


Metamodelagem do processo de deposição em pré-processamento de óleo para otimizar a limpeza da rede de trocadores de calor: Uma revisão sistemática

 <https://doi.org/10.56238/sevenced2024.003-009>

Adroaldo Santos Soares

Mestre Senai Cimatec

E-mail: adroaldo.soares@ba.estudante.senai.br

Oberdan Rocha Pinheiro

Doutor, Senai Cimatec

E-mail: oberdan.pinheiro@fieb.org.br

Marcelo Albano Moret Simões Gonçalves

Doutor Senai Cimatec

E-mail: mamoret@gmail.com

Fabio de Sousa Santos

Mestre Senai Cimatec

E-mail: fabio11@ba.estudante.senai.br

Fernando Luiz Pellegrini Pessoa

Doutor Senai Cimatec

E-mail: fernando.pessoa@fieb.org.br

RESUMO

Identificar e analisar possíveis técnicas de metamodelagem para otimizar o desempenho de trocadores de calor no pré-processamento de óleo do ponto de vista do processo de deposição é de grande importância para avaliar o desempenho de trocadores de calor em diferentes configurações de operação e manutenção, a fim de aumentar sua eficiência energética, uma vez que durante a operação de redes de trocadores de calor, a deposição nas superfícies de troca de calor é comum, reduzindo sua eficácia. Neste artigo, uma revisão sistemática foi realizada para estudar as técnicas de metamodelagem e ferramentas de otimização utilizadas. Os resultados do estudo mostraram que existem algumas técnicas utilizadas como: Redes Neurais Recorrentes (RNN); Perceptron Multicamadas (MPL); Memória de Curto Prazo (LSTM); Unidade Recorrente Fechada (GRU); Rede Neural Convolutiva Recorrente (RCNN), e ferramentas que serão abordadas neste estudo.

Palavras-chave: Metamodelagem, Inteligência artificial, Trocadores de calor, Processo de deposição.

1 INTRODUÇÃO

O pré-processamento de petróleo é uma etapa essencial na produção de petróleo e gás. No entanto, durante esse processo, pode ocorrer a deposição de sólidos em trocadores de calor (fig. 1), e a obstrução de tubos e equipamentos (fig. 3,4,5), além de reduzir a eficiência do processo, representa um problema significativo a ser gerenciado. O estudo da previsão e minimização da deposição é, portanto, de grande importância para garantir a segurança e eficiência da produção (Lira et al, 2022). A metamodelagem é uma técnica amplamente utilizada na engenharia de processos, permitindo análises mais eficientes e otimização de processos. Neste trabalho, propomos uma revisão sistemática da aplicação da metamodelagem ao processo de deposição no pré-processamento de petróleo (fig. 2). Espera-se que este trabalho possa contribuir para um caminho para a metamodelagem na otimização de redes de trocadores de calor, uma vez que o uso de redes neurais recorrentes (RNNs), como MPL (Multi-Layer Perceptron) ou LSTM (Long Short-Term Memory), pode ser uma abordagem promissora para metamodelagem no processo de deposição em pré-processamento de óleo. RNNs são modelos de aprendizado de máquina capazes de processar dados sequenciais, o que é particularmente útil no caso de processos de deposição que evoluem ao longo do tempo. Com relação ao projeto de redes neurais recorrentes (RNN), há uma série de opções que podem ser exploradas e algumas sugestões são: Multi-layer Perceptron (MLP); Memória de Curto Prazo (LSTM); Unidade Recorrente Fechada (GRU); Rede Neural Convolutiva Recorrente (RCNN). Cada um deles tem suas vantagens e desvantagens, e o modelo mais adequado pode variar de acordo com o caso em questão. É importante avaliar o desempenho de diferentes modelos em relação aos dados disponíveis antes de escolher o modelo final para metamodelagem. Também é importante ter em mente que a escolha do design da rede neural é apenas uma parte do processo de metamodelagem. Também é necessário definir a arquitetura da rede (ou seja, o número de camadas, o número de neurônios em cada camada, etc.), a função de ativação a ser usada em cada camada, o método de treinamento e otimização dos parâmetros, entre outros aspectos. Uma vez que a rede neural tenha sido definida e otimizada, ela pode ser usada para fazer previsões sobre o processo de deposição. A rede neural pode ser treinada com dados históricos ou simulados do processo de deposição e dos parâmetros do sistema de troca de calor, e pode ser usada para fazer previsões sobre o desempenho do sistema sob diferentes condições operacionais. Vários algoritmos estão disponíveis para o treinamento da rede neural, sendo os mais comuns: Backpropagation; Descida de gradiente; Levenberg-Marquardt e Adam (Zabihi, et al, 2019). Quanto à definição da arquitetura da rede neural, alguns algoritmos populares são: Redes neurais convolucionais (CNN); Redes neurais recorrentes (RNN) e Autoencoders (Zabihi et al, 2019).

