



II CIGELUBRA

Congresso Internacional de Gestão e Engenharia Luso-Brasileiro

03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Monitoramento Inteligente de Incrustação: Softsensors com Aprendizado de Máquina na Indústria de Hidrocarbonetos

Lucas de Jesus Gonçalves

Programa de Pós-Graduação em Engenharia Química (PPGEQ-PG) Universidade Tecnológica Federal do Paraná – Campus Ponta Grossa

Claiton Zanini Brusamarello

Programa de Pós-Graduação em Engenharia Química (PPGEQ-PG) Universidade Tecnológica Federal do Paraná – Campus Ponta Grossa

Resumo: A incrustação em permutadores industriais resulta em significativas perdas dada a necessidade de manutenção, redução da disponibilidade e a diminuição da eficiência operacional. Isso impacta negativamente os esquemas de refino de petróleo, cuja participação na matriz energética brasileira é evidente, principalmente os processos de produção de gasolina dado crescente consumo. Iniciativas de monitoramento baseadas em sistemas orientados por dados, como os softsensors, têm ganhado destaque pela capacidade de modelar processos industriais utilizando dados coletados por instrumentos convencionais, além de responder de forma inteligente com base em situações anteriores. Portanto, esta pesquisa tem como objetivo explorar o potencial das redes neurais recorrentes na predição de incrustações, visando o desenvolvimento de um softsensor capaz de fornecer suporte confiável à definição de protocolos de manutenção preditiva em trocadores de calor de uma unidade experimental de fluido-craqueamento catalítico (FCC). Para o desenvolvimento do sensor virtual, foram empregadas redes neurais artificiais recorrentes (RNNs), reconhecidas por sua proficiência na predição de fenômenos temporais. Especificamente, redes recorrentes do tipo Elman e LSTM foram treinadas com dados reais provenientes de um trocador de calor operando em uma planta experimental de refino de petróleo. Foram empregadas a metodologia PCA e correlação de Pearson para redução de dimensionalidade, Hyperband para exploração ágil dos hiperparâmetros das redes e ADAM de otimização de aprendizado. A rede neural de Elman provou ser a melhor por ter um R^2 de 0,87 no horizonte a curto prazo e 0,78 no espaço de tempo total predito.

Palavras-chave: Manutenção Preditiva; Inteligência Artificial; Deposição; Petróleo.

Intelligent Fouling Monitoring: Machine Learning based Softsensors in the Hydrocarbon Industry

Abstract: Fouling in industrial heat exchangers results in significant losses due to the need for maintenance, reduced availability, and decreased operational efficiency. This negatively impacts oil refining systems, whose participation in the Brazilian energy matrix is evident, especially gasoline production processes, given growing consumption. Monitoring initiatives based on data-driven systems, such as soft sensors, have gained prominence due to their ability to model industrial processes using data collected by conventional instruments, in addition to responding intelligently based on previous situations. Therefore, this research aims to explore the potential of recurrent neural networks in predicting fouling, aiming to develop a soft sensor capable of providing reliable support for defining predictive maintenance protocols in heat exchangers of an experimental fluid

catalytic cracking (FCC) unit. Recurrent artificial neural networks (RNNs), recognized for their proficiency in predicting temporal phenomena, were employed to develop the virtual sensor. Specifically, Elman and LSTM recurrent networks were trained with real data from a heat exchanger operating in an experimental oil refining plant. PCA and Pearson correlation were used for dimensionality reduction, Hyperband for agile exploration of network hyperparameters, and ADAM for learning optimization. The Elman neural network proved to be the best, with an R^2 of 0.87 in the short-term horizon and 0.78 in the total predicted time frame.

Keywords: Predictive Maintenance; Artificial Intelligence; Deposition; Petroleum.

1. Introdução

O petróleo é uma *commoditie* de expressivo crescimento ao longo das duas últimas décadas, segundo Instituto Brasileiro de Petróleo (2022). Jones e Pujado (2006) informam que a necessidade da matriz energética regional é um fator importante na configuração do refino de petróleo pois é o que determina a demanda por gasolina, diesel e óleo combustível.

