

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
CÂMPUS DE ILHA SOLTEIRA
DEPARTAMENTO DE ENGENHARIA MECÂNICA**

ESTÊNIO FUZARO DE ALMEIDA

**TRANSFERÊNCIA DE APRENDIZADO ENTRE MODELOS
ORIENTADOS POR DADOS PARA O MONITORAMENTO DE
TROCADORES DE CALOR**

Ilha Solteira
2025



ESTÊNIO FUZARO DE ALMEIDA

TRANSFERÊNCIA DE APRENDIZADO ENTRE MODELOS
ORIENTADOS POR DADOS PARA O MONITORAMENTO DE
TROCADORES DE CALOR

Dissertação de Mestrado a ser apresentada
à Universidade Estadual Paulista (UNESP),
Faculdade de Engenharia de Ilha Solteira,
sendo parte do processo de obtenção do título
de Mestrado em Engenharia Mecânica

Área de Conhecimento: Sistemas Dinâmicos.

Prof. Dr. Samuel da Silva
Orientador

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

A447t Almeida, Estênio Fuzaro de.
Transferência de aprendizado entre modelos orientados por dados para o monitoramento de trocadores de calor / Estênio Fuzaro de Almeida. -- Ilha Solteira: [s.n.], 2025
68 f. : il.

Dissertação (Mestrado em Engenharia Mecânica) - Universidade Estadual Paulista (UNESP), Faculdade de Engenharia, Ilha Solteira, 2025

Orientador: Samuel da Silva

Inclui bibliografia

1. Trocadores de calor. 2. Detecção de incrustação. 3. Sombra digital. 4. Calibração bayesiana. 5. Modelagem autoregressiva. 6. Transferência de aprendizado.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: TRANSFER LEARNING OF DIGITAL SHADOWS FOR FOULING
MONITORING IN HEAT EXCHANGES

AUTOR: ESTÊNIO FUZARO DE ALMEIDA

ORIENTADOR: SAMUEL DA SILVA

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Mecânica,
área: I - Ciências Mecânicas, área: Ciências Mecânicas pela Comissão Examinadora:

Samuel da

Silva:26693971822

Assinado de forma digital por
Samuel da Silva:26693971822
Dados: 2025.08.06 16:14:15 -03'00'

Prof. Dr. SAMUEL DA SILVA (Participação Virtual)

Departamento de Engenharia Mecânica / Faculdade de Engenharia de Ilha Solteira - UNESP



Documento assinado digitalmente

CLAUDIO GARCIA

Data: 06/08/2025 18:27:26-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. CLAUDIO GARCIA (Participação Virtual)

Departamento de Telecomunicações e Controle / Universidade de São Paulo - USP



Documento assinado digitalmente

MAURO ANTONIO DA SILVA SÁ RAVAGNANI

Data: 07/08/2025 14:18:21-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. MAURO ANTONIO DA SILVA SÁ RAVAGNANI (Participação Virtual)

Departamento de Engenharia Química / Universidade Estadual de Maringá - UEM

Ilha Solteira, 06 de agosto de 2025

AGRADECIMENTOS

A Deus, pela força e pela saúde que me sustentam diariamente, permitindo que eu persista e encontre energia para buscar meus objetivos.

Aos meus pais, Edilson e Edinéia, por toda a base sólida que me deram, moldando meu caráter e minha visão de mundo. A cada decisão que tomo e a cada passo que dou, sinto a presença dos seus ensinamentos e valores, que me guiam e me inspiram a seguir em frente, sempre honrando o legado que vocês construíram.

Ao meu irmão, Estevão, por ser um ponto de apoio constante e alguém em quem sempre pude confiar. Sua presença ao longo de minha vida me ensinou muito sobre lealdade e parceria, mostrando que, mesmo nos momentos mais difíceis, a família é a força que nos mantém firmes.

Ao Prof. Samuel, meu orientador, por todos esses anos de orientação, parceria e amizade. Agradeço também aos meus colegas do SHM Lab, que estiveram juntos nos desafios diários.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) por acreditar no meu potencial e apoiar minha pesquisa de Iniciação Científica no começo da minha trajetória acadêmica, e agora no meu Mestrado. Esse financiamento foi essencial para que eu pudesse chegar até aqui e realizar este trabalho.

E, finalmente, a todos aqueles que, de alguma forma, contribuíram para minha formação, seja direta ou indiretamente, deixo meu mais sincero agradecimento.

“It doesn’t matter how beautiful your theory is, it doesn’t matter how smart you are. If it doesn’t agree with experiment, it’s wrong.”

Richard P. Feynman

ABSTRACT

Fouling in heat exchangers compromises thermal efficiency and increases operational costs in industrial systems. This dissertation proposes a data-driven methodology for fouling detection, based on the construction of simplified digital representations of the thermal behavior of heat exchangers, combined with Transfer Learning, which enables the model to adapt to different equipment geometries. The approach utilizes real-time process data, including temperature, flow rate, and pressure, thereby eliminating the need for computationally expensive advanced numerical simulations. Since collecting and validating real data can be challenging, the techniques were initially tested with a reduced-order model that employs ordinary differential equations to represent the thermal dynamics, combined with a stochastic model for the overall heat transfer coefficient to account for uncertainties and emulate fouling progression. Since there is no real-time communication with the physical system, it is not a Digital Twin, but rather a Digital Shadow. Three distinct datasets were analyzed: the first simulates the thermal aging of a heat exchanger through a stochastic model calibrated using Bayesian computation; the second uses synthetic thermal curves generated from a probabilistic distribution of the overall heat transfer coefficient, enabling the identification of autoregressive models; and the third dataset consists of experimental data from two heat exchangers with different geometries, where fouling conditions were simulated by varying thermal response parameters. From the temperature signals, metrics such as the variance of prediction errors and signal energy are extracted and used in an automatic classification process of the operating states through Support Vector Machines. Transfer Learning, using the JDA method, generalizes the detection algorithm, enabling the reuse of knowledge across different heat exchangers. The proposed methodology demonstrated robustness and satisfactory performance in detecting fouling levels and generalizing the algorithm across different scenarios, even in contexts with simplified instrumentation, providing a versatile tool to enhance predictive maintenance practices in industrial environments.

Keywords: heat exchangers; fouling detection; digital shadow; bayesian calibration; autoregressive modeling; transfer learning.

RESUMO

A incrustação em trocadores de calor compromete a eficiência térmica e eleva os custos operacionais em sistemas industriais. É proposta uma metodologia orientada por dados para a detecção de incrustação, baseada na construção de representações digitais simplificadas do comportamento térmico dos trocadores de calor e na Transferência de Aprendizado, permitindo a adaptação do modelo a diferentes geometrias de equipamentos. A abordagem utiliza dados de processo em tempo real, como temperatura, vazão e pressão, dispensando simulações numéricas avançadas, que são computacionalmente custosas. Como a coleta e validação de dados reais podem ser desafiadoras, as técnicas foram testadas inicialmente com um modelo de ordem reduzida, que emprega equações diferenciais ordinárias para representar a dinâmica térmica, combinadas a um modelo estocástico do coeficiente global de troca de calor, para considerar incertezas e emular a progressão da incrustação. Por não haver comunicação em tempo real com o sistema físico, não se trata de um Gêmeo Digital, mas sim uma Sombra Digital. Foram analisadas três bases de dados distintas: a primeira simula o envelhecimento térmico de um trocador de calor por meio de um modelo estocástico calibrado com computação bayesiana; a segunda utiliza curvas térmicas sintéticas, isto é, simuladas numericamente a partir de uma distribuição probabilística do coeficiente global de troca de calor, permitindo a identificação de modelos autorregressivos; e a terceira base é composta por dados experimentais de dois trocadores com geometrias diferentes, em que a condição de incrustação foi simulada por variações nos parâmetros de resposta térmica. A partir dos sinais de temperatura, são extraídas métricas como a variância dos erros de predição e a energia do sinal, utilizadas em um processo de classificação automática dos estados operacionais por meio de máquinas de vetores de suporte. A Transferência de Aprendizado, usando o método JDA, generaliza o algoritmo, permitindo o reaproveitamento de conhecimento entre trocadores de calor distintos. A metodologia demonstrou robustez e bom desempenho na detecção do nível de incrustação e na generalização do algoritmo em diferentes cenários, mesmo em contextos com instrumentação simplificada, oferecendo uma ferramenta versátil para aprimorar práticas de manutenção preditiva em ambientes industriais.

Palavras-chave: trocadores de calor; detecção de incrustação; sombra digital; calibração bayesiana; modelagem autoregressiva; transferência de aprendizado.

LISTA DE SÍMBOLOS

TÉRMICO / TROCADOR DE CALOR

$T_t(t)$ — Temperatura instantânea do fluido no **tubo** [K]

$T_c(t)$ — Temperatura instantânea do fluido no **casco** [K]

$T_{t,0}$ — Temperatura inicial do fluido no tubo [K]

$T_{c,0}$ — Temperatura inicial do fluido no casco [K]

T_{in} — Temperatura de entrada do fluido [K]

$T(t)$ — Temperatura instantânea do fluido [K]

$\dot{m}_t$ — Vazão mássica no **tubo** [kg/s]

$\dot{m}_c$ — Vazão mássica no **casco** [kg/s]

$\dot{m}$ — Vazão mássica genérica [kg/s]

$c_{p,t}$ — Calor específico do fluido no tubo [J/(kg · K)]

$c_{p,c}$ — Calor específico do fluido no casco [J/(kg · K)]

c_p — Calor específico genérico [J/(kg · K)]

U — Coeficiente global de transferência de calor (determinístico)
[W/(m² · K)]

$\mathbb{U}$ — Coeficiente global de transferência de calor, modelado como
variável aleatória (estocástico) [W/(m² · K)]

$\mathbb{U}_0$ — Valor inicial de $\mathbb{U}$ [W/(m² · K)]

U_{med} — Valor médio de $\mathbb{U}$ [W/(m² · K)]

A — Área de troca térmica [m²]

ρ_t — Massa específica do fluido no tubo [kg/m³]

ρ_c — Massa específica do fluido no casco [kg/m³]

ρ — Massa específica (genérica) [kg/m³]

V_t — Volume do fluido no tubo [m³]

V_c — Volume do fluido no casco [m³]

k — Ganho estático do modelo de 1^a ordem [°C]

τ — Constante de tempo do modelo de 1^a ordem [s]

t — Tempo [s]

Δt — Passo de amostragem [s]

DECAIMENTO / ESTOCÁSTICO

λ — Taxa de decaimento exponencial de $\mathbb{U}$ (incrustação) [s⁻¹]

$\mu_{\mathbb{U}}$ — Média da distribuição de $\mathbb{U}$ [W/(m² · K)]

$\sigma_{\mathbb{U}}$ — Desvio padrão da distribuição de $\mathbb{U}$ [W/(m² · K)]

$\Gamma(\text{forma}, \text{escala})$ — Distribuição gama (parâmetros forma e escala)
[—]

CALIBRAÇÃO BAYESIANA (ABC)

$\mathbf{y}$ — Dados observados (vetor) [—]

$f(\theta; \mathbf{x})$ — Saída do modelo paramétrico [—]

θ — Vetor de parâmetros do modelo (ex.: $\mathbb{U}_0, \lambda$) [—]

$\mathbf{x}$ — Vetor de entradas [—]

ε — Erro de medição/ruído [—]

$\pi(\theta|\mathbf{y})$ — Distribuição a posteriori dos parâmetros [—]

$\pi(\mathbf{y}|\theta)$ — Verossimilhança [—]

$\pi(\theta)$ — Distribuição a priori dos parâmetros [—]

MODELOS AR / MÉTRICAS

$y(k)$ — Temperatura de referência (limpa) no instante k [K]

$x(k)$ — Temperatura sob condição desconhecida no instante k [K]

$A(q)$ — Polinômio AR: $A(q) = 1 + a_1q^{-1} + \dots + a_pq^{-p}$ [—]

q^{-1} — Operador de atraso [—]

a_i — Coeficientes do modelo AR [—]

p — Ordem do modelo AR $[-]$

$e_{\text{ref}}(k)$ — Erro de predição do sinal de referência [K]

$e_{\text{desc}}(k)$ — Erro de predição do sinal sob diagnóstico [K]

$\mathcal{X}_1$ — Razão de variâncias dos erros $\sigma^2(e_{\text{desc}})/\sigma^2(e_{\text{ref}})$ $[-]$

$\mathcal{X}_2$ — Energia do sinal de temperatura (integral trapezoidal) $[\text{K} \cdot \text{s}]$

CLASSIFICAÇÃO (SVM)

$\mathbf{x}_i$ — Vetor de características (amostra i) $[-]$

y_i — Rótulo da amostra (+1 limpo, -1 incrustado) $[-]$

$\mathbf{w}$ — Vetor de pesos do hiperplano $[-]$

b — Viés do hiperplano $[-]$

TRANSFER LEARNING / JDA

$\mathbf{X}_s$ — Matriz de atributos do domínio **fonte** $[-]$

$\mathbf{y}_s$ — Rótulos do domínio fonte $[-]$

$\mathbf{X}_t$ — Matriz de atributos do domínio **alvo** (não rotulado) $[-]$

$\mathbf{A}$ — Matriz de projeção para o espaço latente $[-]$

C — Número de classes (aqui $C = 2$) $[-]$

$\|\cdot\|_F$ — Norma de Frobenius $[-]$

λ_{JDA} — Parâmetro de regularização da JDA $[-]$

CONSTANTES / OUTROS

a — Constante de tempo associada ($a = 4000$ s no texto) [s]

RMSE — Raiz do erro quadrático médio [K]

CONTEÚDO

1	INTRODUÇÃO	11
1.1	OBJETIVOS E CONTRIBUIÇÕES ESPERADAS	15
1.2	ORGANIZAÇÃO DO TEXTO	16
2	METODOLOGIA GERAL: MODELAGEM, CLASSIFICAÇÃO E TRANSFERÊNCIA DE APRENDIZADO	20
2.1	MODELAGEM ESTOCÁSTICA E CALIBRAÇÃO BAYESIANA (ABC)	21
2.1.1	Modelagem Analítica de Ordem Reduzida	22
2.1.2	Calibração por Computação Bayesiana Aproximada (ABC)	24
2.2	MODELOS AUTOREGRESSIVOS (AR)	26
2.2.1	Extração de Atributos Estatísticos	27
2.3	CLASSIFICAÇÃO COM MÁQUINAS DE VETOR SUPORTE (SVM)	28
2.4	TRANSFERÊNCIA DE APRENDIZADO POR ADAPTAÇÃO DE DISTRIBUIÇÃO CONJUNTA (JDA)	30
2.5	CONCLUSÃO DO CAPÍTULO	32
3	APLICAÇÃO NAS SIMULAÇÕES NUMÉRICAS	33
3.1	BASE 1 - SIMULAÇÃO COM ABC E DECAIMENTO DE U	33
3.1.1	Geometria dos Trocadores Fonte e Alvo	34
3.1.2	Deteção no Espaço Original de Características	35
3.1.3	Deteção no Espaço Latente	37
3.2	BASE 2 - SIMULAÇÃO COM AR E $U \sim \Gamma$	38
3.3	CONCLUSÃO DO CAPÍTULO	48
4	VALIDAÇÃO EXPERIMENTAL COM TROCADORES REAIS	49
4.1	TROCADOR CASCO E TUBO	49
4.2	TROCADOR DE PLACAS PLANAS	50
4.3	AJUSTE DAS CURVAS E SIMULAÇÃO DE INCRUSTAÇÃO	50
4.4	CLASSIFICAÇÃO COM MODELOS AR E TRANSFERÊNCIA DE APRENDIZADO	54
4.5	CONCLUSÃO DO CAPÍTULO	58
5	CONCLUSÕES E PERSPECTIVAS	59

5.1	CONCLUSÕES	59
5.2	TRABALHOS FUTUROS	61
5.3	LISTA DE PUBLICAÇÕES ATÉ O MOMENTO	62
5.4	DISPONIBILIDADE DE DADOS	62
5.5	FINANCIAMENTO	63
	REFERÊNCIAS BIBLIOGRÁFICAS	64

1 INTRODUÇÃO

Os trocadores de calor são componentes essenciais em diversos setores industriais, como geração de energia, processos químicos e sistemas de refrigeração, devido à sua capacidade de transferir calor eficientemente entre fluidos. A eficiência energética e a redução de custos operacionais desses sistemas dependem diretamente da manutenção da integridade e do desempenho dos trocadores, o que os torna fundamentais para otimizar processos energéticos em larga escala.