Figura 1: Figura 2:



INCROPERA, F. P. & WITT, D. P., Fundamentos de Transferência de Calor e Massa, terceira edição, 1998.

Figura 3;

Figura 4;

Figura 5;



Incrustação de óleo bruto em PHTs Shell e Tube; Lado tubo; Lado da concha (F. Coletti et al, 2015)

2 METODOLOGIA

A revisão sistemática é um tipo de investigação científica. Essas revisões são consideradas estudos observacionais retrospectivos ou experimentais que recuperam e analisam criticamente a literatura. Eles testam hipóteses e visam levantar, reunir, avaliar criticamente e sintetizar os resultados de vários estudos primários (Donato et al, 2019). A pesquisa foi realizada no período de 2017 a 2023 de publicações nacionais e internacionais que estudam as técnicas de metamodelagem utilizadas para otimizar o desempenho dos trocadores de calor no pré-processamento do petróleo, do ponto de vista do processo de deposição com vistas ao aumento da eficiência energética. Para atingir esse objetivo, foi necessária a utilização de uma metodologia de pesquisa para ter acesso aos estudos atuais. Toda a pesquisa foi realizada em sites de referência, com reconhecimento acadêmico consolidado e periódicos e repositórios internacionais e nacionais, possibilitando os estudos sobre Redes Neurais Recorrentes (RNN); Perceptron Multicamadas (MPL); Memória de Curto Prazo (LSTM); Unidade Recorrente Fechada (GRU); Rede Neural Convolutiva Recorrente (RCNN), e as ferramentas que serão abordadas neste estudo. Nesse processo de revisão sistemática, foram utilizadas as bases de dados Mendeley, Google Scholar e Dimensios para levantamento dos artigos a serem estudados, seguido de seleção com base no fator de impacto da revista, e organizados em grupos. Após a coleta dos dados e seleção do material, foram encontrados noventa e dois artigos, todos pesquisados utilizando os descritores "metamodelling in the deposition", "optimization of heat exchangers", "metamodels and simulation in petrochemicals", "LSTM (long short term memory) networks and oil" e "MPL (mult lear preceiver) and oil". Após a mineração da base de artigos a serem utilizados, esse

número foi reduzido para 61 artigos. Esta pesquisa encontrou importantes técnicas de metamodelagem para otimizar o desempenho de trocadores de calor no pré-processamento de óleo, do ponto de vista do processo de deposição.

