



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE - CAA
NÚCLEO DE TECNOLOGIA
CURSO DE ENGENHARIA DE PRODUÇÃO

SIDNEY MANOEL DA SILVA

**DESENVOLVIMENTO DE FERRAMENTA BASEADA EM REDES NEURAIS PARA
APOIO A DECISÃO NA MANUTENÇÃO DE TROCADORES DE CALOR: Uma
aplicação em refrigeração**

Caruaru

2022

SIDNEY MANOEL DA SILVA

**DESENVOLVIMENTO DE FERRAMENTA BASEADA EM REDES NEURAIS PARA
APOIO A DECISÃO NA MANUTENÇÃO DE TROCADORES DE CALOR: Uma
aplicação em refrigeração**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Bacharel em Engenharia de Produção.

Área de concentração: Pesquisa Operacional.

Orientador: Prof^o. Dr. Thalles Vitelli Garcez

Caruaru

2022

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Silva, Sidney Manoel da.

Desenvolvimento de ferramenta baseada em redes neurais para apoio a
decisão na manutenção de trocadores de calor: Uma aplicação em refrigeração /
Sidney Manoel da Silva. - Caruaru, 2022.

63 p. : il., tab.

Orientador(a): Thalles Vitelli Garcez
Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro Acadêmico do Agreste, Engenharia de Produção, 2022.
Inclui referências, apêndices.

1. Refrigeração. 2. Trocadores de calor. 3. Incrustação. 4. Regressão linear. 5.
Redes neurais artificiais. I. Garcez, Thalles Vitelli. (Orientação). II. Título.

620 CDD (22.ed.)

SIDNEY MANOEL DA SILVA

**DESENVOLVIMENTO DE FERRAMENTA BASEADA EM REDES NEURAIS PARA
APOIO A DECISÃO NA MANUTENÇÃO DE TROCADORES DE CALOR: Uma
aplicação em refrigeração**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Bacharel em Engenharia de Produção.

Aprovado em: 25 de outubro de 2022

BANCA EXAMINADORA

Prof^o. Dr. Thalles Vitelli Garcez (Orientador)
Universidade Federal de Pernambuco - UFPE

Prof^o. Dr. Lucimário Gois de Oliveira Silva (Avaliador)
Universidade Federal de Pernambuco - UFPE

Prof^a. Dr^a. Thárcylla Rebeca Negreiros Clemente (Avaliadora)
Universidade Federal de Pernambuco - UFPE

AGRADECIMENTOS

Agradeço ao meu pai, Antônio Manoel (in memoria) que sempre foi exemplo de um homem digno, trabalhador e que sempre me deu força para lutar por tudo aquilo que acredito. Pai todo o ensinamento que me deu, as profissões e o conhecimento que busquei, nada disso teria acontecido sem você!

Agradeço imensamente a minha mãe Maria José por ser essa mulher guerreira, que até hoje trabalha incansavelmente de domingo a domingo, no intuito de sempre buscar e poder dar melhores condições de vida para os seus filhos, obrigado mãe pelo apoio e dedicação em tudo!

Agradeço a minha irmã e a minha namorada que estiveram sempre presentes quando necessitei e que mesmo nas minhas varias horas de ausência debruçados sobre esse trabalho, me apoiaram em tudo!

Agradeço ao meu orientador, Prof. Dr. Thalles Vitelli Garcez, por todo conhecimento transmitido nas diversas disciplinas lecionadas durante o curso e pela confiança em mim depositada nessa etapa final da graduação.

Aos professores da Universidade Federal de Pernambuco (UFPE), em especial o Prof. Dr. Rodrigo Sampaio Lopes, pela parceria no grupo de pesquisa e pelo apoio nas publicações científicas.

E a todos os que de algum modo puderam contribuir para o meu crescimento pessoal e ou profissional.

RESUMO

Trocadores de calor são componentes indispensáveis na indústria da refrigeração. Nesse contexto, o controle da evolução do processo de incrustação do trocador deve ser buscado, dado que a falta de limpeza provoca ineficiência no processo de resfriamento e perdas energéticas do sistema. Desta forma, a limpeza adequada do trocador pode determinar ou promover ganhos de competitividade na organização. Porém, devido a alta complexidade para se determinar o intervalo de limpeza de um trocador de calor, métodos computacionais de regressão surgem como ferramentas que auxiliam na tomada de decisão. Para tal, o presente trabalho objetiva desenvolver um modelo computacional capaz de identificar de forma indireta a incrustação de um trocador de calor, onde tal modelo sirva como base para a elaboração de uma ferramenta de apoio à decisão. Para isto, dados de um trocador de calor foram coletados e implementados em dois modelos de regressão, sendo um modelo de regressão linear múltipla e um modelo de rede neural. Os resultados do trabalho permitiram concluir que a regressão linear múltipla não foi uma boa preditora para se determinar a incrustação do equipamento. Entretanto, o modelo de rede neural artificial se mostrou aderente ao problema, visto que foi possível se obter mais de 96% de acertos nas previsões utilizando uma rede neural do tipo MLP *Multilayer Perceptron*. A partir dessa constatação, foi possível ainda realizar a implantação desta rede em um sistema de computação em nuvem de modo que técnicos e gestores de manutenção se beneficiem da ferramenta.

Palavras-chave: refrigeração; trocadores de calor; incrustação; regressão linear; redes neurais artificiais.

ABSTRACT

Heat exchangers are indispensable components in the refrigeration industry. In this context, the control of the evolution of the exchanger fouling process must be sought, since the lack of cleaning causes inefficiency in the cooling process and energy losses in the system. In this way, the proper cleaning of the exchanger can determine or promote gains in competitiveness in the organization. However, due to the high complexity to determine the cleaning interval of a heat exchanger, computational regression methods emerge as tools that help in decision making. To this end, the present work aims to develop a computational model capable of indirectly identifying the fouling of a heat exchanger, where this model serves as a basis for the development of a decision support tool. For this, data from a heat exchanger were collected and implemented in two regression models, being a multiple linear regression model and a neural network model. The results of the work allowed us to conclude that the multiple linear regression was not a good predictor to determine the fouling of the equipment. However, the artificial neural network model proved to be adherent to the problem, since it was possible to obtain more than 96% of correct predictions using an MLP Multilayer Perceptron neural network. From this finding, it was still possible to implement this network in a cloud computing system so that technicians and maintenance managers can benefit from the tool.

Keywords: refrigeration; heat exchangers; encrustation; linear regression; artificial neural networks.

LISTA DE FIGURAS

Figura 1 –	Ciclo de refrigeração de Carnot	15
Figura 2 –	Comparação ciclo real x ideal	16
Figura 3 –	Detalhe trocador de calor tipo microcanal	18
Figura 4 –	Configuração do trocador de calor tipo microcanal	19
Figura 5 –	Processo de incrustação	20
Figura 6 –	Bioincrustação de um trocador de calor	21
Figura 7 –	Dispersão de valores	25
Figura 8 –	Quantis	25
Figura 9 –	Escala e locação ajustada	26
Figura 10 –	Distância de Cook's	26
Figura 11 –	Esquema de rede perceptron multicada	27
Figura 12 –	Expositor de auto serviço para acondicionamento de carnes	33
Figura 13 –	Detalhe da unidade condensadora referente ao expositor de carne	33
Figura 14 –	Detalhe do trocador de calor da unidade condensadora	34
Figura 15 –	Limpeza do trocador de calor com jato de alta pressão	35
Figura 16 –	Termômetro penta III full galge	36
Figura 17 –	Pontos de medição da velocidade do ar na face do trocador	36
Figura 18 –	Anemômetro Digital MDA-01 minipa	37
Figura 19 –	Arquitetura da rede MLP	41
Figura 20 –	Construção e configuração do modelo de rede neural	42
Figura 21 –	Vazão do fluido frio Ar (m ³ /s)	43
Figura 22 –	Picos e difusão na tendência	44
Figura 23 –	Comportamento de tendência	44
Figura 24 –	Teste de dinâmica entre as variáveis	45
Figura 25 –	Método setpwise com backward e confirmação de informação de Akaike	46
Figura 26 –	Regressão linear múltipla	47
Figura 27 –	Teste de dinâmica entre as variáveis	48
Figura 28 –	Distribuição dos resíduos	49
Figura 29 –	Normalidade dos resíduos	49

