

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

**Proposta de Dissertação de Mestrado**

**Áreas: Inteligência Computacional**

**Título: Modelo de Digital Twin baseado em Deep Learning para detecção de anomalias em séries temporais multivariadas de sensores**

**Orientador: Sérgio Murilo Maciel Fernandes (sergio.fernandes@upe.br)**

**Descrição** – Digital Twin, ou gêmeo digital, consiste em uma instanciação computacional dinâmica de um ativo, processo ou sistema físico, sustentada por modelos digitais, fluxos de dados, mecanismos de sincronização e inferência ao longo de seu ciclo de vida [1], [2]. Em sistemas instrumentalizados por sensores, essa representação incorpora séries temporais multivariadas capazes de expressar a evolução conjunta de variáveis operacionais, condições de funcionamento e padrões de degradação. Nessa perspectiva, o Digital Twin atua como modelo computacional orientado por dados, com atualização contínua do estado digital do ativo e suporte à decisão em contextos de monitoramento inteligente [3].

A detecção de anomalias em séries temporais multivariadas constitui um problema relevante em sistemas físicos monitorados, pois desvios operacionais emergem de dependências temporais, correlações entre sensores, regimes variáveis de operação e processos graduais de degradação [4]. Métodos baseados em limiares fixos, regras manuais ou modelos estatísticos simplificados apresentam restrições diante da não linearidade, alta dimensionalidade e variabilidade operacional desses dados. Modelos de Deep Learning permitem aprender representações latentes do comportamento normal, capturar dependências temporais e estimar desvios por reconstrução, previsão ou modelagem sequencial [4], [5].

Este projeto propõe desenvolver um modelo de Digital Twin baseado em Deep Learning para detecção de anomalias em séries temporais multivariadas de sensores. O modelo deverá processar janelas temporais de dados operacionais, extrair relações temporais e interdependências entre variáveis, produzir escores de anomalia e atualizar a condição digital do ativo. Serão investigadas arquiteturas como Autoencoders, LSTM Autoencoders, GRU Autoencoders e redes convolucionais temporais, considerando sua capacidade de representar padrões normais, identificar desvios progressivos e apoiar diagnóstico operacional [4], [5].

A validação experimental será conduzida com uma base pública de degradação de motores turbofan, como o NASA C-MAPSS, tratada como fonte de dados para treinamento e teste do modelo. Cada motor será representado como uma instância temporal do ativo físico, enquanto as leituras dos sensores formarão a entrada multivariada do Digital Twin. A partir dessas séries, serão construídas janelas de treinamento, validação e teste, com representação do estado digital em níveis operacionais, como normal, atenção, anômalo e crítico. Essa estratégia é aderente a estudos recentes nos quais Digital Twins e aprendizado profundo são empregados para detecção de anomalias e suporte ao monitoramento de ativos industriais [6].

A avaliação do modelo será realizada por métricas quantitativas, incluindo precision, recall, F1-score, AUC, taxa de falso alarme, erro de reconstrução e atraso de detecção. Também serão analisados aspectos de interpretabilidade operacional, como contribuição relativa dos sensores e evolução temporal do escore de anomalia. Espera-se obter um modelo computacional capaz de integrar dados sensoriais, aprendizado profundo e atualização de estado em um Digital Twin voltado ao monitoramento inteligente de ativos físicos, contribuindo para diagnóstico precoce, suporte à decisão e manutenção preditiva [4], [6].

## Referências Bibliográficas

- [1] **SCHROEDER, G. N.; STEINMETZ, C.; RODRIGUES, R. N.; HENRIQUES, R. V. B.; RETTBERG, A.; PEREIRA, C. E.** A Methodology for Digital Twin Modeling and Deployment for Industry 4.0. *Proceedings of the IEEE*, v. 109, n. 4, p. 556–567, 2021.
- [2] **TAO, F.; XIAO, B.; QI, Q.; CHENG, J.; JI, P.** Digital twin modeling. *Journal of Manufacturing Systems*, v. 64, p. 372–389, 2022.
- [3] **AHELERROFF, S.; XU, X.; ZHONG, R. Y.; LU, Y.** Digital Twin as a Service in Industry 4.0: An architecture reference model. *Advanced Engineering Informatics*, v. 47, 101225, 2021.
- [4] **ZAMZADEH DARBAN, Z.; WEBB, G. I.; PAN, S.; AGGARWAL, C. C.; SALEHI, M.** Deep Learning for Time Series Anomaly Detection: A Survey. *ACM Computing Surveys*, v. 57, n. 1, Article 15, p. 1–42, 2024.
- [5] **AUDIBERT, J.; MICHIARDI, P.; GUYARD, F.; MARTI, S.; ZULUAGA, M. A.** Do Deep Neural Networks Contribute to Multivariate Time Series Anomaly Detection? *Pattern Recognition*, v. 132, 108945, 2022.
- [6] **CASTELLANI, A.; SCHMITT, S.; SQUARTINI, S.** Real-World Anomaly Detection by Using Digital Twin Systems and Weakly-Supervised Learning. *IEEE Transactions on Industrial Informatics*, v. 17, n. 7, p. 4733–4742, 2021.