“O craqueamento é um processo de refino cujo objetivo é aumentar a produção de nafta (composto da gasolina) e gás liquefeito de petróleo (GLP), de maiores valores comerciais, por meio da conversão de frações pesadas do petróleo (gasóleo e resíduos)” (Lage et al., 2008). Segundo o autor, o processo foi desenvolvido dado o aumento da demanda por gasolina proveniente do crescimento da indústria automobilística desde meados de 1910.

A incrustação é um processo inerente à operação de equipamentos de processo que fazem uso de troca de calor, portanto é um fator limitante à sua operação (Cardoso; Fisch, 2016; Kiparissides, 2022; Neblinger et al., 2023; Rohman et al., 2022b). A procura por meios de prevenção à sedimentação de material em superfícies de troca térmica é um tema recorrente na literatura, mas pouco se encontra sobre a predição de tais eventos. Parte dessa escassez se deve à dificuldade de aferir incrustação em si, quanto mais de se prever (Vandewalle et al., 2017).

O impacto financeiro da incrustação é significativo: segundo estimativas de Sheriffa et al. (2022), esse fenômeno gera um custo anual de aproximadamente 14 bilhões de dólares apenas em trocadores de calor nos Estados Unidos. No entanto, não há como medir diretamente a incrustação em equipamentos, o que faz com que o fenômeno seja classicamente aferido de forma indireta. É uma prática comum medir os seus impactos em parâmetros de processo (Rohman et al., 2022a; Bottcher et al., 2022). Contudo, tais metodologias trazem um panorama a curto prazo, não sendo adequadas para previsões a médio e longo prazo, como um protocolo de manutenção preditiva.

Plantas de processo são repletas de instrumentos que, segundo Kadlec, Gabrys e Strandt (2009), tem seus sinais alimentados a modelos preditivos chamados *softsensors*. A vantagem dessa classe de sensor é ser orientada a dados adquiridos na mesma planta, permitindo que o modelo retrate a realidade atual seja com maior fidelidade do que um modelo idealizado (Kadlec; Gabrys; Strandt, 2009). Rohman et al. (2022a) e Zhang et al. (1999) também ressaltam a aceitabilidade do uso de diversos protocolos de redes neurais em *softsensors*. Tais técnicas são de alto valor na engenharia de processos pois, como define Baughman (1995), desenvolver modelos tradicionais baseados em princípios físicos é tipicamente extenso e difícil de se obter resultados assertivos.

As redes neurais artificiais (RNA) são algoritmos que simulam o funcionamento do sistema neural humano, adotando mecanismos de aprendizado e processamento de informações que diferem fundamentalmente da lógica dos computadores digitais convencionais (Haykin, 2001). As redes neurais recorrentes (RNN) são caracterizadas pela sua estrutura fechada que retroalimenta estados passados para seus futuros cálculos (Haykin, 2001) e são particularmente eficientes no aprendizado de sequências (Programmer, 2024). A Rede

Neural Recorrente de Elman (ERNN) se caracteriza pela retroalimentação simples do estado anterior, já as redes *Long Short-Term Memory* (LSTM) estão um passo à frente na complexidade e capacidade pelo acréscimo da memória a longo prazo por meio dos *controller gates* (Geron, 2019).

Na literatura de aprendizado de máquina é muito discutido o problema da "maldição da dimensionalidade". Geron (2019) define esse paradigma como a forma em que uma rede é impactada negativamente pelo excesso de parâmetros. Diante disso, metodologias como o coeficiente de Pearson e análise de componentes principais (PCA) ganham atenção por discriminar variáveis de baixa relevância e por resumir as entradas em menos vetores, respectivamente.


Este trabalho teve como objetivo desenvolver um softsensor baseado em redes neurais recorrentes, capaz de prever a progressão da resistência à troca térmica — parâmetro que, de forma indireta, indica a necessidade de manutenção dos equipamentos de troca térmica. A proposta visa fornecer subsídios confiáveis para a definição de protocolos de manutenção preditiva. Além da precisão nas previsões, buscou-se criar uma ferramenta aplicável em refinarias sem demandar grandes investimentos, mantendo-se compatível com o volume e a complexidade da instrumentação convencional dessas plantas. O modelo foi alimentado com dados reais provenientes de uma planta experimental, permitindo que o sistema enfrentasse os desafios típicos de conjuntos de dados industriais, frequentemente não otimizados.

