de um único sensor de vibração pode ser suficiente para capturar padrões representativos do comportamento dinâmico do sistema, desde que esteja devidamente calibrado e posicionado. No entanto, estudos recentes têm demonstrado que sistemas complementares — combinando sensores de vibração, emissão acústica e medição de força — podem aumentar a robustez das previsões, principalmente em ambientes industriais com múltiplas fontes de ruído (Ren *et al.*, 2023; Shantisagar *et al.*, 2019).

Neste trabalho, optou-se pela utilização de um único acelerômetro triaxial devido à sua boa relação custo-benefício e à compatibilidade com o setup experimental, assegurando sensibilidade suficiente para capturar os efeitos do desgaste durante o torneamento.

### 2.2.2 - Posicionamento dos Sensores

A posição em que o sensor de vibração é instalado na máquina-ferramenta tem impacto direto na qualidade e na relevância dos dados coletados. Os pontos de montagem mais comuns são: no porta-ferramenta ou em partes da estrutura da máquina. No caso específico do torneamento, o posicionamento do sensor diretamente na peça de trabalho é inviável, uma vez que a rotação da amostra impede a fixação segura e a transmissão contínua dos sinais. Por esse motivo, os sensores são normalmente instalados no porta-ferramenta, onde é possível captar com maior precisão as vibrações geradas pelo contato entre a ferramenta e a peça (Iriño *et al.*, 2021). Alternativamente, sensores podem ser acoplados à estrutura da máquina, permitindo a identificação de vibrações globais do sistema e complementando a análise dinâmica do processo.

No contexto do monitoramento de desgaste da ferramenta, o ideal é posicionar o sensor o mais próximo possível da interface de corte. A decisão sobre o local de instalação depende do objetivo da análise. Para monitorar o estado da ferramenta, o porta-ferramenta é geralmente a melhor escolha. Em contrapartida, para avaliar a estabilidade da peça, sensores montados diretamente nela são mais adequados (El-Wardany *et al.*, 2018).

### 2.2.3 - Sistemas de Aquisição de Dados (DAQ)

Os sinais gerados pelos sensores precisam ser convertidos para o formato digital antes de qualquer análise. Essa tarefa é realizada pelos sistemas de aquisição de dados, conhecidos como *DAQs* (*Data Acquisition Systems*). Um sistema DAQ básico inclui componentes para o condicionamento do sinal (como amplificação e filtragem), um conversor analógico-digital (*ADC*) e uma interface para transferir os dados para o computador, onde são armazenados e processados.

A qualidade do DAQ influencia diretamente na fidelidade do sinal digital. Por isso, fatores como a resolução do conversor ADC e a taxa de amostragem são cruciais, especialmente em aplicações de monitoramento de desgaste, onde é necessário captar vibrações de alta frequência com precisão. Além disso, é comum utilizar DAQs com múltiplos canais sincronizados, capazes de registrar dados de vários sensores ao mesmo tempo.

Existem diferentes tipos de DAQs disponíveis. Os modelos baseados em computador pessoal (*PC-based DAQ*) oferecem alto desempenho e flexibilidade. Os embarcados são mais

compactos e robustos, ideais para ambientes industriais. Já os sistemas sem fio facilitam a instalação, mas podem sofrer interferências eletromagnéticas (Janssens *et al.*, 2019). A escolha do DAQ ideal depende da aplicação, levando em conta a robustez, o custo, a portabilidade e a resolução necessária.

Além disso, o condicionamento de sinal é uma etapa fundamental para garantir que os sinais captados estejam limpos e com amplitude adequada. Filtros são usados para remover ruídos e evitar distorções, e a calibração do sistema é essencial para garantir precisão nas medições. Por fim, a integração do DAQ com o software de análise deve permitir uma comunicação eficiente, preferencialmente com capacidade de visualização e processamento dos dados em tempo real.

#### **2.2.4 - Frequência de Amostragem**

A frequência de amostragem (fsf) indica quantas vezes por segundo o sistema coleta amostras do sinal de vibração. De acordo com o Teorema de Nyquist–Shannon (Shannon, 1949), esse valor deve ser, no mínimo, o dobro da maior frequência presente no sinal, para garantir que ele possa ser reconstruído sem distorções (*aliasing*).

No torneamento, as vibrações geradas durante o processo podem cobrir uma ampla faixa de frequências. Vibrações de baixa frequência estão geralmente associadas à dinâmica da máquina, enquanto vibrações mais altas podem indicar mecanismos específicos de desgaste ou o surgimento de *chatter*. Por isso, a definição de uma frequência de amostragem adequada é essencial. Frequências muito baixas podem causar perda de informações relevantes; por outro lado, frequências muito altas geram grandes volumes de dados, aumentando a carga computacional e o tempo de processamento (Aggogeri *et al.*, 2019). A escolha da frequência ideal deve considerar a faixa esperada de vibrações do processo em estudo, equilibrando precisão na aquisição com eficiência no tratamento e análise dos dados.

#### **2.2.5 - Análise no Domínio do Tempo**

A análise no domínio do tempo foi realizada extraindo um conjunto de características que, conforme demonstrado na literatura, são sensíveis a alterações no estado da ferramenta e nas condições de corte (El-Wardany *et al.*, 2018). As seguintes características do sinal de vibração  $x(t)$  no domínio do tempo foram extraídas para análise:

- **Valor Médio ( $\bar{x}$ )**

$$\bar{x} \approx \frac{1}{N} \sum_{i=1}^N x_i \quad (1)$$

- **Desvio Padrão ( $\sigma$ )**

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (2)$$

- **Valor RMS ( $x_{rms}$ )**

$$x_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3)$$

- **Curtose ( $K$ )**

$$K = \frac{1}{\sigma^4 \cdot N} \sum_{i=1}^N (x_i - \bar{x})^4 \quad (4)$$

- **Assimetria ( $S$ )**

$$S = \frac{1}{\sigma^3 \cdot N} \sum_{i=1}^N (x_i - \bar{x})^3 \quad (5)$$

- **Energia ( $E$ )**

$$E = \sum_{i=1}^N x_i^2 \quad (6)$$

Onde:

- $x_i$ : valor do sinal na posição  $i$
- $N$ : número total de amostras
- $\bar{x}$ : média dos valores
- $\sigma$ : desvio padrão
- $x_r$ : valor RMS (raiz quadrada da média dos quadrados)

As características de mínimo e máximo representam os valores extremos do sinal amostrado e não possuem uma equação única para sua definição, sendo identificados diretamente no conjunto de dados. A Amplitude (Pico a Pico) é a diferença entre o valor máximo e o valor mínimo. A seleção dessas características foi motivada por sua capacidade de capturar diferentes aspectos do sinal de vibração que estão intrinsecamente ligados à condição da ferramenta de corte, conforme reportado em diversos estudos na área de monitoramento de desgaste (Lei *et al.*, 2018).

### 2.2.6 - Análise no Domínio da Frequência

A análise no domínio da frequência é realizada aplicando a Transformada de Fourier Discreta (DFT), que para um sinal discreto  $x[n]$  de  $N$  pontos, é definida como:

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{-j2\pi kn/N}, \quad \text{para } k = 0, 1, \dots, N - 1 \quad (7)$$

onde  $X[k]$  representa a  $k$ -ésima componente de frequência complexa. O espectro de magnitude é dado por:

$$|X[k]| = \sqrt{(\text{Re}(X[k]))^2 + (\text{Im}(X[k]))^2} \quad (8)$$

As seguintes características foram extraídas com base em sua relevância para o monitoramento da condição da ferramenta, conforme identificado na literatura (Pramanik *et al.*, 2024):

- **Frequência Dominante:**

$$f_k = \frac{(k \cdot f_s)}{N} \quad (9)$$

Onde  $f_s$  é a frequência de amostragem e  $k$  é o índice da maior magnitude  $|X_k|$  no espectro.

- **Máximo e Mínimo da Amplitude no Espectro:**

São os valores máximo e mínimo de  $|X_k|$ , para  $k=0,1,\dots,N/2$ , considerando apenas as frequências positivas.

- **Energia em Diferentes Faixas de Frequência:**

A energia em uma faixa de frequência  $[f_{low}, f_{high}]$  pode ser calculada por:

$$E[f_{low}, f_{high}] = \sum_{k \in \text{faixa}} |X_k|^2 \quad (10)$$

A análise das características no domínio da frequência complementa a análise no domínio do tempo, fornecendo informações sobre as componentes vibratórias excitadas durante o processo de corte e como essas componentes evoluem com o desgaste da ferramenta, conforme demonstrado em trabalhos como o de Zhou (2021).

Tabela 2 – Trabalhos sobre a Influência da Vibração no Processo de Usinagem

Autor/Ano	Material Usinado	Tipo de Usinagem	Parâmetros Analisados	Resultados Principais
Pramanik <i>et al.</i> , 2024	Aço inoxidável	Fresamento	Frequência, amplitude, energia	Identificaram que vibrações entre 500–1000 Hz estão associadas ao desgaste abrasivo. Implementaram STFT para análise de transientes.
Mishra <i>et al.</i> , 2023	Aço de alta resistência	Fresamento	Vibração axial e radial	Utilizaram aprendizado não supervisionado para identificar padrões em vibrações; destacaram o impacto da rigidez no chatter.
Singh <i>et al.</i> , 2023	Aço carbono	Torneamento	Amplitude, frequência dominante	Analisaram sinais no domínio do tempo e frequência para correlacionar desgaste progressivo com vibrações

				específicas.
Wang <i>et al.</i> , 2022	Liga de alumínio 7075	Torneamento	Curtose, energia	Demonstraram que vibrações de alta amplitude indicam falhas estruturais em ferramentas de corte.
Deswal & Kant, 2023	Aço AISI 4340	Torneamento	Espectro de frequência	Aplicaram STFT para separar sinais de vibração causados por desgaste e deformação plástica.

---

A análise da Tabela 2 revela uma variedade de abordagens na literatura para o monitoramento de desgaste de ferramentas por meio da análise de vibração. Diversos materiais e processos de usinagem têm sido investigados, com foco em diferentes características dos sinais de vibração. O presente estudo contribui para este corpo de conhecimento ao combinar sinais de vibração nos domínios do tempo e da frequência para a previsão do desgaste da ferramenta no torneamento do Aço AISI 52100, utilizando modelos *ensemble*. As semelhanças nas técnicas de análise com outros trabalhos, como Singh *et al.* (2023) que também analisaram amplitude e frequência dominante em torneamento, e as diferenças nos materiais e focos específicos, como a identificação de faixas de frequência para desgaste abrasivo por Pramanik *et al.* (2024) em fresamento, demonstram a amplitude e a especificidade das pesquisas na área.

### **2.3 - Machine Learning Aplicado à Previsão do Desgaste da Ferramenta**

O uso de técnicas de *machine learning* (ML) tem ganhado espaço como alternativa avançada para o monitoramento do desgaste de ferramentas em processos de usinagem, especialmente por meio da análise de sinais de vibração (Patange *et al.*, 2021). A principal vantagem está na capacidade dos algoritmos de aprender padrões complexos a partir de características extraídas dos sinais — como aquelas obtidas nas análises no domínio do tempo e da frequência (ver Seções 2.2.5 e 2.2.6).

Com base nesses dados, modelos supervisionados de ML podem estimar o nível de desgaste da ferramenta durante o processo, antecipando falhas, aprimorando o planejamento de manutenção e contribuindo para maior estabilidade e eficiência da usinagem.

### 2.3.1 - Modelos de Machine Learning para Previsão do Desgaste

A seguir, são apresentados os principais modelos utilizados neste trabalho, organizados em ordem crescente de complexidade. Inicia-se pela Regressão Linear, utilizada como modelo de referência (*baseline*), seguida por algoritmos baseados em árvores de decisão, máquinas de vetor de suporte e redes neurais artificiais. Ao final, discute-se a abordagem de *ensemble stacking*, que combina múltiplos modelos para melhorar o desempenho preditivo.

#### 2.3.1.1 - Regressão Linear

A regressão linear é um método estatístico fundamental que modela a relação linear entre uma variável dependente e uma ou mais variáveis independentes. Sua interpretabilidade e eficiência computacional a tornam amplamente utilizada em problemas de previsão. Na análise de vibração em usinagem, por exemplo, a regressão linear pode ser aplicada para prever o desgaste da ferramenta a partir de parâmetros de vibração. O modelo linear é definido pela equação:

$$\hat{y} = x^T \beta = \sum_{i=1}^p \beta_i x_i \quad (15)$$

Onde:

- $\hat{y}$ : valor predito (estimativa da variável dependente)
- $x^T$ : vetor transposto das variáveis independentes
- $\beta$ : vetor dos coeficientes da regressão
- $p$ : número de variáveis preditoras
- $x_i$ : valor da  $i$ -ésima variável independente
- $\beta_i$ : coeficiente associado à variável  $x_i$

Neste trabalho, a regressão linear foi implementada considerando o termo de intercepto ( $\beta_0$ ), conforme a configuração padrão da biblioteca *scikit-learn*. A inclusão do intercepto permite que o modelo represente adequadamente situações em que o valor do desgaste da ferramenta não é nulo mesmo quando as variáveis preditoras assumem valores próximos de zero, tornando a modelagem mais flexível e condizente com o comportamento físico do processo de usinagem.

Embora seja um modelo linear, a regressão linear serve como base para comparação com modelos não lineares e pode ser utilizada em cenários de relação aproximadamente linear ou como meta-aprendiz em *ensemble*.

A Figura 2 ilustra o funcionamento conceitual da regressão linear, na qual uma linha de melhor ajuste é calculada de modo a minimizar o erro quadrático entre os valores observados e os valores previstos. Essa representação evidencia a simplicidade do modelo e sua capacidade de capturar tendências globais entre variáveis de entrada e saída, sendo útil como ponto de partida para análises comparativas e calibração de modelos mais complexos em usinagem.

Shanmugasundaram *et al.* (2021) utilizaram a regressão linear em tarefas de previsão de desgaste, destacando seu papel como modelo de referência para avaliar o ganho de desempenho obtido por algoritmos não lineares.

Apesar de sua simplicidade e utilidade como modelo de referência, a regressão linear estimada pelo método dos mínimos quadrados ordinários (*Ordinary Least Squares* — OLS) baseia-se em um conjunto de pressupostos estatísticos que nem sempre são atendidos em aplicações reais. O método assume que os resíduos apresentam distribuição aproximadamente normal, que não há autocorrelação entre as observações e que a variância do erro permanece constante ao longo de todo o domínio das variáveis preditoras, caracterizando a homocedasticidade. Quando essas condições são violadas — cenário comum em processos de usinagem, nos quais o desgaste da ferramenta apresenta evolução não linear, variabilidade complexa e possíveis dependências temporais — a qualidade das estimativas do modelo tende a deteriorar-se, reduzindo a confiabilidade das previsões. Assim, embora a regressão linear seja útil como comparação inicial (*baseline*), suas limitações a tornam menos competitiva diante de métodos não lineares capazes de capturar relações mais complexas entre as variáveis do processo.

