

Universidade de Pernambuco

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

Proposta de Dissertação de Mestrado

Área: **Computação Inteligente**

Título: **Aprendizado Federado para Otimização de Processos de Usinagem**

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

Resumo

Considerando as crescentes demandas de qualidade superficial e produtividade nas indústrias automotiva, aeroespacial e de manufatura em geral, a otimização dos processos de usinagem torna-se imprescindível para controlar desvios finos de forma, que afetam diretamente a performance e a vida útil dos componentes e máquinas [1], [2]. Ademais, a troca prematura ou tardia de ferramentas representa cerca de 20% dos tempos de parada de máquinas, elevando significativamente os custos operacionais e reduzindo o OEE (*Overall Equipment Effectiveness*) [3]. Embora técnicas convencionais de aprendizado de máquina demonstrem eficácia na predição de parâmetros críticos, como forças de corte, desgaste de ferramenta e consumo de energia, elas ainda dependem de grandes volumes de dados centralizados e são sensíveis à heterogeneidade dos ambientes de usinagem [4].

Nesse contexto, o Aprendizado Federado emerge como uma solução capaz de agregar conhecimento distribuído entre múltiplas máquinas CNC ou plantas de produção, preservando a privacidade dos dados e promovendo modelos colaborativos que não apenas elevam a eficiência e prolongam a vida útil das ferramentas, mas também reduzem a carga de trabalho mental dos operadores e reforçam a confiabilidade das operações de usinagem [4], [5], [6], [7].

O aprendizado federado surgiu recentemente como uma abordagem que possibilita o ajuste de modelos de aprendizagem de máquina a partir de bases de dados dispersas e descentralizadas, sem que seja necessário compartilhar diretamente as informações brutas entre os participantes [5], [8]. Dessa forma, diferentes agentes geograficamente distribuídos podem cooperar no treinamento de um modelo inteligente, mantendo seus dados locais intactos. Entre seus principais benefícios, destaca-se a preservação de privacidade: os dados permanecem em seus dispositivos originais, garantindo maior segurança e confidencialidade. Além disso, ao aproveitar o poder computacional dos próprios nós finais, reduz-se substancialmente a carga sobre o servidor central. Outro ponto relevante é o caráter colaborativo dessa técnica, que permite a construção conjunta de conhecimento sem expor dados sensíveis [6].

Diante desse contexto, este trabalho propõe o desenvolvimento e avaliação de um framework de Aprendizado Federado especificamente voltado à otimização de processos de usinagem em ambientes industriais heterogêneos. A ideia central é permitir que múltiplas máquinas CNC colaborem no treinamento de modelos capazes de prever o desgaste de ferramentas e a qualidade superficial das peças, sem a necessidade de transferir dados brutos para um servidor central, assegurando tanto a privacidade quanto a segurança das informações de cada unidade produtiva. Para isso, serão adaptadas e avaliadas estratégias de agregação federada, balanceamento de carga e tolerância a falhas, além de técnicas para lidar com a diversidade dos dados gerados em diferentes máquinas e condições de operação. Espera-se, com isso, aumentar o OEE e reduzir custos associados a trocas inadequadas de ferramentas, contribuindo para a adoção de soluções de inteligência distribuída na usinagem avançada.

Referências Bibliográficas

[1] F. Aggogeri, N. Pellegrini, and F. L. Tagliani, "Recent advances on machine learning applications in machining processes," Sep. 01, 2021, MDPI. doi: 10.3390/app11188764.

- [2] A. Gouarir, G. Martínez-Arellano, G. Terrazas, P. Benardos, and S. Ratchev, "In-process tool wear prediction system based on machine learning techniques and force analysis," in *Procedia CIRP*, Elsevier B.V., 2018, pp. 501–504. doi: 10.1016/j.procir.2018.08.253.
- [3] H. C. Möhring, S. Eschelbacher, and P. Georgi, "Machine learning approaches for real-time monitoring and evaluation of surface roughness using a sensory milling tool," in *Procedia CIRP*, Elsevier B.V., 2021, pp. 264–269. doi: 10.1016/j.procir.2021.09.045.
- [4] I. S. Kaleli, P. Unal, B. U. Deveci, O. Albayrak, and A. M. Ozbayoglu, "A Domain-Aware Federated Learning Study for CNC Tool Wear Estimation," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Science and Business Media Deutschland GmbH, 2024, pp. 250–265. doi: 10.1007/978-3-031-68005-2_18.
- [5] T. Zhang, Z. He, and R. B. Lee, "Privacy-preserving Machine Learning through Data Obfuscation," Jul. 2018, [Online]. Available: <http://arxiv.org/abs/1807.01860>
- [6] M. Aledhari, R. Razzak, R. M. Parizi, and F. Saeed, "Federated Learning: A Survey on Enabling Technologies, Protocols, and Applications," 2020, Institute of Electrical and Electronics Engineers Inc. doi: 10.1109/ACCESS.2020.3013541.
- [7] Abhishek V A, Binny S, Johan T R, Nithin Raj, and Vishal Thomas, "Federated Learning: Collaborative Machine Learning without Centralized Training Data," *international journal of engineering technology and management sciences*, pp. 355–359, Sep. 2022, doi: 10.46647/ijetms.2022.v06i05.052.
- [8] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y Arcas, "Communication-Efficient Learning of Deep Networks from Decentralized Data," Feb. 2016, [Online]. Available: <http://arxiv.org/abs/1602.05629>.