Figura 30 –	Configurações da rede neural	50
Figura 31 –	Estatística de treinamento da rede neural	50
Figura 32 –	Estatística de teste da rede neural	51
Figura 33 –	Tela final do App para consulta do modelo	53
Figura 34 –	Recomendações recebidas com a inserção de alguns valores teste	54

LISTA DE SIGLAS

ADAM	Adaptive Moment Estimation (Estimador de Momento Adaptativo)
AIC	Akaike Information Criteria (Critério de Informação de Akaike)
IOT	Internet Of Things (Internet Das Coisas)
L-BFGS-B	Limited-Memory BFGS
MAE	Mean Absolute Error (Erro Médio Absoluto)
MLP	Multilayer Perceptron
MSE	Mean Squared Error (Erro Quadrático Médio)
NBR	Norma Brasileira
RMSE	Root Mean Squared Error (Raiz Quadrada do Erro Médio)
SGD	Stochastic Gradient Descent (Descida do Gradiente Estocástico)

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Justificativas.....	13
1.2	Objetivo geral.....	14
1.3	Objetivo Específico.....	14
2	FUNDAMENTAÇÃO TEÓRICA.....	15
2.1	O ciclo de refrigeração de carnot.....	15
2.2	Ciclo real de refrigeração por compressão de vapor.....	16
2.3	Trocadores de calor.....	17
2.4	Incrustação de trocadores de calor refrigerados a ar.....	20
2.5	Manutenção em trocadores de calor.....	21
2.6	Modelo de regressão.....	23
2.6.1	Regressão Linear.....	23
2.6.2	Regressão utilizando redes neurais.....	26
2.6.2.1	Número de <i>epochs</i>	27
2.6.2.2	Função de ativação.....	28
2.6.2.3	Número de camadas ocultas.....	29
2.6.2.4	Números de neurônios.....	29
2.6.2.5	Método de otimização.....	29
2.6.2.6	Ajuste de regularização alfa.....	30
2.6.2.7	Avaliação do modelo.....	30
3	METODOLOGIA.....	31
3.1	Classificação da pesquisa.....	31
4	ESTUDO DE CASO.....	32
4.1	Descrição da empresa.....	32
4.2	Características do sistema.....	32
4.3	Obtenção dos dados.....	34
4.4	Estruturação do estudo a partir dos dados.....	40
4.4.1	Análise das variáveis.....	40
4.4.2	Modelo de regressão linear.....	40
4.4.3	Modelo de rede neural.....	41
4.4.3.1	Configuração e treinamento da rede.....	42

4.5	Resultados do estudo.....	43
4.5.1	Resultados da análise das variáveis.....	43
4.5.1.1	Correlação entre as variáveis.....	45
4.5.1.2	Seleção das variáveis.....	45
4.5.2	Resultados da regressão linear.....	46
4.5.2.1	Avaliação da variância e da normalidade dos erros.....	48
4.5.3	Resultados da rede neural (validação e teste)	49
4.5.4	Implantação e consolidação do modelo de rede neural.....	52
5	CONCLUSÃO E TRABALHOS FUTUROS.....	55
5.1	Proposta de trabalhos futuros.....	55
	REFERÊNCIAS.....	57
	APÊNDICE A – CÓDIGO DA REDE NEURAL EM PYTHON.....	61
	APÊNDICE B – CÓDIGO APP ESCRITO EM PYTHON.....	63

1 INTRODUÇÃO

A necessidade de o homem armazenar alimentos perecíveis e climatizar ambientes datam de períodos remotos. Nesta época, as técnicas de produção de frio artificial ainda não eram dominadas pelo homem. Segundo Martins (2018), a necessidade de se produzir gelo artificial surgiu devido à alta demanda do gelo natural (proveniente de lagos e geleiras) que vinha sendo usado e comercializado por volta de 1880 no sul dos estados unidos.

Com o advento da eletricidade, a revolução industrial e os avanços científicos vários sistemas mecânicos capazes de produzir um ciclo de refrigeração contínuo foram desenvolvidos. Segundo Neto, Veloso e Fernandes (2006), os sistemas de refrigeração mais utilizados atualmente em instalações comerciais e industriais operam de acordo com o ciclo de compressão a vapor.

No ciclo de compressão a vapor, para que seja possível o resfriamento, vários componentes são indispensáveis. Souza (2019) estabelece que o trocador de calor desempenha uma função muito importante na refrigeração, sendo este o principal responsável pela troca de calor entre os fluidos a diferentes temperaturas, proporcionando assim o efeito da refrigeração.

Atualmente existem diversos tipos de trocadores de calor para atender aos mais variados tipos de projetos. Ainda segundo Souza (2019), na área de refrigeração e climatização um dos mais difundidos é o trocador feito com tubos e aletas, sendo este adequado para a troca de calor entre um fluido refrigerante e o ar ambiente, caracterizando assim um sistema aberto.

Por ser um sistema aberto e está sempre em contato com o ar ambiente, segundo S. Passos et al. (2021), ocorre então de forma natural a incrustação da superfície do trocador, que é o acúmulo de impurezas nos tubos e aletas do mesmo. Parise e Godke (2018) fala ainda que a camada incrustante possui baixa condutividade térmica, provocando assim a perda de eficiência do sistema acarretando em um aumento no consumo de energia e consequentemente perdas financeiras.

Desta forma, a manutenção do trocador de calor se torna um ponto crucial para o bom desempenho do equipamento, entretanto para se determinar o intervalo de limpeza adequado de um trocador de calor, se faz necessário estimar o coeficiente de transferência de calor do mesmo. Giardini e Tibiriça (2016) fala que vários estudo são

realizados com o intuito de melhorar o desempenho dos trocadores de calor, porém estimar o desempenho térmico de um trocador de calor não é algo trivial.

Meloni e Souza (2019) estabelece que dada a limitação humana em gerenciar determinados processos de manutenção, surgem para suprir tal lacuna novos softwares e sistemas que utilizam conceitos como “machine to machine”, internet das coisas e soluções que concentram informações que auxiliem na tomada de decisão, tais tecnologias permitem uma rápida resposta na antecipação da falha e conseqüentemente um aumento na confiabilidade do equipamento.

Assim sendo, o presente trabalho, visa desenvolver uma ferramenta computacional que auxilie o técnico de manutenção a identificar de forma indireta a incrustação de um trocador de calor de um equipamento de refrigeração, de modo que tal ferramenta contribua nas rotinas de manutenção e na limpeza do equipamento.

1.1 Justificativas

Em visita realizada em diversos empreendimentos da cidade de Caruaru-PE e região, dentre eles shoppings e supermercados, verificou-se a falta de uma rotina adequada de eliminação de sujeiras e incrustações nos trocadores de calor dos equipamentos de refrigeração.

Diante de um cenário extremamente competitivo e marcado de incertezas, a manutenção desempenha um papel fundamental na estratégia organizacional onde, paradas não planejadas em equipamentos prejudicam o desempenho da organização devendo assim a manutenção ser assertiva. (FREITAS, 2018).

Segundo Gaidex (2019), a manutenção e a limpeza nos trocadores de um equipamento de refrigeração são de fundamental importância para a continuidade do processo de transferência de calor, pois tal limpeza evita a incrustação do mesmo.

Requião, Kalid e Soares (2012), estabelece ser um desafio determinar o intervalo de limpeza de um trocador de calor, uma vez que para tal se faz necessário determinar o coeficiente global de troca térmica. Ainda segundo Requião, Kalid e Soares (2012) para se determinar o coeficiente global de troca térmica se faz necessário o uso da reconciliação de dados para fechar o balanço de massa e energia de forma simultânea.