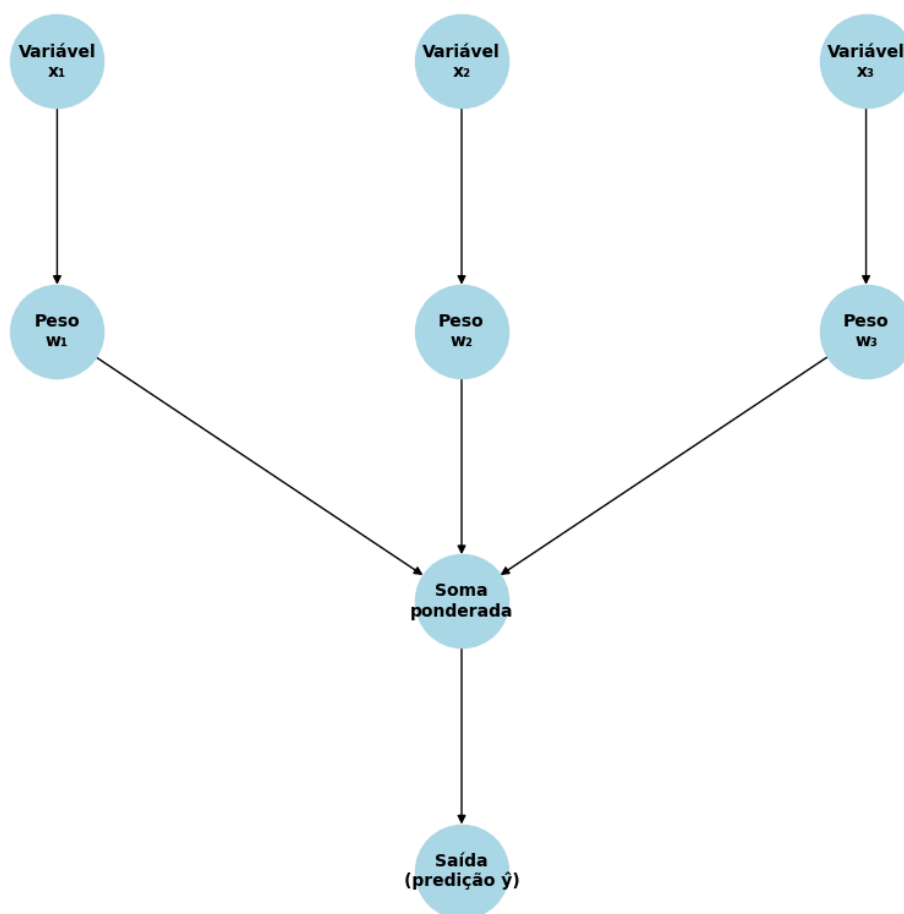


Figura 2 – Exemplo de uma regressão linear. Fonte: Autor

### 2.3.1.2 - ExtraTreesRegressor

O ExtraTreesRegressor (Extremely Randomized Trees) é um modelo de *ensemble* baseado em um conjunto de árvores de decisão, amplamente reconhecido na literatura de aprendizado de máquina por sua eficácia em tarefas de regressão. Similar ao *Random Forest*, ele constrói múltiplas árvores e combina suas previsões para obter uma estimativa mais robusta. No entanto, o ExtraTreesRegressor introduz um nível adicional de aleatoriedade no processo de construção das árvores, distinguindo-se como uma abordagem promissora para modelar fenômenos complexos em dados de alta dimensionalidade.

Uma diferença fundamental em relação ao *Random Forest* reside na seleção dos pontos de divisão nos nós das árvores. Enquanto o *Random Forest* busca a melhor divisão dentro de um subconjunto aleatório de atributos, o *ExtraTreesRegressor* escolhe esses pontos de divisão de forma puramente aleatória. Essa característica promove uma maior diversidade entre as

árvores do *ensemble*, o que é teoricamente vantajoso para a redução da variância e, consequentemente, para a melhoria da capacidade de generalização do modelo. A predição final do *ExtraTreesRegressor* ( $\hat{y}$ ) para uma dada entrada  $x$  é dada pela média das previsões de todas as  $T$  árvores individuais no ensemble:

$$\hat{y} = 1/M \sum_{i=1}^M T_i(x) \quad (13)$$

- $\hat{y}$ : valor previsto (saída do modelo)
- $M$ : número total de árvores na floresta
- $T_i(x)$ : predição da árvore  $i$  para a entrada  $x$

A relevância de métodos baseados em árvores de decisão para o monitoramento da condição de ferramentas tem sido amplamente explorada na literatura. Por exemplo, Xue *et al.* (2023) investigaram o uso de *Weighted Random Forest* para o reconhecimento do estado de desgaste da ferramenta, demonstrando a capacidade desses modelos de lidar com a complexidade dos dados de sinais e parâmetros de usinagem.

A natureza aleatória do *Extra Trees Regressor*, representada na Figura 3, permite a construção de múltiplas árvores de decisão independentes, o que favorece a diversificação dos resultados e reduz a variância do modelo. Essa característica torna o método uma alternativa promissora para a previsão do desgaste da ferramenta, potencialmente capturando padrões sutis nos sinais de vibração que outros modelos podem não identificar.

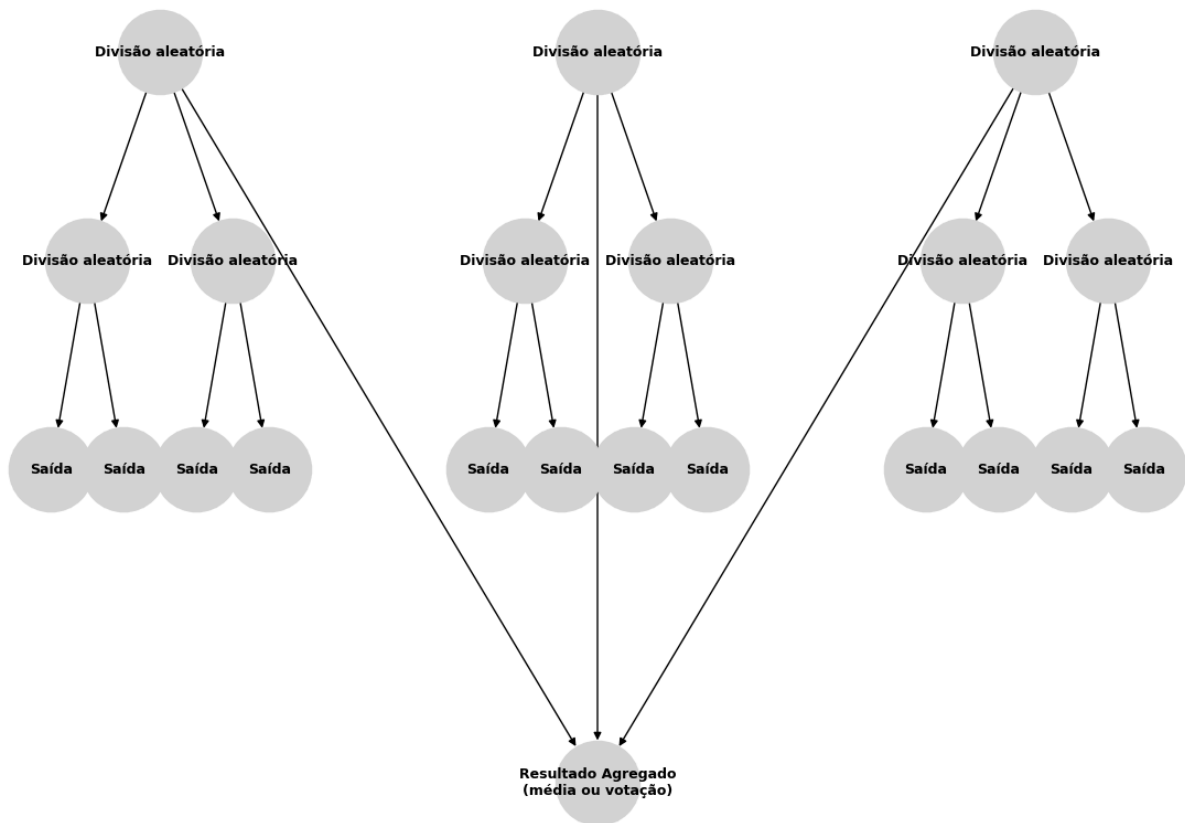


Figura 3 – Exemplo de uma *extra trees regressor*. Fonte: Autor

### 2.3.1.3 - Random Forest Regressor

O Random Forest é um método de *ensemble learning* robusto para tarefas de regressão, como a previsão do desgaste da ferramenta. Ele opera construindo uma floresta de árvores de decisão, cada uma treinada em um subconjunto aleatório do conjunto de dados original por meio da técnica de *bagging* (amostragem com reposição). A aleatoriedade é ainda incrementada pela seleção randômica de um subconjunto de atributos em cada nó durante a construção das árvores, forçando a diversidade entre elas. A predição final ( $\hat{y}$ ) para uma nova entrada  $x$  é o resultado da agregação das previsões de todas as  $T$  árvores na floresta, tipicamente através da média:

$$\hat{y} = 1/T \sum_{t=1}^T h_t(x) \quad (14)$$

- $\hat{y}$ : valor previsto (output final do modelo)
- $T$ : número total de árvores na floresta
- $h_t(x)$ : predição da árvore  $t$  para a entrada  $x$

Essa estratégia de amostragem e seleção de atributos torna o *Random Forest* eficaz na captura de relações não lineares e interações complexas presentes em dados de vibração, cruciais para a previsão do desgaste. Sua inerente capacidade de reduzir o *overfitting* e fornecer uma estimativa da importância das variáveis a torna uma ferramenta valiosa na identificação dos parâmetros de vibração mais preditivos.

A Figura 4 apresenta a estrutura conceitual de um modelo *Random Forest Regressor*, composta por múltiplas árvores de decisão treinadas com subconjuntos diferentes de dados e variáveis. Esse arranjo garante maior robustez e estabilidade preditiva, uma vez que as previsões finais resultam da combinação das saídas individuais de cada árvore.

Estudos como o de Mahmood *et al.* (2022) comprovam a eficiência do *Random Forest* na estimativa precisa dos níveis de desgaste da ferramenta, demonstrando seu potencial para aplicações de monitoramento preditivo em processos de usinagem.

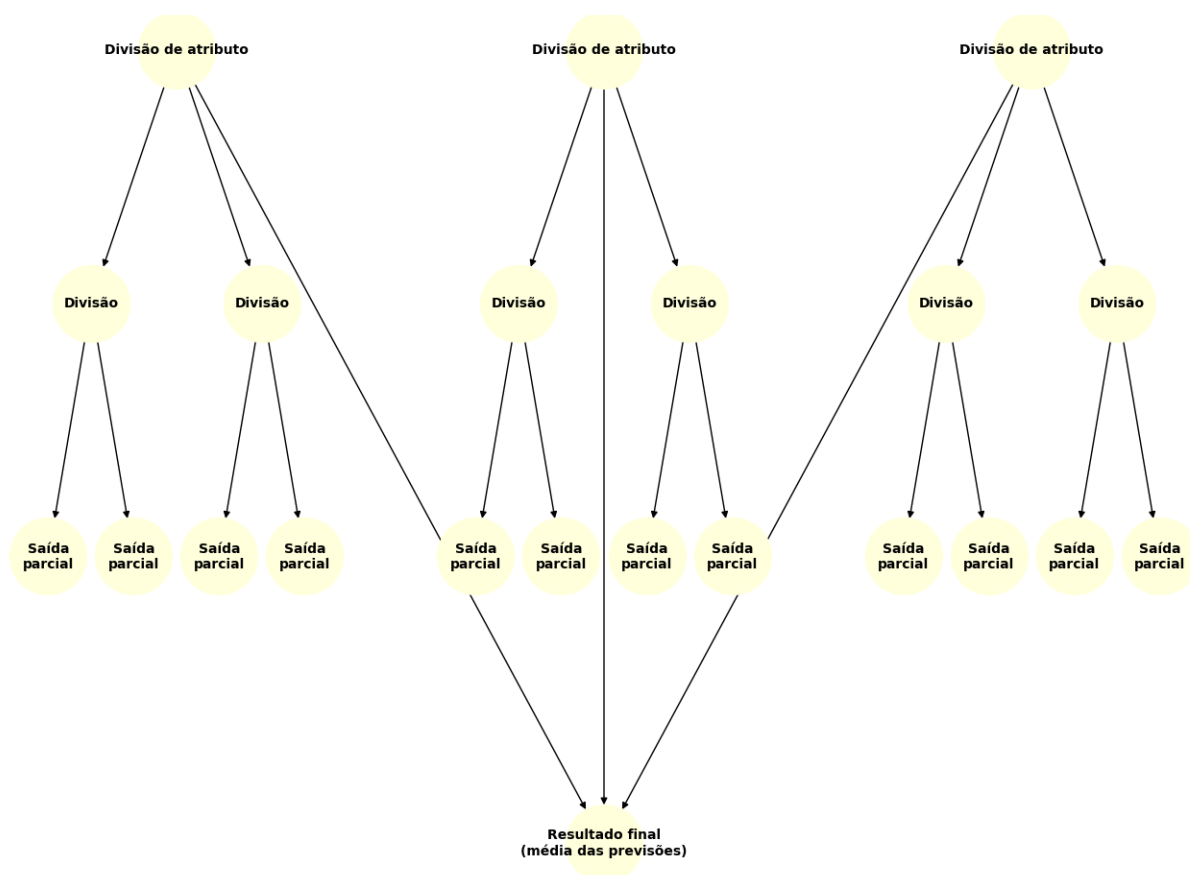


Figura 4 – Exemplo de uma *random forest regressor*. Fonte: Autor

### 2.3.1.4 - Gradient Boosting Regressor

*Gradient Boosting* é um método de ensemble que constrói modelos de forma aditiva e sequencial, corrigindo os erros dos modelos anteriores para aprimorar a previsão do desgaste. O processo constrói um modelo preditivo aditivo de aprendizes fracos, tipicamente árvores de decisão, onde cada novo modelo ( $h_m(x)$ ) é treinado para prever os resíduos dos modelos anteriores, minimizando uma função de perda e refinando iterativamente a previsão do desgaste. A previsão final ( $F_m(x)$ ) é dada pela soma do modelo inicial com a contribuição ponderada de cada modelo subsequente:

$$F_m(x) = F_{m-1}(x) + \eta \cdot h_m(x) \quad (16)$$

Onde:

- $F_m(x)$ : modelo final após  $m$  iterações (predição no estágio  $m$ )
- $F_0(x)$ : modelo inicial (geralmente a média dos valores da variável-alvo no conjunto de treino)
- $h_m(x)$ : modelo fraco (árvore de decisão) treinado na  $m$ -ésima iteração
- $\eta$ : taxa de aprendizado (learning rate), que controla o peso de cada novo modelo
- $m$ : número de iterações (ou árvores adicionadas)

Algoritmos populares de *Gradient Boosting* incluem o XGBoost (Xie *et al.*, 2021) e o LightGBM (Lu *et al.*, 2023), amplamente reconhecidos por sua eficiência e desempenho na previsão do desgaste de ferramentas.

