

Avaliação da Efetividade de Trocadores de Calor Utilizando Aprendizado de Máquina *

Igino G. S. Guerra * Heber P. Gomes * Juan J. M. Villanueva *
Aristóteles T. Neto **

* *Laboratório de Eficiência Energética e Hidráulica em Saneamento (LEHNS), Universidade Federal da Paraíba, PB, (e-mails: igsg@academico.ufpb.br, heberp@uol.com.br e jmauricio@cear.ufpb.br)*
** *Departamento de Transformação Digital, Vivix Vidros Planos, PE, (e-mail: aristoteles.neto@vivix.com.br)*

Abstract: This study reports on the analysis of the operational performance of four plate heat exchangers, which are part of a cooling system in a glass factory. The overall objective of this work is to develop a diagnostic methodology that can be utilized by the partner company. The energy balance between the hot and cold fluids, the method of the logarithmic mean temperature difference, and the effectiveness-number of transfer units method were used to correlate the pressures, flow rates, and temperatures recorded in the process over a defined period. These techniques helped consolidate a statistical database with heat transfer rates, the amount of heat transferred, operation effectiveness, pressure drop, and other thermophysical parameters. To investigate the influence that pressure drop and operating equipment have on the system's effectiveness, supervised machine learning models were developed. An inferential sensor was modeled using linear regression to correlate effectiveness with total pressure drop, yielding a coefficient of determination of 0.8663. A classifier was modeled using the K-Nearest Neighbors algorithm to identify which equipment is in operation, and its predictions achieved an accuracy of 0.9426 in relation to the observed operational classes. It is concluded that the system's effectiveness decreases as the pressure drop increases and that each set of operating equipment can be identified based on the recorded signals.

Resumo: Este estudo relata a análise do desempenho operacional de uma instalação composta por quatro trocadores de calor de placas, pertencentes a um sistema de resfriamento de uma fábrica de vidros e o objetivo geral do trabalho é desenvolver uma metodologia de diagnóstico que possa ser aproveitada pela empresa parceira. O balanço de energia entre os fluidos quente e frio, o método da média logarítmica das diferenças de temperatura e o método da efetividade-número de unidades de transferência foram usados para correlacionar as pressões, vazões e temperaturas registradas no processo ao longo de um período definido. Essas técnicas ajudaram a consolidar uma base estatística com as taxas de transferência de calor, quantidade de calor transferida, efetividade da operação, perda de carga hidráulica e outros parâmetros termofísicos. Para investigar a influência que a perda de carga hidráulica e os equipamentos em operação possuem sobre a efetividade do sistema, foram desenvolvidos modelos de aprendizado de máquina supervisionado. Um sensor inferencial foi modelado com regressão linear para correlacionar a efetividade com a perda de carga total e seu coeficiente de determinação foi de 0.8663. Um classificador foi modelado com o algoritmo *K-Vizinhos mais Próximos* para identificar quais equipamentos estão em operação e as suas previsões tiveram uma acurácia de 0.9426 em relação às classes operacionais observadas. Conclui-se que a efetividade do sistema diminui a medida que a perda de carga aumenta e que cada conjunto de equipamentos em operação pode ser identificado em função dos sinais registrados.

Keywords: Glass production; Industrial utilities; Heat transfer; Computational intelligence; Digital transformation.

Palavras-chaves: Produção de vidros; Utilidades industriais; Transferência de calor; Inteligência Computacional; Transformação digital.

1. INTRODUÇÃO

O vidro é um material conhecido e utilizado desde a antiguidade, distinguindo-se por possuir uma estrutura não cristalina e pelo seu processo de fabricação, no qual a sílica em mistura com outros óxidos são aquecidos além dos pontos de fusão, a massa resultante de alta viscosidade é conformada para uma geometria desejada e, por fim, resfriada e solidificada (transição vítrea) (Groover, 2010). Além de servir como matéria-prima de utensílios artísticos, científicos e domésticos, as suas propriedades únicas e o custo-benefício em relação a outros materiais tornaram a sua aplicação proeminente nos setores automobilístico, da construção civil e da telecomunicação (Pellegrino, 2002).

