

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

LUCAS VILLA

**O USO DO APRENDIZADO DE MÁQUINA NO MONITORAMENTO DE
INCRUSTAÇÕES EM TROCADORES DE CALOR: UMA REVISÃO SISTEMÁTICA
DA LITERATURA**

FRANCISCO BELTRÃO

2023

LUCAS VILLA

**O USO DO APRENDIZADO DE MÁQUINA NO MONITORAMENTO DE
INCRUSTAÇÕES EM TROCADORES DE CALOR: UMA REVISÃO SISTEMÁTICA
DA LITERATURA**

**The use of machine learning in fouling monitoring in heat exchangers: a
systematic review of the literature**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título de
Bacharel em Engenharia Química da Universidade
Tecnológica Federal do Paraná (UTFPR).

Orientador(a): Claiton Zanini Brusamarello

FRANCISCO BELTRÃO

2023



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

O USO DO APRENDIZADO DE MÁQUINA NO MONITORAMENTO DE INCRUSTAÇÕES EM TROCADORES DE CALOR – UMA REVISÃO SISTEMÁTICA DA LITERATURA

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia Química da Universidade Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 06/Dezembro/2023

Claiton Zanini Brusamarrello
Doutorado em Engenharia Química
Universidade Federal de Santa Catarina

Andriele De Pra Carvalho
Doutorado em Administração
Universidade Tecnológica Federal do Paraná

Vilmar Steffen
Doutorado em Engenharia Química
Universidade Estadual de Maringá

“A folha de aprovação assinada encontra-se na Coordenação do Curso”

FRANCISCO BELTRÃO
2023

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão aos meus pais, Adir e Sinésia, e à minha irmã, Raquel, por todo o apoio. Agradeço por estarem sempre presentes nos momentos desafiadores e nos triunfos que celebramos juntos durante este período. A todos os meus amigos que fiz durante a faculdade e que compartilharam risos e momentos especiais ao longo desta jornada acadêmica, meu mais sincero obrigado. Um agradecimento especial ao meu professor orientador, Claiton, cuja orientação sábia e feedback construtivo foram fundamentais para o desenvolvimento deste trabalho.

RESUMO

A pesquisa teve como objetivo descobrir quais são os principais métodos de aprendizado de máquina utilizados para a fiscalização de incrustações em trocadores de calor, por meio de uma revisão sistemática. Além disso, buscou-se analisar os desafios relacionados ao uso desses algoritmos nessa inspeção, e foram também examinadas as perspectivas futuras para essa área de pesquisa. O estudo fundamentou-se no uso do software StArt para auxiliar na elaboração do protocolo da revisão. Como proposta de protocolo, foram empregadas quatro bases de dados - SCOPUS, Science Direct, IEEE e Web of Science - para a busca de artigos. Dessa maneira, foram obtidos sete artigos relevantes, seguindo o protocolo estabelecido. Entre os métodos mais comuns para o monitoramento das incrustações, destacam-se o SVM e k-NN, seguidos pela árvore de decisão. Os algoritmos LSTM e NARX, juntamente com os preditores de longo e curto prazo, sobressaíram-se como os mais bem-sucedidos, seguidos pelos algoritmos GPR, SVM, k-NN e IGWO-SVR. Entretanto, os estudos avaliados ainda se encontram em fase de teste e não foram aplicados em trocadores de calor reais. Portanto, num futuro próximo, espera-se que haja investimentos nessa área, possibilitando a efetiva implementação prática desses algoritmos.

Palavras-chave: revisão sistemática; monitoramento; aprendizado de máquina; incrustação.

ABSTRACT

The research aimed to discover the main machine learning methods used to inspect fouling in heat exchangers, through a systematic review. Furthermore, we sought to analyze the challenges related to the use of these algorithms in this inspection, and future perspectives for this area of research were also examined. The study was based on the use of StArt software to assist in the preparation of the review protocol. As a protocol proposal, four databases were used - SCOPUS, Science Direct, IEEE and Web of Science - to search for articles. In this way, seven relevant articles were obtained, following the established protocol. Among the most common methods for monitoring fouling, SVM and k-NN stand out, followed by the decision tree. The LSTM and NARX algorithms, along with the long and short-term predictors, stood out as the most successful, followed by the GPR, SVM, k-NN and IGWO-SVR algorithms. However, the studies evaluated are still in the testing phase and have not been applied to real heat exchangers. Therefore, in the near future, it is expected that there will be investments in this area, enabling the effective practical implementation of these algorithms.

Key-words: systematic review; monitoring; machine learning; fouling.

LISTA DE ABREVIATURAS E SIGLAS

ML	Aprendizado de Máquina
IA	Inteligência Artificial
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
k-NN	<i>K-Nearest Neighbours</i>
ANN	<i>Artificial Neural Network</i>
GPR	<i>Gaussian Process Regression</i>
RS	Revisão Sistemática
UFSCar	Universidade Federal de São Carlos
LaPES	Laboratório de Pesquisa em Engenharia de Software
SNIP	<i>Source Normalized Impact per Paper</i>
PFHE	Trocador de Placas de Fluxo Cruzado
NN	<i>Neural Network</i>
NARX	<i>Nonlinear Auto-Regressive Exogenous Model</i>
LSTM	<i>Long Short-Term Memory</i>
ORC	<i>Organic Rankine Cycle</i>
PCA	Análise de Componentes Principais
GMM	<i>Gaussian Mixture Model</i>
IGWO-SVR	<i>Grey Wolf</i>
EM	<i>Expectation Maximization</i>
ECS	Sistema de Controle Ambiental
ARIMA	Média Móvel Integrada Autorregressiva
TCL	Trocador de Calor Latente
IEEE	Biblioteca Digital do Instituto de Engenheiros Eletricistas e Eletrônicos

Sumário

1	INTRODUÇÃO	8
1.1	Algoritmos de aprendizado de máquina	9
2	MÉTODO	10
2.1	Questões da pesquisa	12
2.2	Estratégia de busca e seleção dos estudos primários	13
2.3	Critérios e procedimentos para seleção dos estudos	14
3	RESULTADOS E DISCUSSÃO	17
3.1	Descrição dos estudos primários	17
3.1.1	Fontes de Pesquisa	21
3.2	Aplicação dos Critérios de Inclusão e Exclusão	21
3.2.1	Valores de SNIP	25
3.2.2	Ano de publicação	25
3.2.3	Artigos sem acesso aos portais de periódicos.....	27
3.3	Questões de pesquisa	27
3.3.1	- Quais são as técnicas de aprendizado de máquina mais utilizadas para detecção de incrustação em trocadores de calor na engenharia química?.....	30
3.3.2	- Qual é o desempenho dos algoritmos de aprendizado de máquina em detectar as incrustações em TCL frente aos métodos usuais?	32
3.3.3	- Quais são os principais desafios a serem enfrentados na utilização do aprendizado de máquina para a detecção de incrustação em trocadores de calor na engenharia química?	34
3.3.4	- De que maneira as características do sistema influenciam a eficácia da detecção de incrustação por meio do uso de aprendizado de máquina?.....	36
3.3.5	- Quais são as lacunas específicas na literatura atual e para onde a área pode avançar na aplicação do aprendizado de máquina na detecção de incrustação em trocadores de calor na engenharia química?	36
4	CONCLUSÕES E PESQUISAS FUTURAS	38
	REFERÊNCIAS	40

1 INTRODUÇÃO

Para Bergman e Lavine (2019) um trocador de calor é o dispositivo responsável pela transferência de calor entre dois fluidos, que estão em temperaturas distintas e são separados por uma parede sólida, permitindo assim sua troca térmica. Ainda segundo Kakaç; Liu; Pramuanjaroenkij, (2020) trocadores de calor tem aplicações em áreas variadas, como na geração de energia, nos processos químicos, nas engenharias ambiental, eletrônica e de alimentos. Esse equipamento é amplamente empregado em diversas indústrias, desempenhando um papel fundamental no resfriamento e aquecimento de fluidos, resultando na otimização dos processos. Em decorrência da crise energética global, a eficiente recuperação ou dissipação de calor tornou-se uma meta altamente valorizada pelos engenheiros que trabalham com esse equipamento (Kah Hou et al., 2016).

No entanto, a deposição indesejada de material nas superfícies de transferência de calor (incrustação) reduz drasticamente a eficiência dos trocadores de calor, levando não apenas a uma maior demanda de serviços externos, mas também a problemas operacionais, rendimento reduzido e desligamento periódico de unidades individuais ou inteiras para limpeza (Diaz-Bejarano et al., 2019). Algumas alternativas de remediar as incrustações incluem o revestimento da superfície, uso de agentes antiincrustantes, modificações nas condições de operação dos trocadores de calor e limpezas periódicas (químicas ou mecânicas) das unidades (Santamaria; Macchietto, 2020). No entanto, em 2014, uma estimativa apontou que as indústrias nos Estados Unidos enfrentavam um custo econômico anual de aproximadamente US\$ 14 bilhões devido à incrustação em trocadores de calor (Sheriff et al., 2022).

Para minimizar a incrustação e aumentar a eficiência energética, é necessário monitorar rapidamente sua ocorrência, diagnosticar causas subjacentes que levam à deposição, associa-las a condições operacionais mensuráveis e prever com segurança o desempenho futuro dos trocadores de calor à medida que a incrustação se acumula (Diaz-Bejarano et al., 2019). Diante disso uma das grandes vantagens do uso do aprendizado de máquina é sua velocidade e precisão. Nesse viés, se faz o uso dessa tecnologia para atividades que exigem alta precisão e que podem ser construídos em modelos com a autoaprendizagem para reconhecer padrões, aprender com os dados obtidos e se tornar mais inteligente com o passar do tempo (Dobbelaere et al., 2021).