Aroucha, Pereira e Nogueira (2020) elenca outras dificuldades em relação a determinação do coeficiente de transferência de calor, onde as principais dificuldades

estão relacionadas ao tipo do trocador e aos parâmetros geométricos das aletas tais como: Espaçamento entre aletas, altura das aletas, espessura das aletas e entre outros.

Devido à alta complexidade para se determinar o intervalo de manutenção em um trocador de calor, a utilização de ferramentas computacionais para auxiliar na tomada de decisão surge como alternativa. Segundo Lourenço (2010), modelos de aprendizado computacional auxiliam o reconhecimento de padrões e estabelece correlações a fim de determinar o comportamento do sistema.

Desta forma, a manutenção periódica em sistemas de refrigeração com o auxílio de ferramentas computacionais podem trazer diversos benefícios. Segundo Meloni e Souza (2019), o acompanhamento regular de um sistema mecânico minimiza as perdas energéticas desnecessárias, aumenta o lucro e a produtividade da atividade fim, como também prolonga a vida útil do equipamento, reduzindo assim também seu impacto ambiental.

1.2 Objetivo geral

Desenvolver uma ferramenta computacional capaz de identificar de forma indireta a incrustação de um trocador de calor do tipo microcanal, tal ferramenta terá como base uma de rede neural que irá auxiliar na tomada de decisão para a manutenção de um equipamento de refrigeração.

1.3 Objetivo específico

- Descrever a perda de eficiência por incrustação dos trocadores de calor;
- Identificar as principais variáveis correlacionadas a incrustação;
- Realizar levantamento de dados reais em um equipamento de refrigeração;
- Verificar e testar modelos de regressão
- Desenvolver um algoritmo com modelo de aprendizagem computacional;
- Implementar ferramenta com modelo de aprendizagem computacional.

2 FUNDAMENTAÇÃO TEÓRICA

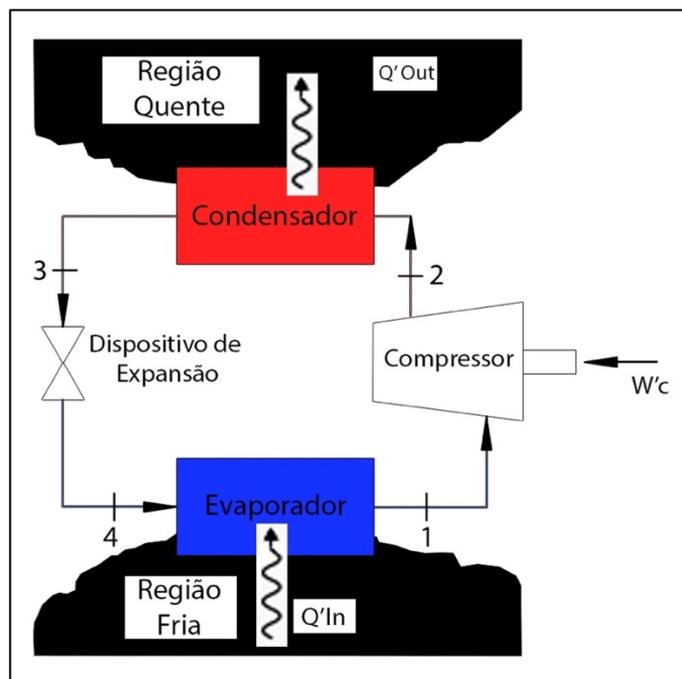
Partindo do princípio da refrigeração, é possível se estabelecer que qualquer fenômeno físico ou químicos de natureza endotérmica (que absorve frio) pode ser aproveitado como método de geração de frio. Entretanto, para que o processo se mantenha se faz necessário que uma série de transformações termodinâmicas ocorram de forma cíclica (CARLESSO; DUTRA; ROSA, 2020).

Segundo Geniêr, Costa e Junior (2013), quando essas transformações termodinâmicas ocorrem de forma cíclica de modo que a transferência de calor ocorra de uma região de baixo potencial energético para uma região de alto potencial energético, dá-se o nome de ciclo de refrigeração.

2.1 O ciclo de refrigeração de carnot

A máquina teórica que opera de acordo com o ciclo de refrigeração de Carnot é composta por quatro processos reversíveis, segundo Meloni e Sousa (2019), e de acordo com a Figura 1, os processos são: 1-2 compressão adiabática, 2-3 rejeição isotérmica de calor, 3-4 expansão adiabática e 4-1 absorção isotérmica de calor.

Figura 1 – Ciclo de refrigeração de Carnot



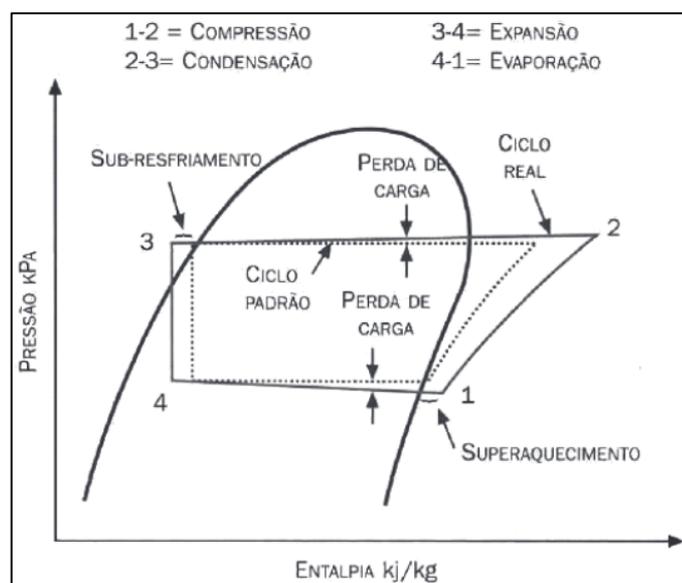
Fonte: Adaptado de Meloni e Souza (2019)

Na prática, o processo termodinâmico do ciclo de Carnot não pode ser implementado de forma factível uma vez que o mesmo é um modelo ideal e possui diversas limitações em aplicação de equipamentos reais. Desta forma, para se implementar o ciclo real de refrigeração utiliza-se o modelo do ciclo por compressão de vapor, que é considerado assim um caso particular do ciclo de Carnot. (CARLESSO; DUTRA; ROSA, 2020).

2.2 Ciclo real de refrigeração por compressão de vapor

De acordo com a Figura 2, o compressor realiza trabalho de forma a elevar a pressão e a temperatura do fluido refrigerante que está em estado de vapor dentro do trocador de calor (condensador), este vapor superaquecido perde temperatura dentro do trocador e, conseqüentemente condensa, o líquido condensado em alta pressão segue em direção ao dispositivo de expansão que se encarregará em expandir o fluido em uma mistura de líquido mais vapor a baixa pressão e baixa temperatura, a mistura em baixa temperatura segue então para o outro trocador de calor (evaporador) que absorve calor do ambiente e transfere para o fluido, fazendo assim o fluido se vaporizar por completo, o vapor então segue para o compressor que inicia o ciclo novamente (CARLESSO; DUTRA; ROSA, 2020).

Figura 2 - Comparação ciclo real x ideal



Fonte: Carlesso, Dutra e Rosa (2020)

Como visto anteriormente alguns componentes são indispensáveis para que o ciclo real de refrigeração por compressão de vapor ocorra, (MENDES, 2012) cita que o ciclo de refrigeração por compressão de vapor deve possuir minimamente um compressor, dois trocadores de calor (condensador e evaporador) e um dispositivo de expansão.

2.3 Trocadores de calor

Os trocadores de calor são componentes que realizam a troca térmica entre os mais diferentes tipos de fluidos, possuem diversas aplicações nos mais variados segmentos do mercado que vão desde processos industriais até refrigeração e climatização (PARISE; GODKE, 2018).

