

# Predição Inteligente na Indústria com Processamento de Borda

André Correia<sup>1</sup>, Mateus Passos<sup>1</sup>, Dhyonatan Freitas<sup>2</sup>, Tathiana Duarte<sup>2</sup>, Maurício Pillon<sup>1</sup>

<sup>1</sup>Laboratório de Processamento Paralelo e Distribuído (LABP2D)

Universidade do Estado de Santa Catarina (UDESC/CCT)

<sup>2</sup>Centro Universitário SENAI Santa Catarina (UniSENAI)

{andre.lcf, mateus.passos1605}@edu.udesc.br,

{dhyonatan.freitas, tathiana.amarante}@edu.sc.senai.br,

mauricio.pillon@udesc.br

**Resumo.** O ecossistema tecnológico da indústria 4.0 depende de decisões assertivas e autônomas. A coleta e processamento de dados em ambientes críticos são essenciais para manter a segurança e a qualidade da produção. A inteligência artificial (IA) e o processamento na borda são aliados na busca de bons resultados neste ecossistema de produção. Este trabalho apresenta a aplicação de modelos preditivos de IA em um ambiente real no contexto da Indústria 4.0 com processamento na borda e análise computacional. Os resultados preliminares demonstram a viabilidade de processamento destes modelos em dispositivos localizados na borda.

## 1. Introdução

A Indústria 4.0 tem impulsionado avanços significativos em automação, conectividade e inteligência operacional, redefinindo a forma como fábricas e processos industriais operam [Santos et al. 2018]. Nesse contexto, um dos desafios centrais é o monitoramento contínuo e instantâneo dos equipamentos, essencial para garantir eficiência, segurança, flexibilidade e viabilizar estratégias de manutenção inteligente.

A integração de Internet das Coisas (IoT) com tecnologias de computação em borda, como a Edge-AI, tem se destacado como uma solução promissora para esse desafio. Esse modelo permite o processamento descentralizado dos dados diretamente nos dispositivos de borda, reduzindo a latência e minimizando a dependência de infraestrutura em nuvem [Li et al. 2019]. Como resultado, as operações industriais tornam-se mais ágeis, eficientes e resilientes [Hesse et al. 2019].

Este trabalho investiga a aplicação de tecnologias da Indústria 4.0 em um laboratório de usina-gem, no qual máquinas rotativas com sensores monitoram vibração e temperatura. A proposta avalia a capacidade dos dispositivos de borda em processar e interpretar dados localmente, permitindo a inferência do estado operacional das máquinas. O objetivo é verificar a viabilidade da manutenção preditiva sem dependência contínua da nuvem, reduzindo a latência e aprimorando a eficiência na tomada de decisão.

## 2. Indústria 4.0

A Indústria 4.0 representa a atual revolução na manufatura, caracterizada pela integração de tecnologias digitais como IoT, computação em nuvem, análise de *Big Data* e Inteligência Artificial (IA) para otimizar processos, aumentar a eficiência e promover a personalização em massa [Li et al. 2017]. A aplicação de modelos preditivos, impulsionados pela IA, desempenha um papel crucial nesse cenário, permitindo a antecipação de falhas, a otimização da manutenção e a melhoria da tomada de decisões em tempo real [Zhang et al. 2017].

No contexto do monitoramento do parque fabril, foco deste trabalho, essas ferramentas viabilizam a análise instantânea do funcionamento das máquinas, identificando padrões operacionais e antecipando possíveis falhas [Lee et al. 2015]. Além de classificar estados básicos, como ligado ou desligado, os modelos de IA possibilitam a previsão do tempo de uso futuro dos equipamentos, contribuindo para a manutenção preditiva e a gestão eficiente dos ativos industriais [Carvalho et al. 2019]. Essa abordagem pode reduzir paradas não planejadas, otimizar o consumo energético e melhorar a tomada de decisão, promovendo maior confiabilidade e desempenho operacional [Wang et al. 2016].

### 3. Análise Experimental e Ambiente de Testes

A presente investigação é conduzida em um laboratório de usinagem inserido no contexto da Indústria 4.0, localizado na unidade do SENAI em Joinville/SC. Esse ambiente dispõe de uma infraestrutura composta por sensores instalados em tornos mecânicos, máquinas CNC e fresadoras, todos situados em um mesmo galpão. A camada de conectividade é estruturada por um dispositivo *gateway* responsável pela agregação dos sinais provenientes dos sensores e pelo encaminhamento dos dados a uma plataforma web destinada à gestão dos ativos industriais.

Na camada de processamento em borda, o sistema é composto pelo hardware de um Raspberry Pi 4 Model B, equipado com processador quad-core Cortex-A72 de 64 bits, 1.5 GHz, 8 GB de RAM, conectividade sem fio nas frequências de 2.4 GHz e 5.0 GHz, Gigabit Ethernet, Bluetooth 5.0 e executando o sistema operacional Raspberry Pi OS Bookworm, baseado no Debian 12, além de sensores WEGScan101, capazes de capturar parâmetros de vibração e temperatura das máquinas [WEG 2024].