O objetivo deste trabalho é revisar, avaliar e verificar quais as lacunas e oportunidades que os estudos sobre a aplicação de aprendizado de máquina na análise do nível de incrustações em trocadores de calor apresentam. A abordagem inclui uma análise qualitativa do funcionamento desses equipamentos e uma análise quantitativa baseada em dados estatísticos por meio de uma revisão sistemática da literatura nos últimos 11 anos (2012-2023), utilizando bancos de dados como SCOPUS, IEEE, Science Direct e Web of Science. O foco principal é examinar como o aprendizado de máquina é utilizado para detectar incrustações, com um enfoque secundário na análise do desempenho das técnicas, avaliando o impacto da geometria do trocador de calor, desafios na implementação e áreas que necessitam de investimento, com base nas conclusões e tendências propostas pelos autores.

1.1 Algoritmos de aprendizado de máquina

O aprendizado de máquina (ML) é um subconjunto da inteligência artificial (IA) que se concentra no desenvolvimento de algoritmos capazes de aprender e fazer previsões ou decisões independentes com base nos dados já fornecidos (Kufel et al., 2023; Sun et al., 2024).

De acordo com Dobbelaere et al., (2021) existe uma ampla gama de modelos de aprendizado de máquina que podem ser utilizados. Dentre eles é possível citar duas categorias principais: a de classificação ou regressão e a de metodologia de aprendizagem que abrange a aprendizagem não supervisionada e supervisionada. O Quadro 1 adaptado de Wang et al., (2020) faz notações sobre termos do aprendizado de máquina e explicações dos mesmos.

Quadro 1 - Notações e explicações sobre os termos do aprendizado de máquina

Termo	Explicação
Aprendizagem Supervisionada	Um subgrupo de modelos de ML que requer preditores e resultados (rótulos);
Aprendizagem Não Supervisionada	Um subgrupo de modelos de ML destinados a encontrar padrões anteriormente desconhecidos em dados sem rótulos pré-existent;
Regressão	Uma previsão de um valor contínuo com base nas variáveis de entrada;
<i>Support Vector Machine (SVM)</i>	Um classificador supervisionado que procura encontrar o melhor hiperplano para separar os dados;
<i>Support Vector Regression (SVR)</i>	Um regressor capaz de encontrar uma função que modele os dados de treinamento e, ao mesmo tempo, mantenha as discrepâncias (ou erros) dentro de uma tolerância aceitável.;
<i>k-nearest neighbours (kNN)</i>	Um tipo de aprendizagem baseada em instâncias, onde a previsão é apenas aproximada localmente com os k vizinhos mais próximos;
<i>Artificial Neural Network (ANN)</i>	Um modelo computacional baseado em uma coleção de unidades ou nós conectados chamados neurônios artificiais, que modelam vagamente os neurônios em um ambiente biológico;
<i>Decision Tree</i>	Uma árvore com um conjunto de decisões hierárquicas que eventualmente fornece uma decisão final;

Fonte: Adaptado Wang et al., (2020)

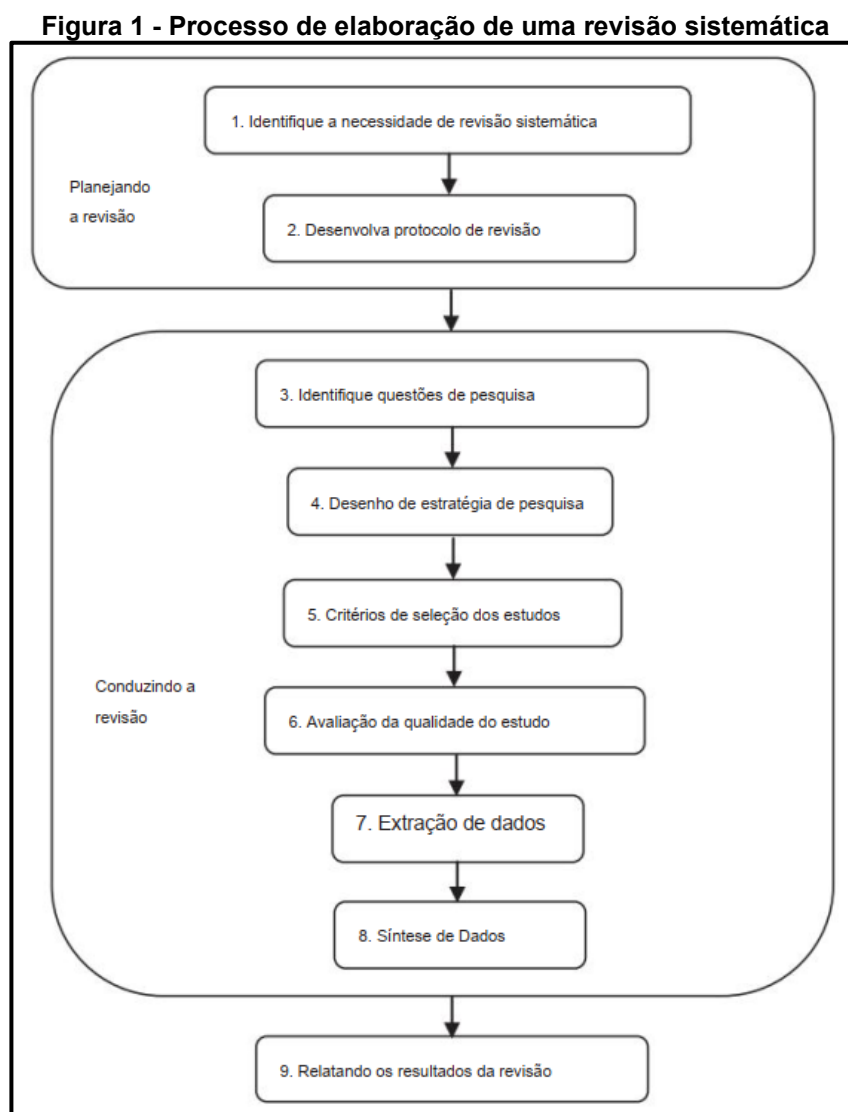
No entanto, é pertinente mencionar que algumas técnicas de aprendizado de máquina, como *Decision Tree* e Regressão, apresentam variantes e extensões que podem conduzir a respostas mais eficazes, dependendo da natureza das variáveis de entrada ou do conjunto de dados fornecido. São alguns exemplos de extensões: *Logistic regression*, *SoftMax regression*, *Gaussian Process Regression (GPR)* e *Bagged Trees*.

2 MÉTODO

Conforme Biolchini et al., (2005) a Revisão Sistemática (RS) é uma metodologia específica que vai além de uma simples visão geral da área de pesquisa. Com o aumento na produção de trabalhos científicos, o papel da revisão da literatura se tornou fundamental para filtrar estudos mais centralizados. Diante disso, foram desenvolvidas regras gerais para a realização de resumos da literatura, como forma de garantir uma qualificação das informações do material apresentado pelo revisor.

Para Kitchenham, (2004), uma estratégia de busca predefinida deve ser seguida durante as realizações da RS. Ademais, pesquisadores que realizam esse tipo de inspeção da literatura devem ser coerentes com as pesquisas, relatando quais pontos são compatíveis ou não com a sua hipótese da pesquisa.

A Figura 1 feita por Malhotra (2015) demonstra todo o processo do protocolo, desde o planejamento, condução e análise de artigos, até a parte final onde se relata os resultados da pesquisa feita.



Fonte: Malhotra (2015)

O protocolo do presente trabalho está baseado na estruturação de Page et al., (2021), que inclui o checklist PRISMA 2020. No entanto, modificou-se a estrutura de protocolo utilizada por Page et al., (2021) para anexar e fazer uso do *software* StArt Versão 3.4 Beta desenvolvido pela Universidade Federal de São Carlos (UFSCar) em

conjunto com o laboratório de pesquisa em engenharia de software (LaPES), tal aplicativo é de uso específico para desenvolvimento de revisões sistemáticas. Ainda assim, é válido salientar que o protocolo desenvolvido neste trabalho realiza uma combinação entre o checklist PRISMA 2020, o modelo de Malhotra (2015) e o de Biolchini et al. (2005), procurando apresentar uma abordagem única.

Além disso, como forma de buscar uma maior qualidade dos artigos estudados, foi realizada a conferência do *Source Normalized Impact per Paper* (SNIP) de cada artigo. A ideia da abordagem de fonte normalizada é corrigir diferenças nas práticas de citação entre campos científicos sem exigir um sistema de classificação de campo no qual os limites dos campos são explicitamente definidos (Waltman et al., 2013).

O desenvolvimento de um protocolo bem estruturado reduz o risco de extrapolar os limites da pesquisa. Na subsequência, serão apresentadas as questões principais que alinham todo estudo e os passos seguintes do protocolo exposto pela Figura 1.

2.1 Questões da pesquisa

As perguntas referentes ao protocolo deste trabalho estão apresentadas no Quadro 2. Foram escolhidas uma questão principal (Q1) e outras quatro questões secundárias (Q2, Q3, Q4 e Q5), na tentativa de atender todos os objetivos propostos. Tais questões desempenham papel fundamental da estruturação e condução do processo de revisão. Elas ajudam a definir o escopo, a direção e os critérios de inclusão/exclusão dos estudos a serem analisados, garantindo que a revisão seja conduzida de forma metodológica e sistemática.