Dentre os problemas em vida que os trocadores podem apresentar, a incrustação é uma preocupação bem documentada desde os primeiros estudos sobre a eficiência desses sistemas. Bott e Melo (1997) destacaram os impactos da formação de depósitos sólidos em superfícies de troca térmica, observando que esse fenômeno prejudica o desempenho térmico, aumenta a resistência ao fluxo de calor e resulta em elevações significativas nos custos operacionais devido a paradas frequentes para limpeza e manutenção (Müller-Steinhagen; Watkinson, 2011). Em setores como refinarias e plantas de geração de energia, esses problemas podem representar bilhões de dólares em custos anuais (Diaz-Bejarano *et al.*, 2017). Estima-se que, nos Estados Unidos, os custos anuais associados à manutenção de trocadores de calor, em grande parte devido à incrustação, ultrapassem US\$ 14 bilhões (Sheriff *et al.*, 2022). Esse valor ressalta a importância do desenvolvimento de técnicas mais eficientes para monitoramento, manutenção preditiva e limpeza desses equipamentos.

Como apontado por Inamdar *et al.* (2016) em sua revisão bibliográfica, nos anos 1980 e 1990, estudos experimentais como o de Bott e Bemrose (1983) começaram a investigar a incrustação em geometrias mais complexas, como trocadores de calor com tubos aletados em espiral. Os autores utilizaram carbonato de cálcio para promover a incrustação e observaram que o acúmulo afetava significativamente o fator J de Colburn (uma grandeza adimensional usada para avaliar a eficiência da transferência de calor em escoamentos forçados, como em um trocador de calor) e o fator de atrito, indicando a necessidade de modelagem mais precisa para prever o comportamento do fenômeno. No entanto, devido à complexidade dos trocadores de calor, a modelagem preditiva desses processos ainda permanecia desafiadora.

Inamdar *et al.* (2016) apontam que a partir dos anos 2000, houve um avanço significativo na modelagem física da incrustação. Um exemplo é o estudo de Siegel e Nazaroff (2003), que desenvolveram um modelo utilizando simulações de Monte Carlo

para prever a deposição de partículas em trocadores de calor, abrangendo uma ampla faixa de diâmetros de partículas. Eles identificaram que, para partículas menores, o movimento Browniano era predominante, enquanto para partículas maiores, a impacção e outros mecanismos se tornavam mais significativos. A abordagem aplicada é bastante relevante, pois oferece um modelo flexível que pode ser adaptado para diferentes cenários e condições operacionais. O modelo é inovador também do ponto de vista da abordagem estocástica, porém busca caracterizar o movimento do particulado dentro da região de fluxo, quando a preocupação industrial se concentra mais na eficiência da troca de calor através de relações entrada e saída, em que o transiente do trocador não é tão relevante.

Historicamente, a detecção de incrustação nos trocadores de calor utilizou métodos baseados em medições de pressão e temperatura, que, apesar de eficientes para indicar perdas de eficiência, são limitados por sua abordagem reativa. Ou seja, apenas detectam a presença de incrustações quando estas já impactaram significativamente o desempenho do sistema (Wallhäußer; Hussein; Becker, 2012). Por exemplo, a sobrecarga gerada pela deposição de material nas superfícies de troca térmica aumenta a queda de pressão e diminui a transferência de calor, mas a incrustação já é, normalmente, de grande magnitude, quando essa variação é detectada (Jackowski; Smith, 2017). Isso limita a capacidade de planejar manutenções de maneira eficiente, muitas vezes levando a custos elevados e perdas de produção. Essas limitações motivaram o desenvolvimento de técnicas preditivas baseadas em modelos mais sofisticados.

Nos últimos anos, os avanços em aprendizado de máquina e técnicas orientadas por dados abriram novas possibilidades para o monitoramento preditivo dos sistemas industriais, incluindo trocadores de calor. Técnicas como o filtro de Kalman têm sido aplicadas, melhorando a precisão e adaptabilidade ao incorporar variações operacionais (Muenthong; Chattakarn; Lersbamrungsuk, 2020). Outra técnica de interesse são os gêmeos digitais, por exemplo, que permitem que dados coletados em tempo real para finalidades de controle de processos, como temperatura, vazão e pressão, sejam utilizados para criar replicas digitais que simulam o comportamento do sistema (Chen; Zhao; Tao, 2023; Yu *et al.*, 2022). Uma vez calibrados, esses modelos podem fornecer informações importantes sobre o estado de saúde dos trocadores de calor, permitindo uma detecção mais eficiente da incrustação e a implementação de estratégias de manutenção mais eficazes. Uma vez que um gêmeo digital é composto de sensores e atuadores, seria possível detectar alterações na operação indicadoras de incrustação, emitir um alerta ao operador e também adap-

tar as variáveis de entrada de forma a compensar o fenômeno indesejado. Além disso, técnicas de calibração bayesiana para integrar incertezas operacionais em gêmeos digitais se mostram promissoras, especialmente em contextos industriais onde é difícil modelar todos os aspectos de maneira determinística (Diaz-Bejarano; Coletti; Macchietto, 2017). A aplicação dessas técnicas permite que o modelo seja ajustado em tempo real com base nos dados operacionais, aprimorando a adaptação e a precisão preditiva dos sistemas de monitoramento.

Estudos recentes destacam o uso de métodos baseados em modelos para monitorar, visualizar e diagnosticar a incrustação em trocadores de calor. Ao integrar sistemas de monitoramento dinâmico e análise de dados avançada, esses métodos demonstram uma capacidade aprimorada de otimizar cronogramas de limpeza e melhorar o desempenho operacional (Diaz-Bejarano; Coletti; Macchietto, 2020; Diaz-Bejarano; Coletti; Macchietto, 2019). Outra inovação importante é a Transferência de Aprendizado, que surge como uma técnica promissora para generalizar modelos de detecção de incrustação, permitindo que o conhecimento adquirido em um trocador de calor seja transferido para outro com geometria diferente, como demonstrado em aplicação em pontes por Souza *et al.* (2024). Essa abordagem pode reduzir significativamente a necessidade de coleta de grandes volumes de dados para cada trocador, acelerando o processo de desenvolvimento de modelos preditivos.

Com base nas técnicas discutidas, este trabalho propõe uma abordagem orientada por dados para detecção e diagnóstico de incrustação em trocadores de calor, utilizando modelos autoregressivos (*Auto Regressive* – AR) e Transferência de Aprendizado (*Transfer Learning* – TL). Por ainda não haver comunicação em tempo real com o sistema físico, não se pode chamar a metodologia de “Gêmeo Digital”, neste caso, havendo um modelo computacional com classificação de estados de incrustação calibrado com dados reais (mas sem realimentação do sistema físico), podemos chamar de “Sombra Digital”, ou *Digital Shadow*. A metodologia baseia-se na construção de *Digital Shadows*, identificados a partir de curvas de temperatura em condição limpa, com o objetivo de monitorar desvios no comportamento térmico associados à incrustação.

Três bases de dados são analisadas: duas obtidas por simulação numérica e uma experimental. A primeira base simula dois trocadores do tipo casco e tubo, ambos com água como fluido de trabalho, porém com geometrias distintas. As condições limpa e incrustada são fruto de parâmetros calibrados via Computação Bayesiana Aproximada

(ABC), sendo a incrustação consequência de um modelo de envelhecimento do trocador de calor através da redução do coeficiente global de transferência de calor $\mathbb{U}$ ao longo do tempo. Nessa base, as variáveis de entrada no classificador são as temperaturas de saída dos compartimentos.

A segunda base numérica considera também dois trocadores casco e tubo de geometrias diferentes, mas com fluidos distintos: o trocador fonte opera com água-água e o alvo com óleo-água. Aqui, as curvas de temperatura são geradas sinteticamente com base em variações estocásticas de $\mathbb{U}$ modeladas por uma distribuição gama. Modelos AR são identificados para cada curva em condição limpa, e características estatísticas como razão entre variâncias dos erros de predição e energia do sinal são extraídas para compor o espaço de atributos. Por fim, a base experimental é composta por dados coletados em dois trocadores reais: um do tipo casco e tubo e outro de placas planas. Ambos operam com água e foram instrumentados em condição limpa. A partir das curvas obtidas, aplicou-se o mesmo procedimento de modelagem AR e extração de atributos utilizado na segunda base.


A partir desses dados (numéricos e experimentais) são construídos os conjuntos de treinamento e teste. Um classificador binário do tipo *Support Vector Machine* (SVM) é treinado inicialmente no domínio fonte para distinguir entre estados limpo e incrustado. No entanto, observou-se queda de desempenho ao aplicar diretamente esse classificador ao domínio alvo, devido às discrepâncias estruturais e operacionais entre os trocadores.

Para contornar essa limitação, é aplicada a técnica de *Joint Distribution Adaptation* (JDA), que projeta os atributos fonte e alvo em um espaço latente comum. O espaço latente é o resultado da transformação feita por um algoritmo de adaptação de domínio, ou seja, é a representação visual dos atributos projetados no novo domínio. Nesse espaço, a distância estatística entre os domínios é minimizada, permitindo a reutilização do classificador mesmo sem dados rotulados no alvo. A JDA pertence à classe de técnicas de transferência de aprendizado baseadas em características, sendo ideal para aplicações industriais com instrumentação limitada e dados escassos.

A Figura 1 ilustra esse processo, destacando como o conhecimento adquirido em um trocador bem instrumentado pode ser transferido para outro com baixa disponibilidade de dados. Isso torna a abordagem promissora para a expansão de estratégias preditivas em sistemas térmicos de diferentes configurações.

A proposta se mostra especialmente relevante para contextos industriais, onde ape-

Figura 1 – Fluxograma da metodologia proposta



Fonte: Produção do próprio autor

nas alguns trocadores são monitorados de forma intensiva, enquanto a maioria opera com número reduzido de sensores. Ao permitir a transferência de conhecimento mesmo entre trocadores com geometrias e condições distintas, a metodologia oferece uma solução escalável, prática e de baixo custo para o diagnóstico de incrustação e suporte à manutenção preditiva.

1.1. OBJETIVOS E CONTRIBUIÇÕES ESPERADAS

O objetivo principal deste trabalho é desenvolver e validar uma metodologia orientada por dados para detecção de incrustação em trocadores de calor, com capacidade de generalização entre diferentes geometrias e condições operacionais, por meio de técnicas de Transferência de Aprendizado. A abordagem proposta combina modelagem autoregressiva, extração de atributos estatísticos e adaptação de domínios utilizando o algoritmo *Joint Distribution Adaptation* (JDA).

Para isso, são consideradas três bases de dados distintas: duas simuladas numericamente (uma com modelagem estocástica e calibração bayesiana do coeficiente global de transferência de calor, e outra com geração sintética baseada em modelos AR) além de uma base experimental obtida em bancada com trocadores de geometrias reais (casco e tubo, e placas planas).

As principais contribuições esperadas deste estudo são:

- **Proposição de uma metodologia unificada de diagnóstico térmico por**

dados, aplicável tanto a cenários simulados quanto experimentais, com potencial de generalização entre trocadores distintos;

- **Construção de Sombras Digitais por modelos autoregressivos (AR)**, permitindo representar o comportamento térmico esperado em condição limpa e detectar desvios por meio de métricas extraídas do erro de predição;
- **Aplicação de Transferência de Aprendizado baseada em características (JDA)**, com mapeamento para espaço latente compartilhado entre domínios, permitindo o reaproveitamento de classificadores treinados mesmo em contextos com poucos dados rotulados;
- **Validação da metodologia em diferentes cenários**, incluindo trocadores com fluidos distintos (água e óleo), geometrias diversas e dados reais, demonstrando robustez frente a variações operacionais e de instrumentação.

Com essa abordagem, espera-se contribuir com soluções viáveis e escaláveis para manutenção preditiva de trocadores de calor, particularmente em ambientes industriais com restrição de sensores ou escassez de dados históricos.

1.2. ORGANIZAÇÃO DO TEXTO

Este trabalho está estruturado em seis capítulos, além das referências bibliográficas, conforme descrito a seguir:

- **Capítulo 1 — Introdução:** Apresenta o contexto industrial da incrustação em trocadores de calor, seus impactos econômicos e operacionais, e a motivação para o desenvolvimento de metodologias preditivas orientadas por dados. Define os objetivos do estudo, destaca suas contribuições e resume a organização da dissertação.
 - **1.1 Objetivos e Contribuições Esperadas:** Expõe o propósito central do trabalho e os avanços metodológicos propostos.
 - **1.2 Organização do Texto:** Apresenta a estrutura dos capítulos e suas respectivas funções.
- **Capítulo 2 — Metodologia Geral: Modelagem, Classificação e Transferência de Aprendizado:** Apresenta os fundamentos das técnicas aplicadas ao

longo da dissertação, comuns às três bases de dados. Este capítulo estabelece a base teórica e computacional da metodologia proposta.