Na produção de vidros planos, o processo de fabricação desenvolvido pela Pilkington em 1952 até hoje tem o seu padrão adaptado mundialmente. Nele, a massa fundida é escoada em regime automático e contínuo do forno de fusão para a superfície de uma piscina com estanho fundido (*tin bath*), química e termicamente controlada, de modo que fica flutuando sobre o metal liquefeito. A medida que a massa avança, ela resfria, solidifica e se transforma no vidro plano, seguindo para um forno de recozimento que promove o alívio de tensões internas. Por fim, o corte é realizado para obter as dimensões desejadas. O produto resultante possui aparência homogênea, superfícies com boa planicidade, bom paralelismo e baixa rugosidade e dispensa operações de acabamento. É conhecido no mercado como vidro *float* e sua espessura pode variar entre 0,4 e 25 mm em função do avanço na linha produtiva (Uusitalo, 2014).

Quanto às utilidades industriais, a água é um recurso essencial nas fábricas de vidros modernas, sendo utilizada em grandes quantidades nos processos de resfriamento (Dakwala et al., 2014), acarretando muito consumo energético e elevados custos operacionais para transportá-la ao longo das redes de captação e distribuição (Gomes, 2021).

Devido à globalização, inflação e regulamentações ambientais, as indústrias precisam manter a integridade dos equipamentos e gerenciar a utilização dos recursos sem comprometer a qualidade dos produtos ou causar danos à sociedade e ao meio ambiente. Assim, aumentar a eficiência energética dos processos é uma meta relevante que deve ser buscada continuamente (Dakwala et al., 2014).

As técnicas de manufatura inteligente, que envolvem a utilização de sensores, plataformas de computação, comunicação e controle, modelagem e simulação intensiva de dados e engenharia preditiva, estão se tornando cada vez mais atrativas para resolver problemas industriais complexos como o monitoramento do desempenho de equipamentos, otimização de processos e manutenção preditiva (Kusiak, 2018). Sistemas computacionais capazes de imitar a inteligência humana (Inteligência Artificial) vêm sendo desenvolvidos com esta finalidade e o aprendizado de máquina é uma das abordagens mais promissoras desta área, possuindo como base a utilização de muitos dados (*big data*) para inferir automaticamente novas informações (Schoen, 2024).

* Ao CNPq e à Vivix pelo fomento à esta pesquisa através do Programa de Mestrado e Doutorado Acadêmico para Inovação.

Neste cenário, o objetivo deste trabalho é determinar e avaliar indicadores de desempenho para os trocadores de calor do sistema termo-hidráulico instalado na empresa parceira (Vivix Vidros Planos). A metodologia proposta visa utilizar aprendizado de máquina para diagnosticar as condições operacionais do processo de resfriamento ao longo do tempo, considerando aspectos como efetividade da troca térmica, perda de carga hidráulica e equipamentos em operação. O trabalho é justificado por conta da necessidade periódica de operações de manutenção.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Desempenho operacional de trocadores de calor

Trocadores de calor (TC) são uma classe de equipamentos empregados para transferir a energia térmica de um fluido quente para um fluido frio. Os fluidos não se misturam no seu interior e a transferência de calor se dá através de uma superfície sólida. Suas configurações construtivas possuem diferentes tecnologias consolidadas destacando-se o *trocador de calor de placas*, formado por placas planas corrugadas dispostas em série e com passagens internas por onde os fluidos escoam em contracorrente. Devido à sua grande área superficial em relação ao volume esse tipo de equipamento é classificado como compacto e pode-se afirmar que ele está entre os mais eficientes para as aplicações industriais (Nilpueng et al., 2023).

Para analisar o desempenho operacional de um TC é necessário relacionar os parâmetros de processo (temperaturas, vazões e pressões) e calcular a taxa de transferência de calor promovida. O processo é modelado com base na distribuição de temperaturas em elementos diferenciais dos fluidos. O caso do TC com escoamentos em contracorrente é ilustrado na Fig. 1. Essa configuração proporciona a transferência de calor entre as parcelas quentes dos fluidos em uma extremidade, e entre as parcelas mais frias na outra. O maior gradiente de temperatura se dá na entrada do equipamento (Bergman et al., 2014).