Quadro 2 - Questões de pesquisa

Questões de pesquisa	
Q1	Quais são as técnicas de aprendizado de máquina mais utilizadas para detecção de incrustação em trocadores de calor na engenharia química?
Q2	Qual é o desempenho dos algoritmos de aprendizado de máquina em detectar as incrustações em Trocador de Calor Latente (TCL) frente aos métodos usuais?
Q3	Quais são os principais desafios a serem enfrentados na utilização do aprendizado de máquina para a detecção de incrustação em trocadores de calor na engenharia química?
Q4	De que maneira as características do sistema influenciam a eficácia da detecção de incrustação por meio do uso de aprendizado de máquina?
Q5	Quais são as lacunas específicas na literatura atual e para onde a área pode avançar na aplicação do aprendizado de máquina na detecção de incrustação em trocadores de calor na engenharia química?

Fonte: Autoria própria (2023)

2.2 Estratégia de busca e seleção dos estudos primários

A estratégia de busca e seleção dos estudos primários é baseada na escolha das fontes de pesquisa, palavras-chave e a escolha do idioma dos trabalhos. Para encontrar os estudos primários, fez-se uso das expressões booleanas, mais precisamente os operadores lógicos “OR” e “AND”. Além disso, foram empregadas quatro palavras-chave principais, juntamente com algumas de suas derivações que estão expostas a seguir: “*Heat exchanger*” OU “*heat exchangers*” E “*Machine learning*” E “*Fouling*” E “*Detection*” OU “*fault detection*”. No Quadro 3 estão apresentadas as *strings* de busca que foram colocadas nas bases de dados.

Quadro 3 - Strings de busca

Busca	String
1	“Heat exchanger” OR “Heat exchangers” AND “Fouling” AND “Machine learning”
2	“Heat exchanger” OR “Heat exchangers” AND “Fouling” AND “Machine learning” AND “Detection” OR “Fault Detection”

Fonte: Autoria própria (2023)

Por consequência, após definir os termos de busca, escolheu-se as fontes de pesquisa. As fontes devem estar acessíveis via internet, preferencialmente em bases de dados científicas. A seguir estão listados os portais digitais utilizados para seleção dos estudos primários:

- (1) Scopus;
- (2) Biblioteca Digital do Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE);
- (3) Science Direct;
- (4) Web of Science.

No quesito do idioma, o escolhido foi o inglês por se tratar da língua internacionalmente aceita para a publicação de trabalhos científicos, sendo ideal para que a pesquisa atinja maior número de estudos.

2.3 Critérios e procedimentos para seleção dos estudos

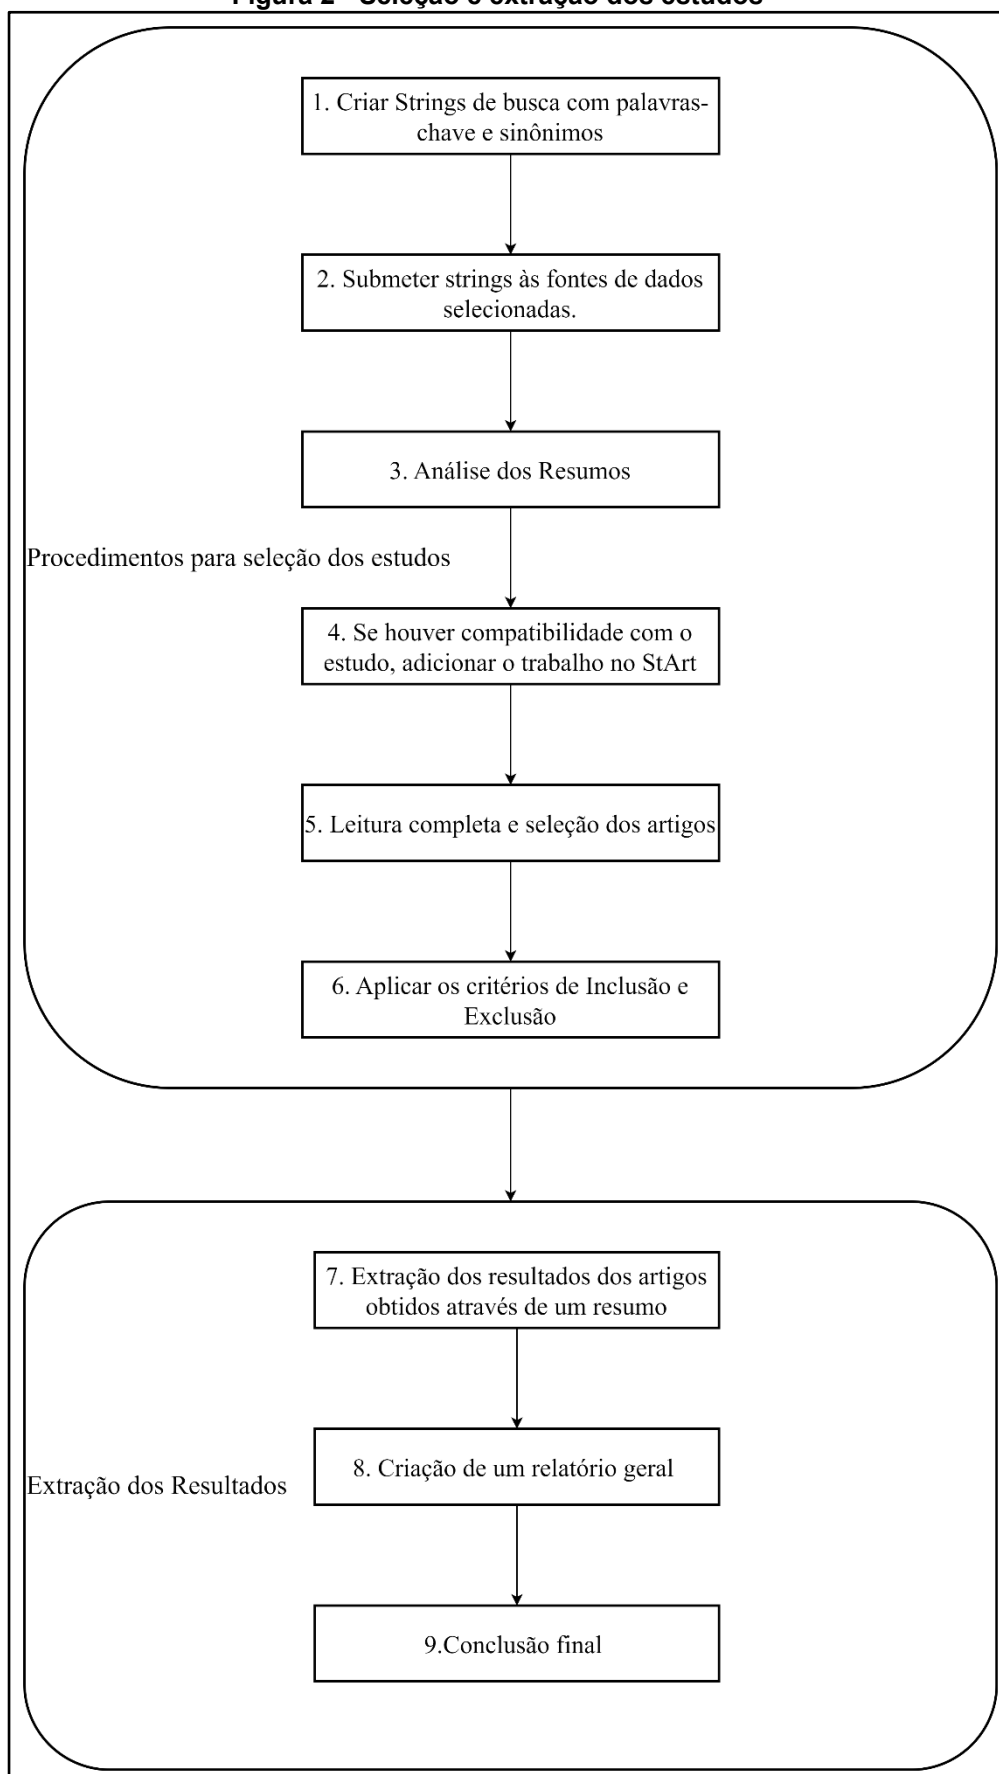
Os seguintes critérios de inclusão e exclusão foram propostos e expostos no Quadro 4 para garantir que os objetivos colocados sejam atendidos e, assim, prosseguir com artigos selecionados direcionados ao tema desta pesquisa.

Quadro 4 - Critérios de Inclusão e Exclusão

CRITÉRIOS	
INCLUSIVOS	EXCLUSIVOS
I. Inclui-se trabalhos científicos publicados nos últimos onze anos (2012-2023);	VI. Descartou-se estudos publicados antes de 2012;
II. Artigos publicados em periódicos que estejam com um SNIP maior ou igual à 0,5;	VII. Eliminou-se artigos que possuem o SNIP menor à 0,5;
III. Acrescentou-se os trabalhos que foram publicados e estão integralmente disponíveis na plataforma CAPES-CAFE;	VIII. Não foram incluídos artigos que possuem acesso restrito na plataforma CAPES-CAFE;
IV. Incorporou-se trabalhos que se referem diretamente a técnicas de aprendizado de máquina utilizados para verificar as incrustações nos TCL na indústria química;	IX. Excluiu-se trabalhos que não utilizaram métodos como o aprendizado de máquina para fazer a verificação das incrustações nos trocadores de calor na indústria química;
V. Incluídos somente artigos científicos à pesquisa como forma de restringir o estudo a esses trabalhos.	X. Excluídos quaisquer outros trabalhos que não sejam artigos científicos.