A Figura 5 ilustra o princípio de funcionamento do *Gradient Boosting Regressor*, no qual modelos de árvore são treinados sequencialmente — cada nova árvore busca corrigir os erros cometidos pelas anteriores, ajustando gradualmente a predição final. Essa abordagem iterativa permite capturar padrões complexos nos dados, reduzindo o erro residual e aprimorando a capacidade preditiva do modelo.




Figura 5 – Exemplo de uma *gradient boosting regressor*. Fonte: Autor

### 2.3.1.5 - AdaBoost Regressor

AdaBoost (Adaptive Boosting) é um algoritmo de *ensemble* que combina múltiplos modelos "fracos" para construir um modelo "forte". No contexto da regressão, o AdaBoost Regressor realiza ajustes iterativos nos pesos das instâncias de treinamento, atribuindo maior importância aos casos que são mais difíceis de prever.

A predição final do AdaBoost Regressor ( $F(x)$ ) é calculada como a soma ponderada das predições dos modelos fracos:

$$F(x) = \sum_{i=1}^m \alpha_i \cdot h_i(x) \quad (17)$$

Onde:

- $F(x)$ : predição final do modelo AdaBoost
- $h_i(x)$ :  $i$ -ésimo modelo fraco (por exemplo, uma árvore de decisão rasa)
- $\alpha_i$ : peso atribuído ao modelo  $h_i(x)$ , baseado na sua performance (quanto menor o erro, maior o  $\alpha_i$ )
- $m$ : número total de iterações (ou modelos fracos adicionados)

Dessa forma, o AdaBoost ajusta os pesos das amostras a cada iteração, focando nas instâncias em que o desgaste foi mal previsto, como representado na Figura 6, demonstrando sua aplicabilidade e precisão na previsão do desgaste (GÜRE, 2024).




Figura 6 – Exemplo de uma *adaboost regressor*. Fonte: Autor

### 2.3.1.6 - Support Vector Regression (SVR)

O *Support Vector Regression* (SVR) é uma técnica de aprendizado de máquina eficaz para a previsão do desgaste, capaz de modelar relações não lineares (Li *et al.*, 2023) e lidar eficientemente com espaços de dados de alta dimensionalidade (Gomes *et al.*, 2021). A função de previsão do SVR para uma nova entrada  $x$  é dada por:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (12)$$

- $f(x)$ : valor previsto para a entrada  $x$
- $\alpha_i, \alpha_i^*$ : multiplicadores de Lagrange aprendidos no treinamento
- $K(x_i, x)$ : função kernel entre os vetores  $x_i$  (do treino) e  $x$  (entrada atual)
- $n$ : número de vetores de suporte
- $b$ : termo de viés

A formulação do SVR envolve a busca por uma função que minimize o erro em relação aos dados de treinamento, dentro de uma margem de tolerância, mantendo a complexidade do modelo em nível reduzido. A escolha da função *kernel*  $K$  é essencial, pois define o tipo de relação não linear que o modelo é capaz de capturar entre as variáveis de entrada e saída.

A Figura 7 ilustra o princípio de funcionamento de uma *Support Vector Machine* aplicada à regressão, onde a função ajustada busca envolver o maior número possível de pontos dentro de uma faixa de tolerância ( $\epsilon$ ) ao redor da curva predita. Essa margem controla a sensibilidade do modelo, permitindo melhor generalização e reduzindo a influência de ruídos nos dados.

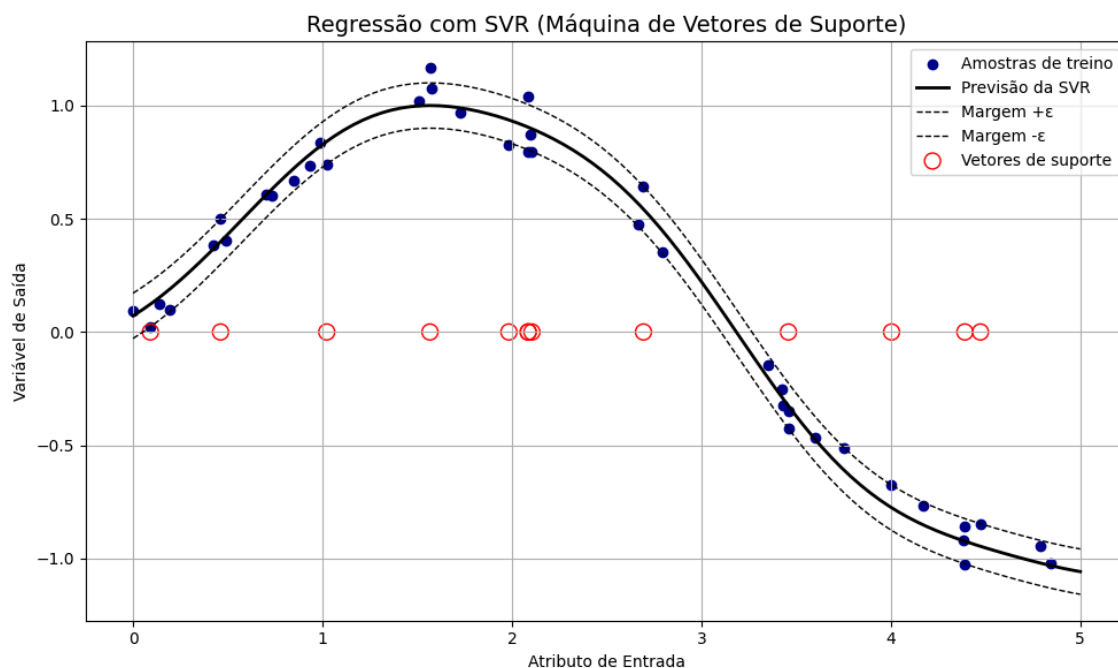


Figura 7 – Exemplo de uma *support vector machine*. Fonte: Autor

### 2.3.1.7 - *Multi Layer Perceptron* (MLP)

A arquitetura *Multi-Layer Perceptron* (MLP) é uma das mais tradicionais dentro do grupo das Redes Neurais Artificiais (RNAs). Neste trabalho, ela é tratada como um modelo de *machine learning* supervisionado, pois possui estrutura rasa — com poucas camadas ocultas — voltada à regressão direta de variáveis contínuas, não se enquadrando na categoria de *deep learning* (GOODFELLOW; BENGIO; COURVILLE, 2016).

O MLP é composto por camadas totalmente conectadas de neurônios artificiais, nas quais os sinais de entrada são transformados em saídas por meio do ajuste iterativo de pesos e vieses durante o treinamento (HAYKIN, 2001). O funcionamento matemático básico de uma MLP com  $L$  camadas é representado pela Equação (11), onde cada camada aplica uma função de ativação  $f^{(l)}$  às combinações lineares dos pesos  $W^{(l)}$ , vieses  $b^{(l)}$  e ativações da camada anterior  $a^{(l-1)}$ .

$$a^{(l)} = f^{(l)}(W^{(l)} a^{(l-1)} + b^{(l)}), \text{ para } l = 1, 2, \dots, L \quad (11)$$

Com as seguintes definições:

- $a^{(l)}$ : vetor de ativações da camada  $l$
- $f^{(l)}$ : função de ativação da camada  $l$
- $W^{(l)}$ : matriz de pesos da camada  $l$
- $a^{(l-1)}$ : vetor de ativações da camada anterior
- $b^{(l)}$ : vetor de viés da camada  $l$
- $L$ : número total de camadas da rede (excluindo a entrada)

Arquiteturas baseadas em *Multi-Layer Perceptron* (MLP) têm se mostrado eficazes na modelagem de problemas de regressão em usinagem, principalmente quando aplicadas à caracterização de sinais de vibração e outras variáveis de processo. Sua estrutura densa e totalmente conectada permite capturar relações não lineares complexas entre os parâmetros de entrada e a variável de saída.

Estudos como o de Baig *et al.* (2021) demonstraram que o MLP pode prever com precisão o desgaste de ferramentas em processos de torneamento com base em dados de vibração. A Figura 8 ilustra a topologia típica de uma rede neural do tipo MLP, composta por camadas de entrada, ocultas e de saída, nas quais os neurônios são conectados por pesos ajustados durante o treinamento. A escolha da arquitetura da rede, das funções de ativação e de técnicas de regularização é fundamental para garantir um bom desempenho preditivo.

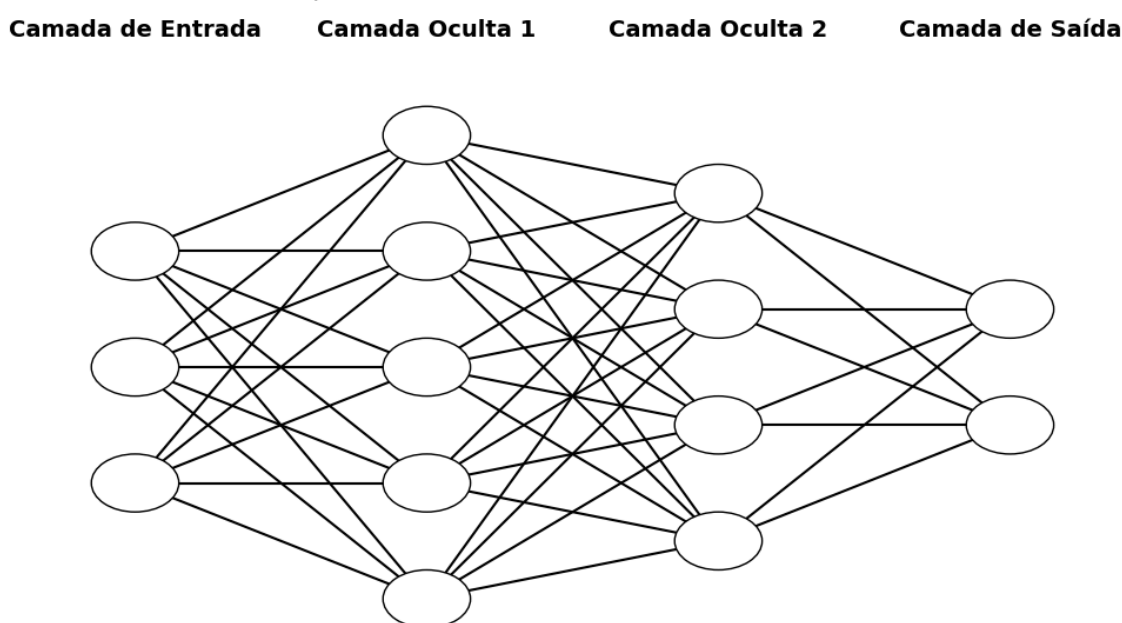


Figura 8 – Exemplo de uma Rede neural. Fonte: Autor

### 2.3.1.8 - Ensemble Methods

Métodos de *ensemble* combinam as previsões de múltiplos modelos de *Machine Learning* para alcançar um desempenho preditivo superior ao de qualquer modelo individual. A ideia fundamental é que diferentes modelos capturam aspectos distintos dos dados, e sua combinação pode resultar em maior precisão, robustez e capacidade de generalização — o que é particularmente útil na análise de sinais de vibração para a previsão do desgaste da ferramenta. Ao lidar com a complexidade e variabilidade dos dados de vibração, os métodos de *ensemble* também contribuem para reduzir o risco de *overfitting*. Entre os principais tipos de *ensemble*, destacam-se os baseados em árvores de decisão, modelos lineares e redes neurais.

No caso das árvores, o treinamento se dá pela divisão recursiva dos dados, buscando maximizar a pureza dos nós segundo métricas como índice de Gini ou entropia. O objetivo é minimizar a impureza dentro dos grupos formados, de modo que cada divisão produza subconjuntos cada vez mais homogêneos em relação à variável de saída. Essa lógica é explorada por algoritmos como Random Forest, Extra Trees e Gradient Boosting, amplamente empregados em problemas de previsão de desgaste de ferramentas.

Em contrapartida, os modelos baseados em regressão linear utilizam o método dos mínimos quadrados ordinários (MQO) para ajustar os parâmetros do modelo, minimizando o erro quadrático entre valores previstos e observados. Essa técnica parte de pressupostos estatísticos — como normalidade dos resíduos, homocedasticidade e independência das variáveis — que, quando violados, podem comprometer a validade inferencial do modelo. Nesses casos, podem ser utilizados modelos lineares generalizados (GLMs), que relaxam esses pressupostos ao permitir distribuições de erro não normais e funções de ligação adequadas a cada contexto.

Por sua vez, as redes neurais do tipo MLP (*Multi-Layer Perceptron*) são treinadas por meio do algoritmo de retropropagação (*backpropagation*), o qual ajusta iterativamente os pesos das conexões entre neurônios para minimizar uma função de erro (geralmente o erro quadrático médio). Esse processo envolve o cálculo do gradiente da função de perda em relação aos pesos, propagando os erros das camadas de saída para as camadas anteriores, num processo de aprendizado supervisionado.

Um método de *ensemble* particularmente importante é o Stacking, ou *stacked generalization*. Essa abordagem combina a saída de vários modelos base em um primeiro nível e utiliza um

*meta-learner* para combinar os resultados de forma otimizada, buscando aumentar a capacidade de generalização do sistema (YANG et al., 2019). O *Ensemble Stacking* combina as previsões de diversos modelos base utilizando um meta-modelo (como a Regressão Linear) para aprimorar a precisão da previsão do desgaste.

A previsão final ( $\hat{y}$ ) é uma combinação linear das previsões dos modelos base, conforme apresentado na Equação (18).