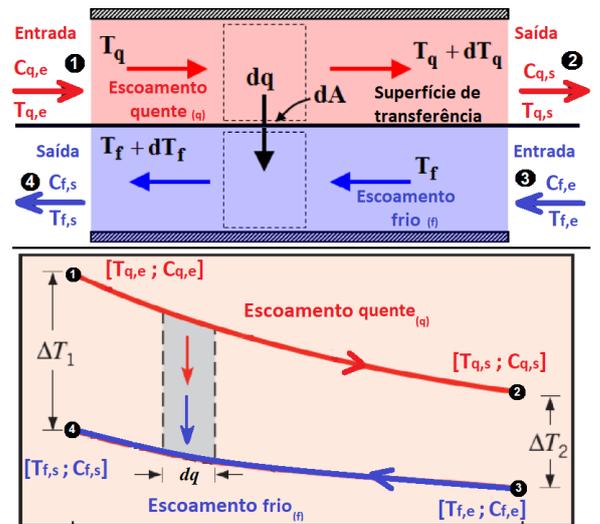


Figura 1. Transferência de calor em TC com escoamentos em contracorrente (Bergman et al., 2014)

Dadas as condições operacionais de temperatura e pressão em cada corrente, os seus valores médios podem ser usados como referência para recuperar as propriedades termofísicas da água, disponíveis em Lemmon et al. (2023). Combinando isso com as respectivas vazões volumétricas pode-se aplicar (1), (2) e (3) para calcular a taxa de transferência de calor de cada escoamento e (4) para calcular a quantidade de calor transferida em um intervalo de tempo:

$$\begin{cases} \dot{m}_q = \dot{v}_q \cdot \rho_q \\ \dot{m}_f = \dot{v}_f \cdot \rho_f \end{cases} \quad (1)$$

$$\begin{cases} C_q = \dot{m}_q \cdot c_{p,q} \\ C_f = \dot{m}_f \cdot c_{p,f} \end{cases} \quad (2)$$

$$\begin{cases} q_q = C_q \cdot \Delta T_q = C_q \cdot (T_{q,s} - T_{q,e}) \\ q_f = C_f \cdot \Delta T_f = C_f \cdot (T_{f,s} - T_{f,e}) \end{cases} \quad (3)$$

$$\begin{cases} Q_q = \int_i^f (q_q) dt \\ Q_f = \int_i^f (q_f) dt \end{cases} \quad (4)$$

Onde:

- q subscrito representa o escoamento do fluido quente.
- f subscrito representa o escoamento do fluido frio.
- e subscrito representa a entrada no TC.
- s subscrito representa a saída do TC.
- ρ é a densidade do fluido em kg/m^3 .
- v é a vazão volumétrica do fluido em m^3/s .
- \dot{m} é a vazão de massa do fluido em kg/s .
- c_p é o calor específico a pressão constante do fluido em $kJ/kg.K$.
- C é a taxa de capacidade calorífica em kW/K .
- T é a temperatura do fluido em $^{\circ}C$.
- ΔT é a diferença de temperatura em K .
- q é a taxa total de transferência de calor em kW .
- Q é a quantidade de calor transferida em kJ .

O valor de q também pode ser calculado sem precisar resolver uma integração usando o método da *diferença de temperatura média logarítmica (DTLM)* (5), (6) e (7). Para o escoamento em contracorrente temos:

$$\begin{cases} \Delta T_1 = T_{q,e} - T_{f,s} \\ \Delta T_2 = T_{q,s} - T_{f,e} \end{cases} \quad (5)$$

$$\Delta T_{ml} = \frac{\Delta T_2 - \Delta T_1}{\ln(\Delta T_2/\Delta T_1)} \quad (6)$$

$$q = \int_e^s dq = U \cdot A \cdot \Delta T_{ml} \quad (7)$$

Onde:

- ΔT_{ml} é a diferença de temperatura média logarítmica entre os fluidos quente e frio em K .
- A é a área total da superfície de transferência em m^2 .
- U é o coeficiente global de transferência de calor em $kJ/m^2.K$.
- dq é a taxa diferencial de transferência de calor kJ .

