

# ESTUDO DA EFICÁCIA DE SÉRIES TEMPORAIS E MODELAGEM ARIMA NA PREVISÃO DA INCRUSTAÇÃO NA REDE DE TROCADORES DE CALOR DO PRÉ-PROCESSAMENTO DO PETRÓLEO

A.S. Soares<sup>1,2</sup>; A.L.N Santos<sup>2</sup>; M.A. Moret<sup>2</sup>; O.R. Pinheiro<sup>2</sup>; F.L.P. Pessoa<sup>2</sup>

<sup>1</sup> Doutorando PPG MCTI SENAI CIMATEC; (adroaldo.soares@ba.estudante.senai.br)

<sup>2</sup> Centro Universitário SENAI CIMATEC; Salvador, Bahia, Brasil; (fernando.pessoa@fieb.org.br)

## RESUMO

Esse trabalho apresenta uma abordagem baseada em técnicas de IA para prever a deposição na bateria de trocadores de calor do tipo casco e tubo, utilizados no refino do petróleo. A deposição ou incrustação, que ocorre nas superfícies de troca térmica dos trocadores de calor, durante a operação, reduz a eficiência desses equipamentos e gera um aumento no custo do refino para a planta petroquímica em função da modificação dos parâmetros ideais de operação e alteração das variáveis do processo, como vazão, pressão e temperatura, de entrada e saída dos trocadores de calor, bem como dos parâmetros termodinâmicos, como coeficiente de resistência a incrustação e coeficiente global de transferência de calor. O objetivo geral desse trabalho é prever a deposição no trocador de calor do tipo casco e tubo com o uso de IA podendo assim ajudar a minimizar os custos de manutenção e aumentar a eficiência energética, tornando as operações mais seguras e eficientes, trazendo benefícios significativos para a indústria do petróleo. O método proposto utiliza o modelo de série temporal *Auto Regressive Integrated Moving Average* (ARIMA). Os dados foram coletados de trocadores de uma bateria de pré-aquecimento de petróleo com dados de 2014 a 2021. O modelo foi treinado com os dados para prever a ocorrência da deposição. Os resultados mostraram que o modelo apresentou um erro médio absoluto de 3.71 na previsão de série temporal de até 10 dias, na ocorrência da deposição em trocadores de calor.

**PALAVRAS-CHAVE:** Inteligência artificial; Trocador de calor; Processo de deposição; Petróleo

## 1. INTRODUÇÃO

O refino de petróleo, muitas vezes chamado de processamento do petróleo, consiste na configuração de um conjunto de processos cujo objetivo é transformar o óleo cru (petróleo) em derivados de valor comercial como diesel, gasolina, GLP, querosene, nafta, dentre outros (ANP, 2019). O petróleo é uma mistura complexa de ocorrência natural, composto de diversos tipos de moléculas formadas em sua maior parte por hidrocarbonetos. Estes átomos de carbono, hidrogênio, oxigênio, nitrogênio e enxofre se combinam de forma infinitamente variável. Em função dessa diversidade de compostos químicos, ocorre frequentemente a deposição ou incrustação, dentro dos trocadores de calor casco e tubo, presentes em plantas petroquímicas que realizam o pré-processamento do petróleo. Trocadores de calor são equipamentos utilizados na indústria para realizar a troca térmica entre fluidos, a diferentes temperaturas, mas que não estão em contato direto. Na indústria de refino, são utilizados para resfriamento de gases, condensação, aquecimento ou em processos de tratamento como, por exemplo, para a quebra de emulsões (ABBASI et al., 2020). No entanto, a incrustação, também conhecida como “fouling”, é um fenômeno comum, causando redução da eficiência, aumento da resistência térmica e, em alguns casos, falha prematura do equipamento (Taborek et al., 1972; Panchal & Liao, 1997). Diversos fatores, como a precipitação de sais, reações químicas, deposição de partículas sólidas, crescimento biológico e deposição de polímeros, podem contribuir para a incrustação em trocadores de calor (Müller-Steinhagen et al., 2011). O desenvolvimento de tecnologias e a utilização de ferramentas como o modelo ARIMA, podem ser utilizadas como formas de predição de fenômenos complexos tal qual o fenômeno de deposição, uma vez que podem correlacionar facilmente as condições operacionais, e o treinamento do modelo, e detectar a mudança de condições através da análise dos dados adquiridos durante a operação do equipamento (DOBBLELARE, 2021). No amplo campo científico da previsão de séries temporais, os modelos ARIMA e suas variantes têm sido amplamente aplicados devido à sua simplicidade matemática e flexibilidade de aplicação. Com os recentes avanços no desenvolvimento e na implementação eficiente de modelos e técnicas de inteligência artificial, tornando-se aparente a abordagens de aprendizagem automática e profunda, mesmo sem uma avaliação completa da superioridade da nova abordagem sobre os algoritmos estatísticos clássicos (Kontopoulou et al., 2023) visto que a abordagem clássica com relação à análise e previsão de séries temporais baseia-se principalmente em modelos integrados de média móvel autorregressiva (ARIMA) e suas diversas versões (Caixa et al., 2015).