3 DISCUSSÃO

3.1 METAMODELAGEM NO PRÉ-PROCESSAMENTO DE ÓLEO

Uma revisão das técnicas baseadas em metamodelagem de última geração em apoio à otimização do projeto, incluindo aproximação de modelos, exploração espacial de projeto, formulação de problemas e resolução de vários tipos de problemas de otimização para enfrentar os desafios e o desenvolvimento futuro de metamodelagem em apoio ao projeto de engenharia, é necessária para ser analisada e discutida (Amaral et al, 2021). Diferentes plataformas de software para simulação, controle e supervisão de processos são utilizadas para projetar e implementar processos complexos da indústria petroquímica. Um erro comum cometido em cálculos de processo é tratar os problemas em uma base pontual e não como um intervalo, sem considerar as incertezas associadas aos parâmetros de medição (Kalid et al, 2012). É necessário conhecer a importância da confiabilidade dos dados e entender como pequenas incertezas nessas informações podem afetar significativamente o desempenho técnico e econômico de uma planta industrial (Santana et al, 2021). A literatura levantada apresenta uma proposta de infraestrutura MDE (Model-Driven Engineering) para o desenvolvimento de aplicações de operação, controle e simulação na indústria petroquímica, mais especificamente no campo da definição de classes de equipamentos de plantas industriais (fig. 2), onde a infraestrutura, denominada M4PIA (Model-Driven Engineering for Petrochemical Industry Automation), é composta por três metamodelos em dois níveis de abstração (independente e dependente da plataforma alvo sobre a qual a aplicação será implementada) e os mapeamentos necessários para transformar automaticamente o sistema modelado no mais alto nível de abstração em um modelo específico da plataforma e, em seguida, gerar automaticamente o código-fonte da aplicação a ser usado na implementação na plataforma definida. Esta análise propõe duas plataformas de software: MPA, para aplicações de operação, automação e controle de processos industriais; e EMSO, para simulação de processos petroquímicos. Esta aplicação serve para ilustrar a utilização das soluções propostas, bem como para permitir uma análise sistemática da proposta em termos das características desejadas para uma infraestrutura de MDE (Damo et al, 2019). Como mencionado, trabalhos anteriores propuseram a infraestrutura denominada Model-Driven Engineering for Petrochemical Industry Automation (M4PIA), que possibilita a representação de plantas industriais utilizando modelos diferenciados, compatíveis e orientados a objetos. Através de transformações de modelos, a infraestrutura suporta a geração automática de código a partir de um modelo de abstração de alto nível para plataformas de software específicas. A literatura pesquisada propõe o uso da

engenharia reversa baseada em modelos na infraestrutura M4PIA, de modo que a partir de um modelo de sistemas legados desenvolvidos no nível mais baixo, seja possível, por meio das transformações Text-to-Model (T2M) e Model-to-Model (M2M), obter um modelo em um nível mais alto de abstração. A infraestrutura do M4PIA suporta duas plataformas de domínio amplamente utilizadas na indústria petroquímica: o Módulo de Procedimentos Automatizados (MPA), para aplicações de operação, automação e controle de processos industriais; e o Ambiente de Modelagem, Simulação e Otimização (EMSO), para simulação de processos petroquímicos. A solução mostrou-se adequada para engenharia reversa, facilitando a reengenharia de sistemas legados na indústria petroquímica (Cruz et al, 2021).