2. Metodologia

A metodologia será dividida em duas partes. A primeira retratará o processo físico analisado e suas variáveis; a segunda, o tratamento dos dados e processamento das informações no que tange a utilização de redes neurais.

2.1. Processo Analisado

O sistema utilizado está inserido em uma planta piloto multipropósito de um centro de pesquisa em uma refinaria no estado do Paraná, cujo o objetivo é testar a operação de unidades de fluido-craqueamento catalítico (FCC) mediante diferentes cargas e configurações para avaliação do seu rendimento. Será analisada parte da área de condensação que contempla os permutadores P-13A e P-13B, conforme a adaptação do fluxograma de engenharia original da unidade demonstrada na Figura 1.



Fonte: Autoria própria (2025)

Diferentemente dos usos industriais, cujo objetivo é focar na produção de produtos específicos de petróleo, essa planta objetiva o armazenamento dos produtos para posterior análises e balanços de massa. Para reduzir as altas temperaturas de saída do sistema regenerador, diversos condensadores são implementados para facilitar o armazenamento dos produtos.

O sistema chama atenção pela sua quantidade relativamente alta de instrumentos. O sistema é resfriado utilizando água bruta e objetiva a remoção de calor para liquefação da fração pesada de hidrocarboneto da corrente gasosa de entrada do equipamento. A Tabela 1 conta com as seguintes variáveis de processo:

Tabela 1 – Relação entre TAG e variável de processo

TAG	Variável	Descrição
TI-060	T_{G0}	Temperatura de entrada de gás
PI-70	P_{G0}	Pressão de entrada de gás
TI-083	T_{GA}	Temperatura de saída permutador A
TI-081	T_{GB}	Temperatura de saída permutador B
TI-122	T_{H0}	Temperatura de entrada de água
PI-17	P_{H0}	Pressão de entrada de água
TI-080	T_{HA}	Temperatura de saída de água do permutador A
TI-082	T_{HB}	Temperatura de saída de água do permutador B
TI-123	T_{HS}	Temperatura de água a jusante dos permutadores

Fonte: Autoria Própria (2025)

A função a ser predita pelo *softsensor* será a resistência à troca térmica pois é ela que causa o aumento dos custos de operação que leva à necessidade da manutenção. Como feito por Rehman et al. (2023), é possível aferir para um permutador o seu fluxo de calor trocado por meio da Equação 1 e sua diferença de temperatura média logarítmica pela Equação 2, para que seja posteriormente calculada o coeficiente global de troca térmica pela equação 3

$$Q_i(t) = \dot{m}_i C_p (T_{si}(t) - T_o(t)) \quad (1)$$

$$\Delta T_{MLi}(t) = \frac{\Delta T_{1i}(t) - \Delta T_{2i}(t)}{\ln \frac{\Delta T_{1i}(t)}{\Delta T_{2i}(t)}} \quad (2)$$

$$U_i(t) = \frac{Q_i(t)}{A_i \Delta T_{MLi}(t)} \quad (3)$$

Por fim, é calculada a resistência a troca térmica por meio da equação 4, que utiliza o coeficiente global de troca térmica definida pela equação 3.

$$R_{fi}(t) = \frac{1}{U_i(t)} - \frac{1}{U_i(t=0)} \quad (4)$$

2.2. Redes Neurais Recorrentes

Por conta da incrustação se enquadrar como um processo transiente, foram escolhidas duas redes neurais recorrentes de complexidade crescente para avaliação do custo benefício. Diferentemente do trabalho de Jradi, Marvillet e Jeday (2025), que focou na utilização de redes neurais testadas em trabalhos similares, a compatibilidade da teoria do método com o problema investigado foi o principal motivo da escolha da categoria de RNA.

