

PREVISÃO INTELIGENTE DAS FORÇAS DE CORTE E DA RUGOSIDADE SUPERFICIAL NA USINAGEM DA LIGA TI-6AL-4V: ANÁLISE COMPARATIVA ENTRE MODELOS DE APRENDIZADO DE MÁQUINA E GRANDES MODELOS DE LINGUAGEM (LLMS)

Alex Fernandes de Souza – alex_fernandes1989@live.com
Pedro Paulo Balestrassi – pedro@unifei.edu.br

Palavras-chave: Ti-6Al-4V, Usinagem, Aprendizado de máquina, ChatGPT.

1. INTRODUÇÃO

Nas últimas décadas, o avanço das tecnologias digitais e da inteligência artificial tem transformado profundamente o campo da engenharia de manufatura. Entre os processos produtivos, a usinagem de ligas metálicas de alto desempenho, como o titânio Ti-6Al-4V, destaca-se por sua ampla aplicação nas indústrias aeroespacial, biomédica e automotiva. Contudo, o controle preciso de variáveis como a força de corte e a rugosidade superficial ainda representa um desafio técnico, devido à natureza complexa e não linear das interações entre parâmetros de corte, ferramenta e material.

Paralelamente, o desenvolvimento de modelos de machine learning e, mais recentemente, de large language models (LLMs), abriu novas possibilidades para a previsão e otimização de processos industriais. Essas tecnologias permitem analisar grandes volumes de dados experimentais, identificar padrões e gerar estimativas com elevado grau de precisão, contribuindo para a eficiência operacional e a redução de custos.

Nesse contexto, o presente estudo tem como objetivo comparar o desempenho de modelos tradicionais de aprendizado de máquina, como Random Forest, XGBoost, SVR e Redes Neurais Artificiais, com modelos de linguagem natural da série GPT, na predição das forças de corte e da rugosidade superficial durante a usinagem da liga Ti-6Al-4V. A pesquisa busca verificar a viabilidade do uso de modelos baseados em linguagem como alternativa acessível e eficaz para previsões técnicas em engenharia

de produção, ampliando o alcance das ferramentas inteligentes no ambiente industrial.

2. REFERENCIAL TEÓRICO

A usinagem de ligas metálicas avançadas, como a Ti-6Al-4V, permanece central em setores aeroespacial e biomédico, mas impõe desafios recorrentes de controle da força de corte (F_c) e da rugosidade superficial (R_a) devido à baixa condutividade térmica, à reatividade e às interações não lineares entre velocidade, avanço e profundidade de corte. Esses fatores dificultam modelos analíticos fechados e reforçam a demanda por abordagens preditivas baseadas em dados para otimização de processo e qualidade dimensional. (Chua et al., 2021)

Nesse contexto, técnicas de aprendizado de máquina têm ganhado destaque por lidar bem com relações complexas e dados ruidosos. Em manufatura, estudos recentes reportam bons resultados de XGBoost, Random Forest, SVR e redes neurais na previsão de desempenho e respostas de usinagem; além disso, florestas oferecem medidas de importância de variáveis úteis à engenharia e à análise de sensibilidade, enquanto SVR e variantes robustas elevam a resiliência a ruídos e outliers. (Al Bukhari; Pervaiz, 2025; Antoniadis; Lambert-Lacroix; Poggi, 2021; Desmond Kofi, 2021; Akhtar; Tanveer; Arshad, 2024)

Paralelamente, a maturidade de modelos de linguagem de grande porte (LLMs) tem ampliado possibilidades para tarefas quantitativas guiadas por *prompts*, reduzindo barreiras de adoção para equipes sem forte base em programação. Embora concebidos para linguagem natural, LLMs vêm sendo explorados como motores de inferência em cenários técnicos, exigindo avaliação rigorosa de acurácia, robustez e vieses antes da integração a rotinas industriais — especialmente em processos sensíveis como a usinagem de Ti-6Al-4V. (Dhillon; Metcalf; Hooper, 2025)

2.2 Metodologia

A metodologia adotada baseou-se na Metodologia de Superfície de Resposta (RSM), utilizando um Delineamento Composto Central (CCD) com 19 ensaios para analisar o efeito da velocidade de corte, avanço por dente e profundidade de corte sobre a rugosidade superficial (R_a) e a força de corte (F_c) na usinagem da liga Ti-6Al-

4V. As operações foram conduzidas em torno CNC sob condições a seco, mantendo ferramenta, material e setup constantes. Os dados coletados foram submetidos a análise estatística exploratória, incluindo medidas descritivas, teste de normalidade de Shapiro-Wilk e correlação de Pearson, a fim de identificar padrões e verificar a consistência experimental.

Na etapa de modelagem, foram aplicados algoritmos de aprendizado de máquina (Random Forest, SVR, MLP e XGBoost), com divisão dos dados em 70% para treino e 30% para teste, além de validação cruzada 10-fold e normalização das variáveis. Em paralelo, os modelos GPT-5 e GPT-5 Thinking foram avaliados em modo *zero-shot* e *few-shot* por meio de *prompts* estruturados para prever Ra e Fc sem necessidade de programação. O desempenho foi comparado utilizando métricas como MAE, RMSE, R^2 e MAPE, complementadas por análises gráficas de resíduos, assegurando a confiabilidade e a robustez das previsões obtidas.