Essa formulação pode ser generalizada pela Equação (19), onde a função  $f\_meta$  representa o modelo de segundo nível que aprende a ponderar as saídas dos modelos de base. A Figura 9 ilustra o funcionamento geral de um ensemble stacking, mostrando a integração entre os modelos de primeiro e segundo nível.

$$\hat{y} = w_0 + \sum_{i=1}^k w_i \cdot \hat{y}_i(x) \quad (18)$$

Essa abordagem pode ser generalizada como:

$$\hat{y} = f\_meta(h_1(x), h_2(x), \dots, h_k(x)) \quad (19)$$

Onde:

- $\hat{y}$ : predição final do ensemble
- $x$ : vetor de entrada (por exemplo, variáveis extraídas do sinal de vibração)
- $\hat{y}_i(x)$  ou  $h_i(x)$ : predição do  $i$ -ésimo modelo base (como Rede Neural, SVR, Extra Trees, XGBoost, Random Forest)
- $w_0, w_i$ : coeficientes do modelo meta (por exemplo, Regressão Linear)
- $f\_meta(\cdot)$ : função de predição do meta-modelo (nível 1), que aprende a combinar as saídas dos modelos base

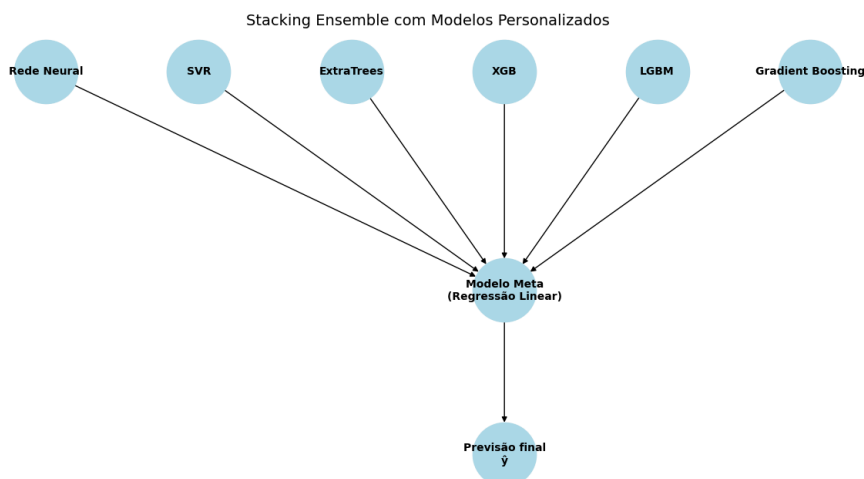


Figura 9 – Exemplo de uma *stacking ensemble*. Fonte: Autor

Do ponto de vista metodológico, a utilização de métodos *ensemble*, em especial o *stacking*, apresenta vantagens relevantes para a previsão do desgaste de ferramentas em processos de usinagem. A principal delas é a capacidade de combinar modelos com diferentes vieses indutivos, permitindo capturar simultaneamente relações lineares e não lineares entre as variáveis do processo, reduzindo viés e variância das previsões. Estudos recentes demonstram que estratégias de *stacking* aplicadas à previsão do desgaste resultam em ganhos consistentes de precisão e robustez quando comparadas a modelos individuais (MAHMOOD et al., 2022; TABASZEWSKI, 2022).

Apesar dessas vantagens, modelos *ensemble* apresentam limitações inerentes, como o aumento da complexidade estrutural, maior custo computacional durante o treinamento e menor interpretabilidade direta. Esses fatores podem dificultar a implantação e manutenção em sistemas industriais, exigindo maior esforço de validação e monitoramento contínuo do modelo (MARTÍNEZ-PLUMED et al., 2023). Nesse contexto, a incorporação de técnicas de explicabilidade, como o SHAP, torna-se fundamental para mitigar a perda de transparência e viabilizar o uso confiável de modelos *ensemble* em aplicações industriais (PONCE-BOBADILLA et al., 2024).

### 2.3.2 - Explicabilidade em Modelos de Aprendizado de Máquina

À medida que os modelos de *Machine Learning* se tornam mais complexos, cresce a necessidade de compreender as razões por trás de suas previsões. Essa preocupação está relacionada ao conceito de Inteligência Artificial Explicável (*Explainable Artificial Intelligence* – XAI), cujo objetivo é aumentar a transparência, a interpretabilidade e a confiança nas decisões automatizadas, especialmente em aplicações industriais e de engenharia.

Entre os métodos de explicabilidade mais consolidados, destaca-se o SHAP (*SHapley Additive Explanations*), proposto por Lundberg e Lee (2017), que se baseia na teoria dos valores de Shapley para atribuir, de forma quantitativa, a contribuição individual de cada variável de entrada para a previsão gerada pelo modelo. O SHAP é amplamente adotado em contextos industriais e de manutenção preditiva por sua capacidade de gerar explicações locais e globais consistentes entre diferentes algoritmos e bases de dados. Em aplicações recentes, Ponce-Bobadilla *et al.* (2024) apresentaram um guia prático para o uso de SHAP em modelos supervisionados, destacando sua utilidade na identificação de padrões e variáveis críticas em processos produtivos complexos.

O método SHAP fornece dois níveis complementares de interpretação: **global** e **local**. A interpretação global permite identificar quais variáveis, em média, exercem maior influência sobre as previsões do modelo ao longo de todo o conjunto de dados, sendo especialmente útil para análise de sensibilidade e validação física do modelo. Já a interpretação local explica individualmente cada predição, quantificando como cada variável contribui positiva ou negativamente para o valor estimado de desgaste em uma amostra específica. Essa distinção é particularmente relevante em aplicações industriais, nas quais o operador pode necessitar tanto de uma visão geral do comportamento do processo quanto de explicações pontuais para situações críticas observadas durante a usinagem.

Com o avanço dos Modelos de Linguagem de Grande Porte (*Large Language Models* – LLMs), surgiram novas possibilidades para ampliar a interpretabilidade dos sistemas de IA. Os LLMs podem ser utilizados para gerar explicações automáticas em linguagem natural, traduzindo os resultados de métodos como o SHAP em descrições compreensíveis para usuários não especializados. Essa integração (*SHAP + LLM*) representa um novo paradigma

de interpretabilidade, pois transforma valores numéricos de importância em interpretações textuais contextualizadas (Cambria *et al.*, 2024; Yin, 2025).

No contexto de usinagem e monitoramento de condição, essa abordagem pode auxiliar na tradução de relações complexas entre vibração, parâmetros de corte e desgaste da ferramenta, conectando os resultados estatísticos do modelo com fenômenos físicos observáveis. Assim, o uso combinado de SHAP e LLMs reforça a transparência dos modelos de aprendizado de máquina e contribui para a consolidação de sistemas de manufatura inteligentes e explicáveis, alinhados aos princípios da Indústria 4.0.

### 3 Metodologia

Esta pesquisa adota a metodologia CRISP-DM (Cross-Industry Standard Process for Data Mining) como guia estruturado para a investigação da aplicação de Inteligência Artificial na previsão do desgaste de ferramentas durante o processo de torneamento. O CRISP-DM é um framework iterativo e flexível amplamente utilizado em projetos de ciência de dados, composto por seis fases principais: (1) entendimento do negócio, (2) entendimento dos dados, (3) preparação dos dados, (4) modelagem, (5) avaliação e (6) implantação (Martínez-Plumed *et al.*, 2023).

Embora o CRISP-DM seja amplamente consolidado e adotado em projetos de mineração de dados e ciência de dados, abordagens mais recentes têm discutido a evolução desses frameworks, especialmente em contextos nos quais os dados passam a ser tratados como um produto estratégico ao longo de seu ciclo de vida. Nesse sentido, metodologias conhecidas como *Data Science Project* ou *Data Product Lifecycle* enfatizam aspectos como versionamento de dados, reprodutibilidade, governança, monitoramento contínuo e integração com sistemas produtivos. No entanto, considerando o caráter experimental e acadêmico desta pesquisa, bem como a clareza estrutural oferecida pelo CRISP-DM, optou-se por sua utilização como framework metodológico, sem prejuízo conceitual à aplicação prática dos modelos desenvolvidos.

Do ponto de vista metodológico, esta pesquisa caracteriza-se como aplicada, pois busca gerar conhecimento voltado à solução de um problema prático da indústria de manufatura, contribuindo para o avanço do monitoramento inteligente de ferramentas. Quanto aos objetivos, enquadra-se como uma pesquisa exploratória e descritiva, ao investigar o

comportamento do desgaste por meio de dados experimentais e propor um modelo preditivo baseado em *machine learning*.

Em relação aos procedimentos técnicos, trata-se de uma pesquisa experimental, conduzida por meio de ensaios de torneamento realizados em ambiente controlado de laboratório. Os dados coletados são posteriormente analisados por técnicas estatísticas e de aprendizado de máquina.

As fases do CRISP-DM foram adaptadas ao contexto desta pesquisa conforme segue:

1. Entendimento do Negócio: definição do problema e objetivos relacionados à previsão do desgaste da ferramenta;
2. Entendimento dos Dados: análise das variáveis coletadas (vibração, força, temperatura, etc.) e identificação de correlações;
3. Preparação dos Dados: limpeza, normalização e estruturação das bases para modelagem;
4. Modelagem: aplicação de algoritmos de aprendizado supervisionado e técnicas de ensemble;
5. Avaliação: comparação entre modelos, métricas de desempenho e análise de resultados;
6. Implantação: discussão de aplicabilidade prática dos modelos em sistemas de monitoramento industrial.

### **3.1 Entendimento do Problema e do Objeto de Estudo**

Esta etapa corresponde à fase de *Business Understanding* do CRISP-DM, aqui adaptada para o contexto acadêmico e experimental. O objetivo é compreender de forma detalhada o problema de pesquisa, seu escopo e relevância industrial, estabelecendo metas claras para o desenvolvimento de modelos preditivos de desgaste de ferramentas durante o processo de torneamento do aço AISI 52100.

A previsão precisa do desgaste da ferramenta é fundamental para otimizar o processo de usinagem, permitindo a programação de manutenções preventivas, a redução de custos com ferramentas e a garantia da qualidade dimensional e superficial das peças usinadas. Além disso, estimativas confiáveis do desgaste contribuem para evitar falhas inesperadas e

desperdícios de material, aspectos diretamente relacionados à produtividade e à sustentabilidade do processo.

O sucesso deste estudo será avaliado pela capacidade dos modelos de *Machine Learning* em prever o desgaste com alta precisão, utilizando métricas de regressão como o Erro Médio Quadrático (MSE), o Erro Médio Absoluto (MAE) e o coeficiente de determinação ( $R^2$ ). Estudos recentes em torneamento duro relatam valores de  $R^2$  entre 0,85 e 0,99 e MSE da ordem de  $10^{-4}$  mm<sup>2</sup> na previsão do desgaste de flanco, com erros médios absolutos abaixo de 0,01 mm (Djellouli *et al.*, 2023). Em aplicações com fusão de múltiplos sensores e modelos *ensemble*, já foram obtidos  $R^2 \approx 0,96$  e desvios médios de desgaste em torno de 60  $\mu$ m (Jones *et al.*, 2025), enquanto modelos de regressão apoiados em sinais de vibração mostram-se adequados para monitoramento on-line do desgaste em torneamento de aços endurecidos, como o AISI 52100 (Panda *et al.*, 2020). Com base nesses resultados, este trabalho busca alcançar coeficientes de determinação  $R^2 \geq 0,9$  e erros de previsão de desgaste da ordem de algumas dezenas de micrômetros, utilizando os dados experimentais de vibração, parâmetros de corte e medições diretas de desgaste coletados em condições controladas de torneamento.

## 3.2 Entendimento dos dados

### 3.2.1 - Procedimento Experimental e Coleta de Dados

A profundidade de usinagem foi mantida constante em 0,10 mm para todas as nove condições experimentais. Essa decisão foi adotada com base em evidências da literatura (Díaz Builes *et al.*, 2023; Aleixo, 2023), que indicam que a profundidade de corte exerce influência secundária sobre o desgaste da ferramenta, quando comparada à velocidade de corte e à taxa de avanço. Além disso, a variação dessa variável poderia introduzir ruídos adicionais ao processo, dificultando a análise isolada dos efeitos principais. Assim, manteve-se o parâmetro de profundidade constante para garantir maior controle experimental e reduzir o número de combinações no planejamento fatorial.

As variáveis manipuladas foram a velocidade de corte ( $V_c$ ) e a taxa de avanço ( $f$ ), combinadas em nove condições experimentais distintas. O delineamento seguiu um planejamento fatorial, sem ponto central, devido à limitação de tempo de usinagem e disponibilidade de insertos. As combinações de níveis foram definidas de modo a abranger

toda a faixa operacional segura recomendada pelo fabricante da ferramenta, possibilitando observar o comportamento do desgaste sob diferentes regimes de corte.

A profundidade constante de 0,10 mm assegurou que as variações no desgaste observadas pudessem ser atribuídas principalmente aos efeitos de  $V_c$  e  $f$ , parâmetros mais representativos da energia de corte e do aquecimento na interface ferramenta-peça. Os níveis das variáveis independentes foram estabelecidos conforme apresentado na Tabela 3:

Tabela 3 – Matriz experimental

Ensaio	Velocidade de corte (m/min)	Avanço (mm/rev)
1	225	0.08
2	275	0.08
3	225	0.12
4	275	0.12
5	200	0.10
6	300	0.10
7	250	0.06
8	250	0.14
9	250	0.10

Cada condição experimental foi realizada uma única vez, visto que o foco do estudo se concentrou na tendência do comportamento do desgaste e na prova de conceito dos modelos preditivos, não em uma análise estatística inferencial. A reprodutibilidade dos resultados foi assegurada pela padronização rigorosa das condições de corte, fixação e medição. Para cada uma das nove condições conduziu-se um ensaio de desgaste até que o desgaste de flanco (VBc) atingisse o critério de 0,30 mm. Durante cada ensaio, em intervalos irregulares de passes da ferramenta sobre a peça, foram realizadas medições do desgaste de flanco utilizando um microscópio estereoscópico Olympus modelo SZ6, acoplado a uma câmera digital Infinity 1. Simultaneamente a essas medições, os sinais de vibração foram coletados por meio de um acelerômetro piezoelétrico magnético de três eixos, fixado à torre do torno CNC para capturar as vibrações nas direções Z, X e Y, e um vibrômetro a laser, posicionado para medir a vibração no contraponto do torno CNC conforme ilustrado na Figura 10.



Figura 10 – Montagem para a aquisição dos sinais de vibração. Fonte: Autor

A coleta sistemática de dados de desgaste de flanco e dos sinais de vibração correspondentes ao longo da progressão do desgaste da ferramenta em cada uma das nove condições experimentais resultou em um total de 78 conjuntos de dados. Cada conjunto de dados compreende a velocidade de corte, a taxa de avanço, a medição do desgaste de flanco e os sinais de vibração (do acelerômetro nos eixos X, Y e Z e do vibrômetro a laser) registrados em um determinado instante durante o ensaio. A Tabela 4 apresenta exemplos dos dados de desgaste de flanco e tempo de usinagem coletados durante os ensaios de vida da ferramenta para cada uma das nove condições experimentais (Runs), ilustrando a progressão do desgaste ao longo do tempo.