Fonte: Autoria própria (2023)

Por conseguinte, a Figura 2 apresenta os procedimentos iniciais para seleção de estudos e os passos para extração dos resultados. Tal figura apresenta um modelo único de seleção e extração de resultados.

Figura 2 - Seleção e extração dos estudos

Fonte: Autoria própria (2023)

3 RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados e classificações obtidos a partir dos estudos primários. Em primeira instância serão demonstrados alguns dados retirados da pesquisa e, em seguida, apresentadas as respostas obtidas de cada artigo para as questões propostas.

3.1 Descrição dos estudos primários

Esta seção fornece uma breve descrição dos estudos primários. Inicialmente, após concluir a pesquisa, foram identificados 30 artigos iniciais em várias bases de dados. No entanto, muitos desses artigos estavam presentes em mais de uma base de dados, resultando em redundâncias. O Quadro 5 expõe os autores, títulos e ano de todos os artigos encontrados nesse estudo primário, separados pelas diferentes buscas que envolvem um conjunto variado de palavras-chave. É válido salientar que nesse Quadro 3 estão incluídos os artigos considerados duplicados.

Quadro 5 – Pesquisa realizada nas bases de dados

Base	Busca	Nº	Autor	Título	Ano	Referência
SCOPUS	1	1	Jianguo Wang, Xuefei Xu, Yuan Xu, Yanchen Liu, Yandong Liang	Fouling prediction of heat exchanger surface under alternating magnetic field based on IGWO–SVR.	2023	(WANG et al., 2023a)
		2	SUN Lingfang, ZHANG Yingying, ZHENG Xinpeng, YANG Shanrang, QIN Yukun	Research on the Fouling Prediction of Heat exchanger Based on Support Vector Machine	2008	(SUN et al., 2008)
		3	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
		4	Cadei, L.; Corneo, A.; Milana, D.; Loffreno, D.; Lancia, L.; Montini, M.; Rossi, G.; Purlalli, E.; Fier, P.; Carducci, F.	Advanced analytics for predictive maintenance with limited data: Exploring the fouling problem in heat exchanging equipment	2019	(CADEI et al., 2019)
		5	Soualhi, M.; El Koujok, M.; Nguyen, K.T.P.; Medjaher, K.; Ragab, A.; Ghezzaz, H. ; Amazouz, M. ; Ouali, M.-S.	Adaptive prognostics in a controlled energy conversion process based on long- and short-term predictors	2021	(SOUALHI et al., 2021)
		6	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
		7	Hosseini, S.; Khandakar, A.; Chowdhury, M.E.H.; Ayari, M.A.; Rahman, T.; Chowdhury, M.H.; Vaferi, B.	Novel and robust machine learning approach for estimating the fouling factor in heat exchangers	2022	(HOSSEINI et al., 2022)
		8	Sun, L. ; Saqi, R. ; Xie, H.	Research on the fouling prediction of heat exchanger based on wavelet relevance vector machine	2010	(SUN; SAQI; XIE., 2010)
		9	Sun, L. ; Zhang, Y. ; Saqi, R.	Fouling prediction of heat exchanger based on genetic optimal SVM algorithm	2009	(SUN; ZHANG; SAQI, 2009)
	2	10	Kumar, S.M. ; Al Mahmoud, M.A.H. ; Al Yahyae, N.	Gap to Potential Identification through An Online Process Digital Twin	2022	(KUMAR et al., 2022)
		11	Wang, J. ; Zuo, Q. ; Liao, G. ; Luo, F. ; Zhao, P. ; Wu, W. ; He, Z. ; Dai, Y.	Machine Learning-Based Fault Detection and Diagnosis of Organic Rankine Cycle System for Waste-Heat Recovery	2021	(WANG et al., 2021)


		12	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
		13	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
Science Direct	1	14	Soualhi, M.; El Koujok, M.; Nguyen, K.T.P.; Medjaher, K.; Ragab, A.; Ghezzaz, H. ; Amazouz, M. ; Ouali, M.-S.	Adaptive prognostics in a controlled energy conversion process based on long- and short-term predictors	2021	(SOUALHI et al., 2021)
		15	Hosseini, S.; Khandakar, A.; Chowdhury, M.E.H.; Ayari, M.A.; Rahman, T.; Chowdhury, M.H.; Vaferi, B.	Novel and robust machine learning approach for estimating the fouling factor in heat exchangers	2022	(HOSSEINI et al., 2022)
		16	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
	2	17	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
IEEE	1	18	M. Al-Naser ; S. El-Ferik ; R. B. Mansour ; H. Y. AlShammari ; A. AlAmoudi	Intelligent Prediction Approach of Fouling Location in Shell and Tube Heat Exchanger	2020	(AL-NASER et al., 2020)
		19	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
Web of Science	1	20	Sun, L. ; Zhang, Y. ; Saqi, R.	Fouling prediction of heat exchanger based on genetic optimal SVM algorithm	2009	(SUN; ZHANG; SAQI, 2009)
		21	Hosseini, S.; Khandakar, A.; Chowdhury, M.E.H.; Ayari, M.A.; Rahman, T.; Chowdhury, M.H.; Vaferi, B.	Novel and robust machine learning approach for estimating the fouling factor in heat exchangers	2022	(HOSSEINI et al., 2022)
		22	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
		23	SUN Lingfang, ZHANG Yingying, ZHENG Xinpeng, YANG Shanrang, QIN Yukun	Research on the Fouling Prediction of Heat exchanger Based on Support Vector Machine	2008	(SUN et al., 2008)

		24	Ikonen, E ; Liukkonen, M ; Hansen, AH ; Edelborg, M ; Kjos, O ; Selek, I ; Kettunen, A	Fouling monitoring in a circulating fluidized bed boiler using direct and indirect model-based analytics	2023	(IKONEN et al., 2023)
		25	Soualhi, M.; El Koujok, M.; Nguyen, K.T.P.; Medjaher, K.; Ragab, A.; Ghezzaz, H. ; Amazouz, M. ; Ouali, M.-S.	Adaptive prognostics in a controlled energy conversion process based on long- and short-term predictors	2021	(SOUALHI et al., 2021)
		26	Srinivasarengan, K ; Ragot, J ; Maquin, D ; Aubrun, C	Takagi-Sugeno model based Nonlinear Parameter Estimation in Air Handling Units	2016	(SRINIVASARENGAN et al., 2016)
		27	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
	2	28	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
		29	Srinivasarengan, K ; Ragot, J ; Maquin, D ; Aubrun, C	Takagi-Sugeno model based Nonlinear Parameter Estimation in Air Handling Units	2016	(SRINIVASARENGAN et al., 2016)
30		William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)	

Fonte: Aatoria própria (2023)

3.1.1 Fontes de Pesquisa

Diante da pesquisa realizada, o Gráfico 1 apresenta a quantidade de artigos encontrados e a porcentagem que eles representam em cada base de dados. É notório que a porcentagem de artigos é maior nas bases de dados da Scopus e no Web of Science. Isso pode ser reflexo da qualidade dessas bases, o que as torna mais abrangentes e precisas em relação ao assunto abordado neste trabalho, ao contrário das bases Science Direct e IEEE, que parecem ser mais limitadas.




Fonte: Autoria própria (2023)

3.2 Aplicação dos Critérios de Inclusão e Exclusão

Nesse item serão expostas as classificações que os 30 artigos foram submetidos. Ainda assim, serão apresentados os artigos excluídos, juntamente com os critérios de exclusão aplicados. Da mesma forma, serão destacados os artigos incluídos e os critérios de inclusão ao qual cada artigo atendeu.

Muitos artigos selecionados, como indicado anteriormente e mostrado pelo Gráfico 2, estão presentes em mais de uma base de dados, evidenciando uma repetição frequente. A duplicação dos artigos significa que eles são considerados apenas na primeira busca; nas inclusões subsequentes, o software StArt automaticamente os marca como duplicados. Isso resulta em uma redução significativa no número de artigos que passarão pelos critérios de seleção.

Gráfico 2 - Números de artigos aceitos, rejeitados e duplicados

Fonte: Autoria própria (2023)

Adicionalmente, os dados referentes à quantidade de artigos aprovados e rejeitados são apresentados no Gráfico 2. Como resultado, essas informações serão revisitadas ao longo da extensão do estudo. Diante disso, o Quadro 6 mostra somente os artigos aceitos e os rejeitados, excluindo os artigos duplicados.