3. RESULTADOS E DISCUSSÃO

Os resultados da pesquisa demonstraram excelente desempenho dos modelos de aprendizado de máquina na previsão da força de corte (Fc) e da rugosidade superficial (Ra) durante a usinagem da liga Ti-6Al-4V. Para o raio de ferramenta de 0,8 mm, todos os modelos apresentaram alta precisão, com destaque para o Random Forest e o XGBoost, que obtiveram erros médios absolutos (MAE) entre 0,7 e 0,9, RMSE entre 1,0 e 1,5 e coeficiente de determinação (R^2) acima de 0,99. O modelo MLP também apresentou bom desempenho (MAE = 1,23; R^2 = 0,99), enquanto o SVR atingiu precisão razoável (R^2 = 0,97), mostrando-se sensível a variações menores nas condições experimentais.

No entanto, para o raio de 0,4 mm, observou-se queda significativa no desempenho preditivo. O modelo SVR apresentou falha de generalização, com R^2 negativo e MAPE superior a 22%, enquanto o MLP obteve MAE = 4,75 e $R^2 \approx 0,07$, revelando baixa robustez nesse regime de corte. Ainda assim, os métodos Random Forest e XGBoost mantiveram resultados mais estáveis, com R^2 variando entre 0,47 e 0,70, o que confirmou sua maior consistência entre diferentes condições operacionais e reforçou sua adequação para ambientes com maior previsibilidade.

Os testes realizados com o GPT-5 revelaram desempenho surpreendentemente alto, superando as expectativas iniciais quanto à aplicação de modelos de linguagem em tarefas numéricas. O modelo apresentou $MAE = 0,20$, $RMSE = 0,26$, $MAPE$ inferior a 1% e $R^2 = 0,998$ para o raio de 0,4 mm, além de $R^2 = 0,984$ para 0,8 mm, reproduzindo quase integralmente a variabilidade dos dados experimentais. Esses resultados demonstram que, quando bem estruturado e conduzido com *prompts* adequados, o GPT-5 pode competir diretamente com algoritmos tradicionais de aprendizado de máquina, ampliando o potencial de uso de modelos de linguagem de grande porte (LLMs) em aplicações técnicas de engenharia e manufatura.

4. CONSIDERAÇÕES FINAIS

Com base nos resultados obtidos, conclui-se que os modelos de aprendizado de máquina, especialmente o Random Forest e o XGBoost, apresentaram desempenho superior e consistente na previsão da força de corte (F_c) e da rugosidade superficial (R_a) na usinagem da liga Ti-6Al-4V, destacando-se por sua capacidade de generalização e estabilidade sob diferentes condições operacionais. No entanto, o desempenho excepcional do GPT-5, com elevados coeficientes de determinação e baixos índices de erro, demonstrou o potencial dos modelos de linguagem de grande porte (LLMs) como ferramentas viáveis para aplicações quantitativas em engenharia. Assim, o estudo evidencia que a integração entre ML e IA generativa representa um caminho promissor para o desenvolvimento de sistemas inteligentes de predição e otimização em processos de manufatura avançada, alinhados aos princípios da Indústria 4.0.

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio concedido ao desenvolvimento desta pesquisa, fundamental para a execução das etapas experimentais e analíticas do estudo.

REFERÊNCIAS

AKHTAR, Mushir; TANVEER, M.; ARSHAD, Mohd. **HawkEye: advancing robust regression with bounded, smooth, and insensitive loss function**. arXiv, [S. l.], 15 fev. 2024. Disponível em: <https://doi.org/10.48550/arXiv.2401.16785>. Acesso em: 24 jul. 2025.

AL BUKHARI, Sabrina; PERVAIZ, Salman. Advanced Machine Learning Approaches for Predicting Machining Performance in Orthogonal Cutting Process. **Lubricants**, v. 13, n. 2, p. 83, 2025. Disponível em: <https://doi.org/10.3390/lubricants13020083>. Acesso em: 12 ago. 2025.

ANTONIADIS, Anestis; LAMBERT-LACROIX, Sophie; POGGI, Jean-Michel. Random forests for global sensitivity analysis: a selective review. **Reliability Engineering & System Safety**, v. 206, p. 107312, fev. 2021. Disponível em: <https://doi.org/10.1016/j.res.2020.107312>. Acesso em: 30 jun. 2025.

CHUA, Guang Yuan et al. Drilling of titanium alloy (Ti6Al4V) – a review. **Machining Science and Technology: An International Journal**, v. 25, n. 4, p. 637–702, 2021. Disponível em: <https://doi.org/10.1080/10910344.2021.1925295>. Acesso em: 27 jul. 2025.

DESMOND, Kofi. Application of machine learning in predicting construction project profit in Ghana using Support Vector Regression Algorithm (SVRA). **Engineering, Construction and Architectural Management**, v. 28, n. 5, p. 1491–1514, 2021. Disponível em: <https://doi.org/10.1108/ECAM-08-2020-0618>. Acesso em: 26 jul. 2025.

DHILLON, Vikram; METCALF, David; HOOPER, Max. Building Up to Large Language Models (LLMs). In: _____. **AI Frameworks Enabled by Blockchain**. Berkeley, CA: Apress, 2025. p. 53–87. Disponível em: https://doi.org/10.1007/979-8-8688-1402-0_2. Acesso em: 04 ago. 2025.