- **2.1 Modelagem Estocástica e Calibração Bayesiana (ABC):** Detalha o modelo térmico com degradação do coeficiente global $\mathbb{U}$, tratado como variável aleatória, e sua calibração via Computação Bayesiana Aproximada.
 - **2.2 Modelos Autoregressivos (AR):** Apresenta os fundamentos dos modelos AR e sua utilização como Sombras Digitais para diagnóstico térmico.
 - **2.3 Extração de Atributos Estatísticos:** Descreve as métricas utilizadas para caracterizar o estado térmico do trocador, como razão de variância de erro e integral do sinal de temperatura.
 - **2.4 Classificação com *Support Vector Machine* (SVM):** Introduz o classificador SVM e sua aplicação ao problema de detecção binária de incrustação.
 - **2.5 Transferência de Aprendizado por Adaptação de Distribuição Conjunta (JDA):** Apresenta o algoritmo de Adaptação de Distribuição Conjunta como técnica para adaptação de domínios.
 - **2.6 Conclusão do Capítulo:** Resume os conceitos apresentados e sua integração na metodologia.
- **Capítulo 3 — Aplicação nas Simulações Numéricas:** Aplica a metodologia proposta a duas bases de dados sintéticas, com diferentes abordagens de simulação, avaliando o desempenho do processo de classificação e transferência de aprendizado.
 - **3.1 Base 1 — Simulação com ABC e Decaimento de $\mathbb{U}$:** Aplica SVM e JDA a dados de dois trocadores com geometrias distintas, simulados com degradação estocástica do coeficiente de troca térmica.
 - * **3.1.1 Geometria dos Trocadores Fonte e Alvo:** Detalha os sistemas simulados e suas condições de contorno.
 - * **3.1.2 Detecção no Espaço Original de Características:** Avalia o desempenho da classificação sem adaptação de domínio.
 - * **3.1.3 Detecção no Espaço Latente:** Analisa a aplicação de JDA e a adaptação entre domínios.

- **3.2 Base 2 — Simulação com AR e $U \sim \text{Gama}$:** Utiliza curvas sintéticas de dois trocadores casco e tubo, com modelagem AR e extração de atributos para detecção de incrustação.
- **3.3 Conclusão do Capítulo:** Compara os resultados entre as bases numéricas e discute a robustez dos métodos.
- **Capítulo 4 — Validação Experimental com Trocadores Reais:** Reúne a descrição da bancada experimental, os procedimentos de aquisição e pré-processamento de dados, e a aplicação da metodologia de classificação com Transferência de Aprendizado (JDA) a dois trocadores reais com geometrias distintas.
 - **4.1 Trocador Casco e Tubo:** Descreve o trocador utilizado como domínio fonte e sua instrumentação.
 - **4.2 Trocador de Placas Planas:** Apresenta o trocador alvo com geometria plana e diferentes regimes de operação.
 - **4.3 Ajuste das Curvas e Simulação de Incrustação:** Detalha a obtenção dos parâmetros térmicos e a geração de curvas sintéticas representando diferentes condições operacionais.
 - **4.4 Classificação com Modelos AR e Transferência de Aprendizado:** Apresenta os resultados de classificação utilizando SVM e JDA a partir dos atributos extraídos dos modelos AR.
 - **4.5 Conclusão do Capítulo:** Resume os resultados obtidos com os dados reais e valida a aplicabilidade da metodologia.
- **Capítulo 5 — Conclusões e Perspectivas:** Reúne as principais conclusões do estudo, analisa limitações e propõe desdobramentos futuros para aplicação prática e extensão da metodologia.
 - **5.1 Conclusões:** Resume as contribuições e os resultados da pesquisa.
 - **5.2 Trabalhos Futuros:** Aponta direções futuras, como aplicação em plantas industriais e integração com gêmeos digitais.
 - **5.3 Lista de Publicações até o Momento:** Relaciona os trabalhos acadêmicos derivados desta dissertação.

- **5.4 Disponibilidade de Dados:** Apresenta os dados e algoritmos em plataforma livre para divulgação e reprodução.
- **5.5 Financiamento:** Registra o apoio financeiro recebido de agências de fomento à pesquisa.

Ao final, são apresentadas as **Referências Bibliográficas**, contendo todas as fontes técnicas e científicas que fundamentam o desenvolvimento do trabalho.

2 METODOLOGIA GERAL: MODELAGEM, CLASSIFICAÇÃO E TRANSFERÊNCIA DE APRENDIZADO

Neste capítulo são apresentados os fundamentos metodológicos da abordagem proposta nesta dissertação, aplicáveis às três bases de dados analisadas. Essas bases foram desenvolvidas com características distintas, a fim de validar a metodologia em diferentes níveis de fidelidade e complexidade:

- **Base 1 – Simulação com Calibração Bayesiana (ABC):** Simula dois trocadores do tipo casco e tubo com geometrias distintas e água como fluido em ambos os compartimentos. A incrustação é representada pelo envelhecimento progressivo, descrito por uma alteração do coeficiente global de transferência de calor $\mathbb{U}$, modelado como uma variável aleatória com decaimento exponencial. Os parâmetros foram calibrados por Computação Bayesiana Aproximada (ABC). Nesta base:
 - Utiliza-se um modelo de ordem reduzida baseado em equações diferenciais;
 - A modelagem de $\mathbb{U}$ é estocástica e temporal;
 - As variáveis de entrada no classificador são as temperaturas de saída dos fluidos;
 - A classificação é realizada via SVM;
 - Aplica-se Transferência de Aprendizado via JDA.
- **Base 2 – Simulação com AR e $\mathbb{U} \sim \text{Gama}$:** Simula também dois trocadores casco e tubo com geometrias diferentes. O trocador fonte opera com água-água e o alvo com óleo-água. A condição de incrustação é gerada por variações nos parâmetros da distribuição gama de $\mathbb{U}$, sem modelar o tempo. Para cada curva gerada, são identificados modelos AR e extraídas métricas estatísticas dos resíduos. Nesta base:
 - Utiliza-se geração sintética de curvas térmicas;
 - São aplicados modelos autoregressivos (AR);
 - As variáveis de entrada no classificador são métricas extraídas dos modelos AR;
 - A classificação é feita via SVM;

- A adaptação de domínios é realizada com JDA.
- **Base 3 – Experimental:** Dados coletados em bancada experimental envolvendo dois trocadores reais com geometrias distintas: um casco e tubo (fonte) e um de placas planas (alvo), ambos operando com água. As curvas de temperatura são utilizadas para identificação de modelos AR, a partir dos quais se extraem atributos estatísticos. A condição de incrustação é simulada artificialmente pela alteração dos parâmetros térmicos aproximados em um sistema de primeira ordem, descrito por um ganho e por uma constante de tempo, gerando por Monte Carlo, sinais de temperatura como resposta deste sistema. Nesta base:
 - Os dados são reais e obtidos com instrumentação experimental;
 - São identificados modelos AR para cada curva;
 - Utiliza-se extração de atributos baseada no erro de predição e energia do sinal;
 - A classificação também é feita com SVM;
 - A transferência de aprendizado é aplicada via JDA.

As próximas seções deste capítulo apresentam em detalhes as técnicas utilizadas: (i) modelagem estocástica e calibração ABC, (ii) modelos autoregressivos para construção de *Digital Shadows*, (iii) extração de atributos estatísticos, (iv) classificação com *Support Vector Machine* e (v) adaptação de domínios com *Joint Distribution Adaptation* (JDA).

2.1. MODELAGEM ESTOCÁSTICA E CALIBRAÇÃO BAYESIANA (ABC)

Para as bases de dados 1 e 2 (numéricas), a dinâmica da troca térmica em trocadores do tipo casco e tubo concêntricos e contrafluxo foi modelada utilizando equações diferenciais ordinárias (EDOs) para capturar as variações de temperatura dos fluidos quente e frio, bem como o comportamento estocástico do coeficiente global de transferência de calor U . Essas EDOs foram integradas utilizando o método de Runge-Kutta de 4.^o ordem, com o comando `ode45` do MATLAB®.

2.1.1 Modelagem Analítica de Ordem Reduzida

O sistema de EDOs que descreve a variação da temperatura dos fluidos do casco e do tubo e o decaimento de $\mathbb{U}$ ao longo do tempo é definido pelas seguintes equações, adaptadas de Garcia (2022):

$$\frac{dT_t}{dt} = \mathbb{U}(t) \cdot \left(\frac{-A}{\dot{m}_t \cdot c_{p,t}} \right) \cdot (T_t(t) - T_c(t)) + \left(\frac{\dot{m}_t}{\rho_t \cdot V_t} \right) \cdot (T_{t,0} - T_t(t)) \quad (2.1)$$

$$\frac{dT_c}{dt} = \mathbb{U}(t) \cdot \left(\frac{A}{\dot{m}_c \cdot c_{p,c}} \right) \cdot (T_t(t) - T_c(t)) + \left(\frac{\dot{m}_c}{\rho_c \cdot V_c} \right) \cdot (T_{c,0} - T_c(t)) \quad (2.2)$$

$$\frac{d\mathbb{U}}{dt} = \frac{U_{\text{med}}}{4000} \cdot \left(-e^{-\frac{t}{4000}} \right) \quad (2.3)$$

sendo $T_t(t)$ e $T_c(t)$ as temperaturas instantâneas dos fluidos no tubo e no casco, respectivamente, em graus Celsius ($^{\circ}\text{C}$) e $T_{t,0}$ e $T_{c,0}$ as temperaturas de entrada; $\dot{m}$ é a vazão mássica dos fluidos, em kg/s ; c_p é a capacidade calorífica específica dos fluidos, em $\text{J}/(\text{kg} \cdot \text{K})$; $\mathbb{U}(t)$ é o coeficiente global de transferência de calor, em $\text{W}/(\text{m}^2 \cdot \text{K})$; A é a área de troca térmica, em m^2 ; ρ é a massa específica do fluido, em kg/m^3 ; V_c é o volume do fluido no casco e V_t no tubo, em m^3 . Aqui, $\mathbb{U}(t)$ representa o coeficiente global de transferência de calor, modelado como uma variável estocástica que decai ao longo do tempo, devido à incrustação acumulada no sistema. Para a presente análise, foi considerada a transferência de calor direta entre o fluido quente e o fluido frio, ou seja, o coeficiente de troca de calor por condução k foi desconsiderado, porém seu efeito pode ser dissolvido dentro do coeficiente $\mathbb{U}$ estocástico, inclusive incorporando sua incerteza.

Para lidar com as incertezas inerentes ao processo de condução, às vazões dos fluidos e ao próprio fenômeno de incrustação, o modelo adota um coeficiente global de transferência de calor modelado como uma variável aleatória $\mathbb{U}$. Com isso, a simulação dos campos de temperatura, será feita usando o método de Monte Carlo. Múltiplas simulações são realizadas com valores iniciais aleatórios para $\mathbb{U}$, gerando possíveis cenários. Para garantir que os valores de $\mathbb{U}$ sejam fisicamente viáveis, isto é, estritamente positivos, foi escolhida a distribuição de probabilidade gama. Os parâmetros de forma e escala da distribuição gama não são tão intuitivos quanto os da distribuição normal, portanto foram calculados a partir da média $\mu_{\mathbb{U}}$ e variância $\sigma_{\mathbb{U}}$ da própria distribuição normal, de forma

que ainda seja uma distribuição gama estritamente positiva, mas que emule a forma de uma distribuição normal. A distribuição representada por Γ é mostrada na equação a seguir, onde é possível notar como os parâmetros da distribuição normal foram usados:

$$\mathbb{U} \sim \Gamma\left(\frac{\mu_{\mathbb{U}}^2}{\sigma_{\mathbb{U}}^2}, \frac{\sigma_{\mathbb{U}}^2}{\mu_{\mathbb{U}}}\right) \quad (2.4)$$

A escolha da distribuição de probabilidade para o coeficiente global de transferência de calor $\mathbb{U}$, bem como seus parâmetros estatísticos, foi baseada em estudos anteriores que adotaram abordagens semelhantes para modelar o comportamento estocástico de sistemas térmicos sob condições operacionais variáveis (Cholette *et al.*, 2019).

Na base de dados 2, o foco foi avaliar a sensibilidade do modelo à detecção de incrustação com base na discrepância do erro de predição de modelos AR identificados na condição limpa (associada ao valor inicial de $\mathbb{U}$). Assim, as curvas representando a condição incrustada foram obtidas por meio da alteração dos parâmetros estatísticos da distribuição gama de $\mathbb{U}$, sem a necessidade de modelar explicitamente um decaimento temporal nem de aplicar um novo modelo AR (ambos explicados em seções seguintes).

Por outro lado, na base de dados 1, o objetivo era analisar a evolução da incrustação ao longo do tempo de operação de um trocador de calor. Para isso, modelou-se o decaimento progressivo de $\mathbb{U}$ utilizando uma função exponencial, representando a deterioração térmica causada pelo acúmulo de depósitos:

$$\mathbb{U}(t) = \mathbb{U}_0 \cdot e^{-\lambda t}, \quad (2.5)$$

onde λ é a taxa de decaimento associada à incrustação, ajustável de acordo com os dados empíricos obtidos para refletir condições operacionais reais. Para este estudo, simula-se a incrustação ao longo de 4 anos, com λ calibrada para representar as condições típicas de operação, portanto foi adotado o valor $\lambda = \frac{1}{4000} = 2,5 \times 10^{-4} \text{ s}^{-1}$, equivalente a uma constante de tempo $a = 4000 \text{ s}$. O horizonte de simulação foi definido de forma arbitrária em quatro anos, não havendo um motivo específico para a escolha desse valor exato. A intenção foi representar um período prolongado de operação contínua sem manutenção, de modo a reproduzir o acúmulo progressivo de incrustação. Essa escolha, além de viabilizar a análise do envelhecimento térmico do equipamento ao longo de sua vida útil, também auxilia no balanceamento da classificação: considera-se o primeiro ano como “limpo” e os três subsequentes como “incrustados”, resultando em uma proporção de 1:3 entre as

classes. Assim, o treinamento pode ser realizado apenas com dados limpos, enquanto os demais anos fornecem diferentes estágios de degradação para fins de teste e validação. A abordagem estocástica permite uma simulação com menos parâmetros, refletindo as incertezas operacionais do sistema e proporcionando uma base sólida para a modelagem preditiva. Para garantir que o coeficiente esteja dentro de faixas de valores plausíveis, foi aplicada uma calibração utilizando Computação Bayesiana Aproximada, ou calibração ABC.

2.1.2 Calibração por Computação Bayesiana Aproximada (ABC)

Para estimar o coeficiente global de transferência de calor, $\mathbb{U}(t)$, dentro do modelo de ordem reduzida, utilizamos a calibração por Computação Bayesiana Aproximada (ABC). Esse método é eficaz para inferir parâmetros do modelo, como a taxa de decaimento λ , ao comparar os perfis de temperatura simulados com os dados reais e ajustar o modelo de forma a minimizar as discrepâncias, sem a necessidade de conhecer a função de verossimilhança. Ao contrário do método de Monte Carlo com Cadeia de Markov (MCMC), que exige a definição prévia da função de verossimilhança, o ABC é vantajoso, especialmente porque a imposição de uma verossimilhança a priori pode ser complexa em muitos casos. O processo é formulado como um problema de regressão, que compara os resultados do modelo às observações experimentais (Csilléry *et al.*, 2010):

$$\mathbf{y} = f(\theta; \mathbf{x}) + \boldsymbol{\varepsilon}, \quad (2.6)$$

sendo $\mathbf{y} \in \mathbb{R}^D$ os dados observados, $f(\theta; \mathbf{x})$ a função que representa a saída do modelo com parâmetros $\theta \in \mathbb{R}^n$ (como $\mathbb{U}_0$ e λ) e entradas $\mathbf{x} \in \mathbb{R}^D$ (e.g., temperaturas dos fluidos), e $\boldsymbol{\varepsilon} \in \mathbb{R}^D$ corresponde aos erros de medição.


