

Otimização em trocadores de calor usando inteligência artificial: Uma abordagem híbrida de redes neurais para a previsão do acúmulo de depósitos e a eficiência do equipamento



<https://doi.org/10.56238/sevened2023.006-022>

Adroaldo Santos Soares

Mestre em Ensino de Física
Instituição: Centro Universitário Senai (CIMATEC)
E-mail: adroaldo.soares@ba.estudante.senai.br

Ana Laise do Nascimento dos Santos

Graduada em Engenharia Química Instituição: Centro Universitário Senai (CIMATEC)
E-mail: ana.laise@fbter.org.br

Oberdan Rocha Pinheiro

Doutor em Modelagem Computacional e Tecnologia Industrial Instituição: Centro Universitário Senai (CIMATEC)
E-mail: oberdan.pinheiro@fieb.org.br

Marcelo Albano Moret Simões Gonçalves

Doutor em Ciências Biológicas, Biofísica Instituição: Centro Universitário Senai (CIMATEC)
E-mail: moret@fieb.org.br

Fernando Luiz Pellegrini Pessoa

Doutor em Engenharia Química Instituição: Centro Universitário Senai (CIMATEC)
E-mail: fernando.pessoa@fieb.org.br

RESUMO

Este artigo apresenta uma abordagem baseada em técnicas de inteligência artificial para prever a deposição crítica em trocadores de calor utilizados no pré-processamento de petróleo. A deposição na superfície de troca térmica durante a operação pode reduzir a eficiência do equipamento e causar problemas de manutenção. O método proposto utiliza uma rede neural recorrente em um modelo de Multi Layer Perceptron (MLP). Os dados foram coletados de trocadores de uma bateria de pré-aquecimento de petróleo com dados de 2014 a 2021. A rede neural foi treinada com os dados para prever a ocorrência de deposição. Os resultados mostraram que a rede neural é capaz de prever com precisão a ocorrência da deposição em trocadores de calor. A previsão antecipada da deposição pode ajudar a minimizar os custos de manutenção e aumentar a eficiência energética, tornando as operações mais seguras e eficientes. Assim, a abordagem proposta pode trazer benefícios significativos para a indústria do petróleo ao permitir a previsão antecipada da deposição crítica em trocadores de calor.

Palavras-chave: Inteligência artificial, Trocador de calor, Processo de deposição, Petróleo.

1 INTRODUÇÃO

A deposição (fouling) é um fenômeno comum durante a operação de trocadores de calor, onde consiste na formação de depósitos na superfície destes equipamentos. Atualmente, na literatura, conceitua-se que a deposição pode ocorrer basicamente por três causas, como um resultado da mudança de fase que surge das diferenças de temperatura entre a superfície e o fluido (deposição por cristalização), por reações químicas nas superfícies (deposição por reação química) e por crescimento de organismos na superfície (biodeposição) (BOTT, 1995).

Este fenômeno tem significativa importância de estudo pois com o passar do tempo a incrustação diminui a área da seção transversal de escoamento do fluido o que resulta na necessidade de combustível adicional para compensar a diminuição na área de troca térmica e maior potência de



bombeamento devido ao aumento das perdas de carga nos equipamentos, acarretando o aumento considerável dos custos com energia.

O conhecimento do fenômeno de deposição e sua previsão podem trazer economias significativas no processamento de óleos e suas misturas, pois permitirão prever sua ocorrência e consequências, bem como evitar, na medida do possível, o aparecimento de deposição ao longo da operação. (SMITH, 2015). Atualmente, os modelos mais comuns para previsão da deposição são os semi-empíricos ou modelos de limiar onde se utiliza basicamente de dados experimentais para a previsão do fenômeno, entretanto, apesar de estes preverem as taxas de incrustação de forma satisfatória, ainda há lacunas em termos de eficiência de previsão (DESHANNAVAR, 2020).

O desenvolvimento de tecnologias de inteligência artificial possibilitou a utilização de ferramentas de aprendizado de máquina como formas de previsão de fenômenos complexos tal qual o fenômeno de deposição. Os algoritmos de Machine Learning tipo redes neurais recorrentes (RNN), long short-term memory (LSTM) e redes de perceptrons multicamadas (MLP), podem correlacionar facilmente as condições operacionais, e detectar a mudança de condições através da análise dos dados adquiridos durante a operação do equipamento (DOBBLELARE, 2021). O pré-processamento de petróleo é uma etapa crucial na produção de óleo e gás, que envolve a separação de impurezas e a redução da viscosidade do petróleo para facilitar o escoamento. A eficiência e a eficácia dos trocadores de calor são de grande importância para diversos setores industriais, uma vez que esses equipamentos desempenham um papel crucial na transferência de energia térmica entre fluidos (BOTT, 1995).