Conhecido o valor de q através de (1), (2) e (3), pode-se calcular o valor do produto $U \cdot A$ através de (5), (6) e (7). Em seguida, o método da *efetividade-número de unidades de transferência ($\epsilon-NUT$)* (8), (9), (10) e (11) pode ser usado para determinar o desempenho operacional do TC.

$$\begin{cases} C_{min} = \min(C_q, C_f) \\ C_{max} = \max(C_q, C_f) \\ C_r = \frac{C_{min}}{C_{max}} \end{cases} \quad (8)$$

$$NUT = \frac{U \cdot A}{C_{min}} = \frac{q}{C_{min} \cdot \Delta T_{ml}} \quad (9)$$

$$q_{max} = C_{min} \cdot (T_{q,e} - T_{f,e}) \quad (10)$$

$$\epsilon = \frac{q}{q_{max}} = f(NUT, C_r) \quad (11)$$

Em que:

- min subscrito representa mínimo ou menor.
- max subscrito representa máximo ou maior.
- NUT é o número de unidades de transferência do TC (adimensional).
- C_r é a razão entre a menor e a maior taxa de capacidade calorífica dos fluidos (adimensional).
- ϵ é a efetividade do TC (adimensional).

A efetividade de um TC é a razão entre a q desenvolvida e a q máxima possível, e com a combinação dos métodos *DTML* e $\epsilon-NUT$ pode-se analisar o seu desempenho sob uma perspectiva global, sem o fornecimento de informações sobre as condições no seu interior. (Bergman et al., 2014).

2.1.1 Incrustação de partículas e perda de carga hidráulica

Em todo TC ativo, partículas sólidas se depositam continuamente dentro e fora de seus tubos e/ou placas, sendo referidas como incrustações e sujeira, respectivamente. Como elas alteram o acabamento das superfícies que separam os fluidos, uma nova resistência térmica entre os escoamentos surge, diminuindo os valores de U e de q . Nos piores casos, a massa incrustada assume a forma de substrato tangível capaz de restringir o fluxo de água e para que a vazão necessária seja entregue, as bombas precisarão consumir mais energia. Portanto é plausível afirmar que, a efetividade de um TC diminui ao longo do tempo e ele se tornará incapaz atender às demandas do processo caso não haja alguma intervenção (Kern, 1983).

Mesmo que os efeitos da sujeira e da incrustação sejam conhecidos, diagnosticar com precisão as condições operacionais ainda é uma tarefa difícil. É possível monitorar a evolução da incrustação nos TC através da medição da diferença de pressão (*Pressure Drop - PD*) entre sua entrada e sua saída, ou seja, a perda de carga hidráulica. Uma série temporal com essa informação pode ser usada para construir um indicador de integridade física do equipamento, com a intenção de proporcionar um melhor gerenciamento do ativo e incorporar a possibilidade de trabalhar com manutenção preditiva (Sansana et al., 2023).

2.2 Aprendizado de máquina

2.2.1 Engenharia de atributos

Extrair características adequadas dos dados brutos de um sistema dinâmico, condicionar e reorganizar a informação para um formato que aumente as chances de gerar e treinar bons modelos de aprendizado de máquina (*Machine Learning - ML*) é um processo chamado de engenharia de atributos. Ferramentas estatísticas, correlações espaciais e temporais, e conhecimentos específicos sobre o processo físico são normalmente utilizadas com esta finalidade. O número de atributos usados em um algoritmo é a dimensão do processo de ML. Ter muitos atributos pode ajudar na detecção de características subjacentes aos dados, mas também pode degradar o desempenho do algoritmo de ML devido à demanda excessiva de recursos computacionais, portanto é preferível usar apenas os que mais contribuam com a solução do problema analisado (Schoen, 2024).

2.2.2 Sensores inferenciais e regressão linear

Uma abordagem de ML usada para avaliar indiretamente a eficiência, a saúde e/ou a segurança de um sistema é o desenvolvimento de sensores inferenciais (*Soft Sensors*), que são funções das variáveis de processo registradas. Essas podem ser relações analíticas derivadas de leis físicas e conhecimentos especializados ou relações empíricas obtidas com técnicas baseadas em dados, servindo para calcular parâmetros que representem outras propriedades ou características do sistema. A implementação de sensores inferenciais em aplicações de detecção e diagnóstico de falhas se torna interessante por conta da sua capacidade de fornecer informações precisas e interpretáveis, proporcionam redução na dimensionalidade do problema e podem ser usados como indicadores operacionais após a sua validação (Hale et al., 2022). A regressão linear é um algoritmo de ML supervisionado e se trata de um método estatístico usado para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes. Ela utiliza uma relação linear entre as variáveis como base e estima seus parâmetros a partir de um determinado conjunto de dados (Schoen, 2024), ela é normalmente obtida com o método dos mínimos quadrados e pode ser aplicada para desenvolver sensores inferenciais de natureza empírica.