A abordagem bayesiana permite a atualização das estimativas de θ incorporando os dados observados para ajustar a verossimilhança. A distribuição a posteriori de θ é descrita por:

$$\pi(\theta|\mathbf{y}) = \frac{\pi(\mathbf{y}|\theta)\pi(\theta)}{\pi(\mathbf{y})}, \quad (2.7)$$

O método ABC avalia a distância entre os dados simulados e os observados sem exigir uma função explícita de verossimilhança, amostrando candidatos de parâmetros da

distribuição anterior, simulando o modelo e aceitando os candidatos que geram resultados próximos o suficiente dos dados observados. Um fluxograma da calibração ABC utilizado no caso dos trocadores de calor é apresentado na Figura 2.

Figura 2 – Fluxograma do Processo de Calibração ABC para Ajuste de λ e $\mathbb{U}_0$



Fonte: Produção do próprio autor

Dado que o modelo é baseado em EDOs que descrevem as temperaturas dos fluidos e o comportamento de $\mathbb{U}(t)$, o processo de calibração visa alinhar esses perfis de tempera-

tura com dados experimentais. A distribuição Γ é usada para λ , garantindo que $\mathbb{U}_0$ seja sempre não negativo. Esse método aproxima a distribuição a posteriori $\pi(\theta|\mathbf{y})$ de maneira iterativa, ajustando λ e $\mathbb{U}_0$ até que a convergência seja atingida, representando o método clássico de amostragem por rejeição na ABC (Castello; Ritto, 2023).

A abordagem de calibração bayesiana por meio da Computação Bayesiana Aproximada (ABC) já foi aplicada anteriormente ao problema de monitoramento de trocadores de calor no contexto do grupo de pesquisa. Godoy, Silva e Teloli (2024) utilizaram o método ABC para estimar parâmetros térmicos de trocadores reais a partir de dados experimentais, demonstrando sua robustez frente a incertezas operacionais e viabilizando o uso de modelos de ordem reduzida. Este trabalho segue essa mesma linha metodológica, adaptando a abordagem para a simulação da degradação do coeficiente global de troca térmica $\mathbb{U}$, utilizando dados sintéticos para avaliação do desempenho do modelo e posterior aplicação em Transferência de Aprendizado.

No caso da base de dados 1, que utiliza esta metodologia, os atributos utilizados na classificação após a calibração são as temperaturas de saída dos fluidos no casco e no tubo. Para as bases de dados 2 e 3, utiliza-se extração de atributos provenientes de um modelo AR.

2.2. MODELOS AUTOREGRESSIVOS (AR)

Para a base de dados 2 e para os dados experimentais (base 3), foi adotada a modelagem de cada curva de temperatura em condição limpa como uma resposta de primeira ordem, posteriormente ajustada por modelos autorregressivos (AR) para capturar o comportamento dinâmico do sistema.

Para a medição da temperatura de saída do tubo de um trocador de calor em condição limpa, denotada por $y(k)$, com $k = 1, 2, \dots, N$, um modelo AR pode prever a temperatura um passo à frente com base em observações passadas (Ljung, 1999; Billings, 2013):

$$A(q)y(k) = e_{ref}(k) \quad (2.8)$$

onde $A(q) = 1 + a_1q^{-1} + \dots + a_pq^{-p}$ é o polinômio do modelo AR. Os coeficientes a_i são estimados, q^{-1} é o operador de atraso e p é a ordem do sistema. Os coeficientes podem ser obtidos por métodos como mínimos quadrados ou Yule-Walker (Ljung, 1999; Figueiredo

et al., 2011). Se o modelo estiver bem ajustado, o erro $e_{ref}(k)$ será ruído branco, indicando que toda informação dinâmica foi capturada por $A(q)$.

A Equação 2.8 funciona como uma sombra digital do comportamento esperado do trocador. Para um novo sinal de temperatura $x(k)$, a aplicação do mesmo modelo fornece o erro de predição sob condição desconhecida:

$$A(q)x(k) = e_{desc}(k) \quad (2.9)$$

Se $x(k)$ for uma curva de uma condição limpa, $e_{desc}(k)$ será semelhante a $e_{ref}(k)$; caso contrário, um desvio significativo indica possível incrustação (Sohn; Farrar, 2001; Lu; Gao, 2005).

Cabe ressaltar que, neste trabalho, as expressões “**temperatura do tubo**” e “**temperatura do casco**” (como aparece em muitos dos gráficos) referem-se sempre às temperaturas instantâneas de saída medidas ao final do trocador em cada compartimento. O termo “saída” foi omitido para evitar ambiguidade com o conceito de saída em sistemas dinâmicos. Do ponto de vista físico, cada compartimento possui uma temperatura de entrada e uma de saída, sendo esta última a única utilizada para traçar curvas e extrair atributos. Do ponto de vista matemático, em modelos autorregressivos, qualquer série observada pode ser tratada como saída, inclusive a temperatura de entrada, uma vez que se trata de variáveis acessíveis ao observador, isto é, saídas observáveis no contexto da modelagem estatística. Ressalta-se, entretanto, que neste trabalho a temperatura de entrada (inlet) foi considerada apenas em modelos numéricos, não integrando o conjunto de medições experimentais.

2.2.1 Extração de Atributos Estatísticos

Utilizando as Equações (2.8) e (2.9), propõe-se como primeira métrica a razão entre as variâncias dos erros de predição, sensível a desvios que podem indicar alterações no regime térmico do sistema:

$$\mathcal{X}_1 = \frac{\sigma^2(\mathbf{e}_{desc})}{\sigma^2(\mathbf{e}_{ref})} \quad (2.10)$$

em que $\sigma^2(\cdot)$ representa o operador de variância aplicado aos vetores de erro. Essa razão é equivalente à estatística F , frequentemente utilizada em testes de hipótese para comparar

a variância de duas amostras distintas (Hogg; Ledolter, 1987; Kopsaftopoulos; Fassois, 2010). No contexto deste trabalho, essa comparação permite identificar desvios entre a resposta térmica esperada (limpa) e uma condição desconhecida (possivelmente incrustada). Um pressuposto importante para a validade dessa métrica é que os resíduos $e_{ref}(k)$ da modelagem AR em condição limpa apresentem distribuição Gaussiana (ruído branco), o que indica que o modelo foi bem ajustado. Caso essa hipótese não se sustente ao aplicar o modelo a novos dados, isso pode sinalizar que houve uma mudança na dinâmica do sistema, como ocorre em casos de incrustação.

Além da razão de variâncias, uma segunda característica extraída dos sinais térmicos é a energia total associada à curva de temperatura. Essa métrica é obtida por meio da integração numérica do sinal usando a regra do trapézio, o que fornece uma estimativa da energia térmica acumulada ao longo do tempo:

$$\mathcal{X}_2 = \sum_{k=1}^{N-1} \frac{x(k) + x(k+1)}{2} \Delta t \quad (2.11)$$

em que Δt representa o intervalo de tempo entre as amostras discretas, e a soma corresponde à integração numérica da curva de temperatura $x(k)$. Esse valor pode ser interpretado como a energia térmica trocada ao longo do experimento, sendo útil para identificar quedas de eficiência térmica associadas à presença de incrustações.

A combinação das métricas $\mathcal{X}_1$ (razão de variâncias) e $\mathcal{X}_2$ (energia térmica) forma um espaço de características bidimensional capaz de discriminar entre os estados limpo e incrustado de um trocador de calor. Com esse conjunto de dados históricos, modelos AR podem ser identificados de forma robusta, permitindo a classificação automática do estado operacional com o uso de algoritmos como o Máquina de Vetor Suporte, do inglês *Support Vector Machine* (SVM), abordado na próxima seção.

2.3. CLASSIFICAÇÃO COM MÁQUINAS DE VETOR SUPORTE (SVM)

A classificação entre os estados limpo e incrustado para as três bases de dados foi realizada com o algoritmo *Support Vector Machine* (SVM), que busca maximizar a margem entre as classes. A função objetivo da SVM linear é:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad \text{sujeito a} \quad y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad (2.12)$$

No contexto deste trabalho, a SVM busca encontrar um hiperplano ótimo que separe duas condições operacionais de um trocador de calor (**estado limpo** e **estado incrustado**) com base nos atributos extraídos das curvas de temperatura.

- $\mathbf{x}_i \in \mathbb{R}^n$: é o vetor de características extraídas da i -ésima curva de temperatura do trocador. Dependendo da base, essas características incluem a razão entre variâncias dos erros de predição, a energia do sinal, ou diretamente a temperatura de saída dos fluidos.
- $y_i \in \{-1, +1\}$: é o rótulo associado ao vetor de características $\mathbf{x}_i$, indicando se a curva corresponde a um estado **limpo** (+1) ou **incrustado** (-1).
- $\mathbf{w}$: é o vetor de pesos que define a orientação do hiperplano de separação no espaço de atributos. No contexto térmico, ele representa a direção no espaço de características que mais separa os efeitos da incrustação dos comportamentos típicos do trocador limpo.
- b : é o viés (ou termo de deslocamento) do hiperplano. Ele ajusta a posição da fronteira de decisão no espaço de atributos para maximizar a margem entre as duas classes.
- $\frac{1}{2}\|\mathbf{w}\|^2$: é o termo de regularização que a SVM tenta minimizar, pois ele representa a complexidade do modelo. Reduzir esse termo garante que a margem entre as classes (limpo e incrustado) seja a maior possível, promovendo uma boa generalização.
- A condição $y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1$ assegura que todos os pontos de treinamento estejam corretamente classificados com uma margem mínima de separação. No caso dos trocadores, isso implica que o classificador deve ser capaz de separar corretamente os padrões térmicos associados à operação limpa daqueles que sugerem perda de desempenho devido à incrustação.

A SVM foi treinada com os dados do domínio fonte e testada inicialmente no domínio alvo, com e sem adaptação de domínio.

2.4. TRANSFERÊNCIA DE APRENDIZADO POR ADAPTAÇÃO DE DISTRIBUIÇÃO CONJUNTA (JDA)

A Transferência de Aprendizado (*Transfer Learning* - TL) é uma técnica que permite aplicar o conhecimento adquirido em um conjunto de dados fonte para prever o comportamento de um conjunto de dados alvo. Muitas vezes a escolha do conjunto fonte é feita levando em consideração sua maior quantidade de dados em relação ao alvo. A transferência do aprendizado é feita através de uma adaptação de domínio, em que os dois conjuntos de dados são mapeados para um novo domínio latente, em que ambos os conjuntos tenham características similares. Esse processo reduz a necessidade de coletar extensos dados de treinamento para cada novo ambiente, tornando a TL vantajosa para aplicações industriais com restrições de coleta e processamento de dados, como o monitoramento de trocadores de calor (Pan; Yang, 2010).

Existem diferentes tipos de TL, como a baseada em características (*feature-based*) e a baseada em modelos (*model-based*). A abordagem baseada em características, como a Adaptação de Distribuição Conjunta (*Joint Distribution Adaptation* - JDA) (Long *et al.*, 2013), mapeia as características dos dados de origem e de destino em um espaço compartilhado. Ao minimizar a discrepância entre as distribuições de probabilidade condicional e marginal dos conjuntos, o JDA permite uma adaptação eficiente do classificador, sem a necessidade de ajustes de hiperparâmetros ou complexas estruturas de redes neurais (Nguyen; Xue; Andreae, 2018). Em termos mais simples, JDA faz com que as características de ambos os trocadores de calor no espaço original sejam projetadas em um espaço latente tendo a menor discrepância possível, sendo possível interpretar as nuvens de pontos de conjuntos de dados distintos como as de um único conjunto neste espaço latente.

As principais vantagens dessa abordagem em relação à abordagem baseada em modelos são a **redução no tempo de processamento** e a **dispensa de calibração de hiperparâmetros**, sendo menos dependente de ajustes específicos, o que a torna ideal para dispositivos com restrições de processamento, como sensores industriais (Wang *et al.*, 2019). Porém, no desenvolvimento de gêmeos digitais de trocadores de calor, o padrão desejado é a transferência baseada em modelos, uma vez que a abordagem por características tem a limitação de precisar de **grandes históricos de dados de trocadores fonte** para captar a tendência estatística das características.

Em trocadores de calor, a aplicação de TL ainda é rara. A maioria das abordagens utiliza métodos ajustados para cada equipamento, com modelos customizados que não aproveitam a possibilidade de transferir conhecimento entre trocadores de diferentes geometrias ou condições operacionais (Chiang; Lu; Hsu, 2017).

Na aplicação de JDA, temos um conjunto de dados de origem $\{(\mathbf{X}_s, \mathbf{y}_s)\}$, com $\mathbf{X}_s \in \mathbb{R}^{d \times n_s}$ sendo a matriz de atributos e $\mathbf{y}_s \in \mathbb{R}^{1 \times n_s}$ os rótulos associados, e um conjunto de dados de destino $\mathbf{X}_t \in \mathbb{R}^{d \times n_t}$ sem rótulos, a JDA busca uma matriz de projeção $\mathbf{A} \in \mathbb{R}^{d \times k}$ tal que:

$$\min_{\mathbf{A}} \sum_{c=1}^C \left\| \mathbf{A}^\top \mathbf{X}_s^c - \mathbf{A}^\top \mathbf{X}_t^c \right\|_F^2 + \lambda \|\mathbf{A}\|_F^2 \quad (2.13)$$

em que:

- $\mathbf{X}_s^c$ e $\mathbf{X}_t^c$ representam os subconjuntos de dados da classe c nos domínios de origem e destino, respectivamente;
- C é o número total de classes (neste caso, dois: limpo e incrustado);
- $\|\cdot\|_F$ denota a norma de Frobenius, usada para mensurar a distância entre matrizes;
- λ é um parâmetro de regularização que controla o ajuste da projeção para evitar sobreajuste.

Após a projeção dos dados para esse novo espaço latente, é possível treinar um classificador utilizando apenas os dados rotulados do domínio de origem. Esse classificador pode, então, ser aplicado com eficácia aos dados do domínio de destino, mesmo sem a presença de rótulos. A JDA, portanto, permite que o conhecimento aprendido com um trocador de calor bem monitorado (e.g., casco e tubo com instrumentação completa) seja transferido para outro trocador com geometria distinta ou instrumentação reduzida (e.g., trocador de placas planas).