Existem diversos tipos de trocadores de calor. Ferreira (2014) estabelece que os trocadores de calor podem ser classificados como contato direto ou indireto, sendo que nos trocadores de calor de contato direto os fluidos são misturados provocando a transferência de calor e de massa, enquanto que os trocadores de contato indireto os fluidos permanecem separados e o calor é transferido continuamente através de uma parede.

Já Incropera (2008), estabelece que os trocadores de calor podem ser classificados ainda quanto ao arranjo de escoamento e seu tipo construtivo, onde:

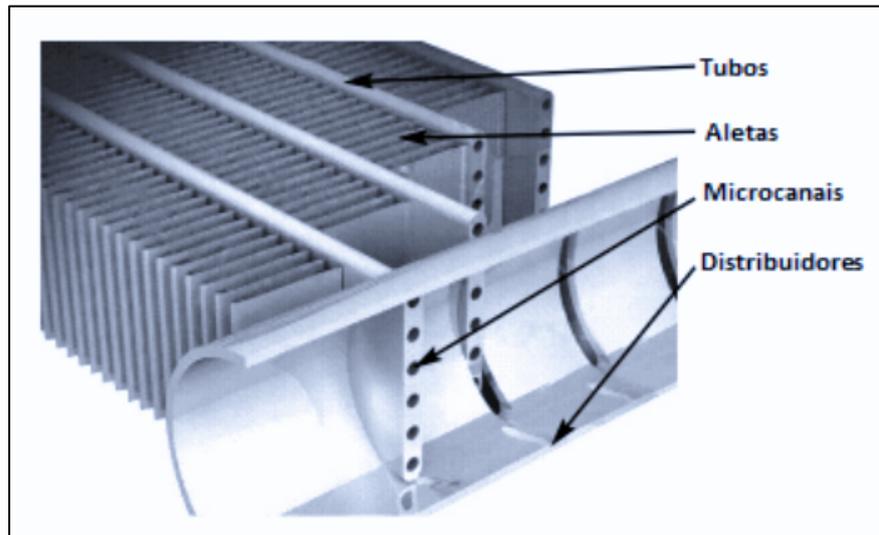
- Segundo a construção: Podem ser classificados como tubulares ou tipo placas.
- Segundo o arranjo de escoamento: Podem ser classificados como correntes paralelas, correntes cruzadas ou contra correntes.

De acordo com Matos (2003), trocadores de calor do tipo tubulares, aletados ou não, são comumente utilizados em sistemas de climatização, refrigeração, aquecedores ou ainda radiadores. Mello e Costa (2014) estabelece que trocadores de calor refrigerados a ar em determinadas situações são mais vantajosos que trocadores refrigerados a água.

Segundo Rametta (2017), um tipo muito difundido de trocador de calor refrigerado a ar é o condensador de microcanal, conforme mostrada na Figura 3,

comumente utilizado em ar condicionados e em radiadores automobilísticos, muito difundido devido a sua alta capacidade de transferência de calor por unidade de volume.

Figura 3 - Detalhe trocador de calor tipo microcanal

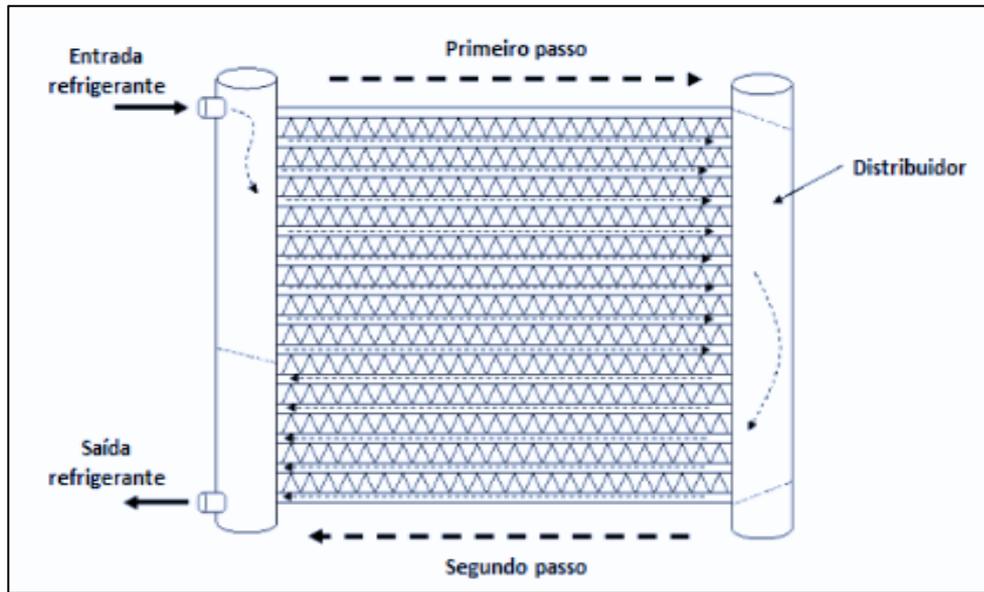


Fonte: Rametta (2017)

Ainda, segundo Rametta (2017), o condensador tipo microcanal pode apresentar diferentes configurações, sendo que a mais comum, conforme mostrado na Figura 4, utiliza uma distribuição onde a serpentina é dividida em dois passos:

- Primeiro passo: Utilizado para dessuperaquecimento e condensação do fluido refrigerante.
- Segundo passo: Utilizada para finalizar a condensação do fluido refrigerante e promover o sub-resfriamento.

Figura 4 - Configuração do trocador de calor tipo microcanal



Fonte: Rametta (2017)

Segundo Martins (2018), a velocidade do ar na face do trocador é dada pela Equação (1), que deduzindo obtém-se a vazão volumétrica do ar Equação (2).

$$v_{f, ar} = \frac{Q_{ar}}{A_f} \quad (1)$$

$$Q_{ar} = v_{f, ar} * A_f \quad (2)$$

Onde:

Q_{ar} é a vazão volumétrica do ar

$V_{f, ar}$ é a velocidade de face do ar

A_f é a área frontal do trocador de calor

Ainda, segundo Martins (2018), a área frontal do trocador pode ser calculada considerando a largura $L1$ e altura $L3$ do trocador conforme Equação (3).

$$A_f = L1 * L3 \quad (3)$$

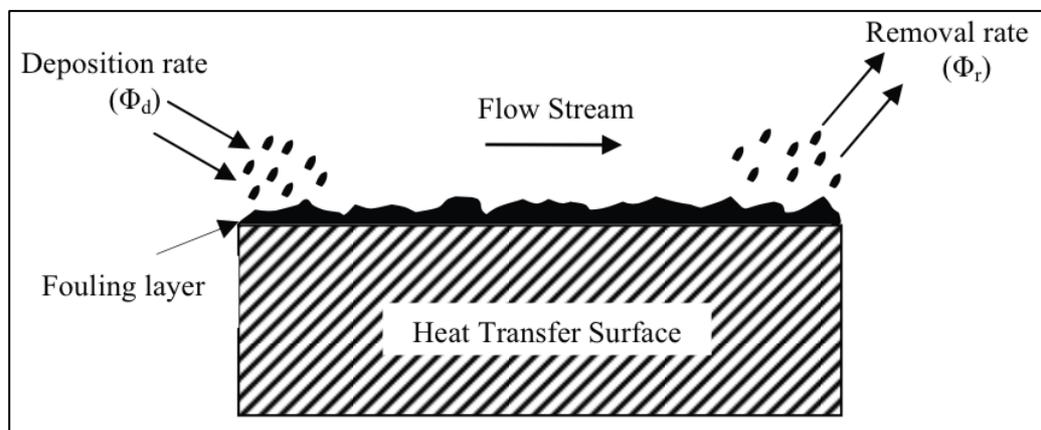
2.4 Incrustação de trocadores de calor refrigerados a ar

De maneira geral o fenômeno da incrustação nada mais é que o acúmulo ou depósito de qualquer tipo de impurezas na superfície onde ocorre a transmissão de calor, aumentando assim de forma significativa a resistência de transferência de calor entre os fluidos e aumentando a resistência de escoamento do fluido com a superfície incrustada, caracterizando assim uma perda de carga do trocador como um todo ao longo do tempo (DOMINGUES, 2019).