2.2.3 Classificação e KNN

O *K-Vizinhos mais Próximos* (*K-Nearest Neighbors - KNN*) é um algoritmo de ML supervisionado não paramétrico que pode fazer classificação ou previsão sobre um ponto de dados, baseado na associação com um grupo de pontos que estão mais próximos dele no espaço de atributos. Sua fundamentação é que objetos semelhantes tendem a possuir atributos semelhantes (Schoen, 2024). Dentre as aplicações do KNN na engenharia destacam-se o monitoramento da condição de equipamentos (detecção de falhas ou identificação de anomalias) e a classificação de estados operacionais com base nas medições das variáveis de processo (Zhao et al., 2019). No contexto da engenharia de manutenção em TC pode-se considerar a efetividade, *NUT*, *Cr* e a perda de carga como os atributos significativos, e usá-los como entradas no algoritmo KNN para classificar os diferentes cenários operacionais.

3. METODOLOGIA

3.1 Estudo de caso: sistema, processo e problema

Nas instalações que compõem o sistema água de resfriamento analisado (Fig. 2) estão presentes dois circuitos hidráulicos integrados entre si por uma malha composta por quatro TC de placas. Um opera em regime de recirculação fechada para a atmosfera (circuito fechado) e o outro com recirculação aberta para a atmosfera (circuito aberto).

Além dos TC, o circuito fechado é constituído por um reservatório de água, quatro conjuntos motobomba, tubulações metálicas, instrumentos de supervisão e controle e ele tem a função de resfriar continuamente os blocos produtivos forno de fusão e piscina de estanho, via abastecimento de água. De acordo com o projeto, a água quente deve retornar da linha de produção a 45°C seguindo para o reservatório. As bombas succionam a água quente, enviando-a para os TC, que devem reduzir a sua temperatura para 40°C antes da sua reentrada. Os níveis de pressão e vazão para a entrada no circuito *top forno* são 5 bar e $450\text{ m}^3/\text{h}$ e para o circuito *top banho* são 5 bar e $740\text{ m}^3/\text{h}$.

O circuito aberto é constituído pelos quatro TC, quatro torres de resfriamento (TR) com reservatórios interligados, cinco conjuntos motobomba, tubulações metálicas, instrumentos de supervisão e controle, e ele tem a função de resfriar a água do circuito fechado. As bombas succionam água do reservatório das TR recalçando-a para os TC, que em seguida retorna aquecida para o seu topo. De acordo com o projeto, para uma vazão de $400\text{ m}^3/\text{h}$ e temperatura de até 40°C na entrada de cada TR ativa, a água deve retornar para os TC na temperatura de até 32°C .

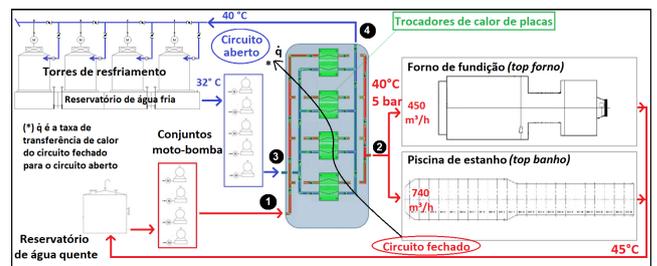


Figura 2. Sistema água de resfriamento: circuitos hidráulicos fechado e aberto (Autoria própria, 2024)

Por conta do regime de produção contínuo, as instalações e o controle supervisão foram projetados para sempre garantir a disponibilidade dos equipamentos necessários em tempo real, dessa forma, enquanto um conjunto capaz de atender a demanda térmica de resfriamento está em operação os remanescentes ficam em modo de espera. Essa prática proporciona intervalos de tempo para a realização de atividades de manutenção sem comprometer a produção e também serve como medida preventiva para um eventual cenário de emergência. Dentre as situações problema conhecidas, as mais recorrentes são: corrosão nas tubulações do circuito fechado, incrustação de sais no circuito aberto e sistema de controle que não consegue garantir a maior eficiência da operação em algumas situações específicas.