Cabe destacar que a aplicação de técnicas de Transferência de Aprendizado neste trabalho segue uma linha de pesquisa contínua do grupo. Trabalhos anteriores abordaram o uso de TL para diagnóstico de danos estruturais em pontes com base em modelos numéricos (Figueiredo *et al.*, 2022), para classificação de estados estruturais em modelos de viga por análise de similaridade (Almeida; Silva; Ritto, 2024), e para transferência de modelos entre condições de fronteira distintas em detecção de falhas (Souza *et al.*, 2024).

O presente trabalho expande essa linha para o domínio térmico, aplicando TL no contexto do monitoramento de trocadores de calor com distintas geometrias e regimes operacionais.

2.5. CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou a estrutura metodológica adotada neste trabalho, comum às três bases de dados consideradas. Foram descritos os procedimentos de modelagem estocástica com calibração bayesiana, utilizados para a geração de dados sintéticos com degradação térmica progressiva, e a formulação de modelos autorregressivos (AR), empregados como sombras digitais para caracterização do comportamento dinâmico. Em seguida, detalhou-se o processo de extração de atributos estatísticos a partir dos resíduos e dos sinais de temperatura, que compõem o espaço de características a ser explorado. Por fim, foram expostos os fundamentos do classificador *Support Vector Machine* (SVM) e da técnica de adaptação de domínios por *Joint Distribution Adaptation* (JDA), que constituem os elementos centrais da etapa de classificação e de transferência de aprendizado.

Dessa forma, este capítulo consolidou o conjunto de ferramentas conceituais e computacionais que sustentam as análises posteriores, servindo de base para a aplicação prática nas diferentes bases de dados apresentadas nos capítulos seguintes.

3 APLICAÇÃO NAS SIMULAÇÕES NUMÉRICAS

Neste capítulo, são analisadas duas aplicações da metodologia proposta utilizando conjuntos de dados gerados por simulação numérica. O objetivo é avaliar a capacidade de generalização da técnica de Transferência de Aprendizado (TL) frente a diferentes níveis de modelagem e discrepância entre domínios. Em ambas as simulações, a metodologia é composta por três etapas principais: construção de modelos, extração de atributos e aplicação de técnicas de classificação com e sem adaptação de domínio.

As simulações foram divididas em duas bases numéricas distintas:

- **Base 1 – Simulação com ABC e Decaimento de $\mathbb{U}$:** modelos de ordem reduzida com decaimento estocástico do coeficiente global de troca térmica. Os dados de entrada da SVM são as temperaturas de saída dos fluidos.
- **Base 2 – Simulação com AR e $\mathbb{U} \sim \text{Gama}$:** curvas geradas sinteticamente por variações estocásticas de $\mathbb{U}$, com modelagem AR e extração de métricas como razão de variâncias e energia do sinal.

Os dados gerados foram organizados em domínios fonte e alvo, para avaliar a detecção de incrustação com e sem técnicas de Transferência de Aprendizado. A seguir, são apresentados os resultados para a Base 1.

3.1. BASE 1 - SIMULAÇÃO COM ABC E DECAIMENTO DE $\mathbb{U}$

Para testar a metodologia elaborada, foram simulados dois trocadores com geometrias distintas: um considerado como **trocador fonte**, e outro como **trocador alvo**. O trocador fonte representa aquele com maior confiabilidade de dados ou conhecimento prévio, e o trocador alvo, aquele para o qual se deseja transferir esse conhecimento, mesmo em condições operacionais diferentes.

Embora ambos os trocadores contenham o mesmo número de amostras nesta aplicação, o trocador fonte foi modelado com base na geometria de uma bancada experimental didática, enquanto o trocador alvo foi definido com uma geometria distinta, projetada para ter menor área de troca térmica e parâmetros de entrada diferentes. O objetivo é verificar se o conhecimento extraído do trocador fonte é suficiente para generalizar a detecção de incrustação no trocador alvo, mesmo com diferenças estruturais

significativas. Fica como proposta futura avaliar o desempenho da metodologia também sob desbalanceamento de volume de dados entre os domínios.

3.1.1 Geometria dos Trocadores Fonte e Alvo

As geometrias e os parâmetros de entrada dos trocadores simulados são:

Tabela 1 – Parâmetros do Trocador de Calor Fonte

Parâmetro	Valor
Comprimento	$1,00 \times 10^0$ m
Diâmetro do casco	$2,815 \times 10^{-2}$ m
Diâmetro do tubo	$1,520 \times 10^{-2}$ m
Temperatura de entrada do tubo	$9,00 \times 10^1$ °C
Temperatura de entrada do casco	$2,00 \times 10^1$ °C
Vazão mássica no tubo	$6,99 \times 10^{-2}$ kg/s
Vazão mássica no casco	$6,00 \times 10^{-2}$ kg/s

Fonte: Produção do próprio autor

Tabela 2 – Parâmetros do Trocador de Calor Alvo

Parâmetro	Valor
Comprimento	$5,00 \times 10^{-1}$ m
Diâmetro do casco	$5,00 \times 10^{-2}$ m
Diâmetro do tubo	$2,50 \times 10^{-2}$ m
Temperatura de entrada do tubo	$8,00 \times 10^1$ °C
Temperatura de entrada do casco	$3,00 \times 10^1$ °C
Vazão mássica no tubo	$7,00 \times 10^{-2}$ kg/s
Vazão mássica no casco	$5,00 \times 10^{-2}$ kg/s

Fonte: Produção do próprio autor

Ambos os trocadores utilizam água como fluido em seus compartimentos quente e frio. As propriedades termofísicas da água líquida foram definidas de acordo com valores típicos encontrados na literatura para temperatura ambiente, conforme utilizado por Garcia (2022). O comportamento térmico dos trocadores foi modelado por um sistema de equações diferenciais ordinárias (EDOs), resolvido numericamente com o método de Runge-Kutta de quarta ordem, por meio da função `ode45` do MATLAB®.

Cada simulação correspondeu a um horizonte de quatro anos de operação contínua, com discretização temporal de 0,1 s. Isso resulta, em termos computacionais, em centenas de milhares de pontos de cálculo por curva, valores que podem parecer elevados, mas que

não devem ser interpretados como “amostras” independentes, e sim como discretizações numéricas de trajetórias temporais.

Para evitar distorções associadas ao regime transiente inicial, os primeiros 4000 pontos de cada curva foram descartados, garantindo que apenas o regime permanente fosse considerado. A degradação térmica decorrente da incrustação foi simulada por meio de um decaimento exponencial do coeficiente global de transferência de calor $\mathbb{U}(t)$, dado por:

$$\mathbb{U}(t) = \mathbb{U}_0 \cdot e^{-\lambda t}, \quad (3.1)$$

com taxa de decaimento $\lambda = \frac{1}{4000} = 2,5 \times 10^{-4} \text{ s}^{-1}$, representando o envelhecimento progressivo do equipamento.

A condição limpa foi definida a partir do regime permanente correspondente ao primeiro ano de operação, enquanto os três anos subsequentes foram considerados como condição incrustada. Os parâmetros iniciais do modelo foram calibrados por Computação Bayesiana Aproximada (ABC), e as curvas utilizadas na análise foram obtidas por amostragem de Monte Carlo, com seleção aleatória de 500 amostras de cada condição (limpo e incrustado) para ambos os trocadores, garantindo diversidade estatística no conjunto de dados. Para a calibração bayesiana (ABC), não se utilizou toda a trajetória simulada, mas apenas o ponto final de cada curva em cada período analisado, de modo que o grande volume de pontos gerados pela discretização serviu apenas para garantir a robustez da simulação, sem impactar diretamente no número de observações empregadas.

3.1.2 Detecção no Espaço Original de Características


Como descrito anteriormente, os dois trocadores foram simulados sob as condições de incrustação com decaimento progressivo de $\mathbb{U}$. Os dados do primeiro ano representaram o estado limpo, enquanto os anos subsequentes o estado incrustado.

A detecção de incrustação foi realizada com um classificador binário do tipo Máquina de Vetores de Suporte (SVM) linear, treinado com os dados do trocador fonte e aplicado aos dados de ambos os trocadores, para verificar a capacidade de separação entre as classes limpo e incrustado.

A Figura 3 ilustra o espaço de características original, formado pela temperatura

de saída do casco pela temperatura de saída do tubo¹. A fronteira de decisão da SVM é representada na figura. À direita e abaixo estão os dados do trocador fonte, em azul (limpo) e vermelho (incrustado); à esquerda e acima estão os dados do trocador alvo, em verde (limpo) e magenta (incrustado).

Figura 3 – Espaço original e classificação SVM para ambos os trocadores de calor



Fonte: Produção do próprio autor

Como pode ser observado, a fronteira de decisão é pouco eficaz no domínio original, indicando que um classificador treinado com dados do trocador fonte não é capaz de generalizar com sucesso para o trocador alvo sem adaptação de domínio. A Tabela 3 apresenta o desempenho da classificação binária no espaço original dos atributos, utilizando a SVM treinada com dados do trocador fonte. Observa-se que apenas 48,0% das amostras incrustadas foram corretamente classificadas, enquanto 52,0% foram confundidas com a condição limpa.

Tabela 3 – Desempenho do classificador no espaço original (valores em porcentagem)

Classe Verdadeira	Incrustado (Previsto)	Limpo (Previsto)
Incrustado	48,0%	52,0%
Limpo	1,1%	98,9%

Fonte: Produção do próprio autor

Para quantificar a capacidade do classificador em detectar corretamente a condição de incrustação, calcula-se o escore F_1 da classe **incrustado**, que combina precisão e revocação em uma única métrica. A precisão (precision) mede a proporção de instâncias

¹ Neste trabalho, as expressões “temperatura do tubo” e “temperatura do casco” (como aparecem nos rótulos de gráficos) referem-se às temperaturas instantâneas medidas ao final do trocador em cada compartimento. Omitiu-se a palavra “saída” para evitar confusão com o conceito de saída em sistemas dinâmicos.

realmente incrustadas entre todas aquelas que o modelo classificou como incrustadas, isto é, avalia a confiabilidade das predições positivas. Já a revocação (recall ou sensibilidade) mede a proporção de instâncias incrustadas corretamente identificadas pelo modelo em relação ao total de casos incrustados existentes, ou seja, indica a capacidade do classificador em não deixar passar exemplos positivos. O escore F_1 é a média harmônica entre precisão e revocação, equilibrando essas duas dimensões: ele só assume valores elevados quando ambas são altas, tornando-se uma medida mais adequada em problemas com classes desbalanceadas, como é o caso deste estudo.

$$\text{Precisão} = \frac{48,0}{48,0 + 1,1} \approx 97,8\%, \quad \text{Revocação} = \frac{48,0}{48,0 + 52,0} = 48,0\%$$

$$F_1 = 2 \cdot \frac{97,8\% \cdot 48,0\%}{97,8\% + 48,0\%} \approx \mathbf{64,4\%}$$


O elevado número de classificações incorretas do estado incrustado como limpo sugere que as características extraídas diretamente dos dados não são suficientemente discriminantes entre os estados operacionais. Como alternativa, adota-se a Transferência de Aprendizado para melhorar a separação das classes.

3.1.3 Detecção no Espaço Latente

Aplicou-se a técnica de Transferência de Aprendizado com *Joint Distribution Adaptation* (JDA), projetando os dados de ambos os trocadores em um espaço latente, onde a discrepância entre os domínios é minimizada. A Figura 4 mostra o novo espaço de características após essa transformação, com uma clara separação entre os estados operacionais, mesmo no trocador alvo.

Após a projeção, a SVM treinada unicamente com dados do trocador fonte passou a ser eficaz na classificação dos dados do trocador alvo. A Tabela 4 apresenta o desempenho do classificador após a aplicação da técnica de Transferência de Aprendizado via JDA, evidenciando uma significativa melhoria na classificação do estado incrustado.

Figura 4 – Espaço latente e classificação SVM para ambos os trocadores de calor



Fonte: Produção do próprio autor

Tabela 4 – Desempenho para a classificação no espaço latente

Classe Verdadeira	Predito como Incrustado	Predito como Limpo
Incrustado	98,7%	1,3%
Limpo	0,1%	99,9%

Fonte: Produção do próprio autor

A precisão e a revocação para a classe **incrustado** podem ser calculadas como:

$$\text{Precisão} = \frac{98,7}{98,7 + 0,1} \approx 99,9\%, \quad \text{Revocação} = \frac{98,7}{98,7 + 1,3} = 98,7\%$$

$$F_1 = 2 \cdot \frac{99,9\% \cdot 98,7\%}{99,9\% + 98,7\%} \approx \mathbf{99,3\%}$$

Esse resultado confirma a efetividade da adaptação de domínio via JDA em alinhar as distribuições de atributos extraídos de trocadores com diferentes geometrias e condições operacionais. A capacidade de generalização do classificador treinado é ampliada, tornando a abordagem promissora para aplicação industrial, especialmente em contextos com instrumentação reduzida e escassez de dados rotulados no trocador alvo.

3.2. BASE 2 - SIMULAÇÃO COM AR E $\mathbb{U} \sim \Gamma$

Nesta segunda base de dados simulada, foi adotado um modelo de troca térmica simplificado, onde a dinâmica da temperatura de saída de um fluido é descrita por uma

equação diferencial ordinária de primeira ordem, considerando $\mathbb{U}$ como uma variável aleatória:

$$\frac{dT}{dt} = \frac{\mathbb{U}A}{mc_p}(T_{\text{in}} - T(t)) \quad (3.2)$$

Nesta equação, $T(t)$ é a temperatura instantânea do fluido, T_{in} a temperatura de entrada, A a área de troca térmica, m a vazão mássica e c_p o calor específico. A integração foi realizada via método de Runge-Kutta de quarta ordem (`ode45` do MATLAB®), com passo de tempo de 0,01 s. Diferente da Base 1, não foi considerada uma função de decaimento contínuo para $\mathbb{U}$. Em vez disso, a condição de incrustação foi simulada por meio da redução do valor médio de $\mathbb{U}$, variando os parâmetros da distribuição gama que rege essa variável, como descrito pela equação 3.3.

$$\mathbb{U} \sim \Gamma\left(\frac{\mu_{\mathbb{U}}^2}{\sigma_{\mathbb{U}}^2}, \frac{\sigma_{\mathbb{U}}^2}{\mu_{\mathbb{U}}}\right) \quad (3.3)$$

Essa abordagem permitiu gerar conjuntos de dados para trocadores em condição limpa e incrustada, sem necessidade de simulação ao longo de um período prolongado.


- **Trocador Fonte:** sistema água-água com 100 curvas simuladas (50 limpas e 50 incrustadas).
- **Trocador Alvo:** sistema óleo-água com 40 curvas simuladas (20 limpas e 20 incrustadas).

Em ambos os trocadores, as curvas de temperatura (da saída do fluido de cada compartimento) foram geradas por simulação de Monte Carlo, considerando um ruído aleatório com desvio padrão de 2% do valor médio (RMS). A condição de incrustação foi simulada por uma redução de 25% no valor médio do coeficiente global de transferência de calor $\mathbb{U}$, representando uma menor eficiência térmica.

