

Comparação de Redes Neurais Siamesas na Detecção de Falhas de Polimerização

Isabela Chiara Allam da Silva^a, Francisco José Burok Teixeira Leite Strunck^a, Amanda Lemette Teixeira Brandão^{a*}

^aPUC-Rio, Departamento de Engenharia Química e de Materiais, Rio de Janeiro-RJ, Brasil

*amanda.lemette@puc-rio.br

RESUMO

O monitoramento de processos químicos exerce um papel crucial na tomada de decisões de diversas indústrias, incluindo farmacêutica, petroquímica e de processamento de alimentos. Na Indústria 4.0, a integração entre sistemas ciber-físicos e a Internet das Coisas colabora neste rastreamento, gerando extensos bancos de dados. Neste contexto, a aplicação de técnicas de *machine learning* se torna uma solução viável para a detecção de falhas em processos (Melo et al., 2024). O presente trabalho comparou duas abordagens que aplicam Redes Neurais Siamesas (SNNs) (Chicco, 2021): uma seguida de camadas do tipo *Long Short Term Memory* (LSTM) (Van Hout et al., 2020) e outra de camadas tipo *Multi-Layer Perceptron* (MLP) (Haykin, 2009). A rede LSTM apresenta arquitetura mais complexa do que uma mais tradicional como a MLP, o que torna o confronto interessante para averiguar a complexidade das informações contidas nos dados. Para o treinamento das redes, foi gerado um banco de dados simulados, por meio do método dos momentos, da polimerização do estireno em CSTR aplicando controle PID. O conjunto resultante continha dados em condições de operação normais e 8 falhas possíveis. A análise dos resultados obtidos mostrou que ambas as redes foram eficientes na detecção de falhas. A melhor SNN-LSTM atingiu acurácia de 98,76% e F1-score de 97,71%, enquanto a melhor SNN-MLP chegou a acurácia de 98,64% e F1-score de 97,10%. Dessa forma, a análise tanto da sofisticação das redes aplicadas quanto das métricas de avaliação sugerem que a rede SNN-MLP seria suficiente para realizar detecções satisfatórias, sem a densidade de parâmetros e o custo computacional de uma rede LSTM.

Palavras-chave: Redes Neurais Siamesas; Detecção de Falhas; *Machine Learning*; Polimerização de Estireno.

Agradecimentos: O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e da Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP) através do programa PRH-ANP (2025/02828-3), administrado pela FAPESP.

Referências

- D. Chicco: Siamese Neural Networks: An Overview in Methods in Molecular Biology (H. Cartwright, Eds.), Humana: 2020.
- S. Haykin: Neural networks and learning machines (3a. Ed.), Pearson: 2009.
- A. Melo, M. M. Câmara e J. C. Pinto: Data-driven process monitoring and fault diagnosis: A comprehensive survey, Processes (12), 251, 2024.
- G. Van Houdt, C. Mosquera e G. Nápoles: A review on the long short-term memory model, Artificial Intelligence Review (53), 5939-5944, 2020.