A troca de calor entre fluidos de diferentes temperaturas é de suma importância para os processos industriais e possui diversas aplicações na engenharia. A manutenção preditiva utiliza diversos métodos para monitorar as condições de equipamentos aplicados em plantas industriais (Araújo et al, 2021). O problema relacionando incrustação em trocadores de calor e perda de eficiência no processo vem sendo motivo de vários estudos e não poderia ser diferente no refino de petróleo, principalmente no pré-aquecimento do petróleo (Júnior et al, 2020). Nesse sentido, levando em consideração às incertezas e pensando na deposição (Santana et al, 2021), o uso de aparatos experimentais de laboratório tem sido bastante comum para o desenvolvimento dos modelos, entretanto a aplicação desses modelos na avaliação e previsão do fenômeno em plantas industriais encontra obstáculos (Santamaria et al 2018), uma vez que os modelos disponíveis na literatura não se aproximam da previsão de forma satisfatória do comportamento de deposição em trocadores industriais.

2 MATERIAL E MÉTODOS

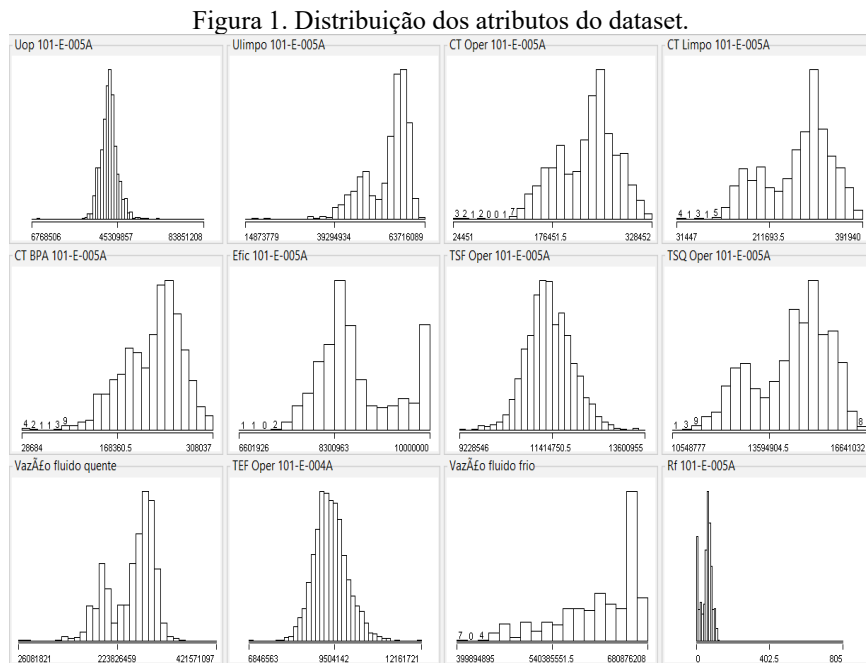
2.1 PREPARAÇÃO DOS DADOS

Os dados utilizados para construção do modelo de previsão foram obtidos a partir do histórico de medições da BPA da REGAP U-101 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.

A Figura 1 apresenta a distribuição dos dados contidos no dataset utilizado para treinamento e validação do modelo após aplicação dos filtros.



Fonte: Autor.


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, discontinuidades 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.

2.2 MODELO DE PREVISÃO

O modelo da rede neural artificial (RNA) utilizado neste trabalho foi baseado na arquitetura Multi Layer Perceptron (MLP) com o algoritmo de retropropagação do erro Backpropagation. A principal característica que torna a MLP interessante para solução de problemas é a capacidade de aprender através de exemplos e de generalizar este aprendizado de forma que seja capaz de reproduzir um resultado a uma entrada diferente da apresentada. A Figura 2 apresenta a arquitetura do modelo de previsão construído nesse trabalho.



Figura 2. Arquitetura do modelo de previsão.



Fonte: Autor.

O modelo baseado em uma RNA é composto por 5 camadas, sendo a camada de entrada composta por 11 neurônios que representam os atributos do dataset para construção do modelo, 3 camadas ocultas compostas por 36 neurônios e uma camada de saída que representa o atributo (coeficiente de deposição) que o modelo deverá fazer a previsão. A técnica de Validação Cruzada (10-fold cross-validation), foi utilizada para realizar os processos de treinamento e construção do modelo. No 10-fold cross-validation, o conjunto de dados é dividido aleatoriamente em 10 partes nas quais cada classe é representada na mesma proporção do conjunto inteiro, aproximadamente. Destas 10 partes, 9 partes são utilizadas para o treinamento e uma serve como base de testes. O processo é repetido 10 vezes, de forma que cada parte seja usada uma vez como conjunto de testes. Ao final, a correção total é calculada pela média dos resultados obtidos em cada etapa, obtendo-se assim uma estimativa da qualidade do modelo.

Como resultado, o algoritmo prevê quão semelhantes as observações recebidas recentemente são com a observação de treinamento. Durante a fase de aprendizado, esse algoritmo mantém o conjunto de treinamento completo. Amostras desconhecidas (ou seja, novos dados de entrada) têm seus rótulos (classes) comparados a cada instância do conjunto de treinamento e, encontrando a média das variáveis de resposta, podemos prevêê-las.