Awad (2011) estudou a incrustação de superfícies de transferência de calor de forma geral, tendo identificado assim que os principais agentes de incrustação podem conter materiais inorgânicos, como poeira e areia transportadas pelo ar, lama pela água, bem como materiais orgânicos, como lodo e substâncias biológicas.

Awad (2011) descreve ainda que a incrustação é a diferença entre a taxa de deposição Φ_d e a taxa de remoção Φ_r cuja resultante é um fator de incrustação como demonstrado na Figura 5.

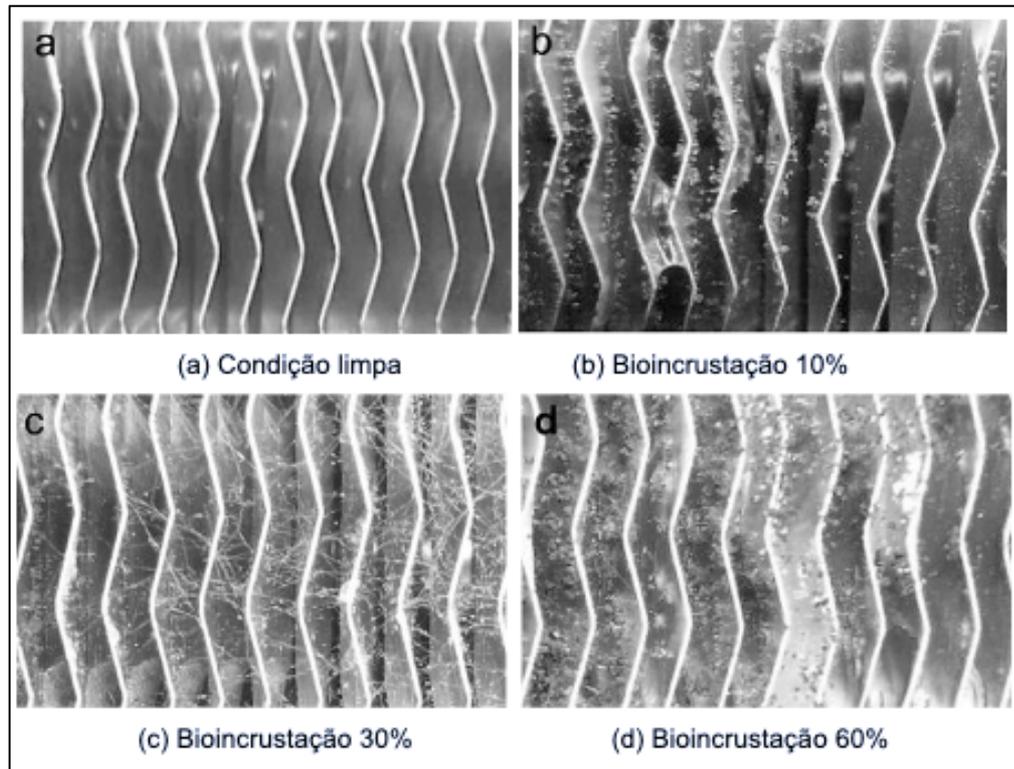
Figura 5 - Processo de incrustação



Fonte: Awad (2011)

Pu et al. (2009) estudou o processo de formação de bioincrustação em trocadores de calor de aletas onduladas do tipo espinha de peixe, onde de acordo com a Figura 6, observou que o coeficiente de transferência de calor em contato com o ar diminuiu 7,2% com uma razão de área de bioincrustação de 10%, chegando a atingir um déficit de 15,9% para uma área de bioincrustação de 60%.

Figura 6 - Bioincrustação de um trocador de calor



Fonte: Pu et al. (2009)

Já Haghghi-Khoshkhoo e McCluskey (2007) descreveu a incrustação provocada pelo ar nos trocadores de calor compactos tipo condensador em veículos industriais. Os mesmos observaram que as partículas são bloqueadas a uma profundidade rasa na frente do trocador, provocando assim o aparecimento de uma tela física de incrustação na frente do mesmo, desviando o fluxo de ar a montante, a qual prejudica significativamente a transferência de calor e consequentemente provocando o superaquecimento do mesmo.

2.5 Manutenção em trocadores de calor

Os trocadores de calor devem ser limpos de forma periódica a depender do seu nível de incrustação, onde a limpeza do mesmo permitirá restaurar a troca térmica entre os fluidos e consequentemente reestabelecer a eficiência do equipamento.

Segundo Awad (2011), em geral as principais técnicas utilizadas para remover os incrustantes das superfícies do trocador de calor podem ser classificadas como: Limpeza Off-Line (onde o equipamento é desligado durante a manutenção) ou limpeza on-line (onde o equipamento permanece ligado durante a manutenção) e ainda ser do

tipo mecânica ou química, sendo que tanto a limpeza mecânica quanto a limpeza química podem ser aplicadas de modo off-line ou on-line.

Ainda, segundo Awad (2011), as principais técnicas de limpeza mecânica e química são:

Limpeza mecânica:

- a) Limpeza manual: Usada em descontaminações macias onde se emprega a lavagem à mão, não sendo muito utilizada devido aos seus custos de mão-de-obra sejam altos.
- b) Limpeza a jato: Comumente utilizada em superfícies com depósitos macios tipo lama, ferrugem solta e biofilmes orgânicos, deve ser aplicada em locais com fácil acessibilidade para passagem do jato de alta pressão, e é bastante utilizada na limpeza de trocadores resfriados a ar com jato de água a uma pressão de 2-4 bar;

Limpeza química:

- a) Circulação: Este método envolve o enchimento do equipamento com solução de limpeza e a circulação por uma bomba. Enquanto a limpeza está em andamento, a concentração e a temperatura da solução são monitoradas.
- b) Limpeza Ácida: As incrustações devido à água de resfriamento são removidas pela circulação de uma solução diluída de ácido clorídrico.
- c) Limpeza de Enchimento e Molho: Neste método, o equipamento é preenchido com uma solução química de limpeza e drenado após um período de tempo. Isso pode ser repetido várias vezes até que resultados satisfatórios sejam alcançados. No entanto, este método é limitado apenas a pequenas unidades.

Ao fim deve-se ter em mente que a limpeza on-line deve ser evitada uma vez que a mesma pode ocasionar acidentes ou curtos elétricos e que os métodos de limpeza química nos trocadores de calor só devam se aplicados quando outros métodos não forem satisfatórios.

Para manutenção dos trocadores de calor, ainda se deve considerar a periodicidade da limpeza dos mesmos, em alguns casos, a limpeza pode ser realizada

durante programas de manutenção como: Manutenção corretiva, detectiva, preventiva, ou preditiva, podendo ainda ser periódica (mensal, trimestral, semestral ou anual) a depender da frequência da limpeza (GAIDEX, 2019).

Deve-se ainda considerar a manutenção de trocadores de calor de acordo com a NBR 13971:2014 que se refere a manutenção programada de sistemas de refrigeração, condicionamento de ar, ventilação e aquecimento.

Contudo, modelos de regressão ainda podem auxiliar a manutenção de tais equipamento, Gut et al. (2004) realizou estudo utilizando regressão para avaliar o fator de atrito do ar nos trocadores de calor.

Maciel et al. (2021), utilizou a regressão para avaliar o desempenho térmico do trocador através do coeficiente global de transferência de calor.

Já Pires, Bastos e Nikel (2015), utilizou o modelo de regressão para avaliar a perda de carga no interior dos tubos de um trocador de calor.

Ou seja, o modelo de regressão aplicado a trocadores de calor já possui diversas contribuições na literatura, com várias aplicações bem consolidadas, a qual podem auxiliar na manutenção do equipamento.

2.6 Modelo de regressão

2.6.1 Regressão linear

A regressão linear pode ser simples ou regressão linear múltipla. Segundo Sell (2005), a regressão linear simples compreende a tentativa de relacionar um conjunto de dados amostrais no intuito descrever a relação entre uma variável dependente e outra independente.