A abordagem proposta neste estudo visa avaliar a capacidade dos dispositivos de borda em processar e interpretar localmente os dados adquiridos pelos sensores, possibilitando a inferência do estado operacional das máquinas e a identificação dos períodos de funcionamento. A investigação busca verificar a viabilidade da implementação de estratégias de manutenção preditiva sem a necessidade de envio contínuo de dados à plataforma web, reduzindo a latência no fluxo de informações e aprimorando a eficiência na tomada de decisão.

#### 3.1. Plano de Testes

O plano de testes consiste em treinar e avaliar modelos de aprendizado de máquina supervisionados para identificar o estado operacional das máquinas e determinar os períodos de funcionamento. O conjunto de dados foi coletado ao longo de cinco meses, permitindo uma análise detalhada da dinâmica operacional do ambiente. Além disso, esta investigação busca avaliar o impacto no consumo de recursos computacionais, como CPU e memória, para determinar se os dispositivos de borda são capazes de sustentar o processamento dos dados sem depender da plataforma web.

Os dados foram obtidos por meio da plataforma *WEGNOLOGY Motion Fleet Management* (MFM), utilizando sensores WEGScan acoplados às máquinas rotativas do ambiente. Coletados a cada cinco minutos, entre setembro de 2024 e fevereiro de 2025, os dados incluem as seguintes variáveis: Temperatura, Aceleração Vertical, Aceleração Horizontal, Aceleração Axial, Velocidade Vertical, Velocidade Horizontal, Velocidade Axial, Frequência, Rotação, Conexão e Status, totalizando 11.305 amostras. Para avaliar os modelos de IA, foi utilizada a linguagem de programação Python na versão 3.10 com as bibliotecas do pacote *scikit-learn* [Pedregosa et al. 2011]. Além disso, os dados foram divididos em três conjuntos: treinamento (70%), teste (20%) e validação (10%). O objetivo desta divisão é avaliar se após o treinamento os modelos são capazes de identificar o status atual das máquinas, observando os dados coletados pelo sensor WEGScan.

### 3.2. Resultados Preliminares

Os resultados deste estudo estão organizados em dois eixos principais: (i) a avaliação dos modelos de IA na identificação do estado operacional das máquinas em ambiente de teste, utilizando dados de vibração, temperatura e rotação; e (ii) a análise da capacidade dos dispositivos de borda em processar a carga computacional demandada pelos modelos de IA.

A aferição do desempenho dos modelos foi conduzida por meio das métricas de acurácia, precisão, *recall* e *F1-score* [Sokolova and Lapalme 2009], considerando os conjuntos de treinamento e teste. Essa abordagem possibilita uma análise comparativa entre os modelos, sobretudo em cenários em que os dados ainda não foram previamente observados. A Tabela 1(a) apresenta os resultados obtidos pelos modelos de IA na etapa de treinamento [Powers 2020].

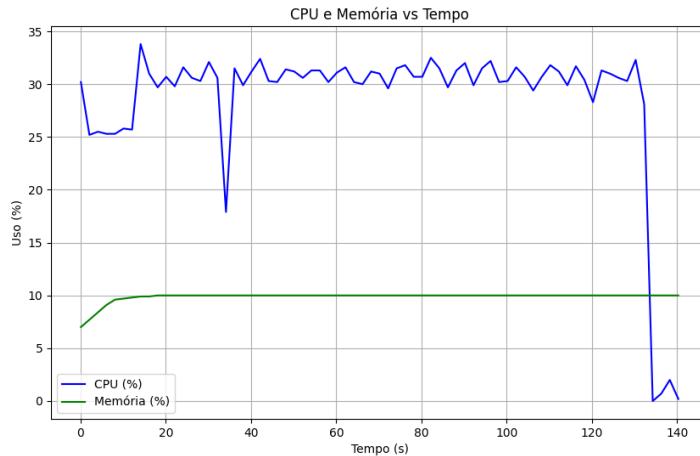
**Tabela 1. Resultados Edge-AI: (a) Treinamento; (b) Validação. Fonte: Autores.**

Treinamento dos modelos de IA					Validação dos modelos de IA			
Modelo de IA	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)	Matriz de Confusão			
					VP	VN	FP	FN
Regressão Logística	99.38	99.37	99.38	99.36	1089	6	35	1
Random Forest	100	100	100	100	1095	0	36	0
Redes Neurais	99.82	99.82	99.82	99.82	1094	1	35	1

Os resultados da validação (Tabela 1(b)), cujo objetivo é classificar automaticamente o estado operacional das máquinas (ligadas ou desligadas), foram analisados por meio de uma matriz de confusão, que permite avaliar a precisão das previsões [Fawcett 2006]. Observou-se que o modelo Random Forest apresentou o melhor desempenho, seguido pelas redes neurais e, por último, pela regressão logística. Esses resultados podem ser explicados pela natureza dos modelos em relação à estrutura dos dados. A regressão logística, por ser um modelo linear, apresenta bom desempenho quando há uma separação linear clara entre as classes, mas pode ter dificuldades em capturar padrões mais complexos. Já as redes neurais, devido à sua capacidade de modelar relações não lineares, demonstraram desempenho superior a Regressão Logística. No entanto, o Random Forest superou os demais modelos, possivelmente por sua robustez na análise de dados tabulares e por sua eficiência na captura de interações entre variáveis, características essenciais quando se trabalha com dados provenientes de sensores, nas quais variações sutis em vibração, temperatura e rotação podem indicar mudanças no estado da máquina.

