

Universidade de Pernambuco

Programa de Pós-Graduação em Engenharia da Computação (PPGEC)

Proposta de Dissertação de Mestrado

Área: **Computação Inteligente**

Título: Aprendizado Autossupervisionado e Explicável para Monitoramento Inteligente da Condição de Ferramentas em Processos de Usinagem

Orientador – Leandro Honorato de Souza Silva (leandro.ssilva@upe.br)

Coorientador - Francisco Augusto Vieira da Silva (francisco.vieira@ifpb.edu.br)

Resumo

O monitoramento da condição de ferramentas de corte constitui um dos principais desafios da manufatura moderna, uma vez que o desgaste progressivo da ferramenta afeta diretamente a qualidade das peças produzidas, a produtividade dos processos e os custos operacionais. Nesse contexto, os sistemas de Monitoramento da Condição da Ferramenta (*Tool Condition Monitoring – TCM*) vêm sendo amplamente investigados como componentes fundamentais da manufatura inteligente (BYRNE et al., 1995; TETI et al., 2010). Entre os diversos sinais utilizados para esse monitoramento, as forças de corte destacam-se por sua forte correlação com os mecanismos de desgaste e pela viabilidade de aquisição em ambientes industriais (TETI et al., 2022). Embora técnicas de aprendizado de máquina apresentem resultados promissores para classificação da condição da ferramenta, sua aplicação ainda enfrenta desafios relacionados à necessidade de grandes volumes de dados rotulados e à limitada interpretabilidade dos modelos (GOUARIR et al., 2018; PENG et al., 2019).

Diante desse cenário, este projeto tem como objetivo desenvolver e validar uma metodologia baseada em Aprendizado Autossupervisionado (*Self-Supervised Learning – SSL*) e Inteligência Artificial Explicável (*Explainable Artificial Intelligence – XAI*) para o monitoramento inteligente da condição de ferramentas de corte a partir de séries temporais multivariadas de força. Parte-se das hipóteses de que representações aprendidas por técnicas autossupervisionadas podem reduzir a dependência de dados rotulados e que métodos de XAI podem fornecer interpretações consistentes dos padrões utilizados pelos modelos para tomada de decisão.

A pesquisa será conduzida a partir de experimentos de torneamento do aço AISI 1020 realizados em um torno CNC Logic 195 III equipado com controlador FANUC 0iTF Plus Type 3. As forças de corte serão adquiridas por meio de um dinamômetro piezométrico multicomponente Kistler 9119AA2, responsável pela medição simultânea das componentes F_x , F_y e F_z . Diferentes condições de desgaste e avarias da ferramenta serão induzidas e documentadas por meio de inspeções ópticas e medições de referência, possibilitando a construção de uma base de dados rotulada.

Os sinais adquiridos serão submetidos a etapas de pré-processamento e posteriormente utilizados para treinamento de modelos autossupervisionados de aprendizado de representações. As representações aprendidas serão avaliadas em tarefas de classificação da condição da ferramenta e comparadas com abordagens tradicionais baseadas em atributos estatísticos e espectrais extraídos manualmente. Por fim, técnicas de Inteligência Artificial Explicável, como SHAP, serão empregadas para identificar quais características dos sinais influenciam as decisões dos modelos, permitindo relacionar os resultados computacionais aos mecanismos físicos de degradação observados experimentalmente. Espera-se como resultado o desenvolvimento de uma metodologia robusta e interpretável para monitoramento inteligente da condição de

ferramentas, contribuindo para aplicações de manutenção preditiva e manufatura avançada alinhadas aos princípios da Indústria 4.0.

Referências Bibliográficas

BYRNE, G. et al. Tool condition monitoring (TCM): the status of research and industrial application. *CIRP Annals*, v. 44, n. 2, p. 541–567, 1995.

ELDELE, E. et al. Time-series representation learning via temporal and contextual contrasting. In: *Proceedings of the International Joint Conference on Artificial Intelligence*. Montreal: IJCAI, 2021. p. 2352–2359.

FU, Y. et al. Analysis of feature extracting ability for cutting state monitoring using deep belief networks. *Procedia CIRP*, v. 31, p. 29–34, 2015.

GOUARIR, A. et al. In-process tool wear prediction system based on machine learning techniques and force analysis. *Procedia CIRP*, v. 77, p. 501–504, 2018.

MOLINA-CORREA, J. A.; MORALES-MENÉNDEZ, R.; RAMÍREZ-MENDOZA, R. A review of explainable artificial intelligence methods and applications in manufacturing systems. *SN Applied Sciences*, v. 7, 2025.

PAPAGEORGIOU, X.; D'ADDONA, D. M.; TETI, R. Explainable AI for tool condition monitoring using explainable boosting machines. *Procedia CIRP*, v. 133, p. 662–667, 2025.

PENG, B. et al. A hybrid approach using machine learning to predict the cutting forces under consideration of the tool wear. *Procedia CIRP*, v. 82, p. 302–307, 2019.

TETI, R. et al. Advanced monitoring of machining operations. *CIRP Annals – Manufacturing Technology*, v. 59, n. 2, p. 717–739, 2010.

TETI, R. et al. Process monitoring of machining. *CIRP Annals*, v. 71, n. 2, p. 529–552, 2022.

WOO, G. et al. CoST: contrastive learning of disentangled seasonal-trend representations for time series forecasting. In: *International Conference on Learning Representations*. Kigali: ICLR, 2022.