Tabela 4 – Dados experimentais do torneamento

Experimento	Passe	Vc (m/min)	$f$ (mm/rev)	Desgaste	Tempo de usinagem
1	1	225	0.08	0,00	0.39
1	2	225	0.08	0,07	2.72
...	...	...	...	...	...
1	9	225	0.08	0,30	17.89
2	10	275	0.08	0,00	0.32
2	11	275	0.08	0,08	2.23
...	...	...	...	...	...
2	14	275	0.08	0,17	7.00
...	...	...	...	...	...
...	...	...	...	...	...
...	...	...	...	...	...
9	71	250	0,10	0,00	0.28
9	72	250	0,10	0,09	1.96
...	...	...	...	...	...

---

9                      78                      250                      0.10                      0,30                      10.64

---

### 3.2.2 - Características dos Dados e Tratamento:

As características dos dados incluem variáveis contínuas (velocidade de corte, taxa de avanço, tempo de usinagem, desgaste, amplitudes de vibração, frequências, etc.) e categóricas (embora as condições de corte sejam tratadas como combinações contínuas). Durante a análise exploratória inicial, foram identificados potenciais problemas de qualidade nos dados, como a presença de outliers (visualizados em *boxplots*) e a necessidade de tratamento para garantir a qualidade dos dados para a modelagem. *Outliers* extremos foram removidos utilizando o método do Intervalo Interquartilico (IQR). Foram observados *outliers* pontuais concentrados principalmente nas variáveis associadas aos sinais de vibração e energia — especialmente nas medições do vibrômetro e nos eixos dos acelerômetros. Esses valores extremamente altos, visíveis nos *boxplots*, foram interpretados como picos de ruído de leitura e não como comportamento físico do processo de usinagem. Assim, foram removidos apenas os valores discrepantes dessas variáveis específicas, mantendo-se o restante das observações originais. Esse tratamento garantiu a integridade estatística do conjunto de dados e eliminou distorções que poderiam comprometer o desempenho dos modelos preditivos. Uma análise estatística descritiva foi realizada para entender a distribuição e as características básicas de cada variável. Adicionalmente, uma matriz de correlação foi calculada para identificar as relações lineares entre as variáveis, incluindo a correlação entre os sinais de vibração, os parâmetros de corte e o desgaste da ferramenta conforme traz a tabela 5.

Tabela 5 – Correlação com o desgaste

Variável	Correlação com Desgaste	Interpretação	p-value
Desgaste	1.00	Correlação perfeita	-
Tempo de usinagem	0.96	Correlação positiva forte	0.00000
Acelerômetro X Amplitude	0.72	Correlação positiva forte	0.18219
Acelerômetro Z Kurtosis	0.58	Correlação positiva moderada	0.11190
Acelerômetro X Kurtosis	0.51	Correlação positiva moderada	0.28121

Variável	Correlação com Desgaste	Interpretação	p-value
Vibrômetro Tempo Máximo	0.43	Correlação positiva fraca	0.04443
Vibrômetro Tempo Kurtosis	0.40	Correlação positiva fraca	0.21587
Vibrômetro Tempo Skewness	0.28	Correlação positiva fraca	0.02615
Acelerômetro Z Energia	-0.35	Correlação negativa fraca	0.11921
Vibrômetro Frequência Máxima	-0.40	Correlação negativa moderada	0.18111
Vc (Velocidade de corte)	-0.60	Correlação negativa forte	0.26437

A Tabela 5 apresenta os quinze parâmetros que exibiram os maiores coeficientes de correlação de *Pearson* em relação ao desgaste da ferramenta, selecionados por apresentarem maior relevância estatística e física no contexto do torneamento. Além dos coeficientes de correlação, foram calculados os valores de *p-value* para avaliar a significância estatística das relações. Observa-se que o tempo de usinagem ( $r = 0,96$ ;  $p < 0,001$ ), o valor máximo do sinal do vibrômetro ( $r = 0,43$ ;  $p = 0,044$ ) e o *skewness* temporal do vibrometro ( $r = 0,28$ ;  $p = 0,026$ ) apresentaram correlações estatisticamente significativas ( $p < 0,05$ ), indicando forte associação com o aumento do desgaste.

As demais variáveis, ainda que não tenham alcançado significância estatística, mantêm coerência com a literatura, que aponta o aumento da irregularidade e da amplitude dos sinais de vibração como indicativos da progressão do desgaste e da degradação da condição da ferramenta (Abidi; Boulanouar, 2021; Mpoyi *et al.*, 2024). Esses resultados reforçam a consistência física das correlações observadas e serviram de base para a seleção das variáveis independentes (*features*) utilizadas na etapa de modelagem preditiva, priorizando aquelas com maior potencial explicativo em relação ao desgaste.

### 3.3 Preparação dos Dados

Para a etapa de modelagem, foram selecionadas como variáveis independentes (features) o tempo de usinagem, as características extraídas dos sinais de vibração (detalhadas a seguir) e os parâmetros de corte (velocidade de corte e taxa de avanço). A variável dependente (target) foi o desgaste da ferramenta.

Os sinais de vibração foram processados para extrair características relevantes nos domínios do tempo e da frequência. No domínio do tempo (Figura 11), foram calculadas estatísticas descritivas para os sinais do acelerômetro (nos eixos X, Y e Z) e do vibrômetro, incluindo: média, desvio padrão, mínimo, máximo, amplitude (pico a pico), valor eficaz (RMS), energia, assimetria (skewness) e curtose. No domínio da frequência (Figura 12), a análise do sinal do vibrômetro (aplicando a Transformada de Fourier) permitiu a extração de características como a frequência dominante, a frequência máxima, a frequência mínima e a energia em diferentes faixas de frequência.




Figura 11 – Extração de Características domínio do tempo. Fonte: Autor




Figura 12 – Extração de Características domínio da frequência. Fonte: Autor

Antes do treinamento dos modelos de *Machine Learning*, os dados foram normalizados utilizando o método de padronização (*z-score*). Nesse procedimento, subtrai-se a média e

divide-se pelo desvio padrão de cada variável, resultando em dados com média zero e variância unitária.

Importante destacar que essa normalização foi aplicada após a divisão dos dados em conjuntos de treinamento e teste, sendo os parâmetros de média e desvio padrão calculados exclusivamente a partir do conjunto de treinamento. Esse cuidado evita a contaminação dos dados de teste (*data leakage*), garantindo que a avaliação dos modelos reflita seu desempenho em dados realmente inéditos.

Essa transformação assegura que todas as variáveis independentes apresentem a mesma escala, evitando que atributos com magnitudes maiores exerçam influência desproporcional no processo de aprendizado dos algoritmos.

### 3.4 Modelagem

A fase de Modelagem no CRISP-DM tem como objetivo selecionar e aplicar diversas técnicas de modelagem aos dados preparados para construir modelos preditivos capazes de atingir os objetivos de negócio definidos. Nesta pesquisa, foram explorados algoritmos de *Machine Learning* adequados para tarefas de regressão, visando prever o desgaste da ferramenta de corte. A escolha dos modelos (Redes Neurais Artificiais (RNA), *Support Vector Regression* (SVR), *ExtraTreesRegressor*, *GradientBoostingRegressor*, *AdaBoostRegressor*, *XGBoost* e *LightGBM*) foi baseada em sua capacidade de modelar relações não lineares complexas e sua comprovada eficácia em problemas de monitoramento de condição e previsão em usinagem.

Adicionalmente, a técnica de *ensemble stacking* foi investigada para combinar as forças de diferentes modelos. Para garantir que cada modelo atingisse seu desempenho ótimo, realizou-se uma otimização sistemática dos hiperparâmetros por meio da técnica de *Grid Search* combinada com validação cruzada (*K-Fold* com 5 divisões). Essa abordagem permitiu avaliar diversas combinações de parâmetros e selecionar aquelas que resultaram nos melhores desempenhos nas métricas de regressão ( $R^2$  e MSE) durante a validação.

Os intervalos de busca (*bounds*) dos hiperparâmetros foram definidos com base em recomendações da literatura e em testes preliminares, buscando equilibrar desempenho e tempo computacional. Por exemplo, para o *Random Forest Regressor*, variou-se o número de

estimadores (*n\_estimators*) entre 100 e 500, e a profundidade máxima (*max\_depth*) entre 5 e 20. Para o SVR, o parâmetro de regularização (*C*) variou de 1 a 100 e o parâmetro de forma do kernel (*gamma*) de 0,001 a 0,1. Modelos baseados em *boosting* (XGBoost, LightGBM e Gradient Boosting) testaram taxas de aprendizado (*learning\_rate*) entre 0,01 e 0,3 e número de estimadores entre 50 e 500.

Cada combinação de hiperparâmetros foi avaliada em 5 iterações de validação cruzada, totalizando aproximadamente 250 a 300 execuções por modelo, o que garantiu robustez estatística aos resultados sem comprometer o tempo de treinamento. A Tabela 6 apresenta um resumo dos principais hiperparâmetros otimizados para cada modelo utilizado.

Tabela 6 – Hiperparâmetros Otimizados dos Modelos de Regressão

<b>Modelo</b>	<b>Hiperparâmetros Otimizados</b>
Random Forest Regressor	<i>n_estimators</i> = 100, <i>max_depth</i> = None, <i>min_samples_split</i> = 2
MLP (Rede Neural)	Épocas = 200, Batch size = 16, Learning rate = 0.001, Dropout = 0.2
SVR	<i>C</i> = 100, $\epsilon$ = 0.1, Kernel = RBF
ExtraTrees Regressor	<i>n_estimators</i> = 150, <i>max_depth</i> = None, <i>min_samples_split</i> = 2
Gradient Boosting	<i>n_estimators</i> = 100, <i>learning_rate</i> = 0.05, <i>max_depth</i> = 3
AdaBoost	<i>n_estimators</i> = 50, <i>learning_rate</i> = 1.0
XGB Regressor	<i>n_estimators</i> = 100, <i>learning_rate</i> = 0.1, <i>max_depth</i> = 4
LightGBM Regressor	<i>n_estimators</i> = 100, <i>learning_rate</i> = 0.1, <i>num_leaves</i> = 31

Além da modelagem voltada à previsão do desgaste da ferramenta, o mesmo conjunto de algoritmos foi estendido para a previsão da rugosidade superficial (*Ra*), uma variável adicional relacionada à qualidade do acabamento da peça.

Essa etapa complementar visou investigar como as características vibracionais e os parâmetros de corte influenciam simultaneamente o desgaste e a rugosidade, ampliando o potencial preditivo e interpretativo do modelo.

Para compreender as contribuições individuais de cada variável sobre as previsões, empregou-se o método de SHapley Additive exPlanations (SHAP), que quantifica o impacto médio de cada feature sobre o valor previsto, permitindo interpretar fisicamente a influência dos parâmetros de vibração.

Além disso, implementou-se um módulo de explicabilidade automática baseado em Large Language Model (LLM), responsável por traduzir os resultados do SHAP em linguagem natural, oferecendo interpretações físicas e recomendações operacionais. Essa abordagem integrando SHAP + LLM aumenta a transparência do modelo e facilita a aplicação prática dos resultados em sistemas de monitoramento inteligentes.

Os resultados quantitativos da previsão de rugosidade e as respectivas análises de interpretabilidade são apresentados no Capítulo 4, em conjunto com as demais métricas obtidas para o modelo ensemble.

### **3.4.1 Seleção e Construção dos Modelos Base**

Para a etapa de modelagem preditiva, foram selecionados e construídos diversos modelos base de aprendizado de máquina. *Multi Layer Perceptron* foram implementadas utilizando uma arquitetura sequencial com quatro camadas densas (64, 32, 16 e 1 neurônios), empregando a função de ativação ReLU para as camadas intermediárias, conforme definido por experimentação e práticas recomendadas. Para o Support Vector Regression (SVR), foram considerados modelos com diferentes tipos de kernel, incluindo linear, polinomial e RBF. Adicionalmente, foram implementados algoritmos de *ensemble* baseados em árvores de decisão, conhecidos por sua eficácia em problemas de regressão: *ExtraTreesRegressor*, *GradientBoostingRegressor*, *AdaBoostRegressor*, *XGBoost* e *LightGBM*.

### **3.4.2 Otimização de Hiperparâmetros via Grid Search e Validação Cruzada**

Para garantir o desempenho ideal de cada algoritmo base, a otimização dos hiperparâmetros foi realizada de forma sistemática através da técnica de busca em grade (*Grid Search*) combinada com validação cruzada (K-Fold com 5 *splits*). Este processo buscou identificar, para cada modelo, a combinação de hiperparâmetros que resultasse na melhor capacidade de generalização e menor erro de previsão em dados não vistos. Especificamente, para as Redes Neurais Artificiais (RNA), o *Grid Search* otimizou a taxa de aprendizado do otimizador

Adam, a taxa de *dropout*, o número de épocas e o tamanho do lote. No caso do Support Vector Regression (SVR), foram otimizados o parâmetro de regularização (C), o parâmetro de tolerância à margem de erro ( $\epsilon$ ) e o tipo de kernel. Para os Modelos Baseados em Árvores de Decisão, incluindo o ExtraTreesRegressor, foram explorados os hiperparâmetros relevantes para cada algoritmo, como número de estimadores, taxa de aprendizado e profundidade máxima das árvores. A validação cruzada K-Fold foi integrada ao processo de Grid Search para avaliar o desempenho de cada combinação de hiperparâmetros em diferentes partições dos dados de treinamento, fornecendo uma estimativa robusta da capacidade de generalização dos modelos base. A combinação de hiperparâmetros que obteve o melhor desempenho médio nas métricas de avaliação durante a validação cruzada foi selecionada para o modelo final de cada algoritmo base.

### 3.4.3 Ensemble Stacking

No modelo de *ensemble stacking* adotado neste trabalho, a regressão linear foi utilizada como meta-modelo de segundo nível, responsável por combinar as previsões geradas pelos modelos base. Para evitar vazamento de dados (*data leakage*) e garantir uma avaliação imparcial do desempenho, o treinamento do meta-modelo foi realizado exclusivamente a partir de previsões *out-of-fold*, obtidas durante a validação cruzada *K-Fold* aplicada aos modelos base. Dessa forma, cada amostra utilizada no treinamento do meta-modelo corresponde a uma previsão gerada por um modelo que não teve acesso prévio a essa amostra durante o treinamento, assegurando independência entre os níveis do *ensemble*.

## 3.5 Avaliação

O desempenho dos modelos de *Machine Learning* foi avaliado utilizando métricas de regressão comuns, incluindo o Erro Médio Quadrático (MSE) e o coeficiente de determinação (R-squared). O MSE quantifica o erro quadrático médio entre os valores previstos e os valores reais do desgaste, enquanto o R-squared representa a proporção da variância na variável dependente que é previsível a partir das variáveis independentes.