As arquiteturas escolhidas foram Rede Neural Recorrente de Elman (ERNN) e Long *Short-Term Memory Networks* (LSTM). Pautando-se novamente no trabalho de Jradi, Marvillet e Jeday (2025), os autores não levaram em consideração métricas de complexidade da arquitetura de rede ou no seu treinamento. Esta problemática pesou na escolha das arquiteturas do presente trabalho, pois a progressão da complexidade possibilita analisar o custo da utilização de redes mais complexas, não se limitando a monitorar hiperparâmetros como número de nodos ou no tempo de treinamento.

O processamento foi feito inteiramente em python com o auxílio das bibliotecas *scikit learn* para cálculo das métricas de regressão e PCA, *scipy* para as análises de Pearson, *tensorflow* para importar a API *keras* da qual foram extraídas os modelos e arquiteturas de rede, *pandas* para a manipulação de dados, *matplotlib.pyplot* para plotagens, *numpy* para manipulações numéricas e *keras_tuner* para usar o comando do *hyperband*.

Como entradas se tem as variáveis de temperaturas e pressões da Tabela 1, a vazão mássica total de óleo, as vazões de água referentes ao permutador A e B, o valor de resistência à troca térmica atual e dados da vazão de óleo obtidas por análises laboratoriais feitas à posteriori, sendo a composição dos gases de combustão e combustível e os rendimentos em frações de produtos de petróleo de gás combustível (GC), gás liquefeito de petróleo (GLP), gás natural liquefeito (GLN), óleo de ciclo leve (LCO) e óleo diesel (OD).

Em plantas de produção, a medição de densidade é pouco comum, o que pode contrariar os requisitos definidos no objetivo principal da pesquisa. No entanto, essas unidades operam com maior estabilidade composicional e baixa variabilidade ao longo do tempo. Já nas plantas de teste, ocorre o oposto: o foco está na geração de informações, sendo comum o uso de cargas diversificadas. Nessas condições, é essencial que as linhas sejam devidamente instrumentadas para garantir a mensuração dos dados, o que não compromete os propósitos centrais do estudo.

Devido à elevada variabilidade nas correntes de entrada da planta de FCC, foi selecionado o teste com o maior número de horas de operação para alimentar o processo de aprendizado, garantindo maior representatividade das diferentes condições operacionais. Foram extraídos 3.384 pontos de análise, correspondentes a 56,4 horas de operação, considerando uma frequência de aquisição de dados a cada minuto. Como a predição de um único valor futuro não é suficiente para embasar decisões de intervenção, as redes

foram configuradas para prever uma sequência de eventos futuros. Para isso, as saídas de treinamento foram redimensionadas para cobrir um horizonte de 100 minutos à frente, o que representa aproximadamente 3% do tempo total analisado.

Para reduzir a complexidade computacional do processamento, optou-se por ampliar o intervalo entre os pontos a serem previstos. Assim, as saídas passaram a representar os valores de resistência à troca térmica ao longo de 100 minutos futuros, distribuídos em apenas dez pontos, com discretização de um valor a cada dez minutos — embora os dados originais estivessem amostrados a cada minuto. Importante destacar que nenhum dado foi descartado na entrada das redes; a estratégia concentrou-se exclusivamente na predição de valores mais espaçados ao longo do tempo.

Antes de ser alimentado ao modelo, foi feita a análise da correlação de Pearson para determinar as entradas de maior influência no modelo e ignoradas aquelas cujos resultados fossem menores que 0,1 em módulo. Como saída, será obtida a estimativa da resistência à troca térmica no futuro. Logo após, foi feito o uso da metodologia PCA para redução da dimensionalidade dos dados e simplificação do conjunto de treinamento. O tratamento não será realizado nos pontos de resistência à troca térmica pois a alta importância dos seus valores na predição é notória e adicionar ao processamento apenas diluiria a influência nos vetores de entrada. Focou-se em escolher autovetores suficientes para explicar 95% da variância do conjunto. Após, o conjunto de dados foi repartido para treinamento, validação e teste, com respectivas frações de 80, 10 e 10%.