3.2 AVALIAÇÃO DE DESEMPENHO, PROCESSO DE DEPOSIÇÃO E OTIMIZAÇÃO DE TROCADORES DE CALOR

Os trocadores de calor são equipamentos utilizados na indústria para a troca de calor entre fluidos em diferentes temperaturas que não estão em contato direto. Na indústria de refino, eles são usados para resfriamento de gases, condensação, aquecimento ou em processos de tratamento como quebra de emulsões (Abbasi et al, 2020). A troca de calor entre fluidos de diferentes temperaturas é de suma importância para os processos industriais e tem muitas aplicações na engenharia. A manutenção preditiva utiliza diversos métodos para monitorar a condição dos equipamentos utilizados nas plantas industriais (Araújo et al, 2021). O uso eficiente da energia é um fator crítico para as indústrias e pode ser um processo economicamente atrativo e competitivo. Um dos principais fatores que fazem com que os trocadores reduzam sua eficiência energética e, conseqüentemente, o coeficiente global de transferência de calor é a incrustação (fig.3,4,5), definida como a formação de depósitos indesejáveis na superfície dos equipamentos de processo (Valle, 2012). Outro ponto a ser levado em conta é a questão ambiental, uma vez que a busca pelo ótimo global e por técnicas mais robustas e eficientes tem retardado um pouco o desenvolvimento de aplicações para uso prático na indústria (Calixto et al, 2021). O problema da incrustação em trocadores de calor e perda de eficiência no processo tem sido objeto de diversos estudos e não poderia ser diferente no refino de petróleo, principalmente no pré-aquecimento de petróleo (Júnior et al, 2020). Nesse sentido, levando em conta as incertezas e pensando na deposição (Santana et al, 2021), o uso de aparatos experimentais laboratoriais tem sido bastante comum para o desenvolvimento de modelos, porém a aplicação desses modelos na avaliação e predição do fenômeno em plantas industriais encontra obstáculos (Santamaria et al 2018), uma vez que os modelos disponíveis na literatura não chegam perto de prever satisfatoriamente o comportamento de deposição em trocadores industriais. As informações necessárias para aplicar os modelos aos dados operacionais são necessárias para gerar modelos precisos e rápidos para otimizar o projeto (Krzywanski et al 2019), controle e operação de trocadores

de calor casco e tubo (STHE) sujeitos a incrustação. Até o momento, os esforços de pesquisa têm se concentrado principalmente na incrustação lateral do tubo. As técnicas propostas para incrustação lateral do casco limitam-se a: Modelos mecanísticos termo-hidráulicos com análise de fluxo simples (FSA); Modelos de dinâmica dos fluidos computacional (CFD). O primeiro ignora a dinâmica do fluxo no lado do casco e o segundo não pode prever quantitativamente a incrustação, além de ser computacionalmente muito pesado e não pode ser usado para otimização e controle. É importante combinar os benefícios dos métodos FSA e CFD criando um Modelo Compartimental (MC) híbrido (Godke et al, 2018). As características dinâmicas da incrustação podem ser incluídas no projeto e no procedimento de retrofit, de modo que a incrustação possa ser mitigada simultaneamente através de ciclos de operação, manipulando sistematicamente as condições de operação e otimizando os cronogramas de limpeza.

3.3 O USO DE REDES NEURAIAS RECORRENTES (RNN), MPL (MULTI LEARNER PRECEPTOR) E LSTM (MEMÓRIA DE CURTO PRAZO) PARA UMA ÓTIMA CAMPANHA DE LIMPEZA DA REDE DE TROCADORES DE CALOR

Uma maneira eficiente de determinar quando as paradas de limpeza precisam ser feitas é por meio do uso de Redes Neurais Artificiais (RNAs), que são técnicas de modelagem matemática baseadas no cérebro humano para resolver dos problemas mais simples aos mais complexos. Para isso, é necessário controlar a evolução da incrustação em um trocador de calor treinando Redes Neurais Artificiais e testando os tipos de estratégias e estruturas que melhor realizam a simulação para esse sistema (Júnior et al, 2019). Aqui está um exemplo de pesquisa onde, com os dados obtidos de um trocador shell-and-tube, que serve para resfriar propano por meio de água de resfriamento, localizado em uma Indústria Petroquímica em São Paulo, onde as variáveis de entrada da RNA foram as temperaturas de entrada do fluido quente e frio e a vazão de saída do fluido frio, e, a variável de saída gerada pela rede foi a vazão de saída de fluido frio e a estrutura e o método de otimização da RNA utilizados foram, respectivamente, MLPs (Multilayer Perceptron) ou perceptron multicamadas com uma ou duas camadas ocultas e os algoritmos de retropropagação com Marquardt Levenberg e Marquardt Levenberg com regularização bayesiana (F. Coletti et al, 2015). Duas estratégias foram utilizadas para a simulação. Na primeira, a temperatura de entrada anterior dos fluidos frios e quentes e a saída anterior e atual do fluido frio foram alimentadas na rede, enquanto a saída foi a saída subsequente do fluido frio. Essa estratégia não obteve sucesso, pois o melhor valor do coeficiente de correlação (R^2) para a simulação foi de 0,3362. A segunda estratégia utilizou as temperaturas atuais e vazões como entrada da rede e a vazão subsequente como saída. Três modelos foram testados e o que melhor representou o sistema industrial estudado foi a estrutura '3-30-30-1' com função de treinamento de Levenberg Marquardt e função de transferência sigmoideal tangente nas camadas intermediárias e


