

12º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

PREDIÇÃO DO FATOR INCRUSTAÇÃO EM TROCADORES DE CALOR DE ÓLEO CRU UTILIZANDO REDES NEURAIS RECORRENTES LSTM

AUTORES:

Ana Laise do N. dos Santos^{1,2}, Victor Leão S. Dias³, Cristiano Hora de Oliveira Fontes¹, Fernando Luiz Pellegrini Pessoa^{2,3}

INSTITUIÇÃO:

¹Escola Politécnica, Programa Pós graduação em Engenharia Industrial, Universidade Federal da Bahia

²Modelagem computacional em tecnologia industrial, Centro Universitário Senai Cimatec,

³Escola de Química, Programa de Pós-Graduação em Engenharia de Processos Químicos e Bioquímicos, Universidade Federal do Rio de Janeiro

PREDIÇÃO DO FATOR INCRUSTAÇÃO EM TROCADORES DE CALOR DE ÓLEO CRU UTILIZANDO REDES NEURAIS RECORRENTES LSTM

Resumo

A incrustação em trocadores de calor reduz a eficiência térmica e aumenta os custos operacionais nas refinarias de petróleo. Este trabalho avalia o uso de redes neurais do tipo Long Short-Term Memory (LSTM) para prever o fator de incrustação em trocadores de calor de óleo cru. A rede LSTM foi escolhida por sua capacidade de capturar dependências de longo prazo nos dados. Utilizou-se dados históricos diários de 2014 a 2021 de uma refinaria brasileira. O pré-processamento, a implementação da rede, o treinamento e a validação foram realizados em Python. Métricas como erro quadrático médio (MSE), raiz quadrada do erro quadrático médio (RMSE) e coeficiente de determinação R^2 foram utilizadas para avaliar o desempenho do modelo. Os resultados mostraram que o modelo LSTM apresentou um MAE de 0,035, MSE de 0,002 e R^2 de 0,916 no treinamento, e R^2 de 0,857 e 0,854 nos conjuntos de teste e validação, respectivamente. A análise dos resíduos indicou que as previsões estão próximas dos valores reais, com uma leve tendência de subestimação, demonstrando a eficácia do modelo em comparação com métodos tradicionais.

Palavras-chave: incrustação, redes neurais LSTM, trocadores de calor.

Abstract

Fouling in heat exchangers reduces thermal efficiency and increases operational costs in oil refineries. This study evaluates the use of Long Short-Term Memory (LSTM) neural networks to predict the fouling factor in crude oil heat exchangers. The LSTM network was chosen for its ability to capture long-term dependencies in the data. Historical daily data from 2014 to 2021 from a Brazilian refinery were used. Data preprocessing, network implementation, training, and validation were performed in Python. Metrics such as mean squared error (MSE), root mean squared error (RMSE), and coefficient of determination were used to evaluate model performance. The results showed that the LSTM model achieved a MAE of 0.035, MSE of 0.002, and R^2 of 0.916 in training, and R^2 of 0.857 and 0.854 in the test and validation sets, respectively. The residual analysis indicated that the predictions are close to the actual values, with a slight tendency to underestimate, demonstrating the model's effectiveness compared to traditional methods.

Keywords: fouling, LSTM neural networks, heat exchangers.

Introdução

O fenômeno da deposição em baterias de pré-aquecimento de óleo cru é um desafio persistente na indústria de refino de petróleo. Essas baterias desempenham um papel crucial ao reduzir a viscosidade do óleo antes de sua entrada na destilação atmosférica, facilitando a separação de frações. No entanto, a formação de depósitos nos trocadores de calor pode comprometer significativamente a eficiência desses sistemas, aumentando a resistência térmica e reduzindo a transferência de calor. Essa incrustação resulta em perda de eficiência energética, aumento de custos operacionais e necessidade de manutenções frequentes (Aminian & Shahhosseini, 2009).

Tradicionalmente, a modelagem do fenômeno de deposição tem se baseado em métodos semi-empíricos e abordagens fenomenológicas. Exemplos desses métodos incluem os modelos de limiar de incrustação, que visam prever as condições de operação sob as quais a incrustação é minimizada. No entanto a modelagem deste fenômeno enfrenta diversos desafios, incluindo a complexidade das composições do óleo cru e suas interações, além da natureza não linear e multifatorial dos processos de incrustação. Estudos demonstram que, apesar dos avanços, esses modelos frequentemente falham ao serem aplicados em condições industriais reais, limitando sua eficácia, os erros de predição deste tipo de modelos estão na ordem de grandeza de 10% chegando até 30% de erro (Dologlu *et al.*, 2023).