3 RESULTADOS E DISCUSSÃO

Uma vez construído o modelo, sua precisão e capacidade de generalização foram testadas utilizando os dados que compõem o conjunto de amostras para treinamento e testes, totalizando 2286 instâncias. O modelo foi treinado até 1000 épocas, utilizando a taxa de aprendizagem de 0.01 e a



constante de momentum de 0.9. A Tabela 1 apresenta o erro médio absoluto, o erro relativo absoluto e a raiz do erro médio quadrático do modelo. O coeficiente de correlação obtido foi de 0.98.

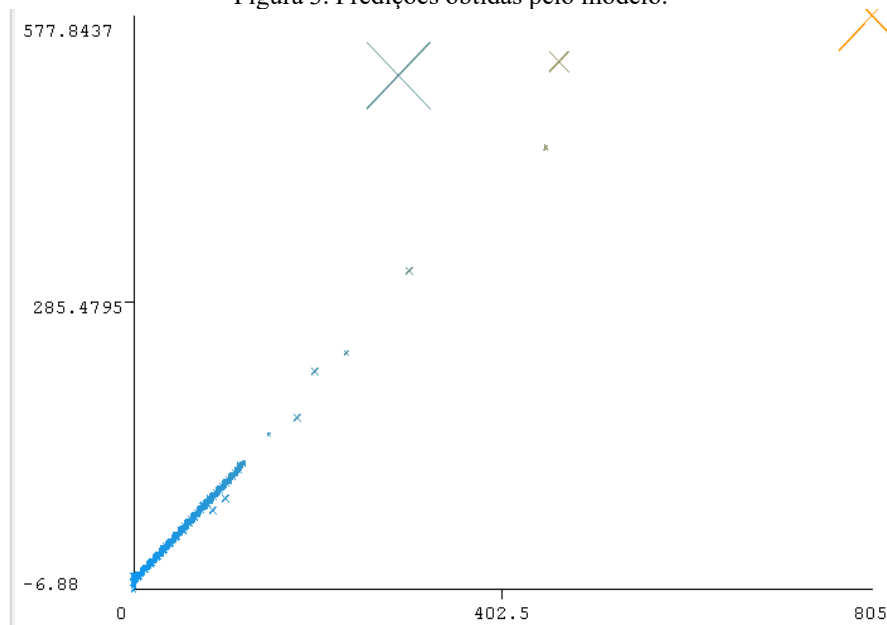
Tabela 1. Erro de previsão.

Erro médio absoluto	Erro relativo absoluto	Raiz do erro médio quadrático
1,0	4,0 %	6,9 %

Fonte: Autor.

Os valores dos erros são utilizados para medir o quão próximas as previsões estão dos resultados. A Figura 3 mostra os valores previstos e reais do modelo. O eixo y projeta valores para cada previsão, enquanto o eixo x apresenta os valores reais. O modelo segue de perto a previsão do coeficiente de deposição, embora apresente pequenas variações.

Figura 3. Previsões obtidas pelo modelo.



Fonte: 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 4% e raiz do erro médio quadrático de 6,9%.

4 CONCLUSÃO

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 a técnica de aprendizado de máquina, particularmente RNA/MLP, 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.



REFERÊNCIAS

- Araújo, Álvaro Souza de; Rocha, Oberdan Pinheiro; Santos, Alex Álisson Bandeira; Modelo computacional para análise de condições e monitoramento de motores elétricos, p. 303-310 .In: VII International Symposium on Innovation and Technology. São Paulo: Blucher, 2021.
- Bott, T. R Fouling of Heat Exchangers. In Chemical Engineering monographs. Elsevier. 1995.
- Deshannavar, U. B., & Marappagounder, R. Revisiting Threshold Fouling Models for Crude Oil Fouling. Heat Transfer Engineering, 0(0), 1–17. (2020).
- 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.
- Júnior, A. R. M.; Análise comparativa de desempenho de modelos semi-empíricos na previsão de deposição em baterias de trocadores de calor de refinarias de petróleo; Programa de Pós Graduação, Centro Universitário SENAI CIMATEC , Salvador, 2020.
- Santamaria, F. L.; Macchietto, S.; Integration of Optimal Cleaning Scheduling and Flow Split Control for Crude Oil Fouling Mitigation in the Operation of Refinery Heat Exchanger Networks; Computer Aided Chemical Engineering, 2018.
- Santana, L. O. S. de; Calixto, Ewerton E. da S.; Pessoa, F. L. P.; Análise de incertezas aplicada ao cálculo da temperatura de bolha de misturas, p. 113-120 . In: VII International Symposium on Innovation and Technology. São Paulo: Blucher, 2021.
- Smith, A. D., & Joshi, H. M. (2015). A Critical Look at the Use of Activation Energy in Crude Oil Fouling Models. International Conference on Heat Exchanger Fouling and Cleaning, 2015, 13–21.