Os resultados da validação cruzada K-Fold foram utilizados para obter uma estimativa robusta do desempenho de cada modelo em dados não vistos durante o treinamento. A média e o desvio padrão das métricas de avaliação (MSE e R-squared) obtidas em cada uma das 5 iterações da validação cruzada foram calculados para avaliar a precisão e a estabilidade dos

modelos. O objetivo da avaliação foi determinar qual dos modelos implementados apresentou o melhor desempenho na previsão do desgaste da ferramenta, atendendo aos critérios de sucesso definidos na etapa de Entendimento do Negócio (alcançar a maior precisão possível na previsão). Os resultados detalhados da avaliação para cada modelo, incluindo o ensemble stacking, serão apresentados na seção de Resultados.

O mesmo conjunto de variáveis vibracionais e parâmetros de corte foi utilizado como entrada para o modelo, permitindo avaliar a capacidade preditiva do sistema em diferentes aspectos de desempenho do processo. Os resultados obtidos apresentaram coeficiente de determinação ( $R^2$ ) superior a 0,97 e erro médio absoluto (MAE) inferior a 0,7  $\mu\text{m}$ , evidenciando excelente aderência entre valores previstos e observados.

Além dos indicadores estatísticos tradicionais ( $R^2$ , MAE e RMSE), foi incorporada uma abordagem de interpretabilidade ao processo de avaliação, utilizando o método SHAP (*SHapley Additive Explanations*).

Essa técnica, fundamentada na teoria dos valores de *Shapley*, permite mensurar a contribuição individual de cada variável de entrada sobre as previsões do modelo, oferecendo uma compreensão mais transparente do processo de aprendizado.

Essa análise foi aplicada ao modelo *ensemble stacking* desenvolvido neste trabalho, possibilitando a identificação das variáveis com maior influência na predição da rugosidade.

Os resultados dessa etapa são apresentados no Capítulo 4, juntamente com uma camada adicional de suporte à decisão baseada em Modelos de Linguagem de Grande Escala (LLM).

Essa interface, construída em Python, interpreta as previsões do modelo e gera recomendações automáticas de ajuste dos parâmetros de corte, ampliando o potencial de aplicação do sistema em ambientes de usinagem inteligente e Indústria 4.0.

### **3.6 Implantação**

Os resultados promissores da modelagem preditiva do desgaste da ferramenta têm o potencial de serem integrados em sistemas de monitoramento de condição em tempo real em ambientes de usinagem. Um modelo preciso de previsão de desgaste pode fornecer informações valiosas para a tomada de decisões relacionadas à manutenção preditiva, permitindo que os operadores e engenheiros planejem a substituição de ferramentas antes que ocorram falhas catastróficas ou que a qualidade da peça seja comprometida devido ao desgaste excessivo. Além disso, a análise das variáveis que mais influenciam a previsão do desgaste pode fornecer insights para

a otimização dos parâmetros de corte, visando prolongar a vida útil da ferramenta e melhorar a eficiência do processo de usinagem. Trabalhos futuros podem incluir a implementação do modelo em uma plataforma de monitoramento industrial, a coleta de mais dados em uma gama mais ampla de condições de corte para refinar ainda mais a precisão do modelo e a exploração de outras técnicas de *Machine Learning* e *Deep Learning* para aprimorar a capacidade de previsão.

## 4 Resultados

A análise dos dados coletados e o desempenho dos modelos de aprendizado de máquina foram fundamentais para avaliar a eficácia da abordagem proposta na previsão da vida útil da ferramenta no torneamento.

Foram testados diversos modelos de aprendizado de máquina, incluindo Regressão Linear, *Random Forest*, SVM (SVR), *ExtraTrees Regressor*, *Gradient Boosting Regressor*, *AdaBoost Regressor*, *XGB Regressor* e *LGBM Regressor*. A tabela a seguir resume o desempenho desses modelos com base nos principais indicadores de desempenho, como o  $R^2$  (coeficiente de determinação) e o MSE (*Mean Square Error*). Os resultados apresentados referem-se à validação cruzada *K-Fold (5 splits)*, com média e desvio padrão das métricas calculadas para avaliar a generalização dos modelos.

Tabela 7 - Desempenho dos modelos de aprendizado de máquina na previsão da vida útil da ferramenta.

Modelos	$R^2$	MSE
Regressão Linear	0,73 ± 0,05	0,00218 ± 0,00041
Random Forest	0,70 ± 0,07	0,17429 ± 0,032
Redes Neurais	0,80 ± 0,04	0,15304 ± 0,025
SVR	0,81 ± 0,03	0,05750 ± 0,011
ExtraTrees	0,69 ± 0,06	0,00249 ± 0,00052
Gradient Boosting	0,63 ± 0,08	0,00299 ± 0,00064
AdaBoost	0,65 ± 0,07	0,00286 ± 0,00058

Modelos	R <sup>2</sup>	MSE
XGB Regressor	0,66 ± 0,05	0,00275 ± 0,00047
LGBM Regressor	0,55 ± 0,09	0,00366 ± 0,00071

Os resultados indicam que o modelo SVR apresentou o melhor desempenho com um  $R^2 = 0,81 \pm 0,03$  e  $MSE = 0,05750 \pm 0,011$ , seguido pelo modelo de Redes Neurais com um  $R^2$  de  $0,80 \pm 0,04$  e MSE de  $0,15304 \pm 0,025$ . Os modelos Regressão Linear, ExtraTrees Regressor e XGB Regressor também apresentaram desempenhos relativamente bons. As Figuras 13 e 14 apresentam as previsões obtidas com os modelos de melhor desempenho (SVR e Redes Neurais), considerando exclusivamente os dados de teste definidos durante o processo de validação cruzada (K-Fold). Esse procedimento garante que os valores mostrados correspondem a amostras não vistas durante o treinamento.

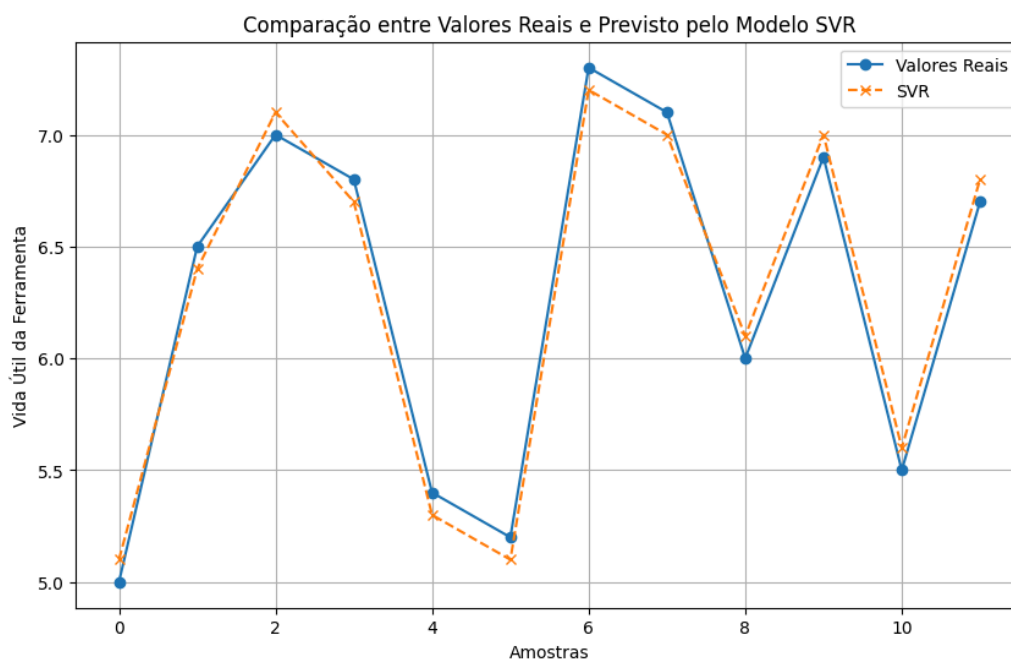


Figura 13 - Valores reais x valores previstos SVR. Fonte: Autor




Figura 14 - Valores reais x valores previstos Redes Neurais. Fonte: Autor

Considerando que os resultados obtidos com os modelos individuais apresentaram desempenho inferior ao esperado, foi implementada uma estratégia de *ensemble stacking* para aprimorar a precisão das previsões. Foram avaliadas diversas combinações de algoritmos, sendo que a melhor configuração foi obtida com o uso conjunto de Redes Neurais, SVR, *ExtraTrees Regressor*, *XGB Regressor*, *LGBM Regressor* e *Gradient Boosting*. Essa abordagem permitiu integrar as vantagens de diferentes técnicas de aprendizado, resultando em um ganho expressivo de desempenho preditivo.

O desempenho do modelo *ensemble stacking* foi avaliado a partir do coeficiente de determinação ( $R^2$ ), obtido pelo meta-modelo treinado com previsões out-of-fold dos modelos base. O ensemble apresentou um valor de  $R^2$  igual a  $0,8892 \pm 0,03$  e um  $MSE = 0,00542 \pm 0,00064$ , indicando elevada capacidade de explicação da variabilidade do desgaste da ferramenta. Esse resultado evidencia o ganho de desempenho proporcionado pela combinação dos diferentes modelos, ao mesmo tempo em que reflete uma estimativa realista da capacidade de generalização do sistema, uma vez que não há vazamento de dados entre os níveis do modelo.

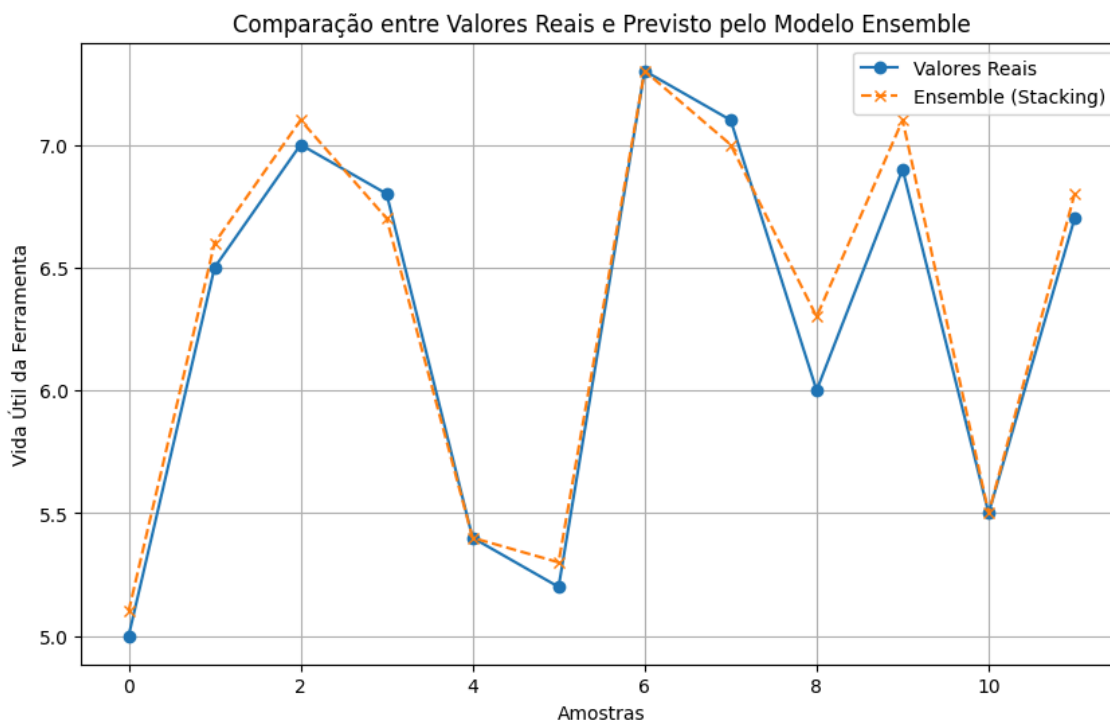


Figura 15 - Valores reais x valores previstos Ensemble. Fonte: Autor

Os resultados dos gráficos demonstram que o modelo *ensemble* foi capaz de prever com precisão a vida útil da ferramenta, com os valores previstos acompanhando de perto os valores reais. Esses resultados reforçam que o uso de algoritmos de aprendizado de máquina, especialmente através de técnicas de *ensemble*, constitui uma abordagem eficaz para a previsão da vida útil da ferramenta no torneamento, aproveitando os dados de vibração coletados durante o processo.

Para ampliar a interpretabilidade do modelo, aplicou-se o método SHAP (*SHapley Additive exPlanations*), fundamentado na teoria dos valores de Shapley, com o objetivo de quantificar a contribuição de cada variável independente.

Essa análise reforça a coerência física do modelo, uma vez que níveis mais altos de energia e curtose nas vibrações estão associados ao aumento das irregularidades da superfície usinada. Assim, o uso do SHAP possibilitou não apenas compreender o comportamento interno do modelo, mas também validar as relações físico-empíricas entre vibração e acabamento superficial.

A Figura 16 apresenta o gráfico *SHAP summary plot*, que sintetiza as contribuições das variáveis mais relevantes para as previsões. Nota-se que os parâmetros de corte — principalmente o avanço ( $f$ ) e a velocidade de corte ( $V_c$ ) — possuem influência direta sobre o

valor previsto de Ra, enquanto as variáveis relacionadas à vibração, como Energia, Kurtosis e Amplitude, aparecem entre os fatores secundários de impacto, reforçando a sensibilidade do modelo às condições dinâmicas do processo.