3.2 Análise do desempenho operacional

Neste trabalho, as instalações do sistema descrito são tratadas como um aparato experimental e computação eletrônica foi o meio escolhido para sua realização. A implementação dos códigos foi feita com a linguagem *python* no ambiente *google colaboratory*. As bibliotecas utilizadas foram *pandas*, *numpy*, *skfuzzy*, *sklearn* e *matplotlib*.

A condução de análises parte da recuperação das variáveis de processo que são medidas e registrados por um sistema supervisorio (SCADA). A empresa parceira disponibilizou um conjunto de sinais referentes ao período de [2024/03/04 00:00:01] a [2024/03/08 13:50:00]. 17 variáveis diretas aos TC foram identificadas e o pré-processamento delas foi realizado para gerar uma base de dados em formato de série temporal com frequência de 1 s, completando os valores ausentes com interpolação linear e totalizando 393802 sinais em cada variável. Valores anômalos (*outliers*) foram identificados e eliminados usando o algoritmo *floresta de isolamento* considerando uma contaminação na razão 1/2000.

A pressão necessária para conduzir a água através dos TC é chamada de perda de carga total (PD_{TC}) e a redução na efetividade dos TC decorrente do aumento de PD_{TC} é a hipótese explorada. Durante a operação cada TC emite um sinal de diferencial de pressão (PD) nas tubulações do circuito aberto, que é o mais sujeito a incrustações. O processamento dos dados consistiu em calcular o valor de PD_{TC} , gerar uma escala percentual para a perda de carga com relação ao maior valor registrado, identificar quais TC estão em operação com base nos sinais de PD e aplicar a modelagem matemática descrita na seção 2.1 enxergando o conjunto de equipamentos ativos como um só. Além disso, também são atribuídas duas variáveis categóricas para cada sinal: uma referente ao nível de perda de carga da operação dentro de uma faixa percentual, e outra referente ao conjunto de equipamentos que estão ativos no instante.

O aprendizado sobre o sistema consistiu na estruturação de modelos supervisionados. Regressão linear foi usada para relacionar o balanço de energia entre os circuitos e para modelar um sensor inferencial que determina a efetividade em função de PD_{TC} com ajuste logarítmico. O coeficiente de determinação (R^2) das curvas foram usados para qualificar a adequação das regressões em relação aos dados observados. Além disso, um modelo de classificação usando o algoritmo KNN ($K=33$) foi treinado com 3/4 dos dados e sua capacidade de identificar a classe operacional de cada sinal do conjunto de teste foi verificada através das métricas precisão, sensibilidade, índice F1 e acurácia.

4. RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados analíticos derivados das condições operacionais dos 4 TC.

Foi analisada a influência das configurações operacionais sobre a taxa de transferência de calor, o balanço de energia e a efetividade ao longo do tempo (Fig. 3). Nota-se que apenas o sinal PD_{87} apresentou mudanças no período observado (valores oscilando entre -1 e 1) e que isso se refletiu nos parâmetros de desempenho. O caso particular $PD_{87} = -1$ indica a presença de corrente de retorno no TC e caracteriza um escoamento instável dentro da tubulação.

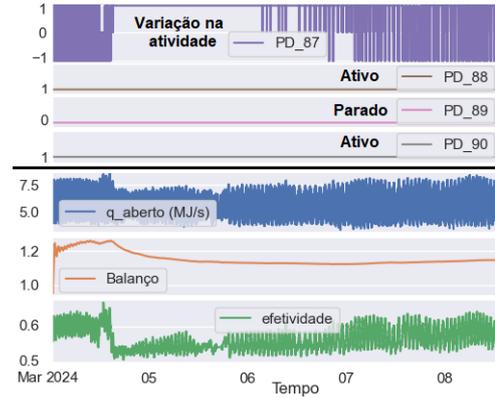


Figura 3. Séries temporais (Autoria própria, 2024)

Para o intervalo de tempo definido, o balanço energético entre os circuitos hidráulicos foi modelado (Fig. 4). A equação da reta obtida com regressão linear aponta uma transferência de calor líquida para o circuito aberto 1.1289 vezes maior, indicando com alta confiabilidade ($R^2 = 0.9997$) a presença de fatores externos aos TC que influenciam significativamente o processo. Essa diferença se reflete na operação das TR que recebem uma carga térmica maior.