Já a regressão linear múltipla Equação (4), segundo Montgomery (2012), envolve a relação de uma variável dependente y e duas ou mais variáveis independentes X_k ($k=1... n$) onde $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ sejam os parâmetros da relação linear, e $\varepsilon = Y - \hat{Y}$ sendo o erro residual apresentado. Tal abordagem é utilizada com a finalidade de melhorar a predição do modelo partindo da premissa que variáveis extras contenham valores significantes que expliquem melhor a variação dos dados (MATOS, 1995).

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (4)$$

Segundo Chein (2019), em relação as medidas de ajustamento do modelo de regressão linear múltipla temos: Soma total dos quadrados Equação (5), soma dos quadrados explicados pela regressão Equação (6), Soma do quadrado dos resíduos Equação (7), de modo que a soma total dos quadrados em y é a soma das variações explicadas pela regressão mais a variação não explicada Equação (8).

$$STQ = \sum_{i=1}^N (Y_i - \bar{Y})^2 \quad (5)$$

$$SQE = \sum_{i=1}^N (\hat{Y}_i - \bar{Y})^2 \quad (6)$$

$$SQR = \sum_{i=1}^N \hat{\varepsilon}_i^2 \quad (7)$$

$$STQ = SQE + SQR \quad (8)$$

Ainda segundo Chein (2019), o coeficiente de correlação R^2 entre o valor atual e o valor predito Equação (9) pode nunca decrescer quando se adiciona uma nova variável, isso por que a soma do quadrado dos resíduos nunca aumenta, de modo que muitas vezes é mais interessante utilizar o conceito do R^2 ajustado Equação (10) que considera o número de variáveis do modelo e pondera a variação explicada pelos graus de liberdade.

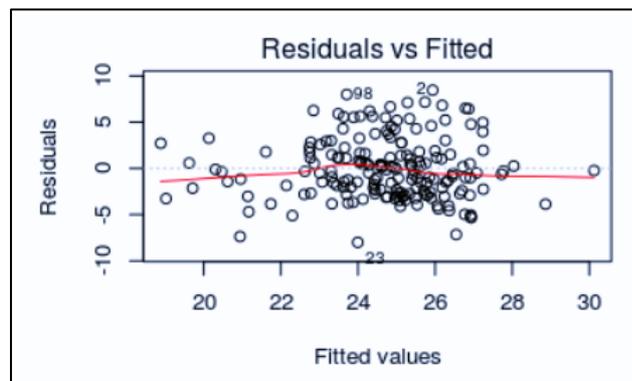
$$R^2 = \frac{(\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{y}))^2}{(\sum_{i=1}^N (y_i - \bar{y})^2)(\sum_{i=1}^N (\hat{y}_i - \bar{y})^2)} \quad (9)$$

$$\bar{R}^2 = 1 - \frac{\frac{SQR}{N - K - 1}}{\frac{STQ}{N - 1}} \quad (10)$$

Grochovski, Santos e Marques (2019) estabelecem que uma das suposições para o modelo de regressão linear seja validado é que os erros tenham distribuição normal, de modo que tais suposições podem ser verificadas através de um dos quatro gráficos a seguir:

- a) Gráfico de dispersão dos valores ajustados x resíduos demonstrado na Figura 7.

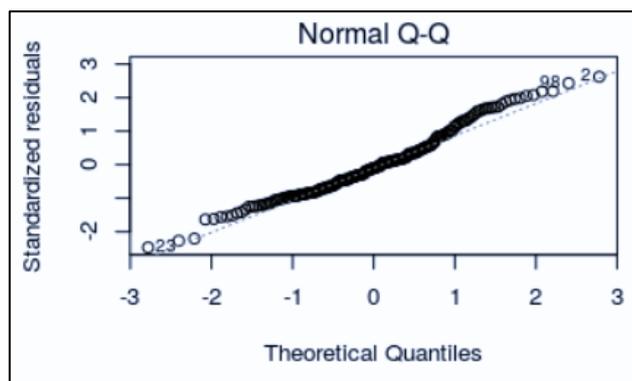
Figura 7 - Dispersão de valores



Fonte: Grochovski, Santos e Marques (2019)

- b) Gráfico Q-Q de quantis teóricos x resíduos padrões demonstrado na Figura 8.

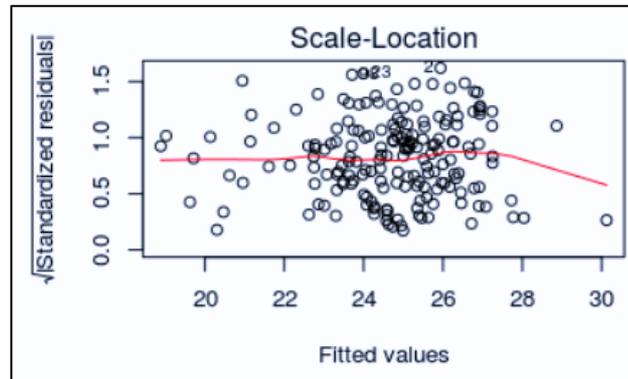
Figura 8 - Quantis



Fonte: Grochovski, Santos e Marques (2019)

- c) Gráfico de escala e locação com valores ajustado x raiz quadrada dos resíduos padrões como demonstrado na Figura 9.

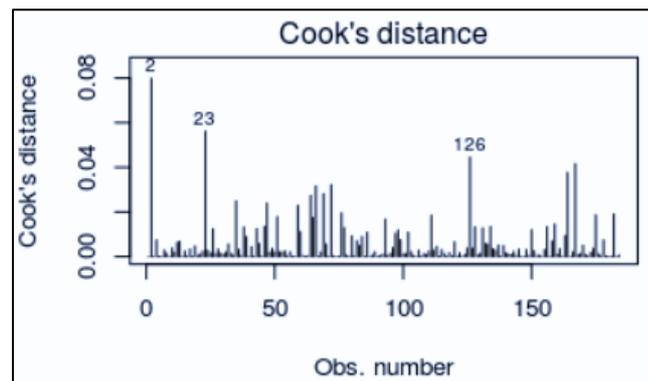
Figura 9 - Escala e locação ajustados



Fonte: Grochovski, Santos e Marques (2019)

d) Gráfico de distância de cook demonstrado na Figura 10.

Figura 10 - Distância de Cook's



Fonte: Grochovski, Santos e Marques (2019)

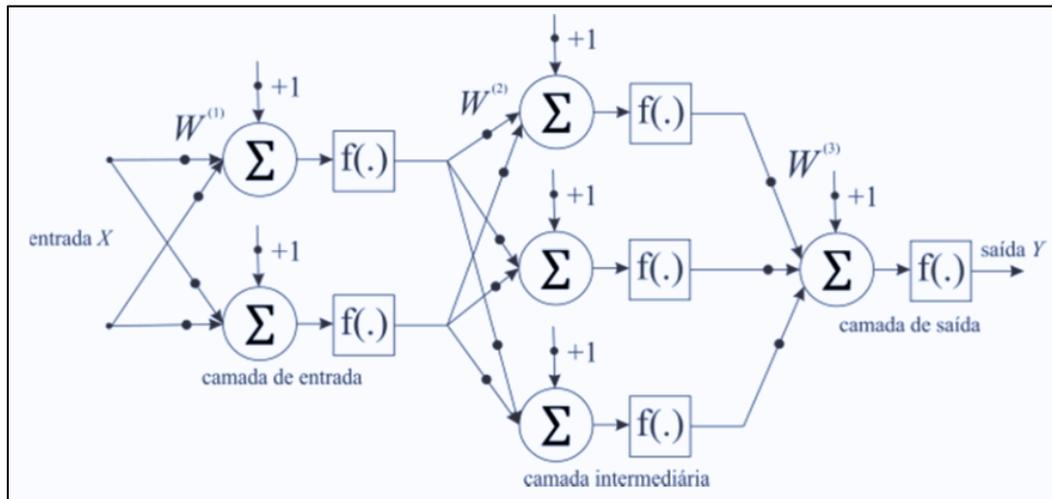
2.6.2 Regressão utilizando redes neurais

As Redes Neurais Artificiais são ferramentas computacionais que possuem modelo matemático inspirado na estrutura biológica do cérebro humano e na maneira como o mesmo realiza suas tarefas. Tal modelo de aprendizagem se dá através de um conjunto bem estruturado de unidade de processamentos denominadas neurônios, que se interligam, absorve e modifica seus parâmetros no intuito de melhorar a aprendizagem e consequentemente o objetivo pretendido (BAPTISTELLA; STEINER; NETO, 2006).