A segunda etapa da análise de resultados concentra-se na avaliação da capacidade dos dispositivos de borda em processar a carga computacional imposta pelos modelos de IA, com foco no consumo de CPU e memória. Essa investigação busca verificar a viabilidade da execução dos modelos em um ambiente descentralizado, garantindo que os dispositivos operem dentro de limites aceitáveis de uso de recursos. A Figura 1 ilustra a evolução temporal do consumo percentual médio de CPU e memória ao longo do intervalo necessário para o treinamento e a avaliação dos modelos. Observa-se que, após uma breve fase transiente, o uso de memória estabiliza em torno de 10%, enquanto o consumo de CPU apresenta variações, oscilando em torno de 30%.

Esses resultados indicam que o dispositivo de borda utilizado demonstrou capacidade suficiente para suportar a execução dos modelos de IA nas etapas de treinamento, avaliação e predição. A estabilização do uso de memória sugere que há margem para a execução de processos adicionais sem comprometer o desempenho do sistema. Embora o consumo de CPU tenha apresentado oscilações, esse nível de utilização está dentro de um intervalo aceitável para operações contínuas, sem risco iminente de sobrecarga.



**Figura 1. Consumo percentual médio de CPU e memória. Fonte: Autores.**

#### 4. Considerações Finais e Trabalhos Futuros

Este estudo confirmou a viabilidade da computação em borda para manutenção preditiva na Indústria 4.0, reduzindo a latência e otimizando a tomada de decisão. O modelo Random Forest destacou-se na classificação do estado operacional das máquinas, e a análise computacional mostrou que o dispositivo de borda suportou os modelos de IA sem sobrecarga, garantindo eficiência operacional. A descentralização do processamento reduziu a dependência da nuvem, tornando o sistema mais autônomo e resiliente, o que é essencial em ambientes industriais com conectividade intermitente.

Como trabalhos futuros, propõe-se implementar testes mais robustos em um ambiente fabril real, incorporar um sistema distribuído para otimizar o processamento e explorar estratégias de segurança para proteger os dados industriais.

#### Agradecimentos

Este trabalho conta com o apoio da Universidade do Estado de Santa Catarina (UDESC) e do Centro Universitário SENAI Santa Catarina (UniSENAI), sendo desenvolvido no Laboratório de Processamento Paralelo e Distribuído (LabP2D) em colaboração com a WEG S.A. (WEG).

#### Referências

- [Carvalho et al. 2019] Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. d. P., Basto, J. P., and Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137:106024.
- [Fawcett 2006] Fawcett, T. (2006). An introduction to roc analysis. *Pattern recognition letters*, 27(8):861–874.
- [Hesse et al. 2019] Hesse, G., Matthies, C., Sinzig, W., and Uflacker, M. (2019). Adding value by combining business and sensor data: An industry 4.0 use case. In *International Conference on Database Systems for Advanced Applications*, pages 528–532. Springer.
- [Lee et al. 2015] Lee, J., Bagheri, B., and Kao, H.-A. (2015). A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing letters*, 3:18–23.
- [Li et al. 2017] Li, D., Yang, B., Xu, L., Cai, X., Ren, Z., and Xie, J. (2017). Industry 4.0: Current status and future trends. *Sensors*, 17(12):2891.
- [Li et al. 2019] Li, E., Zeng, L., Zhou, Z., and Chen, X. (2019). Edge ai: On-demand accelerating deep neural network inference via edge computing. *IEEE Transactions on Wireless Communications*, 19(1):447–457.
- [Pedregosa et al. 2011] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12:2825–2830.
- [Powers 2020] Powers, D. M. (2020). Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. *arXiv preprint arXiv:2010.16061*.
- [Santos et al. 2018] Santos, B. P., Alberto, A., Lima, T. D. F. M., and Charrua-Santos, F. M. B. (2018). Indústria 4.0: desafios e oportunidades. *Revista Produção e Desenvolvimento*, 4(1):111–124.
- [Sokolova and Lapalme 2009] Sokolova, M. and Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4):427–437.
- [Wang et al. 2016] Wang, S., Wan, J., Zhang, D., Li, D., and Zhang, C. (2016). Towards smart factory for industry 4.0: a self-organized multi-agent system with big data based feedback and coordination. *Computer networks*, 101:158–168.
- [WEG 2024] WEG (2024). Weg catalogue.
- [Zhang et al. 2017] Zhang, T., Zhao, L., Zhou, C., Wang, H., Li, G., and Xie, S. (2017). Industry 4.0 and smart manufacturing: A review on research issues and application. *IEEE Access*, 12(5):4–13.