Quadro 6 - Artigos aceitos ou rejeitados

Nº	Autor	Título	Ano	Referência
1	Jianguo Wang, Xuefei Xu, Yuan Xu, Yanchen Liu, Yandong Liang	Fouling prediction of heat exchanger surface under alternating magnetic field based on IGWO–SVR.	2023	(WANG et al., 2023a)
2	SUN Lingfang, ZHANG Yingying, ZHENG Xinpeng, YANG Shanrang, QIN Yukun	Research on the Fouling Prediction of Heat exchanger Based on Support Vector Machine	2008	(SUN et al., 2008)
3	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
4	Cadei, L.; Comeo, A.; Milana, D.; Loffreno, D.; Lancia, L.; Montini, M.; Rossi, G.; Purlalli, E.; Fier, P.; Carducci, F.	Advanced analytics for predictive maintenance with limited data: Exploring the fouling problem in heat exchanging equipment	2019	(CADEI et al., 2019)
5	Soualhi, M.; El Koujok, M.; Nguyen, K.T.P.; Medjaher, K.; Ragab, A.; Ghezzaz, H. ; Amazouz, M. ; Ouali, M.-S.	Adaptive prognostics in a controlled energy conversion process based on long- and short-term predictors	2021	(SOUALHI et al., 2021)
6	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
7	Hosseini, S.; Khandakar, A.; Chowdhury, M.E.H.; Ayari, M.A.; Rahman, T.; Chowdhury, M.H.; Vaferi, B.	Novel and robust machine learning approach for estimating the fouling factor in heat exchangers	2022	(HOSSEINI et al., 2022)
8	Sun, L. ; Saqi, R. ; Xie, H.	Research on the fouling prediction of heat exchanger based on wavelet relevance vector machine	2010	(SUN; SAQI; XIE., 2010)
9	Sun, L. ; Zhang, Y. ; Saqi, R.	Fouling prediction of heat exchanger based on genetic optimal SVM algorithm	2009	(SUN; ZHANG; SAQI, 2009)
10	Kumar, S.M. ; Al Mahmoud, M.A.H. ; Al Yahyae, N.	Gap to Potential Identification through An Online Process Digital Twin	2022	(KUMAR et al., 2022)


11	Wang, J. ; Zuo, Q. ; Liao, G. ; Luo, F. ; Zhao, P. ; Wu, W. ; He, Z. ; Dai, Y.	Machine Learning-Based Fault Detection and Diagnosis of Organic Rankine Cycle System for Waste-Heat Recovery	2021	(WANG et al., 2021)
12	M. Al-Naser ; S. El-Ferik ; R. B. Mansour ; H. Y. AlShammari ; A. AlAmoudi	Intelligent Prediction Approach of Fouling Location in Shell and Tube Heat Exchanger	2020	(AL-NASER et al., 2020)
13	Ikonen, E ; Liukkonen, M ; Hansen, AH ; Edelborg, M ; Kjos, O ; Selek, I ; Kettunen, A	Fouling monitoring in a circulating fluidized bed boiler using direct and indirect model-based analytics	2023	(IKONEN et al., 2023)
14	Srinivasarengan, K ; Ragot, J ; Maquin, D ; Aubrun, C	Takagi-Sugeno model based Nonlinear Parameter Estimation in Air Handling Units	2016	(SRINIVASARENGAN et al., 2016)

Fonte: Aatoria própria (2023)

3.2.1 Valores de SNIP

No Gráfico 3, estão apresentados os valores de SNIP para cada artigo pesquisado. Todos os valores encontrados foram retirados do site *CWTS Journal Indicators* (www.journalindicators.com/indicators). Os artigos que não possuem valor são os quais não foi encontrado um valor de SNIP. No entanto, nenhum desses artigos foi excluído por esse motivo. Diante do observado no Gráfico 3, somente o artigo nº 14 foi excluído por esse critério, uma vez que o mesmo não continha valor de SNIP maior que 0,5. Todos os trabalhos seguem a numeração indicada no Quadro 6.

Gráfico 3 - Valores de SNIP




Fonte: Autoria própria (2023)

3.2.2 Ano de publicação

No Gráfico 4, o eixo “x” demonstra o ano de publicação de cada artigo e o eixo “y” a quantia de artigos publicados por ano. Dados tais números, verifica-se que o estudo e aplicação do aprendizado de máquina ainda é muito recente. Sun et al., (2008) apresentou seu estudo de predição de incrustações em um trocador de calor com o uso da máquina de vetores de suporte que se mostrou efetivo, mas obteve

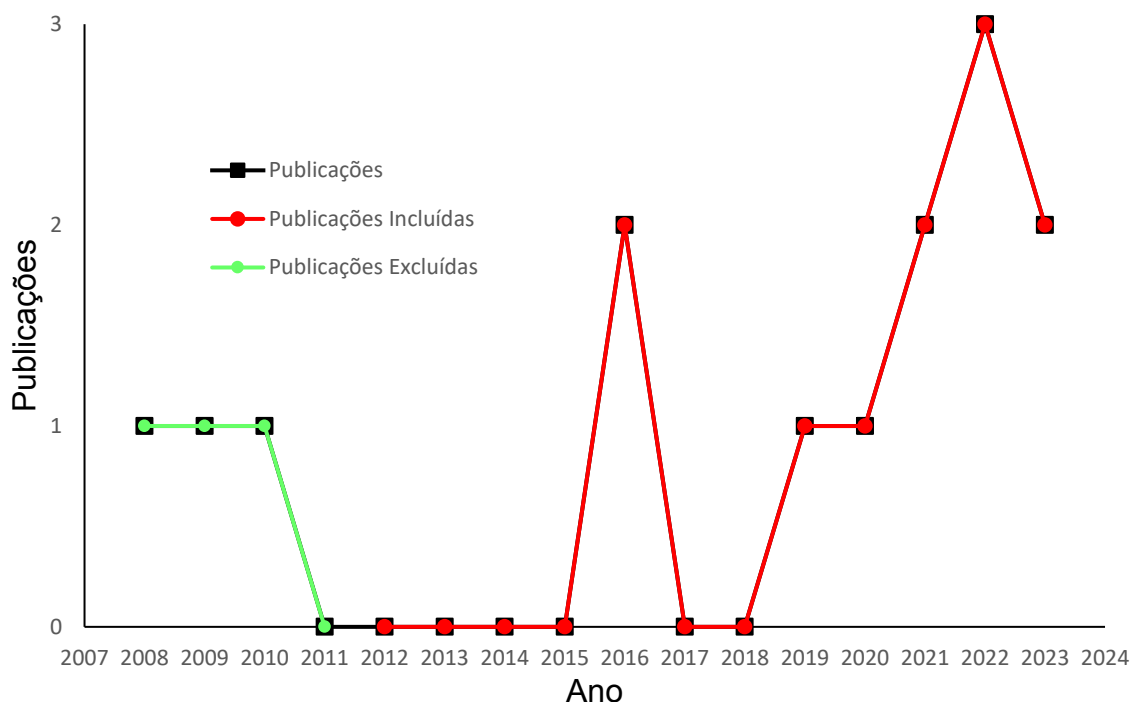
muitas dificuldades, principalmente em questões de precisão e geração de dados. Os mesmos pesquisadores deram sequência nos trabalhos em 2009 e 2010. Em 2016 Najjar et al., (2016) usa o aprendizado de máquina como forma sensorial para prever incrustações em trocadores de calor de uma aeronave. A partir de 2019, observa-se um aumento gradual nas pesquisas sobre esse tema. Isso está ligado aos avanços computacionais que têm levado a resultados mais positivos e precisos nessa área.

Gráfico 4 - Número de publicações por ano



Fonte: Autoria própria (2023)

Diante da busca realizada, apenas três publicações foram rejeitadas por estarem com datas de publicações mais antigas que onze anos, sendo elas os artigos números 2, 8 e 9 do Quadro 6. O Gráfico 5 evidencia qual o período excluído.

Gráfico 5 - Publicações Incluídas e Excluídas

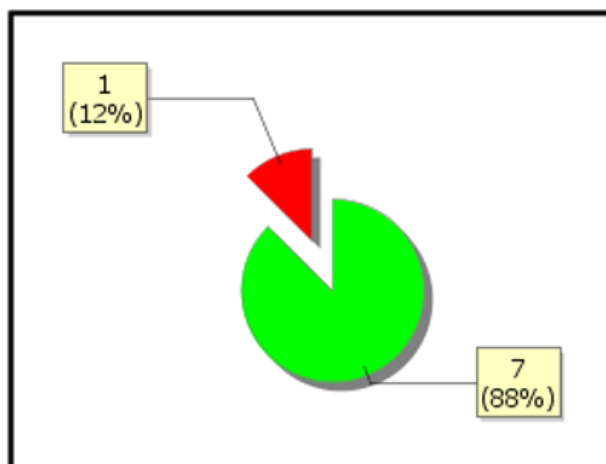
Fonte: Autoria própria (2023)

3.2.3 Artigos sem acesso aos portais de periódicos

Durante o processo de seleção de artigos, os trabalhos de pesquisa número 4 e número 10, referentes ao Quadro 6, foram rejeitados devido à sua incompatibilidade com esse critério. Embora esses artigos pudessem conter informações valiosas relacionadas ao aprendizado de máquina na verificação de incrustações em trocadores de calor, sua falta de acesso aos portais de periódicos os torna inacessível. Portanto, essas exclusões podem ter algum avanço no assunto abordado. No entanto, a decisão de manter o critério de acesso aos portais da CAPES-CAFE foi tomada para garantir que os resultados desta revisão estivessem disponíveis de forma aberta e equitativa para todos os autores.

3.3 Questões de pesquisa

Após aplicação dos critérios de inclusão e exclusão, o Gráfico 6, evidencia que foram obtidos oito artigos que se encaixam no protocolo desse trabalho. No entanto, o artigo nº 13 não apresenta respostas as perguntas efetuadas no trabalho e, portanto, decidiu-se por rejeitar a extração de dados do mesmo. Dessa maneira, o Gráfico 6 faz uma ilustração de tal fato.

Gráfico 6 - Dados dos artigos extraídos

● Aceitos ● Rejeitados

Fonte: Autoria própria (2023)

Na subsequência deste item estão apresentadas as respostas para as questões propostas no protocolo dessa revisão sistemática, cujas respostas foram retiradas dos artigos presentes no Quadro 7, seguindo a numeração do mesmo.