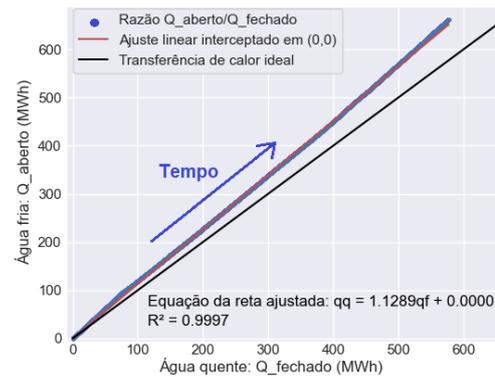


Figura 4. Balanço energético entre os circuitos quente (fechado) e frio (aberto) (Autoria própria, 2024)

Um sensor inferencial que mede a efetividade em função de PD_{TC} foi modelado. A Fig. 5 contém a dispersão entre essas variáveis e a função empírica obtida com $R^2 = 0.8663$. A curva ajustada representa o desempenho médio da operação e define um ponto de partida para uma estratégia de otimização. A distinção em cores refere-se aos níveis percentuais de PD_{TC} e servem para confirmar a hipótese de que a função $\epsilon(PD_{TC})$ é decrescente.

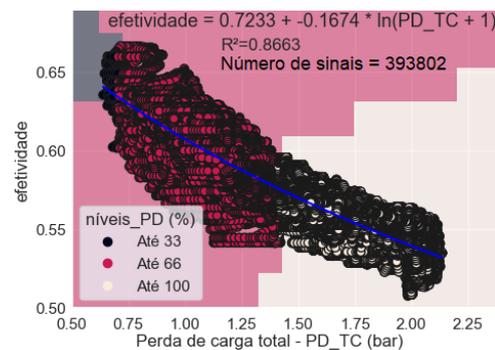


Figura 5. Sensor inferencial para ϵ (Autoria própria, 2024)

Decorrente da variação apenas no sinal de PD_{87} , três classes operacionais foram observadas. A Fig. 6.A também contém a dispersão entre ϵ e PD_{TC} porém, ilustra o conjunto de equipamentos que estão em atividade para cada sinal registrado, já a Fig. 6.B contém a distribuição dos valores de efetividade de cada classe operacional. Por conta da formação de agrupamentos de sinais em cada classe, fica demonstrado a influência que a presença ou ausência dos equipamentos tem sobre o desempenho operacional, facilitando o processo de diagnóstico.

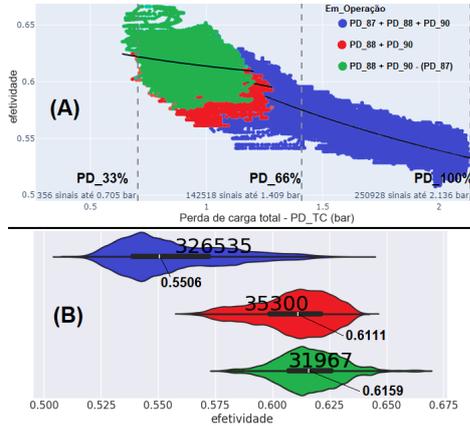


Figura 6. Classes operacionais do sistema e distribuição de frequência da efetividade (Autoria própria, 2024)

Como o agrupamento dos sinais de cada classe é notável o algoritmo KNN foi selecionado para a construção de um modelo de classificação, que foi treinado com 3/4 dos dados. Sobre a qualidade das previsões do modelo, testado com 1/4 dos dados, a Tab. 1 contém as métricas e a Fig. 7 ilustra a matriz de confusão. Em termos globais a acurácia do modelo atingiu 0.9426, o que demonstra a capacidade de classificar corretamente os estados operacionais e reforça a viabilidade desta implementação para melhorar a tomada de decisões sobre atividades de manutenção preditiva.

