



Universidade de Pernambuco (UPE)
Escola Politécnica de Pernambuco (POLI)
Instituto de Ciências Biológicas (ICB)

<https://www.sad.pe.gov.br/>

Coordenação de Pós-Graduação em Engenharia de Sistemas

Proposta de Dissertação de Mestrado

Área: Cibernética

Linha de Pesquisa: **Modelagem e simulação de sistemas inteligentes e embarcados**

Título Provisório: *Estudo do impacto de diferentes condições de operações na capacidade de generalização de modelos de detecção de anomalias.*

Orientador: Rodrigo de Paula Monteiro.

Co-orientador:

Descrição:

A detecção de anomalias em máquinas industriais normalmente envolve analisar dados coletados por sensores que monitoram variáveis como vibração, temperatura, corrente elétrica, entre outros [1]. No entanto, esses dados são geralmente coletados sob condições específicas, como configurações estáveis de operação ou ambientes controlados, que podem não refletir todas as situações reais encontradas durante o uso das máquinas.

Quando um modelo de detecção de anomalias já treinado é exposto a dados com distribuições diferentes daquelas usadas no treinamento, seja devido a mudanças nas condições ambientais, variações nos processos industriais ou até mesmo novos tipos de falhas, seu desempenho na identificação de anomalias pode se degradar significativamente [2]. Esse problema de generalização fora da distribuição (OOD, do inglês *Out-of-Distribution Generalization*) é especialmente crítico em ambientes industriais, onde detectar falhas rapidamente é essencial para evitar paradas não planejadas ou danos severos ao equipamento [3].

No contexto industrial, mudanças na distribuição podem ser causadas por fatores como envelhecimento da máquina, mudanças na carga operacional ou substituição de sensores com características diferentes. Além disso, os dados de anomalias são tipicamente escassos, e o modelo pode não ter sido treinado com exemplos representativos de todas as falhas possíveis [4]. Por isso, garantir que o modelo seja capaz de generalizar para situações não vistas durante o treinamento é um grande desafio.

Este estudo propõe caracterizar as mudanças de distribuição em dados de sensores industriais, considerando fatores como variações operacionais, ambientais e o desgaste de componentes, e analisar seu impacto no desempenho de modelos de detecção de anomalias. Para isso, serão utilizados dados históricos do funcionamento de máquinas industriais, quantificadas as diferenças de distribuição por meio de métricas estatísticas e técnicas de visualização, e treinados modelos em distribuições específicas para avaliar sua



Universidade de Pernambuco (UPE)
Escola Politécnica de Pernambuco (POLI)
Instituto de Ciências Biológicas (ICB)

generalização em cenários divergentes. O objetivo é identificar os principais fatores que afetam a performance dos modelos e propor estratégias para melhorar sua robustez em ambientes industriais reais.

Referências:

- [1] SUMMAIRA, Jabeen et al. Recent Advances and Trends in Multimodal Deep Learning: A Review. arXiv preprint arXiv:2105.11087, 2021.
- [2] HENDRYCKS, Dan; MAZEIKA, Mantas; DIETTERICH, Thomas. Deep anomaly detection with outlier exposure. arXiv preprint arXiv:1812.04606, 2018.
- [3] CUI, Peng; WANG, Jinjia. Out-of-distribution (OOD) detection based on deep learning: A review. Electronics, v. 11, n. 21, p. 3500, 2022.
- [4] CHANDOLA, Varun; BANERJEE, Arindam; KUMAR, Vipin. Anomaly detection: A survey. ACM computing surveys (CSUR), v. 41, n. 3, p. 1-58, 2009.