Quadro 7 - Artigos para extração dos resultados

Nº	Autor	Título	Ano	Referência
1	Jianguo Wang, Xuefei Xu, Yuan Xu, Yanchen Liu, Yandong Liang	Fouling prediction of heat exchanger surface under alternating magnetic field based on IGWO–SVR.	2023	(WANG et al., 2023a)
2	William T. Hale, Efi Safikou, George M. Bollas	Inference of faults through symbolic regression of system data	2022	(HALE; SAFIKOU; BOLLAS, 2022)
3	Soualhi, M.; El Koujok, M.; Nguyen, K.T.P.; Medjaher, K.; Ragab, A.; Ghezzaz, H. ; Amazouz, M. ; Ouali, M.-S.	Adaptive prognostics in a controlled energy conversion process based on long- and short-term predictors	2021	(SOUALHI et al., 2021)
4	Najjar, N.; Gupta, S.; Hare, J.; Kandil, S.; Walthall, R.	Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems	2016	(NAJJAR et al., 2016a)
5	Hosseini, S.; Khandakar, A.; Chowdhury, M.E.H.; Ayari, M.A.; Rahman, T.; Chowdhury, M.H.; Vaferi, B.	Novel and robust machine learning approach for estimating the fouling factor in heat exchangers	2022	(HOSSEINI et al., 2022)
6	Wang, J. ; Zuo, Q. ; Liao, G. ; Luo, F. ; Zhao, P. ; Wu, W. ; He, Z. ; Dai, Y.	Machine Learning-Based Fault Detection and Diagnosis of Organic Rankine Cycle System for Waste-Heat Recovery	2021	(WANG et al., 2021)
7	M. Al-Naser ; S. El-Ferik ; R. B. Mansour ; H. Y. AlShammari ; A. AlAmoudi	Intelligent Prediction Approach of Fouling Location in Shell and Tube Heat Exchanger	2020	(AL-NASER et al., 2020)

Fonte: Autoria própria (2023)

3.3.1- Quais são as técnicas de aprendizado de máquina mais utilizadas para detecção de incrustação em trocadores de calor na engenharia química?

No trabalho de Wang et al., (2023), artigo nº1, os autores propõem a previsão de incrustação da superfície de um trocador de calor sob influência de um campo magnético alternado utilizando o *Support Vector Regression* como o algoritmo central na previsão de incrustações. No entanto, ele precisou de aprimoramento uma vez que, o fator de penalidade de erro e o parâmetro de função do kernel foram fatores que afetaram o desempenho do algoritmo. Para isso se fez uso de otimização com o algoritmo melhorado *grey wolf*.

Já Hale; Safikou; Bolla, (2022), escritores do artigo nº2, fizeram a implantação de sensores inferenciais para detecção de incrustações em um trocador de placas de fluxo cruzado (PFHE). Assim fizeram uso de métodos como *k-nearest neighbours* (k-NN), *Support Vector Machine* (SVM) e *Neural Network* (NN) para comparação e classificação de falhas nesses sensores.

O artigo nº 3, faz uso do aprendizado de máquina aplicado em preditores de curto e longo prazo para rastrear o nível de incrustação nos trocadores de calor de uma empresa de papel e celulose. Os autores Soualhi et al., (2021) destacam o uso dos preditores mais comuns que são regressão de vetores de suporte, modelos ocultos Modelo de Markov e média móvel integrada autorregressiva (ARIMA) como método estatístico e como modelo de aprendizado de máquina os autores fizeram uso de alguns modelos de *NN* como o *nonlinear auto-regressive exogenous model* (NARX), *adaptive neuro-fuzzy inference system* e *long short-term memory* (LSTM).

O trabalho de Najjar et al., (2016b), artigo nº 4 utilizou-se do método de aprendizado não supervisionado para classificação/seleção de sensores de um trocador de calor utilizado em sistemas aeroespaciais. Posteriormente, os dados dos sensores mais bem classificados foram analisados usando o k-NN classificador em combinação com o método de Análise de Componentes Principais (PCA) ou o uso do modelo probabilístico *Gaussian Mixture Model* (GMM) como recurso.

Nesse viés, Hosseini et al., (2022) (nº5) deixam explicitado que o estudo emprega quatro algoritmos de aprendizado de máquina atualizados (*Gaussian*

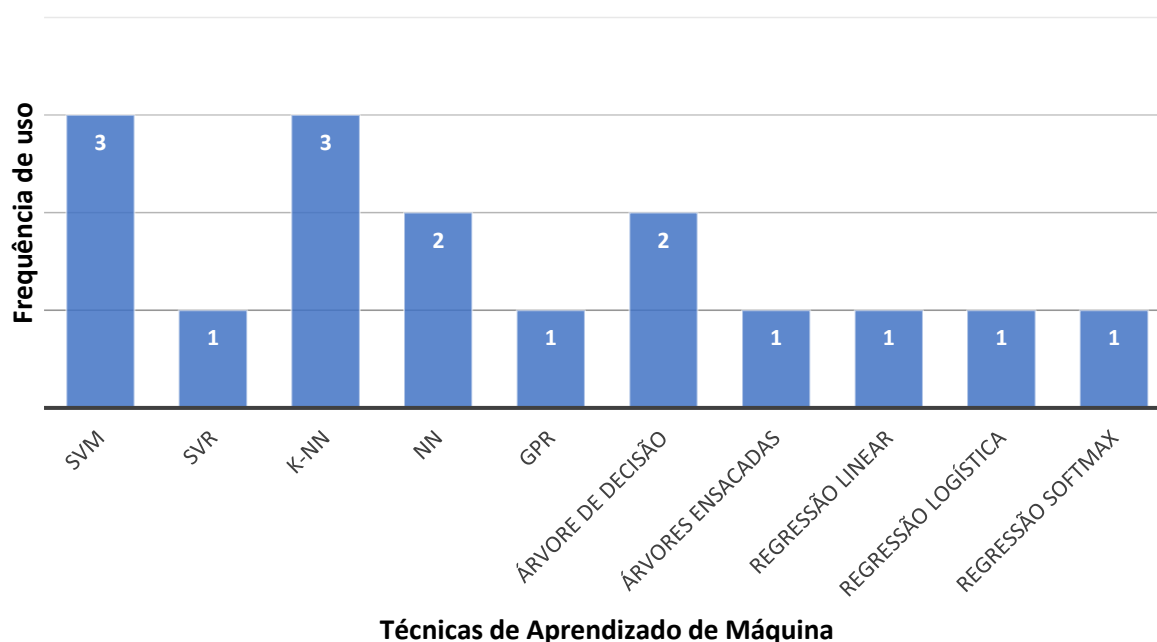
Process Regression, Decision Trees, Bagged Trees, Support Vector Regression) e um modelo tradicional (*Linear Regression*) para estimar o fator de incrustação em função da operação do trocador de calor e suas variáveis.

Os autores do artigo nº 6, Wang et al., (2021), fizeram a análise de três tipos de falhas, sendo elas a falha do expensor, falha da bomba e falha do trocador de calor, em um Sistema de *Organic Rankine Cycle* (ORC) a fim de recuperar calor residual e, para isso, testaram três tipos de algoritmo: *logistic regression, SoftMax regression* e SVM foram descritos.

Já Al-Naser et al., (2020), no artigo número 7, exploraram a segmentação de um trocador de calor em múltiplos segmentos para identificar a localização de incrustações no interior do trocador de calor de casco e tubo, utilizando técnicas de inteligência artificial. Os autores descrevem a seleção dos seguintes algoritmos de aprendizado de máquina para realizar tarefas de classificação: k-NN, *Decision tree* e algoritmos discriminantes, com validação cruzada de 10 vezes. A classificação realizada está diretamente associada aos múltiplos segmentos do trocador de calor

Para finalizar essa questão, o Gráfico 7 demonstra a frequência de uso e quais são as técnicas comumente usadas para o monitoramento da incrustação em trocadores de calor verificadas nos artigos selecionados.

Gráfico 7 - Técnicas de Aprendizado de máquina e frequência de uso



Fonte: Autoria própria (2023)

3.3.2- Qual é o desempenho dos algoritmos de aprendizado de máquina em detectar as incrustações em TCL frente aos métodos usuais?

O artigo escrito por Wang et al., (2023b) (nº 1) fez uma comparação do uso dos métodos de SVR quando aplicados em diferentes formas de otimização. O modelo de predição de incrustação foi estabelecido através de SVR, otimização por algoritmo genético (GA – SVR) e algoritmo aprimorado por *grey Wolf* (IGWO – SVR) com variáveis de entrada como, a condutividade, corrente induzida e resistência à incrustação como variável de saída. Os resultados previstos mostraram que o IGWO – SVR obteve o maior êxito de previsão e a melhor capacidade de generalização.

A análise de desempenho do artigo escrito por Hale; Safikou e BOLLAS, (2022) (nº 2) envolve três algoritmos e dois níveis de incrustação, nível nominal e superior, sendo o nível nominal referente as condições realistas de operação do trocador de calor, dado pelo fluxo de massa igual à $0,25 \text{ kg.s}^{-1}$ e o nível superior considerando uma cota superior ao fluxo de massa normal, dado por 1 kg.s^{-1} . A Tabela 1 faz a comparação das taxas de classificação corretas para os níveis de incrustação. Em conjunto com os três algoritmos, fez-se uso de sensores inferenciais, destacados como i-k-NN desenvolvidos para melhorar a precisão de detecção, sendo esse último o principal enfoque do trabalho.