Tabela 1. Relatório de classificação: métricas (Autoria própria, 2024)

Rótulo	Em Operação	Precisão	Sensibilidade	Índice F1	Suporte
(1)	$PD_{87} + PD_{88} + PD_{90}$	0.9826	0.9845	0.9836	81634
(2)	$PD_{88} + PD_{90}$	0.7153	0.7108	0.7130	8825
(3)	$PD_{88} + PD_{90} - (PD_{87})$	0.7807	0.7703	0.7755	7992
-	Acurácia	-	-	0.9426	98451
-	Média macro	0.8262	0.8219	0.8240	98451
-	Média ponderada	0.9422	0.9426	0.9424	98451

Rótulo verdadeiro	Rótulo previsto		
	(1)	(2)	(3)
(1)	80371 81,64%	980 1,00%	283 0,29%
(2)	1106 1,12%	6273 6,37%	1446 1,47%
(3)	319 0,32%	1517 1,54%	6156 6,25%

Figura 7. Relatório de classificação: matriz de confusão (Autoria própria, 2024)

5. CONCLUSÃO

Os resultados obtidos neste estudo ilustram o potencial que metodologia proposta tem para gerar novas informações e a validam para as atividades de monitoramento e diagnóstico operacional de trocadores de calor.

A transferência de calor significativamente maior no circuito aberto aponta para a necessidade de uma análise detalhada dos fatores externos aos TC. A variabilidade observada no sinal PD_{87} e sua correlação com a instabilidade no escoamento dentro das tubulações são indicadores para a dinâmica operacional não observável. A modelagem do sensor inferencial mostrou-se eficaz, confirmando a relação decrescente entre a efetividade e PD_{TC} . Mesmo sem explorar diferentes valores para K, as previsões do modelo de classificação sobre as três classes operacionais demonstraram boa robustez para uma verificação inicial.

Em trabalhos futuros pretende-se estender a janela de tempo analisada, verificar a influência de outros parâmetros e definir modelos de ML para os outros equipamentos.

AGRADECIMENTOS

Ao LEHNS-PPGEM-UFPB pelo suporte institucional.

REFERÊNCIAS

- Bergman, T.L., Lavine, A.S., Incropera, F.P., and Dewitt, D.P. (2014). *Fundamentos de transferência de calor e de massa*. LTC, Rio de Janeiro, 7° edition.
- Dakwala, M., Mohanty, B., and Bhargava, R. (2014). Simultaneous water and energy conservation through graphical and mathematical programming: a case study for float glass industry. *Journal of Cleaner Production*, 78, 15–34.
- Gomes, H.P. (2021). *Abastecimento de água*. LEHNS/UFPB, João Pessoa.
- Groover, M.P. (2010). *Fundamentals of modern manufacturing: Materials, processes and systems*. John Wiley and Sons, River Street, Hoboken, 4° edition.
- Hale, W.T., Safikou, E., and Bollas, G.M. (2022). Inference of faults through symbolic regression of system data. *Computers and Chemical Engineering*, 157, 107619.
- Kern, D.Q. (1983). *Process Heat Transfer*. McGraw-Hill.
- Kusiak, A. (2018). Smart manufacturing. *International Journal of Production Research*, 56:1(2), 508–517.
- Lemmon, E.W., Bell, I.H., Huber, M.L., and McLinden, M.O. (2023). *Thermophysical Properties of Fluid Systems in NIST Chemistry WebBook: Standard Reference Database Number 69*. NIST, Gaithersburg MD.
- Nilpueng, K., Chomamuang, T., Mesgarpour, M., Mahian, O., and Wongwises, S. (2023). Thermal-hydraulic performance of a plate heat exchanger with grooved copper foam. *Case Studies in Thermal Engineering*, 51, 103525.
- Pellegrino, J.L. (2002). *Energy and environmental profile of the U.S. glass industry*. Energetics Inc., Columbia.
- Sansana, J., Rendall, R., Joswiak, M., Castillo, I., Miller, G., Chiang, L., and Reis, M. (2023). A functional data-driven approach to monitor and analyze equipment degradation in multiproduct batch processes. *Process Safety and Environmental Protection*, 180, 868–882.
- Schoen, M.P. (2024). *Introduction to intelligent systems, control, and machine learning using MATLAB*. Cambridge University Press, United Kingdom.
- Uusitalo, O. (2014). *Float glass innovation in the flat glass industry*. Springer, London.
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., and Gao, R.X. (2019). Deep learning and its applications to machine health monitoring: A survey. *Journal of Manufacturing Systems*, 48, 20–40.