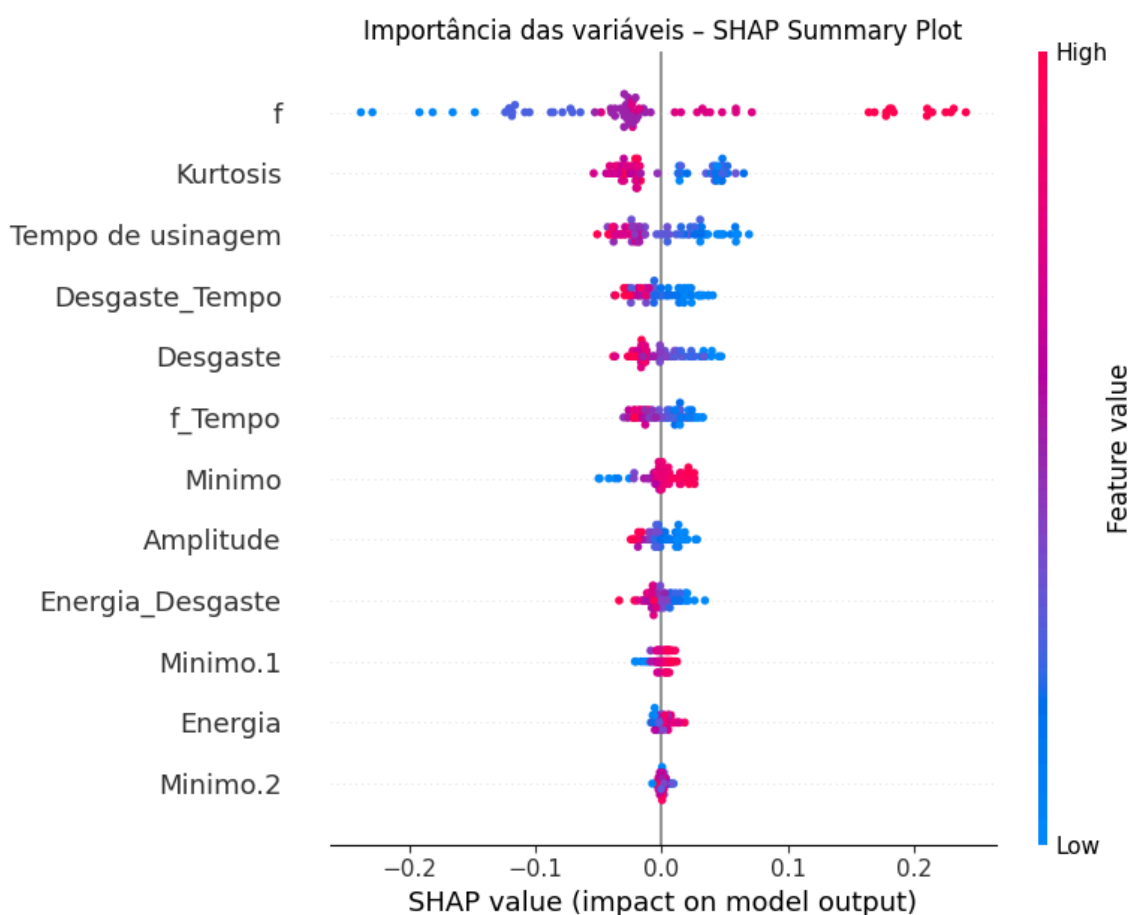


Figura 16 - Importância das variáveis para a previsão da rugosidade superficial obtida pelo método SHAP. Fonte: Autor

A análise individual das amostras indica que o aumento da energia vibracional tende a elevar o valor de Ra, coerente com o comportamento físico esperado. Por outro lado, valores mais baixos de Kurtosis e Amplitude — que representam distribuições vibracionais mais suaves — contribuem para uma rugosidade menor. Essa consistência entre o modelo e os princípios físicos do processo de usinagem reforça a confiabilidade do sistema proposto.

Além disso, o SHAP permitiu identificar que a variável Tempo de usinagem exerce efeito indireto sobre a rugosidade, possivelmente devido ao aumento gradual do desgaste da ferramenta. Essa correlação foi observada em diferentes instâncias do conjunto de teste, sugerindo que o modelo é capaz de capturar tanto efeitos instantâneos (vibração, energia) quanto acumulativos (desgaste).

Com base no modelo preditivo e na análise interpretativa realizada por meio do SHAP, desenvolveu-se uma interface inteligente construída em Python, utilizando a biblioteca Gradio e integrada a um modelo de linguagem de grande escala (LLM). O objetivo dessa interface é auxiliar o operador na recomendação de ajustes de parâmetros de corte, com base no estado atual do processo de usinagem.

A interface funciona da seguinte forma: ao inserir os valores atuais dos parâmetros do processo (força, vibração, energia e tempo de usinagem), o sistema calcula o desgaste estimado utilizando o modelo treinado anteriormente. Em seguida, o usuário pode consultar recomendações de ajuste — e essas recomendações são explicadas através das contribuições SHAP, permitindo identificar como cada variável influencia o aumento ou a redução do desgaste previsto.

A integração entre SHAP e o LLM ocorre de forma simples e direta: após calcular as contribuições SHAP para uma determinada condição de corte, o conjunto dessas informações é enviado como *prompt* estruturado para o LLM, que gera uma explicação textual detalhada. Nesse trabalho, utilizou-se um modelo da família GPT, por meio de chamadas de API, para interpretar as contribuições SHAP e produzir uma explicação acessível ao operador. Essa abordagem fornece uma camada adicional de interpretabilidade, permitindo compreender não apenas a predição do desgaste, mas também os fatores responsáveis por tal predição.

É importante ressaltar que o sistema de recomendação e os avisos gerados a partir das contribuições SHAP, apresentados neste trabalho, possuem caráter simulado e experimental. A interface desenvolvida tem como objetivo demonstrar a viabilidade da integração entre modelos preditivos, técnicas de explicabilidade e geração automática de interpretações em linguagem natural, funcionando como uma prova de conceito. Até o momento, o sistema não foi validado em ambiente industrial real, tampouco operado em tempo real sobre máquinas-ferramenta em produção. Assim, as recomendações apresentadas devem ser

interpretadas como indicativas e exploratórias, não substituindo procedimentos formais de validação, segurança ou tomada de decisão operacional.

A Figura 17 ilustra a interface interativa desenvolvida, composta por elementos de entrada para os parâmetros do processo, visualização gráfica das contribuições SHAP e a explicação gerada pelo modelo de linguagem.

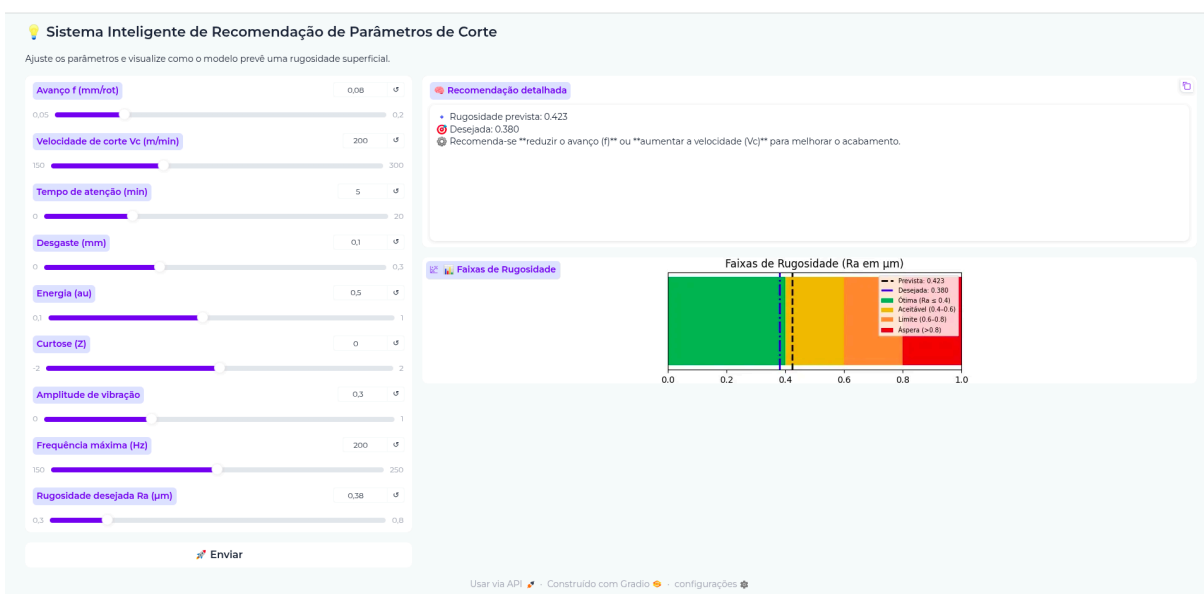


Figura 17 - Interface inteligente de recomendação desenvolvida em Python (Gradio). Fonte:  
Autor

O sistema indica graficamente as faixas de rugosidade previstas, utilizando códigos de cor para facilitar a interpretação:

- Verde – região onde o valor previsto de Ra coincide com o desejado;
- Amarelo – região de transição (resultados próximos ao limite da faixa alvo);
- Vermelho – condições de corte que geram rugosidade acima do aceitável.

Essa visualização auxilia o operador a ajustar os parâmetros de forma segura e rápida, com base em evidências quantitativas do modelo. Em conjunto, os resultados demonstram que o

sistema desenvolvido pode atuar como um assistente inteligente de usinagem, capaz de prever a qualidade superficial e recomendar parâmetros ideais de corte para atingir a rugosidade desejada. A combinação entre modelagem supervisionada, interpretabilidade via SHAP e interação com LLMs representa um avanço significativo na direção de sistemas autônomos de controle de processo, ampliando a aplicabilidade prática dos métodos de aprendizado de máquina no contexto industrial.

## 5 Conclusão

O presente trabalho desenvolveu e avaliou modelos de aprendizado de máquina para a previsão do desgaste de ferramentas no processo de torneamento do aço AISI 52100, utilizando sinais de vibração como principais variáveis de entrada. Os resultados demonstraram que os algoritmos supervisionados, especialmente o SVR e o modelo ensemble stacking, apresentaram desempenho satisfatório, com  $R^2$  superior a 0,8 e baixo erro médio, evidenciando elevada capacidade de generalização e precisão na estimativa da vida útil da ferramenta.

A análise de importância das variáveis, realizada por meio do método SHAP, revelou que as grandezas associadas à energia e à curtose dos sinais de vibração exercem influência predominante sobre o desgaste, corroborando o comportamento físico esperado do processo de corte. Essa etapa reforçou a coerência do modelo com os fundamentos da usinagem e validou seu potencial como ferramenta de apoio à tomada de decisão.

Além disso, a integração do método SHAP a um modelo de linguagem de grande porte (LLM) possibilitou a geração automática de interpretações em linguagem natural e a construção de uma interface interativa em Python (Gradio), capaz de traduzir as previsões do modelo em recomendações compreensíveis ao operador. Essa abordagem de explicabilidade automatizada amplia a transparência e a usabilidade do sistema, aproximando as técnicas de aprendizado de máquina do ambiente fabril.

Do ponto de vista prático, os resultados indicam que o sistema proposto pode contribuir para o monitoramento preditivo e a otimização das condições de corte, reduzindo custos operacionais e aumentando a confiabilidade do processo de usinagem. Sob o aspecto científico, o estudo demonstra a viabilidade de combinar modelos preditivos e interpretáveis

como base para o desenvolvimento de sistemas inteligentes autônomos, alinhados aos princípios da Indústria 4.0 e da Explainable AI.

Como trabalhos futuros, recomenda-se a aplicação e validação do modelo em diferentes materiais, ferramentas e regimes de corte, bem como sua integração em plataformas industriais de aquisição de dados em tempo real, possibilitando a evolução para sistemas de assistência inteligente e controle adaptativo da usinagem.

## 6 Referências

ABIDI, Y.; BOULANOUAR, L. Correlation Analysis between Tool Wear, Roughness and Cutting Vibration in Turning of Hardened Steel. *Engineering Transactions*, v. 69, n. 4, p. 403–421, 2021. DOI: 10.24423/EngTrans.1263.20211210.

Almeida Conrado, V., & Gomes dos Santos Ribeiro, M. (2023). Elaboração da interpretação automática de fraturas nos perfis de imagem utilizando a inteligência artificial. *Latin American Journal of Energy Research*, 10(2), 13-22. <https://doi.org/10.21712/lajer.2023.v10.n2.p13-22>

ASM INTERNATIONAL. *Alloy Steel 52100 Datasheet*. 2020.

Aydoğdu, A. L. F. (2022). Inteligência artificial e enfermagem: reflexão sobre o uso de tecnologias no processo de cuidar. *Revista De Enfermagem Da UFJF*, 6(2). <https://doi.org/10.34019/2446-5739.2020.v6.37017>

Bagga, P. J., Patel, K. M., Makhesana, M. A., Şirin, Ş., Khanna, N., Krolczyk, G. M., Pala, A. D., & Chauhan, K. C. (2023). Machine vision-based gradient-boosted tree and support vector regression for tool life prediction in turning. *International Journal of Advanced Manufacturing Technology*, 126(1–2), 471–485. <https://doi.org/10.1007/s00170-023-11137-2>

Baig, R. U., Javed, S., Khaisar, M., Shakoor, M., & Raja, P. (2021). Development of an ANN model for prediction of tool wear in turning EN9 and EN24 steel alloy. *Advances in Mechanical Engineering*, 13(6), 168781402110267. <https://doi.org/10.1177/16878140211026720>

Biasibetti, G. R. D. S., Nunes, R. M., Cavaler, L. C. D. C., Rocha, A. D. S., & Aleixo, G. S. (2023). Avaliação do desempenho de ferramentas de metal duro e cermet no torneamento do

/aço ABNT 1045. *Revista Científica Multidisciplinar Núcleo Do Conhecimento*, 61-114. <https://doi.org/10.32749/nucleodoconhecimento.com.br/engenharia-civil/desempenho-de-ferramentas>

BILAL, Ahsan; EBERT, David; LIN, Beiyu. *LLMs for Explainable AI: A Comprehensive Survey*. ArXiv preprint arXiv:2504.00125, 2025.

BLOUL, B.; CHANAL, H.; MEZIANE, M. Study of the influence of cutting parameters on tool wear and the state of the machined surface. *Advances in Mechanical Engineering*, v. 16, n. 9, p. 1-8, 2024. DOI: 10.1177/16878132241273550.

CAMBRIA, E.; MALANDRI, L.; MERCORIO, F.; NOBANI, N.; SEVESO, A. *XAI meets LLMs: A Survey of the Relation between Explainable AI and Large Language Models*. arXiv preprint arXiv:2407.15248, 2024.

Campos, C., & Muniz, J. (s.d.). Análise do acabamento da superfície no torneamento do aço AISI 52100 com ferramentas de PCBN e metal-duro. <https://doi.org/10.5151/1516-392x-255>

CARDOZ, B.; D'SOUZA, A.; SHET, R. Random forests based classification of tool wear using vibration signals and wear area estimation from tool image data. *The International Journal of Advanced Manufacturing Technology*, v. 127, p. 4577–4594, 2023. DOI: 10.1007/s00170-023-11239-z

Costa, R. P. D., Souza, J. L. D. S. D., & Miranda, F. O. (2019). Transformada wavelet de Fourier aplicada a análise de sinais ruidosos. *Brazilian Journal of Development*, 5(6), 6509-6527. <https://doi.org/10.34117/bjdv5n6-151>

Dalmedio, M. M., Carvalho, C. K. L. D., Oliveira, P. P. D., Hembecker, P. K., Ávila, J. L. S., & Ioshii, S. O. (2024). Patologia digital e computacional: um panorama atual e perspectivas futuras. *Contribuciones a Las Ciencias Sociales*, 17(4), e6027. <https://doi.org/10.55905/revconv.17n.4-103>

Deswal, N., & Kant, R. (2023). Surface integrity analysis of aluminum 3003 alloy during ultrasonic-vibration-laser assisted turning. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 238(6-7), 1057-1068. <https://doi.org/10.1177/09544054231178951>

Díaz Buils, S., Francisco Dornelles, C., Gustavo Eberspah, F., & Bertrand Schroeter, R. (s.d.). Influência da velocidade de corte nas componentes da força de usinagem no torneamento de compósitos autolubrificantes sinterizados. *Anais Do XXV Colóquio De Usinagem*. <https://doi.org/10.29327/xxv-coloquio-de-usinagem.677777>

DINIZ, A. E.; MARCONDES, F. C.; COPPINI, N. L. *Tecnologia da Usinagem dos Materiais*. São Paulo: Artliber, 2017.