Tabela 1 - Taxa de classificação correta para os três métodos de classificação e aplicação dos sensores inferenciais nos níveis nominal e superior

Algoritmo	Nominal	Superior
k-NN	43,5%	73,9%
SVM	51,5%	92,3%
NN	54,1%	92,4%
i – k-NN	48,3%	92,6%

Fonte: Hale; Safikou; BOLLAS (2022)

O artigo escrito por Soualhi et al., (2021) (nº 3), faz o uso de preditores de curto e longo prazo juntamente com os modelos de aprendizado de máquina, mais especificamente LSTM e NARX desenvolvidos para avaliação da incrustação em trocadores de calor em uma indústria de celulose. De fato, utilizando a abordagem proposta com a junção de um modelo de LSTM e quatro modelos de NARX, pode-se prever o tempo de limpeza do trocador com elevada precisão (95%) 105 horas antes

da evolução da incrustação. Tais resultados foram obtidos através de quatro métricas que consistem na acurácia, precisão, erro percentual médio absoluto, raiz do erro quadrático médio.

Os autores Najjar et al., (2016a) (nº4), consideraram variações em dois parâmetros principais de entrada: a temperatura ambiente para diferentes dias e o peso da aeronave correspondente a diferentes contagens de ocupantes. Diante desses dados agrupados, descrevem que o algoritmo k-NN é aplicado em tais variações. Isso inclui duas etapas: i) segregar os dados de cada sensor, ii) cálculo de entropias médias ponderadas providas da junção de computadores potentes capazes de classificar esses sensores. Dessa maneira, o algoritmo produz excelentes resultados de classificação com o aumento da complexidade computacional, capazes de classificar corretamente 85% das incrustações com auxílio do GMM.

No trabalho feito por Hosseini et al., (2022) (nº 5), fez-se uso de algumas transformações lineares, todas envolvendo o erro de previsão na variável, aplicadas ao fator de incrustação e comparou-se a precisão de cinco métodos diferentes, sendo quatro deles aprendizados de máquina e somente um como abordagem tradicional que já foram descritos na Q1. A comparação de efetividade nesse trabalho foi vista através do R^2 . O modelo mais eficaz foi GPR avaliado em um conjunto de dados interno (por meio de validação cruzada de 5 vezes) e em um conjunto de dados externo, entre tais dados podem ser destacados as temperatura da superfície, a velocidade e temperatura do fluido e o fator de incrustação. O atual modelo de última geração exhibe um coeficiente de determinação R^2 de 0,98999.

Para avaliar a precisão dos sistemas de detecção e diagnóstico de falhas, Wang et al., (2021) (nº 6), empregaram um conjunto de dados experimentais para testar os modelos de detecção de quatro falhas propostas, sendo elas: frouxidão mecânica, bloqueio da bomba, evaporador sujo e condensador sujo. As taxas de precisão na detecção de falhas utilizando regressão logística e máquinas de vetores de suporte foram de 77,42% e 96,77%, respectivamente. No que diz respeito ao diagnóstico de falhas, as taxas de precisão alcançadas com *SoftMax regression* e SVM foram de 91,78% e 94,52%, respectivamente. Além disso, os tempos de teste para o diagnóstico de falhas com *SoftMax regression* e SVM foram de 0,0099 s e 0,0085 s, respectivamente. Os resultados evidenciam que os sistemas de detecção e

diagnóstico de falhas baseados em aprendizado de máquina para o ORC apresentam alta precisão e rapidez.

O artigo Al-Naser et al., (2020) (nº 7), também faz uma exposição dos dados de precisão geral alcançada pela aplicação de algoritmos de aprendizado de máquina nos cenários avaliados. Os autores propuseram três características variáveis como entrada para os algoritmos, sendo elas: temperatura de saída do tubo, temperatura de saída do casco e queda de pressão do tubo. A maior precisão foi obtida com o algoritmo k-NN, principalmente com a técnica de normalização de dados. Os dados de precisão para k-NN, árvore de decisão e discriminante foram 89,56%, 85,06% e 85,38%, respectivamente. Além disso, os pesquisadores relataram uma maior facilidade na detecção da incrustação na temperatura de saída do casco em comparação com a detecção na temperatura de saída do tubo. Para determinar a localização precisa da incrustação, observou-se que o impacto da queda de pressão no tubo é mínimo, exceto em situações de valores de incrustação muito elevados.

3.3.3- Quais são os principais desafios a serem enfrentados na utilização do aprendizado de máquina para a detecção de incrustação em trocadores de calor na engenharia química?

O artigo de Wang et al., (2023b) (nº 1) destaca erros de medição no termopar, com uma variação de aproximadamente 0,25°C. Além disso, aponta um erro na medição do comprimento da haste de aquecimento, o que compromete os dados processados pelo algoritmo e, conseqüentemente, gera variáveis no cálculo final da quantidade de incrustação. Os autores também mencionam um erro máximo na resistência à incrustação de $3.86 \times 10^{-5} \text{ m}^2 \text{ KW}^{-1}$.

Hale; Safikou; Bolla, (2022) (nº 2), explicitaram alguns desafios para a detecção de incrustação. Verificou-se que o parâmetro de incrustação do trocador de calor não era praticamente identificável em todas as condições operacionais com métodos convencionais de estimativa de parâmetros como a umidade, temperatura, pressão e vazão de fluido. Assim, os autores ainda salientam que é difícil evitar que um sistema sem incrustações seja classificado incrustado, podendo ser um alarme falso. Assim como um sistema com muita incrustação seja apresentado com não incrustado, promovendo uma falha de detecção.

Em seu trabalho, Soualhi et al., (2021) (nº3) demonstram em forma de tabela algumas dificuldades do uso de preditores de longo e curto prazo. Os autores descrevem que para preditores de longo prazo houve acúmulo de erros de previsão e se tem perda de informações sobre o estado de degradação do sistema; para preditores de curto prazo: fornece apenas um valor de previsão, não sendo possível capturar tendências de degradação; já para preditores de longo-curto prazo: necessita mais tempo e recursos computacionais para treinar múltiplos preditores.

O artigo escrito por Najjar et al., (2016a) (nº 4), citam o problema de valor financeiro na execução de suas ideias, pelo fato de utilizarem de ferramentas computacionais para realização de suas ideias. Os autores expõem que para se ter uma velocidade maior de funcionamento do GMM requerem o uso do algoritmo *Expectation Maximization* (EM), que exige maior capacidade computacional que o algoritmo usado na pesquisa. Além disso, os dados da pesquisa são gerados a partir de um modelo de Simulink validado experimentalmente a partir do Sistema de Controle Ambiental (ECS) fornecido pela parceria industrial, assim são relatadas várias incertezas geradas por flutuações paramétricas no ambiente de temperatura, quantidade de ocupantes e impedância de fluxo. Diante disso, se faz necessário o uso de métodos probabilísticos para uma melhora significativa no resultado.

Wang et al., (2021) (nº 6), faz uma breve citação expondo que as estruturas ORC operacionais e reais são mais complexas do que as apresentadas no trabalho, portanto, a quantidade e dimensão de dados poderia ser muito maior o que talvez inviabilizaria esse sistema ou o mesmo teria de ser modificado. Nesse caso, várias falhas ocorrem simultaneamente e a aplicabilidade do esquema de detecção e diagnóstico de falhas baseado em aprendizado de máquina para essas situações, ainda precisa ser validada.

No artigo nº 7, os autores Al-Naser et al., (2020) fazem uma autocrítica ao seu trabalho, propondo que seria necessário fazer uma melhora na precisão da inteligência artificial para identificar a localização de incrustação. Além disso, deve ser considerado o fato de que se tenha incrustação em mais de um segmento ao mesmo tempo.

3.3.4- De que maneira as características do sistema influenciam a eficácia da detecção de incrustação por meio do uso de aprendizado de máquina?

No trabalho de Hale; Safikou; Bolas, (2022) (nº 2), os autores destacam a complexidade em detectar a gravidade de incrustações quando há incertezas sobre as condições operacionais de um trocador de placas de fluxo cruzado. Eles comprovam que é desafiador evitar que um sistema livre de falhas seja erroneamente classificado como sujo (alarme falso) e que um sistema sujo seja erroneamente classificado como livre de falhas (não detecção). Essa incerteza resulta na completa sobreposição das saídas de cada cenário de falha, tornando-as praticamente indistinguíveis umas das outras.

O artigo de autoria de Soualhi et al., (2021) (nº 3), destaca que para cada sistema é necessário escolher o aprendizado de máquina apropriado e modelos que correspondem as características desse próprio sistema. Dessa maneira, os autores levam em consideração incrustações nos tubos dos trocadores de calor e verificam a necessidade de construir um modelo capaz de capturar a mudança na evolução das incrustações sob comando de um controlador de malha fechada. Tal sistema seria capaz de conhecer as tendências de degradação do sistema de troca térmica levando em consideração condições operacionais em estado não estacionário.

Najjar et al., (2016a) (nº 4), relatam que as saídas dos sensores que captam as medidas de incrustação nos trocadores estão suscetíveis a variações nos parâmetros operacionais, como número de passageiros, clima do dia e outros fatores, como vibrações mecânicas, distorções do sensor e ruído de medição. Isso tudo pode alterar a detecção correta das incrustações caso não haja uma análise de dados de temperatura, pressão e velocidade de fluido que possam, posteriormente, promover a classificação dos sensores.