As redes neurais Perceptron de multicamadas fazem parte de um grupo importante de redes neurais muito comum nos métodos de otimização. Segundo Alves, Lotufo e Lopes (2013), as redes Perceptron de multicamadas (conforme

mostrado na Figura 11) são do tipo *feedforward* (não-recursivas), ou seja, o fluxo de dados flui somente na direção da entrada para saída e são compostas ainda por vários neurônios do tipo McCulloch-Pitts onde são dispostos em camadas.

Figura 11 - Esquema de rede perceptron multicada



Fonte: Alves, Lotufo e Lopes (2013)

Segundo Lourenço (2010), o aprendizado da RNA ocorre quando um conjunto de entradas é apresentado para o modelo, de modo que a rede ajusta seus pesos sinápticos para se obter o melhor resultado na saída, para isso é possível realizar o treinamento de duas formas distintas:

- Treinamento Supervisionado: Quando partes dos dados de entrada e saída são apresentadas a rede, nesta modalidade a mesma pode comparar a taxa de acerto reajustando assim os pesos sinápticos.
- Treinamento não supervisionado: O treinamento só é realizado com dados de entrada, de modo o algoritmo modifica os pesos da rede e fornece uma resposta na saída.

2.6.2.1 Número de *epochs*

As *epochs* referem-se ao número de interações que o algoritmo de aprendizado irá realizar, caso seja necessário um grande número de interações pode ocorrer o *overffinting* (quando o modelo se ajusta excessivamente aos dados), de modo que a

técnica de parada antecipada pode ser eficiente em tentar alcançar o valor limite (FARIAS, 2018).

2.6.2.2 Função de ativação

Segundo (RIZZO; CANATO, 2020), as funções de ativação são componentes matemáticos que permitem pequenas alterações na saída da rede em relação as mudanças nos pesos. Existem diversas funções de ativação, as principais são:

- a) Função identidade Equação 11: Utilizada para tarefas simples, uma vez que quando se realiza o *backpropagation*, o gradiente da função permanece o mesmo, ou seja, o resultado de todas as camadas posteriores segue uma transformação linear, o que pode ser um problema, pois com isso o erro não está diminuindo e a rede não está aprendendo.

$$f(x) = ax \quad (11)$$

- b) Função sigmoide Equação 12: Tem característica de ser uma curva suave e não ser linear, com a função variando entre 0 e 1 em formato de S, possui problemas quanto a sua simetria e quando a necessitamos que o valor enviado ao próximo neurônio não seja um valor positivo.

$$f(x) = \frac{1}{(1 + e^{-x})} \quad (12)$$

- c) Função tanh Equação 13: A função tanh é apenas uma versão escalonada da função sigmoide, uma vez que a mesma resolve o problema de simetria variando entre -1 a 1, podendo assim facilmente fazer o *backpropagation*.

$$\tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (13)$$

- a) Função ReLu Equação 14: É a função de ativação mais amplamente utilizada e sua principal vantagem em relação as outras funções é que ela não ativa

todos os neurônios ao mesmo tempo, melhorando assim a eficiência computacional.

$$f(x) = \max(0, x) \quad (14)$$

2.6.2.3 Número de camadas ocultas

O número de camadas ocultas possibilitará que o modelo apresente uma capacidade preditiva adequada, de modo que para problemas complexos o aumento gradual do número de camadas ocultas deve melhorar a acurácia da rede, entretanto, com o número muito grande de camadas pode ocorrer o *overfitting* (FARIAS, 2018).

2.6.2.4 Números de neurônios

O número de neurônios nas camadas de entrada e saída vão depender do tipo de problema e de como foi construída a modelagem, entretanto, a quantidade ideal de neurônios nas camadas ocultas pode variar muito, uma boa prática é iniciar com número maior de camadas e um número menor de neurônios. (FARIAS, 2018)

2.6.2.5 Método de otimização

Para os métodos de otimização alguns métodos podem ser utilizados, de modo que tais algoritmos reduzem o erro de forma gradual até a convergência.

- a) SGD (*Stochastic Gradient Descent*): De acordo com o próprio nome o SGD é um algoritmo baseado no método do gradiente, porém com uma parcela estocástica nas componentes da função de custo (JERONYMO, 2019).
- b) Adam (*adaptive moment estimation*): É um algoritmo baseado no método de AdaGrad, possui média e variância que mudam ao longo do tempo, sendo assim um ótimo algoritmo de otimização baseado na descida do gradiente (BOUZON, 2021).

- c) L-BFGS-B (Limited-memory BFGS): É um algoritmo baseado no método BFGS quasi-Newton de memória limitada para otimizações limitadas por restrição (ZHU; BYRD, 1997).

2.6.2.6 Ajuste de regularização alfa

Atualmente, diversas metodologias são utilizadas para solucionar o problema de *overfitting*, de acordo com Amaral (2021) o coeficiente de regularização alfa limita de forma artificial a correção dos pesos durante a retropropagação, controlando assim o ajuste excessivo do modelo e consequentemente minimizando o *overfitting*,

2.6.2.7 Avaliação do modelo

Para a analisar o desempenho da rede, Júnior (2021) estabelece que algumas métricas podem ser utilizadas na comparação entre os valores previstos e os valores reais, são elas:

- a) MSE (*Mean Squared Error*): Indica o erro quadrático médio ente a série predita e a série real Equação 15.

$$MSE = \frac{1}{N} \sum_{t=1}^N (xt - \tilde{xt})^2 \quad (15)$$

- b) MAE (*Mean Absolute Error*): Indica o erro médio absoluto entre a série predita e a série real Equação 16.

$$MAE = \frac{\sum_{t=1}^N |xt - \tilde{xt}|}{n} \quad (16)$$

- c) RMSE (*Root Mean Squared Error*): Indica a raiz quadrada do erro médio quadrático entre a série predita e a série real Equação 17.

$$RMSE = \sqrt{\sum_{i=1}^N (xt - \tilde{xt})^2} \quad (17)$$

3 METODOLOGIA

Nesta seção será apresentada a sequência metodológica que o trabalho seguiu a fim de atingir os objetivos propostos.

3.1 Classificação da pesquisa

O conhecimento científico advém de diversos procedimentos metodológico a qual permite a busca, a análise, e a interpretação de fatos e fenômenos. Segundo Pitanga (2020), a abordagem qualitativa está relacionada as interações interpessoais dos seus informantes a partir de significações que estes dão aos seus atos, enquanto que a abordagem quantitativa parte da mensuração de variáveis de modo a verificar sua influência sobre outras variáveis e assim estabelecer resultados através de correlações estatísticas.

Dentro da abordagem qualitativa ou quantitativa, Batista e Kumada (2021) descreve ainda que existe uma multiplicidade de maneiras de se realizar a investigação científica, podendo ser a partir dos seus objetivos (como pesquisa exploratória, descritiva ou explicativa) e ou a partir dos procedimentos técnicos utilizados (como por exemplo pesquisa bibliográfica, documental, experimental, estudo de caso, pesquisa ação, pesquisa participante e entre outras).

Desta forma, o presente trabalho refere-se a um procedimento do tipo estudo de caso, realizado em um supermercado na cidade de São Caitano-PE que teve por objetivo uma investigação científica do tipo descritiva a qual detalha a coleta de dados e descreve de forma minuciosa as variáveis mensuradas, se desdobrando assim em uma abordagem quantitativa através da aplicação de métodos estatísticos e computacionais com suas respectivas análises.