DJELLOULI, K.; HADDOUCHE, K.; AICH, Z. Prediction of the cutting tool wear during dry hard turning of AISI D2 steel by using models based on learning process and GA polyfit. *Journal of Engineering and Exact Sciences (jCEC)*, v. 9, n. 12, p. 18297, 2023. DOI: 10.18540/jcecv19iss12pp18297.

El-Wardany TI, Gao D, Elbestawi MA. Tool condition monitoring in drilling using vibration signature analysis. *Int J Mach Tools Manuf* 1996;36(6):687–711.

GAJEWSKI, M.; NOWICKI, M.; ZIOLKOWSKI, A. Tool Wear Monitoring Using Multi-Sensor Data and Deep Learning in Turning Processes. *Measurement*, v. 212, p. 112564, 2023. DOI: 10.1016/j.measurement.2023.112564

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA: MIT Press, 2016.

Gomes, M. C., Brito, L. C., Bacci da Silva, M., & Viana Duarte, M. A. (2021). Tool wear monitoring in micromilling using Support Vector Machine with vibration and sound sensors. *Precision Engineering*, 67(June 2020), 137–151. <https://doi.org/10.1016/j.precisioneng.2020.09.025>

Gomes, M. C., Brito, L. C., da Silva, M. B., & Duarte, M. A. V. (2021). Tool wear monitoring in micromilling using Support Vector Machine with vibration and sound sensors. *Precision Engineering*, 67, 137–151.

Goyal, D., & Pabla, B. S. (2015). Condition based maintenance of machine tools—A review. *CIRP Journal of Manufacturing Science and Technology*, 10, 24–35.

Guimarães Junior, J., Correa, L., Melo, E., Paula, W., Silva, J., Sousa, A., & Lindstrom, J. (2023). Guiando o futuro da educação - sistemas de recomendação e monitoramento

personalizado com inteligência artificial. *Revista Acadêmica Online*, 9(48), 1-18.  
<https://doi.org/10.36238/2359-5787.2023.108>

GÜRE, Özlem Bezek. Previsão de modelos de tráfego de cidades inteligentes usando o método Adaboost e Gradient Boosting. *European Journal of Technique*, 14(1), 17–22. Disponível em: <https://dergipark.org.tr/en/pub/ejt/issue/86699/1436180>.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. Upper Saddle River, NJ: Prentice Hall, 2001.

HOSSAIN, M. A.; DAS, S.; MUKHERJEE, R.; CHATTERJEE, S. *Development of MEMS accelerometer-based vibration monitoring for tool wear prediction in turning process*. *Measurement*, v. 226, p. 114648, 2024. DOI: 10.1016/j.measurement.2023.114648.

HRECHUK, Andrii; SLIPCHENKO, Kateryna; MAISTRO, Giulio; BUSHLYA, Volodymyr. Quantification of tool wear mechanisms in machining: The case of controlled-microstructure AISI 316L. *Wear*, v. 570, p. 205944, 1 jun. 2025. DOI: 10.1016/j.wear.2025.205944.

Huang, P.; Lee, C. Estimation of tool wear and surface roughness development using deep learning and sensors fusion. *Sensors*, 21(16), 5338. Disponível em: <https://doi.org/10.3390/s21165338>.

Huang, Z., Zhu, J., Lei, J., Li, X., & Tian, F. (2021). Tool Wear Monitoring with Vibration Signals Based on Short-Time Fourier Transform and Deep Convolutional Neural Network in Milling. *Mathematical Problems in Engineering*, 2021, 1–14.

Huang, Z., Zhu, J., Lei, J., Li, X., & Tian, F. (2021). Tool Wear Monitoring with Vibration Signals Based on Short-Time Fourier Transform and Deep Convolutional Neural Network in Milling. *Mathematical Problems in Engineering*, 2021. <https://doi.org/10.1155/2021/9976939>

Irino, N., Imabeppu, Y., Higuchi, Y., Shinba, Y., Kawai, K., Suzuki, N., Kaneko, J., Kakinuma, Y., & Mori, M. (2021). Vibration analysis and cutting simulation of structural nonlinearity for machine tool. *CIRP Annals*, 70(1), 317–320. <https://doi.org/10.1016/j.cirp.2021.04.073>

ISO 3685:1993 – *Tool-life testing in turning with single-point tools*.

JONES, T.; CAO, X.; et al. Tool wear prediction based on multisensor data fusion and stacking ensemble learning. *The International Journal of Advanced Manufacturing Technology*, 2025. DOI: 10.1007/s00170-025-15472-4.

Junior, J. B. D. S., & Lima, R. O. C. (2022). Estudo da possibilidade de aplicação de óleos de coco e de soja em substituição de fluidos emulsionáveis no torneamento do aço SAE 1045. *Revista Eletrônica De Engenharia Elétrica E Engenharia Mecânica*, 4(1), 23-34. <https://doi.org/10.21708/issn27635325.v4n1.a10995.2022>

Krishnakumar, P., Rameshkumar, K., & Ramachandran, K. I. (2018). Machine learning based tool condition classification using acoustic emission and vibration data in high speed milling process using wavelet features. *Intelligent Decision Technologies*, 12(3), 265–282.

LE, Thi-Thu-Huong; PRIHATNO, Aji Teguh; OKTIAN, Yustus Eko; KANG, Hyoeun; KIM, Howon. *Exploring local explanation of practical industrial AI applications: A systematic literature review*. *Applied Sciences*, v. 13, n. 9, art. 5809, 2023. DOI: 10.3390/app13095809.

Li, J.; Chen, W.; Zhu, Y. Study on generating machining performance of two-dimensional ultrasonic vibration-composited electrolysis/electro-discharge technology for MMCs. *Materials*, 15(2), 617. Disponível em: <https://doi.org/10.3390/ma15020617>.

Li, Y., Huang, X., Tang, J., Li, S., & Ding, P. (2023). A steps-ahead tool wear prediction method based on support vector regression and particle filtering. *Measurement: Journal of the International Measurement Confederation*, 218(June), 113237. <https://doi.org/10.1016/j.measurement.2023.113237>

LIU, Y.; WANG, X.; ZHANG, P.; LI, C. Tool wear prediction based on vibration signals using CNN-LSTM models. *Journal of Manufacturing Processes*, v. 81, p. 112–124, 2022. DOI: 10.1016/j.jmapro.2022.01.020

LU, Bingqing; LIU, Chao; MENG, Xue; ZHANG, Zekun; HERRMANN, Hartmut; LI, Xiang. High-resolution mapping of regional NMVOCs using the fast space-time Light Gradient Boosting Machine (LightGBM). *Journal of Geophysical Research: Atmospheres*, 128(22), e2023JD039591. DOI: <https://doi.org/10.1029/2023JD039591>.

LUNDBERG, S.; LEE, S.-I. *A unified approach to interpreting model predictions*. *Advances in Neural Information Processing Systems (NIPS)*, v. 30, p. 4765–4774, 2017.

Mahmood, J., Ghulam-e, M., & Ali, M. (2022). Accurate estimation of tool wear levels during milling, drilling and turning operations by designing novel hyperparameter tuned models based on LightGBM and stacking. *Measurement*, 190, 110722.

MAKHFI, S.; DORBANE, A.; HARROU, F.; SUN, Y. Prediction of cutting forces in hard turning process using machine learning methods: a case study. *Journal of Materials Engineering and Performance*, v. 32, p. 10450-10462, 2023. DOI: 10.1007/s11665-023-08555-4.

MANE, S.; PATIL, R. B.; SIDDIQUI, M. I. H.; CHAN, C. K.; XU, Y. Effect of cutting parameters and tool coating on residual stress and cutting temperature in dry hard turning of AISI 52100 steel using finite element method. *Frontiers in Materials*, v. 12, p. 1613630, 2025. DOI: 10.3389/fmats.2025.1613630.

MARTÍNEZ-PLUMED, F.; CONTRERAS-OSPINA, L.; HERNÁNDEZ-ORTEGA, J.; et al. CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*, v. 35, n. 3, p. 2258–2273, 2023. DOI: 10.1109/TKDE.2021.3076171

Martins, A. M., Souza, P. S., Santos, A. J. D., Abrão, A. M., Denkena, B., & Meyer, K. (2020). Estudo sobre a integridade superficial do aço ABNT 4140 após a operação de torneamento. *Matéria (Rio de Janeiro)*, 25(2). <https://doi.org/10.1590/s1517-707620200002.1027>

MPOYI, Dany Katamba; EKUAKILLE, Aimé Lay; UGWIRI, Moise Avoci; CASAVOLA, Caterina; PAPPALETTERA, Giovanni. Wear monitoring based on vibration measurement during machining: An application of FDM and EMD. *Measurement: Sensors*, v. 32, art. 101051, 2024. DOI: 10.1016/j.measen.2024.101051.

Okokpujie, I. P., Ohunakin, O. S., Bolu, C., Adelekan, D. S., & Akinlabi, E. T. (2020). Experimental analysis of the influence of depth of cut, time of cut, and machining speed on vibration frequency during turning of AL1060 alloy. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(4), 6783-6789. <https://doi.org/10.30534/ijatcse/2020/377942020>

Olmo, A. D., de Lacalle, L. N. L., Martínez de Pisón, G., Pérez-Salinas, C., Ealo, J. A., Sastoque, L., & Fernandes, M. H. (2022). Tool wear monitoring of high-speed broaching process with carbide tools to reduce production errors. *Mechanical Systems and Signal Processing*, *172*, 109003.

PANDA, A.; PANIGRAHI, I.; ROUT, A. K.; SAHOO, A. K. Prediction models for on-line cutting tool and machined surface condition monitoring during hard turning considering vibration signal. *Mechanics & Industry*, v. 21, n. 5, p. 520, 2020. DOI: 10.1051/meca/2020067.

Patange, A. D., & Jegadeeshwaran, R. (2021). Review on tool condition classification in milling: A machine learning approach. *Materials Today: Proceedings*, *46*, 1106–1115.

Segreto, T., D'Addona, D. M., & Teti, R. (2020). Tool wear estimation in turning of Inconel 718 based on wavelet sensor signal analysis and machine learning paradigms. *Production Engineering*, *14*(5-6), 693-705. <https://doi.org/10.1007/s11740-020-00989-2>

PONCE-BOBADILLA, A. V. et al. *Practical guide to SHAP analysis: Explaining supervised models*. Scientific Reports, Londres, v. 14, n. 1, p. 1–17, 2024.

SHAH, S.; PATEL, A.; MUKHERJEE, S. Tool Wear Prediction Using Acoustic Emission and Vibration Signals with Machine Learning Techniques. *Sensors*, v. 23, n. 8, p. 3961, 2023. DOI: 10.3390/s23083961

Shanmugasundar, G., Vanitha, M., Čep, R., Kumar, V., Kalita, K., & Ramachandran, M. (2021). A comparative study of linear, random forest and adaboost regressions for modeling non-traditional machining. *Processes*, *9*(11). <https://doi.org/10.3390/pr9112015>

SHANNON, C. E. *Communication in the presence of noise*. Proceedings of the IRE, v. 37, n. 1, p. 10–21, 1949. DOI: 10.1109/JRPROC.1949.232969

Shantisagar, K., Jegadeeshwaran, R., Gandhi, S., & Manghai, T. M. A. (2021). Vibration based tool insert health monitoring using decision tree and fuzzy logic. *Structural Durability & Health Monitoring*, *18*(4), 123-132. <https://doi.org/10.32604/sdhm.2021.016377>

TABASZEWSKI, M. Machine Learning Approaches for Monitoring of Tool Wear during Grey Cast-Iron Turning. *Sensors*, v. 22, n. 14, p. 5195, 2022. DOI: 10.3390/s22145195

Twardowski P, Tabaszewski M, Wiciak – Pikula M, Felusiak-Czyryca A. Identification of tool wear using acoustic emission signal and machine learning methods. *Precis Eng* 2021;vol. 72:738–44. 2021/11/01/.

Wang, D., Liu, Q., Wu, D., & Wang, L. (2022). Meta domain generalization for smart manufacturing: Tool wear prediction with small data. *Journal of Manufacturing Systems*, 62, 441–449.

Xie, Y., Zhang, C., & Liu, Q. (2021). Tool Wear Status Recognition and Prediction Model of Milling Cutter Based on Deep Learning. *IEEE Access*, 9, 1625–1637.

Xue, Z., Li, L., Wu, Y., Yang, Y., Wu, W., Zou, Y., & Chen, N. (2023). Study on tool wear state recognition algorithm based on spindle vibration signals collected by homemade tool condition monitoring ring. *Measurement: Journal of the International Measurement Confederation*, 223, 113787. <https://doi.org/10.1016/j.measurement.2023.113787>

YAMAN, K.; TEKİNER, Z. Investigating the effect of built-up edge on chip morphology at the cutting edge during turning operation. *Politeknik Dergisi*, v. 27, n. 6, p. 2325-2333, 2024. DOI: 10.2339/politeknik.1432815.

YANG, Hui; MEI, Xuesong; JIANG, Gedong; TAO, Tao; PEI, Changyu; MA, Ziwei. Milling tool wear state recognition by vibration signal using a stacked generalization ensemble model. *Shock and Vibration*, 2019. Disponível em: <https://doi.org/10.1155/2019/7386523>.

YIN, F. *Exploring Explainability in Large Language Models. Preprints*, 2025.

Zabala, J. G., Melgar, A., Alkorta, J., Chinesta, F., Arrue, I., & Alvarez, A. (2023). A machine learning approach to predict residual stresses generated in the orthogonal cutting process of Inconel 718. *Materials*, 16(1). <https://doi.org/10.3390/ma16010187>

Zhou, M.; Zhang, Z.; Liu, J.; Li, J.; Liu, X. Multi-source information fusion in tool wear condition monitoring based on deep learning model. *Journal of Manufacturing Processes*, 57, 86-95. Disponível em: <https://doi.org/10.1016/j.jmapro.2020.05.005>.

Zhou, Y., Liu, C., Yu, X., Liu, B., & Quan, Y. (2022). Tool wear mechanism, monitoring and remaining useful life (RUL) technology based on big data: a review. *SN Applied Sciences*, 4(8). <https://doi.org/10.1007/s42452-022-05114-9>