A Figura 5 apresenta as curvas simuladas para o trocador fonte, nas condições limpa (azul) e incrustada (vermelho). A Figura 6 mostra as curvas do trocador alvo, também simuladas com variabilidade estocástica e ruído, evidenciando maior dispersão nos sinais.


Para representar o comportamento térmico de referência no trocador fonte, foi identificado um modelo AR a partir de uma única curva de temperatura limpa, escolhida aleatoriamente. A ordem do modelo foi definida com base no Critério de Informação de

Figura 5 – Curvas simuladas por Monte Carlo para o trocador fonte



Fonte: Produção do próprio autor


Figura 6 – Curvas simuladas por Monte Carlo para o trocador alvo



Fonte: Produção do próprio autor

Akaike (AIC), como mostra a Figura 7. O AIC é um critério amplamente utilizado para seleção de modelos, pois busca o melhor equilíbrio entre qualidade do ajuste e complexidade do modelo: penaliza a adição de parâmetros supérfluos, favorecendo representações parcimoniosas. No entanto, embora valores mais baixos de AIC indiquem melhor desempenho relativo, a escolha da ordem não pode se apoiar unicamente na minimização do critério. Ordens muito elevadas tendem a levar ao fenômeno de overfitting, em que o modelo passa a se ajustar a flutuações específicas da base de dados (ruído), perdendo capacidade de generalização. Assim, após análise dos resultados, adotou-se a ordem 6 como adequada: suficientemente baixa para evitar sobreajuste, mas capaz de capturar a dinâmica relevante do sistema e refletir corretamente a diferença entre as condições limpas e incrustadas.


Figura 7 – Critério de Akaike (AIC) aplicado à seleção da ordem do modelo AR — trocador fonte



Fonte: Produção do próprio autor

A Figura 8 ilustra o ajuste do modelo AR de sexta ordem a uma curva de temperatura limpa distinta daquela usada na identificação. O erro de predição é pequeno e o modelo acompanha bem a dinâmica térmica.

Figura 8 – Ajuste do modelo AR de sexta ordem à curva de temperatura do trocador fonte




Fonte: Produção do próprio autor

A validação do modelo foi feita pelo teste de brancura dos resíduos, apresentado na Figura 9. As autocorrelações dos resíduos permanecem dentro do intervalo de confiança de 99%, indicando que o modelo captura bem a dinâmica do sistema.

O mesmo procedimento foi repetido para o trocador alvo. A Figura 10 apresenta o critério AIC aplicado a uma curva limpa, indicando a ordem 10 como a mais adequada para o modelo AR neste caso. Diferentemente do conjunto fonte, o conjunto alvo apre-


Figura 9 – Análise de autocorrelação dos resíduos do modelo AR — trocador fonte



Fonte: Produção do próprio autor

senta dados mais ruidosos, o que demanda um modelo de ordem ligeiramente superior para representar de forma satisfatória as variações observadas. Além disso, por se tratar do conjunto alvo, optou-se por permitir uma ordem maior a fim de capturar nuances adicionais da dinâmica, mesmo com a penalização associada à complexidade. Assim, a ordem 10 mostrou-se um compromisso adequado: suficientemente elevada para lidar com o ruído presente nos dados, mas ainda dentro de um limite que evita sobreajuste excessivo e garante a utilidade do modelo para transferência de aprendizado.


Figura 10 – Critério de Akaike (AIC) para o modelo AR — trocador alvo



Fonte: Produção do próprio autor

A Figura 11 mostra o ajuste do modelo AR de décima ordem a uma curva limpa do trocador alvo. Observa-se que o ajuste apresenta erro de predição mais elevado, com menor aderência ao sinal. Isso se deve à maior variabilidade dos dados simulados para o trocador alvo, evidenciando menor qualidade do conjunto de dados.

Figura 11 – Ajuste do modelo AR de décima ordem à curva de temperatura do trocador alvo




Fonte: Produção do próprio autor

Esse comportamento reforça a motivação para o uso de técnicas de Transfer Learning: a dificuldade em obter um modelo de qualidade diretamente no domínio alvo devido ao maior nível de ruído torna vantajosa a reutilização de conhecimento extraído de um domínio fonte mais confiável.

A Figura 12 apresenta o teste de brancura dos resíduos para o modelo do trocador alvo. Esse teste verifica se as autocorrelações dos resíduos diferem estatisticamente de zero, como esperado para um processo de ruído branco. As bandas representam o intervalo de confiança de 99%, dentro do qual se espera que a maioria das autocorrelações se mantenha quando o modelo é adequado.

Figura 12 – Teste de brancura dos resíduos — modelo AR do trocador alvo



Fonte: Produção do próprio autor

Observa-se que, embora alguns valores se aproximem dos limites, a maior parte das

autocorrelações permanece contida nesse intervalo, não havendo evidência significativa de correlação residual. Isso indica que o modelo consegue capturar de forma satisfatória a dinâmica essencial do sistema, produzindo resíduos compatíveis com o comportamento de ruído branco, indicando que o modelo ainda é útil para extração de atributos.

A curva utilizada para a identificação do modelo AR não foi reutilizada nas etapas de extração de atributos. As demais curvas, tanto limpas quanto incrustadas, foram submetidas ao modelo identificado, sendo então calculadas duas métricas principais:

- Razão entre variâncias dos erros de predição ($\mathcal{X}_1$) da curva analisada em relação à curva de referência:

$$\mathcal{X}_1 = \frac{\sigma^2(\mathbf{e}_{desc})}{\sigma^2(\mathbf{e}_{ref})} \quad (3.4)$$


- Energia total da curva de temperatura ($\mathcal{X}_2$), estimada por integração trapezoidal:

$$\mathcal{X}_2 = \sum_{k=1}^{N-1} \frac{x(k) + x(k+1)}{2} \Delta t \quad (3.5)$$

Essas duas métricas formam o espaço de atributos utilizado para a classificação supervisionada com SVM. Inicialmente, o classificador foi treinado com os dados do trocador fonte e testado diretamente no trocador alvo, sem aplicação de adaptação de domínios.

A Figura 13 apresenta a classificação SVM realizada diretamente no espaço original dos atributos, utilizando dados simulados com base na modelagem AR da Base 2. Observa-se que o classificador foi capaz de identificar corretamente todos os estados de incrustação, mas apresentou falhas ao distinguir as condições limpas.

Figura 13 – Classificação SVM no espaço original



Fonte: Produção do próprio autor

A Tabela 5 apresenta o desempenho do classificador, expresso em termos percentuais. Verifica-se que 16,1% das amostras limpas foram classificadas erroneamente como incrustadas, o que compromete a confiabilidade do sistema em contextos onde a falsificação de falhas representa custo ou intervenção desnecessária.

Tabela 5 – Desempenho do classificador no espaço original (valores em porcentagem)

Classe Verdadeira	Incrustado (Previsto)	Limpo (Previsto)
Incrustado	100,0%	0,0%
Limpo	16,1%	83,9%

Fonte: Produção do próprio autor

Para quantificar a capacidade do classificador em detectar corretamente a condição de incrustação, calcula-se o *score* F_1 da classe **incrustado**, que combina precisão e revocação em uma única métrica:


$$\text{Precisão} = \frac{100,0}{100,0 + 16,1} \approx 86,1\%, \quad \text{Revocação} = \frac{100,0}{100,0 + 0,0} = 100,0\%$$

$$F_1 = 2 \cdot \frac{86,1\% \cdot 100,0\%}{86,1\% + 100,0\%} \approx \mathbf{92,5\%}$$

Apesar da alta taxa de detecção do estado incrustado, o número de falsos positivos reflete uma única observação: todos os dados limpos do trocador alvo foram classificados como incrustados, o que mostra que o classificador não generalizou bem (classificou qualquer condição diferente da treinada como sendo incrustação), reforçando a necessidade de adaptação de domínio para aprimorar a separação entre classes em cenários com trocadores de geometrias distintas.

Para melhor compreensão da discrepância entre os domínios, a Figura 14 apresenta os histogramas das distribuições dos atributos $\mathcal{X}_1$ e $\mathcal{X}_2$ para os dois trocadores. Nota-se a diferença significativa nas distribuições, indicando a necessidade de uma adaptação de domínio.


Posteriormente, aplicou-se a técnica de Transferência de Aprendizado por *Joint Distribution Adaptation* (JDA), que realiza a projeção dos dados para um espaço latente no qual as distribuições marginal e condicional são alinhadas. Após essa adaptação, observou-se melhoria expressiva na acurácia da classificação no domínio alvo, evidenciando o sucesso da transferência de conhecimento.

Figura 14 – Histogramas dos atributos $\mathcal{X}_1$ e $\mathcal{X}_2$ — espaço original

Fonte: Produção do próprio autor

A Figura 15 ilustra a classificação realizada após aplicação da JDA. Percebe-se uma separação mais clara entre os estados limpo e incrustado, mesmo no trocador alvo, indicando a efetiva redução da discrepância entre os domínios.

Figura 15 – Classificação SVM após aplicação da JDA



Fonte: Produção do próprio autor

A Tabela 6 apresenta o desempenho do classificador no espaço latente após a aplicação da técnica de Transferência de Aprendizado via JDA. Nota-se que todos os estados incrustados foram corretamente identificados e apenas 0,8% das amostras limpas foram confundidas com falhas, o que representa um ganho expressivo em relação à classificação no espaço original. Além disso, estes 0,8% representam um único ponto, o que mostra que treinando com mais dados eliminaríamos completamente os falsos positivos. Para quantificar o desempenho do classificador na detecção da condição **incrustado**,

calcula-se novamente o escore F1:

Tabela 6 – Desempenho do classificador no espaço latente (valores em porcentagem)

Classe Verdadeira	Incrustado (Previsto)	Limpo (Previsto)
Incrustado	100,0%	0,0%
Limpo	0,8%	99,2%

Fonte: Produção do próprio autor


$$\text{Precisão} = \frac{100,0}{100,0 + 0,8} \approx 99,2\%, \quad \text{Revocação} = \frac{100,0}{100,0 + 0,0} = 100,0\%$$

$$F_1 = 2 \cdot \frac{99,2\% \cdot 100,0\%}{99,2\% + 100,0\%} \approx \mathbf{99,6\%}$$

O resultado evidencia a eficácia da JDA em alinhar os domínios fonte e alvo, mesmo com diferentes geometrias e parâmetros operacionais. O ganho de desempenho na detecção de incrustação valida a aplicabilidade da metodologia em cenários industriais, onde o conhecimento prévio sobre o comportamento de um trocador pode ser transferido com sucesso para outro com baixa disponibilidade de dados.

Por fim, a Figura 16 apresenta os histogramas das distribuições dos atributos $\mathcal{X}_1$ e $\mathcal{X}_2$ após a aplicação da JDA. Nota-se uma sobreposição muito mais próxima entre as distribuições dos dois domínios, confirmando a eficácia da adaptação.

Figura 16 – Histogramas dos atributos $\mathcal{X}_1$ e $\mathcal{X}_2$ após JDA



Fonte: Produção do próprio autor

A análise desta segunda base complementa os resultados da Base 1, demonstrando que a metodologia proposta mantém sua eficácia mesmo sob diferentes formas de modelagem e maior discrepância entre os domínios. Isso reforça a robustez da abordagem baseada em AR, SVM e JDA para o monitoramento de incrustação em trocadores de calor com características variadas.

3.3. CONCLUSÃO DO CAPÍTULO

Este capítulo apresentou a aplicação da metodologia proposta em duas bases de dados simuladas numericamente, com diferentes níveis de complexidade e estratégias de modelagem. Na Base 1, adotou-se um modelo de ordem reduzida com envelhecimento contínuo do trocador através da redução do coeficiente global de transferência de calor (U), calibrado via Computação Bayesiana Aproximada (ABC). A detecção da incrustação foi realizada diretamente a partir das curvas de temperatura de saída, sem necessidade de extração de atributos.

Já na Base 2, optou-se por uma modelagem simplificada, com geração de curvas por Monte Carlo considerando $U \sim \text{Gama}$ e extração de atributos a partir de modelos AR. Neste caso, as métricas extraídas permitiram estruturar um espaço de características mais robusto para a classificação supervisionada. Ambas as abordagens demonstraram que, apesar das diferenças nas simulações, a técnica de Transferência de Aprendizado via JDA foi eficaz na adaptação entre trocadores fonte e alvo.

Os resultados evidenciam que a aplicação combinada de modelagem autorregressiva, classificação por SVM e adaptação de domínios via JDA constitui uma abordagem promissora para o diagnóstico de incrustação em trocadores de calor, mesmo diante de diferentes geometrias, condições operacionais e complexidades de modelagem. A robustez da metodologia frente a essas variações reforça seu potencial de generalização para aplicações reais em manutenção preditiva.

No capítulo seguinte, a metodologia é aplicada a dados experimentais coletados em bancada, com o objetivo de validar sua aplicabilidade em um cenário real.

4 VALIDAÇÃO EXPERIMENTAL COM TROCADORES REAIS


Este capítulo apresenta a validação experimental da metodologia proposta em dois trocadores de calor reais de geometrias distintas, utilizando a Bancada Didática AG-TRC, desenvolvida pela empresa **ALGETEC – Soluções Tecnológicas em Educação**¹. Os experimentos foram realizados com um trocador do tipo casco e tubo (modelo TST 30-2) e outro do tipo placas brasadas de aço inox (20 placas), operando sob diferentes condições térmicas. São descritas as características construtivas de cada equipamento, os procedimentos de aquisição e processamento de dados e os resultados obtidos com a aplicação das técnicas de modelagem AR, extração de atributos e classificação com Transferência de Aprendizado (JDA).

4.1. TROCADOR CASCO E TUBO

O trocador de calor do tipo casco e tubo utilizado nos testes é o modelo TST 30-2, da **Apema**². Trata-se de um trocador contracorrente com passagem única, composto por um único tubo interno.

A Figura 17 apresenta a montagem experimental do módulo casco e tubo no laboratório, com os circuitos de aquecimento, resfriamento e aquisição de dados.

Figura 17 – Montagem experimental do trocador de calor casco e tubo



Fonte: Produção do próprio autor

¹ Mais informações em: <https://www.algetec.com.br/bancada-didatica-de-trocadores-de-calor>

² Mais informações em: <https://apema.com.br/pdf/catalogo-trocador-calor-casco-tubo.pdf>

4.2. TROCADOR DE PLACAS PLANAS

O segundo trocador utilizado nos ensaios experimentais é um trocador de calor de placas brasadas da **Brewparts**³ com 20 placas de aço inox 304, soldadas com 99,9% de cobre. Cada placa possui área de transferência térmica de aproximadamente 0,012 m², totalizando cerca de 0,24 m². O corpo do equipamento mede 19 cm de comprimento, 7,5 cm de largura e 5,5 cm de altura útil (7,5 cm no total com conexões).

As conexões de entrada e saída são do tipo BSP 1/2", com disposição cruzada entre os dois circuitos, permitindo operação em contrafluxo. Trata-se de um equipamento compacto e eficiente, comumente utilizado em chillers, aplicações domésticas e refrigeração de pequenos processos térmicos.