Embora exista a crescente aplicação de redes neurais artificiais para predição do fator de incrustação, existem poucos trabalhos com aplicação de redes neurais recorrentes do tipo LSTM. As redes *Long Short-Term Memory* (LSTM) são projetadas para capturar dependências de longo prazo e padrões temporais complexos nos dados, características essenciais para a modelagem de processos dinâmicos como a deposição em trocadores de calor, sendo assim, oferecem uma abordagem promissora para superar essas limitações. A capacidade das LSTM de lidar com séries temporais e suas habilidades de memória permitem que esses modelos aprendam e representem relações complexas entre variáveis operacionais e o fenômeno de incrustação, proporcionando previsões mais precisas e confiáveis. (Shaosheng, 2012)

O objetivo deste trabalho é desenvolver um modelo preditivo utilizando redes neurais recorrentes LSTM para estimar o fator de incrustação em trocadores de calor de baterias de pré-aquecimento de óleo cru. Este estudo envolve a coleta e análise de dados operacionais de uma refinaria brasileira, seguido pelo desenvolvimento, treinamento e validação dos modelos de aprendizado de máquina. O banco de dados utilizado consiste em informações industriais reais, incluindo dados diários de temperatura e vazão do óleo cru e dos fluidos utilizados para aquecer o óleo. A segmentação dos dados garantirá a robustez e a qualidade das previsões, e diferentes arquiteturas de redes neurais serão comparadas para identificar a mais eficiente.

Espera-se que o modelo desenvolvido não apenas melhore a predição da incrustação, mas também contribua para a otimização da manutenção e eficiência energética nas refinarias de petróleo, promovendo operações mais sustentáveis e economicamente viáveis. Este trabalho representa um avanço significativo na aplicação de inteligência artificial na indústria de refino, alinhando-se com os princípios da Indústria 4.0 e a crescente demanda por soluções inteligentes e baseadas em dados

Metodologia

Pré-processamento de Dados

A primeira etapa envolveu o carregamento e a preparação dos dados, que foram obtidos de uma planilha Excel contendo informações diárias de temperatura e vazão do óleo cru e dos fluidos utilizados para aquecer o óleo de 2014 a 2021. Os nomes das colunas foram ajustados para garantir a consistência e facilitar a manipulação dos dados. Em seguida, todas as colunas de dados, exceto a coluna de datas, foram convertidas para valores numéricos, tratando e removendo dados não numéricos ou nulos conforme necessário.

Os dados foram então normalizados utilizando a técnica Min-Max Scaling, garantindo que todos os valores estivessem na mesma escala e facilitando o treinamento da rede neural. *Outliers* foram identificados e removidos com base no intervalo interquartil (IQR).

Desenvolvimento do Modelo

Os dados foram divididos em conjuntos de treinamento com informações dos anos 2014 a 2018 e, para teste, foram utilizados os dados de 2019 à 2020. O modelo final foi ainda validado com dados de 2021. A função “*create dataset*” foi utilizada para transformar os dados em um formato adequado para o treinamento da rede LSTM, criando sequências temporais de entrada e saída. Em seguida, os dados foram ajustados para serem compatíveis com a entrada esperada pela camada LSTM.

A rede neural LSTM foi definida com duas camadas LSTM e camadas de *dropout* para evitar *overfitting*. O modelo foi compilado e treinado utilizando o otimizador Adam e a função de perda de erro quadrático médio. O treinamento do modelo envolveu 20 épocas com um tamanho de lote de 32.

Avaliação do Modelo

As previsões foram realizadas no conjunto de teste, e os valores preditos foram comparados com os valores reais utilizando várias métricas de desempenho. As métricas utilizadas incluíram o Erro Médio Absoluto (MAE), que mede a média dos erros absolutos entre as previsões e os valores reais; o Erro Quadrático Médio (MSE), que mede a média dos quadrados dos erros, penalizando mais fortemente os erros maiores; e o Coeficiente de Determinação (R^2), que indica a proporção da variância dos dados explicada pelo modelo.

Resultados e Discussão


Os resultados obtidos a partir da rede neural LSTM para a predição do fator de incrustação (R_f) demonstram um desempenho considerável em diferentes conjuntos de dados. As métricas de desempenho para os conjuntos de treino, teste e validação são apresentadas na tabela abaixo.