3.3.5- Quais são as lacunas específicas na literatura atual e para onde a área pode avançar na aplicação do aprendizado de máquina na detecção de incrustação em trocadores de calor na engenharia química?

Najjar et al., (2016a) (nº 4), os autores destacam explicitamente seus planos futuros, que incluem a implementação em tempo real no trocador de calor de uma aeronave, aplicando a metodologia de diagnóstico de incrustações em dados reais

provenientes de aeronaves. Além disso, pretendem testar e validar os métodos de fusão dos sensores responsáveis por captar variáveis de temperatura e pressão na aeronave. A intenção é utilizar diversas ferramentas de aprendizado de máquina para aprimorar o desempenho da classificação. Outro objetivo específico da pesquisa é desenvolver uma metodologia semelhante de diagnóstico de incrustações para condições de operação de cruzeiro de aeronaves

O artigo de Wang et al., (2021) (nº 6), destaca o quão promissor pode ser o esquema de detecção desenvolvido. Os autores destacam que o sistema pode ser usado como chave de segurança, assim, quando ocorrem falhas, esse pode levar a um desligamento de emergência para protegê-lo. Outro fator é sobre o esquema de diagnóstico que poderia ser implementado em um sistema de monitoramento on-line devido ao seu imediatismo. Além disso, esses esquemas baseados em aprendizado de máquina podem ser promissores na detecção e diagnóstico de falhas do ORC como um sistema inteiro, não apenas um componente específico como apresentado no trabalho.

4 CONCLUSÕES E PESQUISAS FUTURAS

Diante do exposto neste trabalho, observa-se que o desenvolvimento de ferramentas de aprendizado de máquina para a observação e monitoramento de incrustações em trocadores de calor ainda se encontra em estágios de teste. Os modelos apresentados estão sendo desenvolvidos em computadores, sem aplicação prática real. Entretanto, diante do observado, é possível perceber que a pesquisa apresenta coerência e, portanto, poderá ser aplicada nas indústrias em poucos anos.

Os algoritmos mais testados para a realização e estudo de incrustações foram o SVM e o algoritmo k-NN, seguidos pelo algoritmo NN. Diante disso, se fez uma breve descrição e análise de eficácia de todos os algoritmos utilizados. Um dos trabalhos que demonstraram mais sucesso na análise das incrustações foi o escrito Soualhi et al., (2021) (nº 3), onde houve a junção dos algoritmos LSTM e NARX com os preditores de curto e longo prazo, capazes de prever as incrustações até 105 horas antes de começarem a afetar o trocador. Além disso, os métodos GPR, SVM, k-NN e IGWO-SVR também alcançaram ótimos resultados estatísticos nos artigos selecionados.

Entre as dificuldades encontradas, destacam-se os desafios na percepção dos parâmetros de incrustação, juntamente com erros na previsão e perda de informações. Ressalta-se que alguns erros recorrentes na perda de informações ou na não captura delas estão relacionados à capacidade operacional dos computadores utilizados. Vale ressaltar que o custo para adquirir computadores potentes capazes de suportar plataformas e executar os algoritmos é elevado.

As questões futuras abordam a aplicação dos métodos em trocadores de calor reais, bem como a implementação da capacidade de diagnóstico imediato das incrustações. Contudo, essas são previsões que ainda necessitarão de estudos mais aprofundados e testes mais eficazes, especialmente considerando que os estudos avaliados ao longo desta revisão sistemática são recentes, publicados nos últimos anos, embora já apresentem resultados promissores. Todos os artigos analisados estão em fase de teste computacional ou em protótipos. Portanto, é necessário verificar ainda como será a aplicação desses métodos frente a trocadores reais. Diante disso, espera-se que a evolução de estudos nessa área prossiga, podendo proporcionar economias substanciais para as empresas.

Além disso, é importante destacar que, diante do número de artigos encontrados nas bases de dados (30 artigos), existe uma vasta área de pesquisa que pode ser abordada. A enorme quantia de algoritmos capazes de fazer o monitoramento abre um vasto leque de estudo nessa área, promovendo uma melhoria tanto na detecção como na rapidez do aprendizado de máquina.

REFERÊNCIAS

- AL-NASER, M. et al. Intelligent Prediction Approach of Fouling Location in Shell and Tube Heat Exchanger. **IEEE**, 2020.
- BERGMAN, T. L.; LAVINE, A. S. **Fundamentos de Transferência de Calor e de Massa**. 8ª ed. Rio de Janeiro: [s.n.].
- BIOLCHINI, J. et al. **Systematic Review in Software Engineering**. Rio de Janeiro: [s.n.].
- DIAZ-BEJARANO, E. et al. Organic and Inorganic Fouling in Heat Exchangers: Industrial Case Study Analysis of Fouling Rate. **Industrial and Engineering Chemistry Research**, v. 58, n. 1, p. 228–246, 9 jan. 2019.
- DOBBELAERE, M. R. et al. Machine Learning in Chemical Engineering: Strengths, Weaknesses, Opportunities, and Threats. **Engineering**, v. 7, n. 9, p. 1201–1211, 1 set. 2021.
- HALE, W. T.; SAFIKOU, E.; BOLLAS, G. M. Inference of faults through symbolic regression of system data. **Computers and Chemical Engineering**, v. 157, 1 jan. 2022.
- HOSSEINI, S. et al. Novel and robust machine learning approach for estimating the fouling factor in heat exchangers. **Energy Reports**, v. 8, p. 8767–8776, 1 nov. 2022.
- IKONEN, E. et al. Fouling monitoring in a circulating fluidized bed boiler using direct and indirect model-based analytics. **Fuel**, v. 346, 15 ago. 2023.
- KAH HOU, T. et al. **Provisional chapter Industrial Heat Exchanger: Operation and Maintenance to Minimize Fouling and Corrosion**. [s.l.: s.n.]. Disponível em: <www.intechopen.com>.
- KAKAÇ, S.; LIU, H.; PRAMUANJAROENKIJ, A. **Heat Exchangers: Selection, Rating, and Thermal Design**; 4ª ed. Boca Raton: Taylor & Francis Group, 2020.
- KITCHENHAM, B. **Procedures for Performing Systematic Reviews**. [s.l.: s.n.].
- KUFEL, J. et al. What Is Machine Learning, Artificial Neural Networks and Deep Learning?—Examples of Practical Applications in Medicine. **Diagnostics**, v. 13, n. 15, 1 ago. 2023.
- MALHOTRA, R. A systematic review of machine learning techniques for software fault prediction. **Applied Soft Computing Journal**, v. 27, p. 504–518, 2015.
- NAJJAR, N. et al. Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems. **IEEE Sensors Journal**, v. 16, n. 12, p. 4866–4881, 15 jun. 2016a.
- NAJJAR, N. et al. Optimal sensor selection and fusion for heat exchanger fouling diagnosis in aerospace systems. **IEEE Sensors Journal**, v. 16, n. 12, p. 4866–4881, 15 jun. 2016b.

PAGE, M. J. et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. **The BMJ**, v. 372, 29 mar. 2021.

SANTAMARIA, F. L.; MACCHIETTO, S. Online Integration of Optimal Cleaning Scheduling and Control of Heat Exchanger Networks under Fouling. **Industrial and Engineering Chemistry Research**, v. 59, n. 6, p. 2471–2490, 12 fev. 2020.

SHERIFF, 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**, v. 184, p. 233–245, 1 ago. 2022.

SOUALHI, M. et al. Adaptive prognostics in a controlled energy conversion process based on long- and short-term predictors. **Applied Energy**, v. 283, 1 fev. 2021.

SRINIVASARENGAN, K. et al. **Takagi-Sugeno model based Nonlinear Parameter Estimation in Air Handling Units**. IFAC-PapersOnLine. **Anais...Elsevier B.V.**, 2016.

SUN, L. et al. **Research on the fouling prediction of heat exchanger based on support vector machine**. Proceedings - International Conference on Intelligent Computation Technology and Automation, ICICTA 2008. **Anais...2008**.

SUN, L.; ZHANG, Y.; SAQI, R. **Fouling prediction of heat exchanger based on genetic optimal SVM algorithm**. 3rd International Conference on Genetic and Evolutionary Computing, WGEC 2009. **Anais...2009**.

SUN, T. et al. Artificial Intelligence Meets Flexible Sensors: Emerging Smart Flexible Sensing Systems Driven by Machine Learning and Artificial Synapses. **Nano-Micro Letters**, v. 16, n. 1, 1 dez. 2024.

WALTMAN, L. et al. Some modifications to the SNIP journal impact indicator. **Journal of Informetrics**, v. 7, n. 2, p. 272–285, 2013.

WANG, J. et al. Machine Learning–Based Fault Detection and Diagnosis of Organic Rankine Cycle System for Waste-Heat Recovery. **Journal of Energy Engineering**, v. 147, n. 4, ago. 2021.

WANG, J. et al. Fouling prediction of heat exchanger surface under alternating magnetic field based on IGWO–SVR. **International Journal of Thermal Sciences**, v. 184, 1 fev. 2023a.

WANG, J. et al. Fouling prediction of heat exchanger surface under alternating magnetic field based on IGWO–SVR. **International Journal of Thermal Sciences**, v. 184, 1 fev. 2023b.

WANG, W. et al. A systematic review of machine learning models for predicting outcomes of stroke with structured data. **PLoS ONE**, v. 15, n. 6, 1 jun. 2020.