A Figura 18 mostra a montagem do módulo de placas brasadas com instrumentação para medição de temperaturas e vazões em ambas as linhas.

Figura 18 – Montagem experimental do trocador de placas planas



Fonte: Produção do próprio autor

4.3. AJUSTE DAS CURVAS E SIMULAÇÃO DE INCRUSTAÇÃO

As curvas de temperatura foram obtidas por meio de sensores colocados nas entradas e saídas dos trocadores. Para cada execução experimental, extraiu-se o perfil de

³ Mais informações em: <http://brewparts.com.br/index.php>

temperatura do fluido ao longo do tempo e ajustou-se uma resposta de primeira ordem do tipo:

$$\frac{dT}{dt} = \frac{k}{\tau}(T_{\text{in}} - T), \quad (4.1)$$

onde k é o ganho estático, τ a constante de tempo associada à resposta térmica e T_{in} a temperatura de entrada. Para a identificação dos parâmetros dinâmicos das curvas experimentais, foi adotado o ajuste por mínimos quadrados não lineares, utilizando a função `lsqcurvefit` do MATLAB®. O modelo adotado possui a forma:

$$T(t) = k(1 - e^{-t/\tau}) + T_0 \quad (4.2)$$

Em que k representa o ganho estático, τ a constante de tempo e T_0 o valor inicial da temperatura. Embora uma estimativa aproximada de τ pudesse ser obtida pelo tempo necessário para atingir 63% da resposta final (típica de sistemas de primeira ordem), a abordagem por ajuste direto aos dados é mais robusta frente à presença de ruído e variações operacionais, permitindo a estimativa simultânea dos três parâmetros do modelo. O ajuste foi realizado individualmente para cada curva experimental, com os parâmetros posteriormente utilizados na geração de curvas sintéticas via simulação de Monte Carlo.


Para simular a condição de incrustação, os parâmetros identificados para o regime limpo foram alterados sistematicamente: o ganho k foi reduzido em 50% e a constante de tempo τ foi aumentada em 25%, simulando a perda de eficiência térmica e o aumento de inércia associados à incrustação. Os valores de k e τ foram modelados como variáveis aleatórias seguindo distribuições gama, cujos parâmetros foram obtidos a partir das médias e desvios padrão ajustados dos dados reais. A Tabela 7 apresenta os parâmetros das distribuições utilizadas para a geração das curvas sintéticas em condição limpa e incrustada. As Figuras 19 e 20 mostram as curvas de temperatura de saída no casco para o trocador casco e tubo e para o trocador de placas planas, respectivamente.

Tabela 7 – Parâmetros das distribuições gama para simulação das curvas térmicas

Condição	Parâmetro	Média	Ajuste de DP ⁴	Distribuição $\Gamma(\alpha, \theta)$
Limpa	k	$k_{\text{média}}$	$0,3 \cdot \sigma_k$	$\left(\frac{k_{\text{média}}^2}{\sigma_k^2}, \frac{\sigma_k^2}{k_{\text{média}}} \right)$
	τ	$\tau_{\text{média}}$	$0,3 \cdot \sigma_\tau$	$\left(\frac{\tau_{\text{média}}^2}{\sigma_\tau^2}, \frac{\sigma_\tau^2}{\tau_{\text{média}}} \right)$
Incrustada	k	$0,5 \cdot k_{\text{média}}$	$0,3 \cdot \sigma_k$	$\left(\frac{(0,5k_{\text{média}})^2}{\sigma_k^2}, \frac{\sigma_k^2}{0,5k_{\text{média}}} \right)$
	τ	$1,25 \cdot \tau_{\text{média}}$	$0,3 \cdot \sigma_\tau$	$\left(\frac{(1,25\tau_{\text{média}})^2}{\sigma_\tau^2}, \frac{\sigma_\tau^2}{1,25\tau_{\text{média}}} \right)$

Fonte: Produção do próprio autor

Figura 19 – Curvas de temperatura de saída no casco do trocador do tipo casco e tubo



Fonte: Produção do próprio autor


Em ambos os trocadores, foi identificado um modelo AR com base em uma única curva de temperatura limpa, escolhida aleatoriamente. A ordem do modelo foi definida com base no Critério de Informação de Akaike (AIC), como apresentado nas Figuras 21 e 22. A ordem 10 foi selecionada para os dois casos, representando o melhor equilíbrio entre qualidade de ajuste e complexidade.

As Figuras 23 e 24 apresentam o ajuste do modelo AR às curvas de temperatura do casco para cada trocador. Em ambos os casos, o ajuste foi satisfatório, indicando que o modelo foi capaz de capturar adequadamente a dinâmica dominante do sistema térmico.

A validação final dos modelos foi feita por meio da análise de autocorrelação dos resíduos (teste de brancura), como ilustrado nas Figuras 25 e 26. Em ambos os casos, os


⁴ O desvio padrão foi ajustado para reduzir a variabilidade das amostras sintéticas, isto é, aquelas geradas por simulação de Monte Carlo. Essa estratégia visa evitar o entrelaçamento excessivo entre as curvas limpas e incrustadas, causado pela pequena quantidade de dados experimentais disponíveis.

Figura 20 – Curvas de temperatura de saída no casco do trocador de placas planas




Fonte: Produção do próprio autor

Figura 21 – Critério AIC aplicado ao trocador casco e tubo




Fonte: Produção do próprio autor

Figura 22 – Critério AIC aplicado ao trocador de placas planas




Fonte: Produção do próprio autor

Figura 23 – Ajuste do modelo AR ao trocador casco e tubo



Fonte: Produção do próprio autor

Figura 24 – Ajuste do modelo AR ao trocador de placas planas



Fonte: Produção do próprio autor


resíduos encontram-se dentro dos intervalos de confiança, indicando comportamento de ruído branco e, portanto, ausência de estrutura nos erros. Isso valida a adequação dos modelos AR aplicados.

4.4. CLASSIFICAÇÃO COM MODELOS AR E TRANSFERÊNCIA DE APRENDIZADO

As curvas simuladas foram utilizadas para estimar modelos AR de sexta ordem para ambos os trocadores. A partir dos modelos, foram extraídas $\mathcal{X}_1$ (razão entre variâncias dos erros de predição) e $\mathcal{X}_2$ (integral do sinal de temperatura, uma medida de energia).


A Figura 27 apresenta o resultado da classificação por SVM no espaço original,

Figura 25 – Teste de brancura dos resíduos do modelo AR — trocador casco e tubo



Fonte: Produção do próprio autor

Figura 26 – Teste de brancura dos resíduos do modelo AR — trocador de placas planas



Fonte: Produção do próprio autor

treinado apenas com os dados fonte. Desta vez, todas as condições adversas da treinada foram classificadas como limpas, mostrando outro tipo de deficiência na generalização do classificador.


Para quantificar a capacidade de detecção da condição de incrustação, a partir da Tabela 8, calcula-se o *score* F_1 da classe **incrustado**, que combina precisão e revocação:

Tabela 8 – Desempenho do classificador no espaço original (valores em porcentagem)

Classe Verdadeira	Incrustado (Previsto)	Limpas (Previsto)
Incrustado	51,0%	49,0%
Limpas	0,0%	100,0%

Fonte: Produção do próprio autor

Figura 27 – Classificação SVM no espaço original



Fonte: Produção do próprio autor


$$\text{Precisão} = \frac{51,0}{51,0 + 0,0} = 100,0\%, \quad \text{Revocação} = \frac{51,0}{51,0 + 49,0} = 51,0\%$$

$$F_1 = 2 \cdot \frac{100,0\% \cdot 51,0\%}{100,0\% + 51,0\%} \approx 67,5\%$$

Apesar de não apresentar falsos positivos, o classificador falha ao detectar corretamente quase metade das condições incrustadas. Esse comportamento indica que o modelo treinado no trocador fonte não consegue generalizar adequadamente para o trocador alvo no espaço original dos atributos, o que justifica a necessidade de uma adaptação de domínio. A fim de compreender melhor a distribuição das características nos dados experimentais, a Figura 28 mostra os histogramas dos atributos $\mathcal{X}_1$ (razão de variâncias dos erros de predição) e $\mathcal{X}_2$ (energia do sinal de temperatura).


Para superar a limitação de generalização observada no espaço original, aplicou-se a técnica de Transferência de Aprendizado por Adaptação de Distribuição Conjunta (JDA), projetando os dados em um novo espaço latente. A Figura 29 mostra os resultados da classificação com SVM nesse espaço transformado, revelando uma separação bem definida entre as classes operacionais dos dois trocadores. Após a aplicação da JDA, o modelo passou a classificar corretamente os estados limpo e incrustado mesmo no trocador alvo, com desempenho significativamente superior.

Para avaliar a eficácia da adaptação de domínio, a partir da Tabela 9, calcula-se o escore F1 da classe **incrustado** no espaço latente.

Figura 28 – Histogramas dos atributos $\mathcal{X}_1$ e $\mathcal{X}_2$ — espaço original

Fonte: Produção do próprio autor

Figura 29 – Classificação SVM após aplicação da JDA



Fonte: Produção do próprio autor

Tabela 9 – Desempenho do classificador no espaço latente (valores em porcentagem)

Classe Verdadeira	Incrustado (Previsto)	Limpo (Previsto)
Incrustado	100,0%	0,0%
Limpo	0,0%	100,0%


Fonte: Produção do próprio autor

$$\text{Precisão} = \frac{100,0}{100,0 + 0,0} = 100,0\%, \quad \text{Revocação} = \frac{100,0}{100,0 + 0,0} = 100,0\%$$

$$F_1 = 2 \cdot \frac{100,0\% \cdot 100,0\%}{100,0\% + 100,0\%} = \mathbf{100,0\%}$$

Esse resultado confirma que, após a aplicação da JDA, o classificador conseguiu separar com precisão os estados limpo e incrustado nos dados do trocador alvo, validando a eficácia da Transferência de Aprendizado para harmonização de domínios com geometrias distintas. Complementarmente, a Figura 30 apresenta os histogramas dos atributos no espaço latente. Após a adaptação com JDA, observa-se um alinhamento claro entre as distribuições do trocador fonte e do trocador alvo, tanto para o atributo $\mathcal{X}_1$ quanto para $\mathcal{X}_2$, evidenciando a eficácia da técnica em harmonizar os domínios e possibilitar a generalização do classificador.

Figura 30 – Histogramas dos atributos após aplicação da JDA



Fonte: Produção do próprio autor

4.5. CONCLUSÃO DO CAPÍTULO

Os resultados experimentais confirmam a aplicabilidade da metodologia proposta em ambientes reais. Mesmo diante de configurações e comportamentos distintos entre os trocadores casco e tubo e placas planas, a estratégia baseada em modelos AR, extração de atributos e Transferência de Aprendizado (JDA) foi capaz de distinguir com precisão os estados operacionais, simulando o efeito de incrustação. Essa abordagem demonstra potencial para aplicações em campo na detecção preditiva de falhas em trocadores de calor industriais.

5 CONCLUSÕES E PERSPECTIVAS

5.1. CONCLUSÕES

Este trabalho apresentou uma contribuição relevante e inovadora para o monitoramento de trocadores de calor, propondo uma metodologia orientada por dados capaz de identificar a presença de incrustações a partir de sinais térmicos e generalizar o diagnóstico entre equipamentos distintos por meio de técnicas de *Transfer Learning* (TL). A abordagem integra modelagem autoregressiva (AR), extração de atributos estatísticos e classificação com Máquinas de Vetor Suporte (SVM), complementada pelo método de *Joint Distribution Adaptation* (JDA), configurando um arcabouço metodológico sólido, flexível e aplicável tanto em contextos simulados quanto experimentais.

Do ponto de vista científico, o presente trabalho avança o estado da arte ao propor o conceito de *Sombras Digitais* para trocadores de calor, que consistem em representações compactas do comportamento térmico em condição limpa. Novos sinais são comparados a essas representações para detecção de desvios associados à incrustação. Essa proposta se diferencia dos tradicionais modelos físico-matemáticos, pois prescinde da necessidade de caracterizar detalhadamente os fenômenos de transporte e deposição, substituindo-os por uma modelagem estatística acessível, com baixo custo computacional e alta adaptabilidade. O uso de modelos AR, combinado à análise de resíduos e métricas de energia, mostrou-se uma estratégia eficaz para traduzir fenômenos complexos em atributos simples e discriminativos.

Do ponto de vista industrial, a principal contribuição está na demonstração de que é possível detectar incrustação mesmo em sistemas com instrumentação reduzida, realidade comum em plantas químicas, petroquímicas e de geração de energia. Ao basear-se em grandezas como a temperatura de saída dos fluidos, uma das variáveis mais universalmente monitoradas, a metodologia proposta mostra-se imediatamente aplicável a parques industriais já existentes, sem necessidade de investimentos em sensores adicionais ou em modelos físico-químicos complexos. Essa característica confere baixo custo de implementação e alta escalabilidade, permitindo que empresas apliquem a técnica de forma padronizada em múltiplos equipamentos e unidades produtivas.

Outro impacto relevante é a capacidade de generalização entre domínios distintos. Demonstrou-se que classificadores treinados em um trocador de calor podem ser reapro-

veitados em outro, mesmo quando apresentam geometrias e condições operacionais diferentes, graças à aplicação da JDA. Essa generalização é particularmente importante em ambientes industriais onde a coleta de dados rotulados é cara, demorada e, muitas vezes, impraticável. A possibilidade de treinar modelos a partir de poucos equipamentos bem instrumentados e transferir o conhecimento para outros menos monitorados representa um ganho substancial em tempo, custo e confiabilidade na implementação de estratégias de manutenção preditiva.

A validação experimental realizada reforça o potencial de aplicação prática da abordagem. Os resultados obtidos com dois trocadores reais (um de casco e tubo e outro de placas brasadas) demonstraram que a metodologia mantém bom desempenho mesmo diante do ruído inerente aos dados experimentais e das discrepâncias geométricas entre equipamentos. Essa constatação fortalece a aplicabilidade do método fora do ambiente acadêmico, indicando que a transição para cenários industriais em escala real é viável. Do ponto de vista prático, o trabalho oferece à indústria uma ferramenta capaz de reduzir custos de manutenção, otimizar paradas programadas e aumentar a disponibilidade operacional dos sistemas térmicos.

Além disso, o estudo dialoga diretamente com tendências contemporâneas da Indústria 4.0, ao propor soluções de monitoramento inteligente que podem ser integradas a arquiteturas digitais já empregadas em plantas industriais. Embora a metodologia aqui apresentada não constitua um Gêmeo Digital completo, sua formulação como *Sombra Digital* representa um passo intermediário essencial, de menor complexidade e custo, mas já capaz de agregar valor significativo em termos de confiabilidade operacional e redução de desperdícios energéticos. Em longo prazo, a integração de sombras digitais a plataformas digitais mais abrangentes poderá acelerar a evolução rumo a sistemas de monitoramento inteligentes, autônomos e autoajustáveis.