linear na camada de saída. O R2 para esse modelo foi de 0,9435, o erro médio foi de 155,10% e a mediana foi de 13,31%. O objetivo do estudo foi alcançado, pois as simulações de rede representaram bem o comportamento dos dados experimentais, ou seja, comprovou-se que a RNA pode ser usada para prever incrustações em trocadores de calor industriais (Godke et al, 2018)]. Esta revisão sistemática também aponta que o uso de Redes Neurais Recorrentes (RNN), MPL (preceptor multiaprendizagem) e LSTM (memória de curto prazo longo) tem ampla aplicação em petroquímica, como mencionado acima e como também pode ser visto com os dois estudos seguintes, onde o primeiro trata de uma forma alternativa de prever a distribuição da saturação de água em reservatórios com um método de aprendizado de máquina (Sheikhoushaghi, et al, 2022). A memória de curto prazo longa (LSTM) foi usada para construir um modelo preditivo para prever a distribuição da saturação da água. O conjunto de dados resultante do monitoramento e simulação de um reservatório real foi utilizado para treinar e testar o modelo. O modelo de dados após o treinamento foi validado e utilizado para prever a distribuição da saturação de água, a distribuição de pressão e a produção de óleo. A Rede Neural Recorrente (RNN) padrão e a Unidade Recorrente Fechada (GRU), que são métodos populares de aprendizado de máquina, também foram comparadas com o LSTM para melhor previsão da saturação de água. Os resultados mostram que o método LSTM tem um bom desempenho na previsão da saturação de água com um desvio relativo absoluto (TARA) médio geral abaixo de 14,82%. Em comparação com outros métodos de aprendizado de máquina, como GRU e RNN padrão, o LSTM tem melhor desempenho na precisão do cálculo, de modo que o estudo apresentou uma maneira alternativa para a previsão rápida e robusta da distribuição de saturação de água no reservatório (Zhang et al, 2019). A segunda pesquisa adota uma abordagem comparativa para encontrar uma rede apropriada para prever a taxa de produção de petróleo de um campo de petróleo iraniano. O desempenho de várias redes como Rough Neural Network (Rough NN), Long-Short-Term Memory (LSTM), Artificial Neural Network (ANN) com camada apenas densa e 1D Convolutional Neural Network (CONV-1D) foi monitorado através da investigação de vários parâmetros estatísticos como valor do erro, cross plot de dados reais e dados previstos e distribuição do erro. Uma combinação de cinco parâmetros de entrada estáticos e dinâmicos foi tomada como entrada para o modelo. Todas as redes foram treinadas em 80% de todos os dados (10.025 pontos) e o restante foi dividido igualmente para teste e validação. O maior desempenho foi observado nos resultados de Rough-NN com coeficiente de determinação de 0,82 para prever os dados do teste. Os resultados mostraram acurácia ligeiramente inferior à do Rough-NN para o caso CONV-1D ($R^2 = 0,79$). No entanto, o pior desempenho foi em relação à RNA e ao LSTM, onde seu R-quadrado ficou em torno de 0,54 (Sheikhoushaghi et al, 2022).