As redes foram testadas com o processamento de *hyperband* iterando modelos de uma camada oculta com os hiperparâmetros descritos na Tabela 2. De forma a auxiliar, foi configurado o critério de parada com 25 épocas sem alteração de no mínimo 0,0001 no erro percentual absoluto médio (MAPE) e foi utilizado o otimizador ADAM.

Tabela 2 – Variáveis de otimização e suas faixas de valor

Variável	Faixa	Passo
Número de neurônios	5 a 1000	5 em 5
Taxa de aprendizado	1e-3, 1e-4 e 1e-5	-
Função de ativação	relu, tanh e sigmoid	-

Fonte: Autoria Própria (2025)

O método Hyperband realiza o treinamento de todas as configurações de modelo até um número predefinido de épocas, eliminando aquelas que apresentam menor capacidade de redução do erro. Como consequência, é comum que o algoritmo favoreça modelos com taxas de aprendizado mais altas, que reduzem o erro rapidamente nas primeiras iterações, em detrimento de configurações com taxas menores que, embora mais estáveis, demoram a apresentar melhorias significativas. Por isso, é recomendável testar as mesmas arquiteturas com taxas de aprendizado reduzidas, a fim de avaliar seu desempenho quando o erro se aproxima de um platô, possibilitando uma análise mais precisa da convergência final.

Em seguida, os cinco conjuntos de hiperparâmetros com melhor desempenho foram selecionados e testados em códigos dedicados, com o objetivo de aumentar a precisão dos resultados. Isso se justifica pelo caráter exploratório do método Hyperband, que visa identificar as configurações mais promissoras. A avaliação dos modelos foi realizada com base no erro percentual absoluto médio (MAPE) e no coeficiente de determinação (R^2). A rede que apresentou o maior valor de R^2 foi submetida à análise por meio de gráficos de correlação, considerando todas as previsões, bem como previsões segmentadas nos intervalos de 0 a 30 minutos, 30 a 60 minutos e 60 a 100 minutos. Essa abordagem permitiu avaliar o impacto da distância temporal na qualidade das previsões.

3. Resultados

A partir da análise de correlação de Pearson, foi possível reduzir o número de variáveis de 39 para 26, conforme apresentado na Tabela 3. Em seguida, aplicou-se a Análise de Componentes Principais (PCA), que resultou em seis componentes principais capazes de explicar, conjuntamente, 94,77% da variância total do modelo.

Tabela 3 – Análise pela correlação de Pearson

Variável	Correlação de Pearson	Variável considerada para o modelo
Vazão mássica de gás	-0.37	Considerada
H ₂ no gás combustível (%vol)	0.23	Considerada
C ₅₊ no gás combustível (%vol)	-0.17	Considerada
CO ₂ no gás combustível (%vol)	-0.20	Considerada
Propano no gás combustível (%vol)	0.17	Considerada
Propeno no gás combustível (%vol)	0.26	Considerada
Iso-Buteno no gás combustível (%vol)	0.13	Considerada
n-Buteno no gás combustível (%vol)	0.09	Desconsiderada
H ₂ S no gás combustível (%vol)	-0.08	Desconsiderada
Butano no gás combustível (%vol)	-0.06	Desconsiderada
Iso-Butano no gás combustível (%vol)	-0.03	Desconsiderada
Terc-2C ₄ no gás combustível (%vol)	-0.16	Considerada
i-Pentano no gás combustível (%vol)	-0.01	Desconsiderada
Isopropano no gás combustível (%vol)	-0.17	Considerada
n-Pentano no gás combustível (%vol)	0.00	Desconsiderada
Butadieno no gás combustível (%vol)	-0.07	Desconsiderada
Etano no gás combustível (%vol)	0.16	Considerada
Eteno no gás combustível (%vol)	0.02	Desconsiderada
O ₂ no gás combustível (%vol)	-0.12	Considerada
N ₂ no gás combustível (%vol)	-0.16	Considerada
CH ₄ no gás combustível (%vol)	0.00	Desconsiderada
CO no gás combustível (%vol)	-0.23	Considerada
CO ₂ no gás combustão (%vol)	0.16	Considerada
O ₂ no gás combustão (%vol)	0.27	Considerada
N ₂ no gás combustão (%vol)	0.02	Desconsiderada
CO no gás combustão (%vol)	-0.21	Considerada
GC (%)	0.23	Considerada
GLP (%)	0.19	Considerada
GLN (%)	0.06	Desconsiderada
LCO (%)	-0.35	Considerada
OD (%)	0.33	Considerada
TI-144060	0.08	Desconsiderada
PI-14470	0.08	Desconsiderada
TI-144083	-0.17	Considerada
TI-144081	0.26	Considerada
TI-144122	0.43	Considerada
TI-144080	0.16	Considerada
TI-144082	0.55	Considerada
TI-144123	0.18	Considerada