## 2. METODOLOGIA

Os dados utilizados para construção do modelo de predição foram obtidos a partir do histórico de medições de uma refinaria no sudeste do Brasil no período de 01/09/2014 até 25/07/2021, totalizando 2289 registros armazenados em um arquivo CSV (Comma-separated values). Para a predição as variáveis independentes foram os parâmetros de operação do trocador, tais como temperatura e vazões de operação, e como variável dependente foi selecionado o coeficiente de deposição, que é mensurado através do cálculo  $R_f$ , que quantifica a resistência à deposição. Para a qualidade do desempenho do modelo de previsão, os dados devem estar livres de erros e perturbações causadas por falhas de equipamentos e sensores de medição. Erros e perturbações levam a outliers, descontinuidades e lacunas de dados, comprometendo o ajuste do modelo e a qualidade de suas previsões. Nesse sentido, foram aplicados filtros para o pré-processamento dos dados: (i) tratamento de valores nulos e (ii) filtragem de registros superestimados. O modelo de série temporal Auto Regressive Integrated Moving Average (ARIMA) foi utilizado, pois de acordo com Nau (2020), trata-se de um método confiável frequentemente usado na análise de dados para prever dados de séries temporais e, como resultado, a deposição no trocador de calor do tipo casco e tubo pode ser usada para produzir modelos ARIMA para fins de previsão.

## 3. RESULTADOS E DISCUSSÃO

Uma vez construído o modelo, sua precisão e capacidade de generalização foram testadas utilizando os dados que compõe o conjunto de amostras para treinamento e testes, totalizando 2286 instancias. A Tabela 1 apresenta o erro médio absoluto e a raiz do erro médio quadrático do modelo. O coeficiente de correlação obtido foi de 0,88.

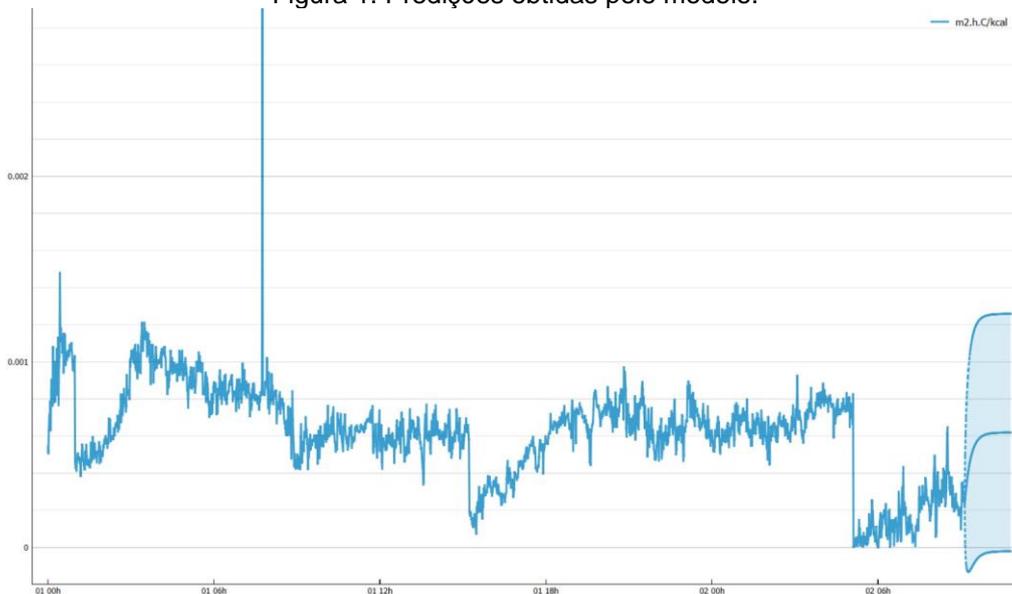
Tabela 1. Erro de previsão.