4 RESULTADOS

Analisando o Gráfico 1, que mostra a relação entre o número de **publicações e os periódicos**, observa-se que, em geral, as universidades têm publicado maior número de artigos(25) sobre os temas propostos nos descritores. O Journal of Petroleum Science and Engineering(9) também publicou um bom número de artigos.

4.1 REVISTAS X NÚMERO DE PUBLICAÇÕES


Gráfico 1:
number of publications versus magazines



Analisando o Gráfico 2, que mostra a relação entre o número de publicações e o **ano** de publicação, verifica-se que 2017 teve um número significativo de publicações, enquanto 2019 e 2021 tiveram menos publicações. Refira-se ainda que, em 2023, houve apenas uma publicação sobre o tema.

4.2 NÚMERO DE PUBLICAÇÕES X ANO

Gráfico 2:
Number of publications versus year



5 CONCLUSÃO

Esta revisão foi um processo de busca, análise e descrição de um corpo de conhecimento e mostra técnicas de otimização no processo de deposição de redes de trocadores de calor usando inteligência artificial. Encontramos evidências robustas de que a literatura atual no período descrito de 2017 a 2023 apresenta expressiva qualidade de pesquisa utilizando redes neurais recorrentes, especialmente MLP e LSTM, e o uso dessas técnicas requer testes extensivos com diferentes configurações para obter experimentalmente o modelo que melhor se adapta ao problema[5]. Assim, o objetivo de levantar, reunir e avaliar criticamente, sintetizando os resultados de vários estudos primários sobre a temática proposta, foi alcançado. A investigação sobre a utilização da inteligência artificial na otimização do processo de deposição numa rede de permutadores de calor, especialmente no que diz respeito aos benefícios económicos que advêm das ligações entre as áreas de concepção e otimização da operação, requer a realização de trabalhos adicionais que proporcionem a simulação e otimização com um maior número de ramos, e que permite a otimização de toda a rede, utilizando inteligência artificial para trazer maiores benefícios a diversas plantas petroquímicas.

Uma lacuna surgiu após este estudo, e uma proposta inédita será desenvolvida com um maior número de ramificações da rede de trocadores de calor, utilizando metamodelagem e visando prever deposição, com o uso de inteligência artificial, em um modelo híbrido MLP+LSTM+Transformer, pois dentre o que tem sido visto na literatura de pesquisa, não existe um metamodelo para prever com precisão a deposição que trabalhe com uma grande quantidade de dados reais e um longo conjunto de dados que sinaliza características da diminuição da vazão e redução da troca de calor a taxas inferiores às especificadas na planta em operação, a fim de treinar a rede em boas condições operacionais e em operação crítica. Dessa forma, teremos boa previsibilidade e aviso prévio para ações de operação e manutenção. Este conjunto de dados será obtido da bateria de trocadores de calor da BPA com 7 ramificações (A,B,C,D,E,F,G) em uma refinaria no sudeste do Brasil, totalizando 25 trocadores de calor casco e tubo.

Portanto, a inovação deste estudo baseia-se nos desafios associados às características técnicas e especificidades para otimizar o desempenho de trocadores de calor no pré-processamento de óleo. Com base na revisão realizada, o trabalho proposto proporcionará um passo à frente em relação ao estado da arte. A manutenção inteligente de trocadores de calor, baseada em deep machine learning, deve preencher uma lacuna acadêmica nessa linha temática, indicando a forma mais eficaz de realizar determinada atividade e auxiliando na tomada de decisão.



REFERÊNCIAS

Amaral, João Victor Soares Do. *Metamodel-Based Optimisation: An Approach to Metamodelling in Discrete Event Simulation*. 2021. 148 f. Federal University of Itajubá, 2021.

Araújo, Álvaro Souza de; Rocha, Oberdan Pinheiro; Santos, Alex Álisson Bandeira; Computational model for condition analysis and monitoring of electric motors, p. 303-310 .In: VII International Symposium on Innovation and Technology. São Paulo: Blucher, 2021. Calixto, EE da S., Pessoa, FLP, Mirre, RC., Hybrid Approach in Total Site Water Networks / Hybrid Approach in Total Site Water Networks. Brazilian Journal of Development , <https://doi.org/10.34117/bjdv7n8-228>, 2021.