Fonte: Autoria Própria (2025)

Entre os quase mil testes realizados com o método Hyperband para cada arquitetura de rede, foram selecionadas as cinco configurações com melhor desempenho. Esses conjuntos de hiperparâmetros estão apresentados na Tabela 4.

Tabela 4 – Seleção de modelos por *hyperband*

Rede	Número de neurônios	Função de ativação	Taxa de aprendizado	MAPE	R ²
LSTM	875	relu	0,001	0,0170	77,15%
LSTM	885	relu	0,001	0,0196	77,48%
LSTM	995	relu	0,001	0,0199	77,23%
LSTM	995	relu	0,001	0,0202	76,30%
LSTM	970	relu	0,001	0,0207	77,09%
ERNN	485	relu	0,001	0,0190	77,76%
ERNN	575	relu	0,001	0,0196	77,43%
ERNN	995	relu	0,001	0,0195	77,27%
ERNN	655	relu	0,001	0,0200	76,67%
ERNN	885	relu	0,001	0,0198	76,80%

Fonte: Autoria Própria (2025)

As configurações de hiperparâmetros obtidas por meio das análises com o método Hyperband foram posteriormente avaliadas individualmente em execuções dedicadas. A Tabela 5 apresenta os conjuntos de hiperparâmetros testados e seus respectivos resultados. As mesmas arquiteturas, ajustadas com taxas de aprendizado menores, e seus desempenhos estão descritos na Tabela 6. Por fim, as cinco configurações com os melhores valores de R² estão organizadas na Tabela 7.

Tabela 5 – Resultados do treinamento dedicado às redes obtidas

Rede	Número de neurônios	Função de ativação	Taxa de aprendizado	MAPE	R ²
ERNN	485	relu	0,001	1,7563	77,07%
ERNN	575	relu	0,001	2,0067	77,35%
ERNN	995	relu	0,001	1,7563	77,07%
ERNN	655	relu	0,001	1,8599	76,70%
ERNN	885	relu	0,001	1,8871	77,26%
LSTM	875	relu	0,001	1,9368	76,74%
LSTM	885	relu	0,001	1,8198	75,89%
LSTM	995	relu	0,001	1,7767	76,98%
LSTM	995	relu	0,001	1,7767	76,98%
LSTM	970	relu	0,001	1,7746	76,54%

Fonte: Autoria Própria (2025)

Tabela 6 – Resultados do treinamento dedicado com menor taxa de aprendizado

Rede	Número de neurônios	Função de ativação	Taxa de aprendizado	MAPE	R ²
ERNN	485	relu	0,0001	1,8020	78,33%
ERNN	575	relu	0,0001	1,8330	78,38%
ERNN	995	relu	0,0001	1,8301	77,64%
ERNN	655	relu	0,0001	1,8155	78,53%
ERNN	885	relu	0,0001	1,8199	77,76%
LSTM	875	relu	0,0001	1,6796	78,07%
LSTM	885	relu	0,0001	1,6743	78,08%
LSTM	995	relu	0,0001	1,7736	77,97%
LSTM	995	relu	0,0001	1,7736	77,97%
LSTM	970	relu	0,0001	1,8055	77,63%

Fonte: Autoria Própria (2025)


Tabela 7 – Resultados do treinamento dedicado com menor taxa de aprendizado

Rede	Número de neurônios	Função de ativação	Taxa de aprendizado	MAPE	R ²
ERNN	655	relu	0,0001	1,8155	78,53%
ERNN	575	relu	0,0001	1,8330	78,38%
ERNN	485	relu	0,0001	1,8020	78,33%
LSTM	885	relu	0,0001	1,6743	78,08%
LSTM	875	relu	0,0001	1,6796	78,07%

Fonte: Autoria Própria (2025)


As Figuras 2, 3, 4 e 5 apresentam os gráficos de correlação referentes à rede finalista.