Erro médio absoluto	Raiz do erro médio quadrático
3.71	8.49 %

Fonte: próprio autor

Os valores dos erros são utilizados para medir o quão próximas as previsões estão dos resultados. A Figura 1 mostra os reais e previstos para 10 dias a frente do modelo.

Figura 1. Predições obtidas pelo modelo.



Fonte: Próprio autor

Nesse contexto, o modelo foi avaliado para determinar a sua precisão e capacidade de generalização. O modelo apresentou boas estatísticas de ajuste, com erro relativo absoluto de 3,71% e raiz do erro médio quadrático de 8,49%.

#### 4. CONSIDERAÇÕES FINAIS

A previsão precisa do coeficiente de deposição é crítica para o planejamento operacional da rede de trocadores de calor no pré-processamento de petróleo. Os resultados mostram uma concordância razoável entre os valores reais e previstos. Este estudo implica que o modelo ARIMA aplicando uma média de erro de estimativa para previsão de séries temporais, pode ser usada na redução dos custos e riscos associados a incrustação na rede de trocadores de calor no pré-processamento de petróleo, fornecendo uma abordagem eficiente para a otimização do processo. Pesquisas futuras analisarão outros bancos de dados para encontrar indicadores apropriados de mérito.

#### Agradecimentos

Ao apoio financeiro da Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP) e da Financiadora de Estudos e Projetos (FINEP), por meio do Programa de Recursos Humanos da ANP para o setor de Petróleo, Gás Natural e Biocombustíveis - PRH -ANP/FINEP, em particular, ao PRH 27.1, do Centro Universitário SENAI CIMATEC.

#### 5. REFERÊNCIAS

ANP. (Anuário Estatístico 2019). AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS, 2023. ISSN 1983-5884. Disponível em: <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/anuario-estatistico/anuario-estatistico-2023>

ABBASI, H. R.; SADEH, E. S.; POURRAHMANI, H.; MOHAMMADI, M. H., **Shape optimization of segmental porous baffles for enhanced thermo-hydraulic performance of shell-and-tube heat exchanger. Applied Thermal Engineering**, v. 180 (2020) 115835, 2020.

CAIXA, G.E; JENKINS, G.M; REINSEL, G.C; LJUNG, G.M; **Análise de Séries Temporais: Previsão e Controle** ; John Wiley & Sons: Hoboken, NJ, EUA, 2015.

DOBBELAERE, M. R. ET AL., **Machine Learning in Chemical Engineering: Strengths, Weaknesses, Opportunities, and Threats. Engineering**, [s. l.], v. 7, n. 9, p. 1201–1211, 2021.

KONTOPOULOU, V.I.; PANAGOPOULOS, A.D.; KAKKOS, I.; MATSOPOULOS, G.K., **Uma revisão de abordagens ARIMA vs. aprendizado de máquina para previsão de séries temporais em redes baseadas em dados. Internet futura 2023**, 15, 255. <https://doi.org/10.3390/ifi15080255>

MÜLLER-STEINHAGEN, H., MALAYERI, M.R., & WATKINSON, A.P., **Heat Exchanger Fouling: Environmental Impacts. Heat Transfer Engineering**, 32(3-4), 189-200, 2011.

NAU R.; **Statistical forecasting: notes on regression and time series analysis.**; duke.edu., 2020.

PANCHAL, C.B., & LIAO, C.F., **Industrial heat exchanger fouling: Mitigation and cleaning strategies. Applied Thermal Engineering**, 17(8-10), 705-715, 1997.

TABOREK, J., AOKI, T., RITTER, R.B., PALEN, J.W., & KNUDSEN, J.G., **Fouling: The major unresolved problem in heat transfer. Chemical Engineering Progress**, 68(2), 59-67, 1972.