No campo acadêmico, este trabalho também deixa um legado relevante. Primeiramente, consolida a aplicação de *Transfer Learning* em sistemas térmicos, área em que ainda são raros os trabalhos comparáveis, ampliando a literatura até então concentrada em sistemas estruturais e mecânicos. Em segundo lugar, apresenta uma metodologia replicável e modular, que pode ser facilmente adaptada para outros problemas de diagnóstico industrial, como corrosão, desgaste de materiais e falhas em turbomáquinas. Finalmente, a pesquisa contribui para a formação de uma base de conhecimento aberta, uma vez que os códigos e dados produzidos foram disponibilizados em plataforma pública,

favorecendo a reprodutibilidade científica e a continuidade de novas pesquisas.

Em síntese, este trabalho não apenas propôs e validou uma metodologia inovadora, mas também demonstrou sua viabilidade prática, impacto econômico e relevância científica. Do ponto de vista industrial, abre caminho para aplicações reais em monitoramento preditivo de trocadores de calor, oferecendo ganhos diretos em redução de custos, eficiência energética e sustentabilidade. Do ponto de vista acadêmico, amplia as fronteiras da *Transfer Learning* para novos domínios de aplicação, consolidando-se como uma contribuição original no cruzamento entre engenharia térmica, ciência de dados e manutenção preditiva.

Assim, o presente trabalho reafirma a importância de abordagens orientadas por dados como complemento às modelagens físico-matemáticas tradicionais e aponta para um futuro em que a integração entre estatística, aprendizado de máquina e engenharia térmica será elemento central na construção de sistemas industriais mais eficientes, inteligentes e resilientes.

5.2. TRABALHOS FUTUROS

Como desdobramento deste trabalho, encontra-se em fase de elaboração um artigo em colaboração com o Prof. Francesco Coletti (Brunel University, Reino Unido), visando aprofundar a aplicação de técnicas de Transferência de Aprendizado em trocadores de calor reais, com base em critérios de similaridade térmica entre equipamentos e estratégias de clusterização de atributos. Esse trabalho tem como objetivo propor métricas para seleção inteligente de domínios fonte, otimizando a eficiência da transferência de conhecimento em contextos industriais.

Além disso, pretende-se expandir a metodologia para monitoramento contínuo e online, com integração a gêmeos digitais e arquiteturas de manutenção preditiva em ambientes industriais reais, envolvendo também ressonância de controladores. Espera-se também investigar abordagens baseadas em aprendizado profundo e modelos não lineares, mantendo a compatibilidade com sensores de baixo custo e infraestrutura de dados limitada.

5.3. LISTA DE PUBLICAÇÕES ATÉ O MOMENTO

Até o momento, o candidato possui três publicações relacionadas aos temas de pesquisa desta dissertação, sendo elas:

- Um artigo publicado na revista da ASME *Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems*, intitulado *"Similarity Analysis to Enhance Transfer Learning for Damage Detection"* (Almeida; Silva; Ritto, 2024), que aborda Análise de Similaridade e Transferência de Aprendizado para generalização de condições de contorno e aprimoramento da detecção de danos em estruturas de viga.
- Um artigo apresentado no congresso *DTE - AICOMAS 2025: Digital Twins in Engineering & Artificial Intelligence and Computational Methods in Applied Science*, realizado em Paris/França, intitulado *"Bayesian Calibration and Transfer Learning for Fouling Diagnosis in Heat Exchangers"* (Almeida; Silva; Godoy, 2025), que trata de Calibração Bayesiana e Transferência de Aprendizado para detecção de incrustação em trocadores de calor.
- Um artigo publicado e apresentado *XVII Simpósio Brasileiro de Automação Inteligente (SBAI 2025)*, promovido pela Sociedade Brasileira de Automática, intitulado *"Monitoramento de Incrustações em Trocadores de Calor por Meio da Transferência de Aprendizado de Sombras Digitais"*, que apresenta parte da metodologia proposta nesta dissertação.

5.4. DISPONIBILIDADE DE DADOS

Todos os algoritmos, conjuntos de dados e scripts utilizados nesta dissertação estão disponíveis em repositório público no *GitHub*, permitindo a total reprodutibilidade dos resultados. O repositório, intitulado ANITA (ANITA: Autoregressive aNalysis and feature-based IdentificaTion for heat exchanger Assessment), contém os códigos de simulação, extração de atributos, identificação de modelos, aplicação de técnicas de classificação e transferência de aprendizado, bem como os dados experimentais coletados em bancada. A estrutura foi organizada para facilitar a navegação e o reaproveitamento dos métodos

por outros pesquisadores interessados na aplicação de técnicas orientadas por dados ao monitoramento térmico de trocadores de calor.

Link para o repositório: <https://github.com/EstenioFuzaro/ANITA.git>

Solicita-se que o autor deste trabalho seja devidamente citado em quaisquer publicações ou projetos que utilizem total ou parcialmente os dados e algoritmos disponibilizados no repositório.

5.5. FINANCIAMENTO

Este estudo foi financiado, em parte, pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil, sob o Processo nº 2024/00140-1. Samuel da Silva agradece o apoio do CNPq por meio dos processos 309467/2023-3 e 404475/2023-0. Os autores também reconhecem o suporte do INCT-EIE (Instituto Nacional de Ciência e Tecnologia – Estruturas Inteligentes em Engenharia), financiado pelas agências brasileiras CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), sob o número de concessão 406148/2022-8, bem como pela CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e pela FAPEMIG/Brasil.

REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, E. F. de; SILVA, S. da; RITTO, T. G. Similarity analysis to enhance transfer learning for damage detection. **Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems**, v. 8, n. 3, p. 031004, 11 2024. ISSN 2572-3901. Disponível em: <https://doi.org/10.1115/1.4067038>.

ALMEIDA, E. Fuzaro de; SILVA, S. da; GODOY, V. Transfer learning of digital shadows for fouling monitoring in heat exchangers. In: **DTE–AICOMAS 2025: Digital Twins in Engineering & Artificial Intelligence and Computational Methods in Applied Science**. [s.n.], 2025. Apresentado em Paris, França, por Samuel da Silva. Disponível em: https://dte_aicomas_2025.iacm.info/event/contribution/459ebf77-85c5-11ef-b344-000c29ddfc0c.

BILLINGS, S. A. **Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains**. [S.l.]: John Wiley & Sons, 2013.

BOTT, T.; MELO, L. Fouling of heat exchangers. **Experimental Thermal and Fluid Science**, v. 14, n. 4, p. 315, 1997. ISSN 0894-1777. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0894177796001331>.

BOTT, T. R.; BEMROSE, C. R. Particulate Fouling on the Gas-Side of Finned Tube Heat Exchangers. **Journal of Heat Transfer**, v. 105, n. 1, p. 178–183, 02 1983. ISSN 0022-1481. Disponível em: <https://doi.org/10.1115/1.3245538>.

CASTELLO, D.; RITTO, T. ABC for model selection and parameter estimation of drill-string bit-rock interaction models and stochastic stability. **Journal of Sound and Vibration**, v. 547, p. 117537, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022460X22007209>.

CHEN, L.; ZHAO, K.; TAO, W.-Q. Research on one-dimensional digital twin algorithm of plate heat exchanger. **Numerical Heat Transfer, Part A: Applications**, Taylor & Francis, v. 0, n. 0, p. 1–20, 2023. Disponível em: <https://doi.org/10.1080/10407782.2023.2222906>.

CHIANG, Y.-T.; LU, C.-H.; HSU, J. Y.-J. A feature-based knowledge transfer framework for cross-environment activity recognition toward smart home applications. **IEEE Transactions on Human-Machine Systems**, v. 47, n. 3, p. 310–322, 2017.

CHOLETTE, M. E. *et al.* Degradation modeling and condition-based maintenance of boiler heat exchangers using gamma processes. **Reliability Engineering & System Safety**, v. 183, p. 184–196, 2019. ISSN 0951-8320. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0951832018303272>.

CSILLÉRY, K. *et al.* Approximate bayesian computation (abc) in practice. **Trends in Ecology & Evolution**, v. 25, n. 7, p. 410–418, 2010. ISSN 0169-5347. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0169534710000662>.

DIAZ-BEJARANO, E. *et al.* Organic and inorganic fouling in heat exchangers – industrial case study: Analysis of fouling state. **Applied Energy**, v. 206, p. 1250–1266, 2017. ISSN 0306-2619. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0306261917314332>.

DIAZ-BEJARANO, E.; COLETTI, F.; MACCHIETTO, S. Thermo-hydraulic analysis of refinery heat exchangers undergoing fouling. **AIChE Journal**, v. 63, n. 3, p. 984–1001, 2017. Disponível em: <https://aiche.onlinelibrary.wiley.com/doi/abs/10.1002/aic.15457>.

_____. Modeling and prediction of shell-side fouling in shell-and-tube heat exchangers. **Heat Transfer Engineering**, Taylor & Francis, v. 40, n. 11, p. 845–861, 2019. Disponível em: <https://doi.org/10.1080/01457632.2018.1446814>.

_____. A model-based method for visualization, monitoring, and diagnosis of fouling in heat exchangers. **Industrial & Engineering Chemistry Research**, v. 59, n. 10, p. 4602–4619, 2020. Disponível em: <https://doi.org/10.1021/acs.iecr.9b05490>.

FIGUEIREDO, E. *et al.* Influence of the autoregressive model order on damage detection. **Computer-Aided Civil and Infrastructure Engineering**, v. 26, n. 3, p. 225–238, 2011. Available from: <https://doi.org/10.1111/j.1467-8667.2010.00685.x>. Access on: 05 dec. 2018.

_____. Transfer learning to enhance the damage detection performance in bridges when using numerical models. **Journal of Bridge Engineering**, American Society of Civil Engineers, v. 28, n. 1, 2022.

GARCIA, C. **Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos**. 3. ed. São Paulo, Brasil: Edusp - Editora da Universidade de São Paulo, 2022. 648 p. (Coleção Acadêmica). Edição revista e ampliada. ISBN 9786557850671. Disponível em: <https://www.edusp.com.br/livros/modelagem-e-simulacao-de-processos-industriais/>.

GODOY, V.; SILVA, S. da; TELOLI, R. Data-driven bayesian modeling using approximate bayesian computation for heat exchanger monitoring. In: . [S.l.: s.n.], 2024.

HOGG, R.; LEDOLTER, J. **Engineering Statistics**. Macmillan, 1987. (Mathematics & statistics). ISBN 9780023557903. Disponível em: <https://books.google.com.br/books?id=RKxaxwEACAAJ>.

INAMDAR, H. V. *et al.* Prediction of air-side particulate fouling of hvac&r heat exchangers. **Applied Thermal Engineering**, v. 104, p. 720–733, 2016. ISSN 1359-4311. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1359431116307396>.

JACKOWSKI, P. R. L.; SMITH, R. Impact of nonuniform fouling on operating temperatures in heat exchanger networks. **Heat Transfer Engineering**, Taylor & Francis, v. 38, n. 7-8, p. 753–761, 2017. Disponível em: <https://doi.org/10.1080/01457632.2016.1206417>.

KOPSAPTOPOULOS, F.; FASSOIS, S. Vibration based health monitoring for a lightweight truss structure: Experimental assessment of several statistical time series methods. **Mechanical Systems and Signal Processing**, v. 24, n. 7, p. 1977–1997, 2010. ISSN 0888-3270. Special Issue: ISMA 2010. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0888327010001561>.

LJUNG, L. **System Identification: Theory for the User**. Prentice Hall PTR, 1999. (Prentice Hall information and system sciences series). ISBN 9780136566953. Disponível em: <https://books.google.com.br/books?id=nHFOqgAACAAJ>.

- LONG, M. *et al.* Transfer feature learning with joint distribution adaptation. In: **2013 IEEE International Conference on Computer Vision**. [S.l.: s.n.], 2013. p. 2200–2207.
- LU, Y.; GAO, F. A novel time-domain auto-regressive model for structural damage diagnosis. **Journal of Sound and Vibration**, v. 283, n. 3, p. 1031–1049, 2005. ISSN 0022-460X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0022460X0400584X>.
- MUENTHONG, S.; CHATTAKARN, S.; LERSBAMRUNGSUK, V. Fouling detection in heat exchangers using extended kalman filter. **IOP Conference Series: Materials Science and Engineering**, IOP Publishing, v. 778, n. 1, p. 012083, apr 2020. Disponível em: <https://dx.doi.org/10.1088/1757-899X/778/1/012083>.
- MÜLLER-STEINHAGEN, M. R. M. H.; WATKINSON, A. P. Heat exchanger fouling: Mitigation and cleaning strategies. **Heat Transfer Engineering**, Taylor & Francis, v. 32, n. 3-4, p. 189–196, 2011. Disponível em: <https://doi.org/10.1080/01457632.2010.503108>.
- NGUYEN, B. H.; XUE, B.; ANDREAE, P. A particle swarm optimization based feature selection approach to transfer learning in classification. In: **Proceedings of the Genetic and Evolutionary Computation Conference**. New York, NY, USA: Association for Computing Machinery, 2018. (GECCO '18), p. 37–44. ISBN 9781450356183. Disponível em: <https://doi.org/10.1145/3205455.3205540>.
- PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p. 1345–1359, 2010.
- 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, 2022. ISSN 0263-8762. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0263876222002489>.
- SIEGEL, J. A.; NAZAROFF, W. W. Predicting particle deposition on hvac heat exchangers. **Atmospheric Environment**, v. 37, n. 39, p. 5587–5596, 2003. ISSN 1352-2310. Indoor Air Chemistry and Physics: Papers from Indoor Air 2002. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1352231003007751>.
- SOHN, H.; FARRAR, C. R. Damage diagnosis using time series analysis of vibration signals. **Smart Materials and Structures**, v. 10, n. 3, p. 446, jun 2001. Disponível em: <https://dx.doi.org/10.1088/0964-1726/10/3/304>.
- SOUZA, L. *et al.* A comprehensive study on unsupervised transfer learning for structural health monitoring of bridges using joint distribution adaptation. **Infrastructures**, v. 9, n. 8, 2024. ISSN 2412-3811. Disponível em: <https://www.mdpi.com/2412-3811/9/8/131>.
- WALLHÄUßER, E.; HUSSEIN, M.; BECKER, T. Detection methods of fouling in heat exchangers in the food industry. **Food Control**, v. 27, n. 1, p. 1–10, 2012. ISSN 0956-7135. Disponível em: <https://www.sciencedirect.com/science/article/pii/S095671351200117X>.
- WANG, J. *et al.* Easy transfer learning by exploiting intra-domain structures. In: **2019 IEEE International Conference on Multimedia and Expo (ICME)**. [S.l.: s.n.], 2019. p. 1210–1215.

YU, W. *et al.* Energy digital twin technology for industrial energy management: Classification, challenges and future. **Renewable and Sustainable Energy Reviews**, v. 161, p. 112407, 2022. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S136403212200315X>.