Cruz, Marcus Vinícius Silva; Model-based reverse engineering for plant simulation, control and operation applications in the petrochemical industry; UFSC - Automation and Systems Engineering degree programme, 2021.

Damo, Thaise Poerschke; Universidade Federal de Santa Catarina, Centro Tecnológico, Postgraduate Programme in Automation and Systems Engineering, Florianópolis, 2019.

Donato, Helena; Donato, Mariana. Steps to carry out a systematic review. *Acta medica portuguesa* , v. 32, n. 3, p. 227-235, 2019.

F. Coletti, B. D. Crittenden, and S. Macchietto, "Chapter one- introduction," in *Crude Oil Fouling*, Boston: Gulf Professional Publishing, 2015, pp. 1-22. Universidade de São Paulo - Instituto de Psicologia - Biblioteca Dante Moreira Leite -Av. Prof. De Mello Moraes, 1721 Bloco C - Cep 05508-030 - SP, <http://www.ip.usp.br/portal/images/biblioteca/revisao.pdf>

Godke, Larissa Mota; Parise, Barbara de França; Development of a neural virtual sensor for predicting fouling in heat exchangers Federal University of São Paulo, 2018.

Júnior, Antonio Rimaci Miguel; Comparative performance analysis of semi-empirical models for predicting deposition in oil refinery heat exchanger batteries; Postgraduate Programme, SENAI CIMATEC University Centre, Salvador, 2020.

Júnior, Lima; Euler, Gladson; Development of a neural virtual sensor for fouling prediction in heat exchangers; Federal de Campina Grande, 2019.

Kalid, Ricardo A.; Martins. Márcio A. F.; Classical methods for evaluating measurement uncertainty in multivariable systems; *Revista Controle & Automação*/Vol.23 no.4/July and August 2012.

Krzywanski, Jaroslaw; A general approach in optimisation of heat exchangers by bio-inspired artificial intelligence methods; *Energies*, 2019.

Lira, Daniel Andrade de; Junior, Antonio Rimaci Miguel; Mirre, Reinaldo Coelho; Souza, Ana Lucia Barbosa de; Pessoa, Fernando Luiz Pellegrini; Analysis of a deposition model in heat exchangers applied to an oil preheating battery; SPE Flow Assurance Technology Congress; Rio de Janeiro, Brazil, November, 2022.

Santamaria, Federico Lozano; Macchietto, Sandro; 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, Leonardo Oliveira Santos de; Calixto, Ewerton Emmanuel da Silva; Pessoa, Fernando Luiz Pellegrini; Uncertainty analysis applied to the calculation of the bubble temperature of mixtures, p. 113-120 . In: VII International Symposium on Innovation and Technology. São Paulo: Blucher, 2021.

Sheikhoushaghi, Amin; Gharaei, Narges Yarahmadi; Nikoofard, Amirhossein; Application of Rough Neural Network to forecast oil production rate of an oil field in a comparative study; Journal of Petroleum Science and Engineering, 2022.

Smaili, F.; Vassiliadis, V. S.; Wilson, D. I. Optimisation of cleaning schedules in heat exchanger networks subject to fouling. Chem. Eng. Comm., v. 189, p. 1517-1549, 2002.

Zabihi , Reza; Mowla, Dariush; Karami, Hamid Reza; Artificial intelligence approach to predict drag reduction in crude oil pipelines; Journal of Petroleum Science and Engineering, 2019.

Zhang, Qitao; Wei, Chenji; Wang, Yuhe; Du, Shuyi; Zhou, Yuanchun; Potential for prediction of water saturation distribution in reservoirs utilising machine learning methods; Energies, 2019.