Figura 2 – Gráfico de correlação referente à predição de todos os pontos futuros




Fonte: Autoria própria (2025)

Figura 3 – Gráfico de correlação referente à predição dos 30 primeiros minutos




Fonte: Autoria própria (2025)

Figura 4 – Gráfico de correlação referente à predição dos 40 a 60 minutos



Fonte: Autoria própria (2025)

Figura 4 – Gráfico de correlação referente à predição dos 30 primeiros minutos



Fonte: Autoria própria (2025)

4. Conclusões

Com isso, foi possível desenvolver um softsensor baseado em redes neurais recorrentes para a predição da resistência à troca térmica, com o objetivo de apoiar estratégias de manutenção em trocadores de calor. As redes de Elman (ERNN) demonstraram

desenvolvimento melhor na previsão dos efeitos desejados, o que pode ser atribuído a diversos fatores.

A principal conclusão que se tira da sutil inferioridade das LSTM para prever a resistência à troca térmica, ao menos conforme os dados trabalhados sugerem, é que a arquitetura de rede mais simples têm resultados superiores por não sofrer com um processamento complexo desnecessário. Portanto, infere-se que a complexidade adicional de arquiteturas como a Long Short-Term Memory (LSTM) se tornou prejudicial ao objetivo.

O fato de a rede com melhor desempenho ser de menor complexidade sugere que vale a pena explorar arquiteturas intermediárias entre ERNN e LSTM, ou até mesmo redes *feedforward* simples. Além disso, os melhores resultados foram obtidos ao reduzir a taxa de aprendizado das configurações inicialmente selecionadas pelo Hyperband. Isso indica que o método, por sua natureza exploratória, pode descartar prematuramente redes com taxas de aprendizado mais baixas, que tendem a convergir de forma mais estável em execuções dedicadas. Assim, realizar novas rodadas de Hyperband específicas para diferentes faixas de taxa de aprendizado pode ser uma estratégia promissora para o sistema analisado.

Cabe destacar que o horizonte de previsão adotado foi limitado a apenas 100 minutos — cerca de 3% do tempo total de operação registrado no banco de dados — devido à quantidade restrita de pontos disponíveis. Essa escolha também se justifica pelo fato de que, nos instantes finais da série temporal, não há dados suficientes para prever valores futuros, o que comprometeria a integridade do treinamento.

Apesar dessa limitação, os resultados obtidos pela melhor rede no intervalo de 0 a 30 minutos apresentaram um coeficiente de determinação (R^2) de 0,87, o que é expressivo considerando que esse intervalo representa apenas 1% do tempo total. A capacidade preditiva da rede diminui gradualmente com o aumento do horizonte temporal, atingindo um R^2 de 0,78 ao final dos 100 minutos.

Outro fator que pode ter influenciado os resultados foi a natureza descontínua dos testes realizados, com pontos não consecutivos e variações nas cargas aplicadas aos equipamentos — variáveis que não foram consideradas nesta etapa da pesquisa. Para superar essa limitação, será necessário generalizar os modelos para incorporar a influência das cargas utilizadas, tornando o softsensor mais flexível e aplicável em diferentes cenários operacionais. Essa é uma das principais direções para trabalhos futuros.