Tabela 1 Métricas de desempenho do modelo

Métrica	Treinamento	Teste	Validação
MAE	0,035	0,066	0,061
MSE	0,002	0,005	0,005
R ²	0,916	0,857	0,854


As métricas indicadas na Tabela 1 revelam que a rede neural LSTM apresentou um erro absoluto médio (MAE) de 0,035 no conjunto de treinamento, refletindo uma boa precisão das predições iniciais. Embora os valores de MAE aumentem para 0,066 e 0,061 nos conjuntos de teste e validação, respectivamente, a predição não foi severamente prejudicada. A possibilidade de *overfitting* é remota, já que o comportamento do modelo com dados não vistos ainda é bastante satisfatório. Os resultados mostram que a rede neural LSTM é capaz de capturar bem a dinâmica do fator de incrustação em um trocador de calor, com um alto coeficiente de determinação no conjunto de treinamento (0,916) e uma performance razoável nos conjuntos de teste e validação (0,857 e 0,853, respectivamente). A predição dos valores para cada um dos conjuntos de treino, teste e validação esta disposta na série temporal ilustrada na figura 1 abaixo

Figura 1 Valores preditos versus reais para cada um dos conjuntos de dados




Observa-se que o modelo consegue acompanhar razoavelmente bem as variações dos dados reais, com os conjuntos de treinamento apresentando menor dispersão em comparação com os conjuntos de teste e validação. Este comportamento é esperado, visto que o modelo é ajustado para otimizar a precisão no conjunto de treinamento. Para além das métricas de desempenho, foi avaliada a distribuição dos resíduos do modelo com o histograma conforme está ilustrado na figura abaixo.

Figura 2 histograma dos resíduos do modelo LSTM



É possível observar uma distribuição aproximadamente normal, centrada entre -0.1 e 0.0. A concentração dos resíduos próximos de zero sugere que a maioria das previsões estão bastante próximas dos valores reais, embora haja uma leve tendência de subestimação nos valores preditos. A Figura 3 mostra os valores de R^2 para cada um dos conjuntos de dados.

Figura 3 R^2 plot para os conjuntos de treino teste e validação

A Figura 3 apresenta gráficos de dispersão que comparam os valores preditos e reais para os conjuntos de treinamento, teste e validação, juntamente com os respectivos coeficientes de determinação R^2 . No conjunto de treinamento, o modelo LSTM apresentou um R^2 de 0.916, indicando que 91.6% da variabilidade nos dados é explicada pelo modelo, refletindo uma forte correlação e boa precisão nas previsões. No conjunto de teste, o R^2 foi de 0.857, um pouco menor que no treinamento, mas ainda alto, mostrando que o modelo mantém uma boa capacidade preditiva com novos dados. A dispersão dos pontos é maior em comparação com o conjunto de treinamento, mas o modelo consegue explicar 85.7% da variabilidade dos dados de teste. No conjunto de validação, o R^2 foi de 0.854, próximo ao do conjunto de teste, indicando consistência do modelo com dados não vistos e boa capacidade de generalização.

Conclusões

Este estudo demonstrou a eficácia das redes neurais Long Short-Term Memory (LSTM) na predição do fator de incrustação (R_f) em trocadores de calor de baterias de pré-aquecimento de óleo cru. O modelo desenvolvido apresentou um desempenho sólido, com alta precisão nas predições para o conjunto de treinamento (MAE de 0,035 e R^2 de 0,916). Nos conjuntos de teste e validação, o modelo manteve uma performance robusta, com R^2 de 0,857 e 0,854, respectivamente, indicando uma boa capacidade de generalização e consistência nas predições com dados não vistos.

A análise dos resíduos revelou uma distribuição aproximadamente normal, sugerindo que as predições estão próximas dos valores reais, apesar de uma leve tendência de subestimação. As séries temporais dos valores preditos versus reais e os gráficos de dispersão corroboraram a capacidade do modelo de acompanhar as variações dos dados reais de forma satisfatória.

Este trabalho representa um avanço na aplicação de inteligência artificial na indústria de refino de petróleo, proporcionando uma ferramenta valiosa para a previsão do fator de incrustação. O uso de LSTM mostrou-se eficaz em superar as limitações dos modelos tradicionais, oferecendo previsões mais precisas e confiáveis.

Agradecimentos

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio parcial a este trabalho, por meio do grant CNPq 465517/2014-5 - INCT Geofísica do Petróleo.

Referências Bibliográficas

AMINIAN, Javad; SHAHHOSSEINI, Shahrokh. Neuro-based formulation to predict fouling threshold in crude preheaters. **International Communications in Heat and Mass Transfer**, v. 36, n. 5, p. 525-531, 2009.

SHAOSHENG, Fan; JU, Wang. Application of diagonal recurrent neural network for measuring fouling in condenser. In: **2007 2nd IEEE Conference on Industrial Electronics and Applications**. IEEE, 2007. p. 169-171.

DOLOGLU, Pelin et al. Data-driven fouling modeling in crude oil heat exchanger. In: **Computer Aided Chemical Engineering**. Elsevier, 2023. p. 685-69