Por fim, os resultados demonstram que a ferramenta proposta representa uma abordagem viável para embasar decisões de manutenção, ao permitir a antecipação de intervenções com base em previsões confiáveis da degradação térmica dos equipamentos. Como o melhor resultado caiu para uma rede de menor complexidade, vale a pena testar redes de complexidade intermediária às redes ERNN e LSTM, ou até mesmo redes *feedforward* simples. Ademais os melhores resultados foram obtidos por reduzir a taxa de aprendizado das configurações obtidas do *hyperband*, que foram testadas no mesmo processo. Isso significa que a *hyperband* foi incapaz de captar o melhor resultado dos aprendizados dedicados, pois as redes de menor taxa de aprendizado foram rapidamente descartadas. Portanto fazer mais *hyperbands* dedicadas a cada taxa de aprendizado parece ser a melhor decisão para o sistema analisado.

Por fim, pode-se dizer que a ferramenta apresenta uma forma viável para embasar a manutenção dos equipamentos por possibilitar saber quando será realmente necessário pará-los.

Referências

- BAUGHMAN, Y. A. L. D. R. **Neural Networks in Bioprocessing and Chemical Engineering**. [S.l.]: Academic Press, 1995.
- BOTTCHER, A. et al. Fouling pathways in emulsion polymerization differentiated with a quartz crystal microbalance (qcm) integrated into the reactor wall. **Macromolecular Reaction Engineering**, 2022.
- CARDOSO, M. N.; FISCH, A. G. Mechanism of fouling in slurry polymerization reactors of olefins. **IEC Research**, 2016.
- GERON, A. **Mãos à Obra: Aprendizado de Máquina com Scikit-Learn TensorFlow**. [S.l.]: Editora Alta Books, 2019. ISBN 978-85-508-0381-4.
- HAYKIN, S. **Redes neurais: Princípios e prática**. [S.l.]: Bookman, 2001. ISBN 978-85-7307-718-6.
- Instituto Brasileiro de Petróleo. **Capacidade de refino e consumo de petróleo por país**. 2022. Disponível em: <https://www.ibp.org.br/observatorio-do-setor/snapshots/capacidade-de-refino-e-consumo-de-petroleo-por-pais/>. Acesso em: 24 set. 2024.
- JONES, D. S. J.; PUJADO, P. R. **Handbook of Petroleum Processing**. [S.l.]: Springer, 2006. ISBN 10 1-4020-2819-9.
- KADLEC, P.; GABRYS, B.; STRANDT, S. Data-driven soft sensors in the process industry. **Computers and Chemical Engineering**, 2009.
- KIPARISSIDES, C. On the elucidation of polymer fouling mechanisms and ethylene decomposition in high-pressure ldp tubular reactors. **Macromolecular Reaction Engineering**, 2022.
- LAGE, D. F. da S. et al. Processos de Refino. 2008.
- NEBLINGER, V. et al. Monitoring polymeric fouling in a continuous reactor by electrochemical impedance spectroscopy. **Chemie Ingenieur Technik**, 2023.
- PROGRAMMER, T. L. **Recurrent Neural Networks: Lstm, gru, and more rnn machine learning architectures in python and theano (machine learning in python)**. [s.n.], 2024. Disponível em: <https://lazyprogrammer.me>. Acesso em: 05 jan 2025.
- RADI, R.; MARVILLET, C.; JEDAY, M. R. Robust intelligent paradigms for estimating fouling in phosphoric acid/steam heat exchanger. **Energy**, 2025.
- REHMAN, O. ur et al. Modeling strategies for crude oil-induced fouling in heat exchangers: A review. **Processes**, 2023.
- ROHMAN, F. S. et al. Application of feed forward neural network for fouling thickness estimation in low density polyethylene tubular reactor. **Materials Today: Proceedings**, 2022.
- ROHMAN, F. S. et al. Nonlinear control of fouling in polyethylene reactors. **ACS Omega**, 2022.
- SHERIFFA, M. Z. et al. An operating economics-driven perspective on monitoring and maintenance in multiple operating regimes: Application to monitor fouling in heat exchangers. **Chemical Engineering Research and Design**, 2022.
- VANDEWALLE, L. A. et al. Dynamic simulation of fouling in steam cracking reactors using cfd. **Chemical Engineering Journal**, 2017.
- ZHANG, J. et al. Estimation of impurity and fouling in batch polymerisation reactors through the application of neural networks. **Computers Chemical Engineering**, 1999.