4 ESTUDO DE CASO

4.1 Descrição da empresa

O estudo será realizado em uma empresa do setor de supermercados da cidade de São Caitano – PE, tem como principal atividade o comércio de mercadorias em geral com predominância de produtos do gênero alimentício para consumidores tanto no atacado quanto no varejo.

O supermercado em questão possui um parque gerador de frio composto por dois expositores verticais de auto serviço para armazenamento de produtos de rápida circulação sendo um de carnes e outro para acondicionamento de margarinas e iogurtes. Possui ainda uma câmara de auto serviço para armazenamento de bebidas geladas, uma câmara de congelado para armazenamento de carnes para longos períodos, dois balcões expositores para cortes de carnes e dez ilhas de congelados para embutidos.

Todos os equipamentos do sistema em questão funcionam através de quatro unidades condensadoras que removem o calor para o ambiente externo segundo o ciclo de compressão de vapor.

4.2 Características do sistema

Para o estudo em questão serão delimitados os equipamentos pertencentes ao sistema do expositor vertical de carnes, sendo assim composto por:

- Um expositor vertical de auto serviço (com 3 módulos evaporativos), utilizados para acondicionamento de carnes com temperatura de operação entre 1 a 5°C, fabricados pela Eletrofrio (vide Figura 12).

Figura 12 - Expositor de auto serviço para acondicionamento de carnes



Fonte: Autor

- É uma unidade condensadora (vide Figura 13) da fabricante Danfoss modelo OPTYMA™ HJM064D20V, funciona com fluido refrigerante R22 e possui capacidade de refrigeração de 12.860 a 15.360 Kcal/h.

Figura 13 - Detalhe da unidade condensadora referente ao expositor de carne



Fonte: Autor

O estudo referente a incrustação será realizado no trocador de calor detalhado na Figura 14. O mesmo é um trocador do tipo microcanal, possui corrente de escoamento cruzada e fabricação em alumínio.

Figura 14 - Detalhe do trocador de calor da unidade condensadora



Fonte: Autor

4.3 Obtenção dos dados

Para a elaboração de um modelo de incrustação do trocador de calor do estudo em questão, se faz necessário identificar as variáveis que se relacionam ao processo de incrustação. Segundo Pu et al. (2009), à medida que a incrustação no trocador aumenta, ocorre de forma gradativa a obstrução da passagem do fluido e conseqüentemente uma redução na vazão do mesmo. Já Haghghi-Khoshkhou e McCluskey (2007) estabelece que a incrustação cria uma barreira térmica dificultando a troca de calor entre os fluidos, resultando na perda de eficiência do mesmo.

Desta forma, esperar-se que os dados de vazão e temperatura dos fluidos sejam significantes para a implementação de um modelo de incrustação em um

trocador de calor do tipo condensador. Sendo assim, será considerado para este trabalho os dados de temperatura (entrada e saída) do fluido quente (fluido refrigerante R22) e os dados de vazão e temperatura (entrada e saída) do fluido frio (Ar).

Não foram considerados dados de vazão do fluido quente (fluido refrigerante R22) uma vez que o mesmo opera em regime fechado e que sua mudança de fase (de vapor para líquido) dentro do trocador não acarreta em precipitação de sólidos, mantendo assim a pureza do fluido e evitando a incrustação do trocador. Já para o fluido frio (Ar) se fez necessário os dados de vazão pois o mesmo opera em ambiente aberto, o que acarreta o transporte de contaminantes (particulados e microrganismos) para a superfície do trocador de calor, provocando assim o fenômeno da incrustação.

Antes da coleta de dados foi realizada a limpeza mecânica do trocador sob jato de água de alta pressão (vide Figura 15), de forma a eliminar possíveis incrustações e assim preparar o trocador de calor para a coleta de dados.

Figura 15 - Limpeza do trocador de calor com jato alta pressão



Fonte: Autor

Para a leitura das temperaturas, foi utilizado um termômetro modelo penta III five sensors da fabricante full galge com faixa de operação de $-50,0\text{ }^{\circ}\text{C} \sim 105,0\text{ }^{\circ}\text{C}$, precisão $\pm 0,3\%$ e resolução de $0,1\text{ }^{\circ}\text{C}$ (vide Figura 16).

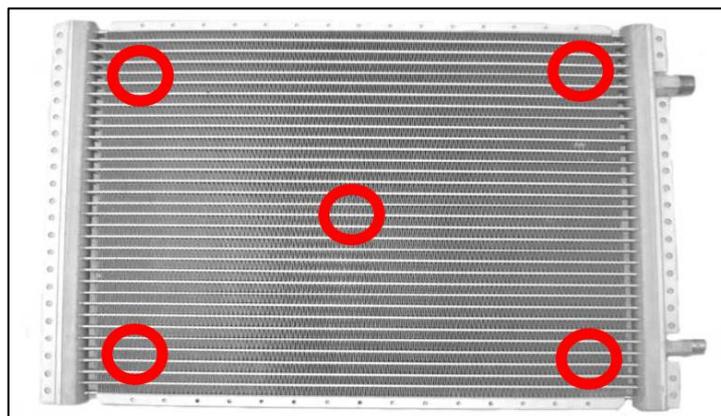
Figura 16 – Termômetro penta III full galge



Fonte: Autor

Os dados de vazão foram calculados a partir da média de velocidade do ar na área frontal do trocador de calor segundo a Equação (2), sendo que a média da velocidade do ar foi calculada a partir das medições em 5 pontos distintos na face do trocador (vide Figura 17), para as medições foi utilizando um anemômetro digital modelo MDA-01 da fabricante minipa com faixa de operação de 1,0 m/s ~30,0 m/s, precisão de $\pm 5\%$ e resolução de 0,1 m/s de acordo com a Figura 18.

Figura 17 – Pontos de medição da velocidade do ar na face do trocador



Fonte: Adaptado Martínez (2009)

Figura 18 – Anemômetro Digital MDA-01 minipa



Fonte: Autor

Os dados foram coletados em momentos onde o equipamento estava operando em plena capacidade e em horários aproximados, a coleta foi realizada no mês de setembro de 2022, com um tempo de observação de 30 dias, onde foi possível obter 30 amostras (uma por dia) e que foram resumidas de acordo com a Tabela 1.

Tabela 1 – Resumo dos dados coletados e calculados

Data	Temp Entr. R22 (°C)	Temp. Saíd. R22 (°C)	Temp. Entr. Ar (°C)	Temp. Saíd. Ar (°C)	Velocid. Ar 1 (m/s)	Velocid. Ar 2 (m/s)	Velocid. Ar 3 (m/s)	Velocid. Ar 4 (m/s)	Velocid. Ar 5 (m/s)	Velocid. Méd (m/s)	Área do Trocad. (m ²)	Vazão (m ³ /s)
01/set	97,15	48,25	42,15	54,25	3,10	2,30	2,30	3,10	3,10	2,78	0,43	1,20
02/set	97,15	48,25	42,15	54,25	3,10	2,30	2,30	3,10	3,10	2,78	0,43	1,19
03/set	97,85	48,85	43,35	58,95	3,10	2,30	2,30	3,10	3,20	2,80	0,43	1,19
04/set	96,75	47,75	42,25	57,85	3,00	2,10	2,20	3,10	3,20	2,72	0,43	1,17
05/set	96,95	48,45	41,85	55,65	2,90	2,10	2,20	2,70	3,20	2,62	0,43	1,13
06/set	98,85	50,35	43,75	57,55	2,90	2,10	2,20	2,60	3,20	2,60	0,43	1,12
07/set	98,25	48,35	41,05	57,75	2,50	2,10	2,60	2,60	3,40	2,64	0,43	1,11
08/set	98,05	49,15	41,85	58,55	2,60	2,10	2,30	2,60	3,20	2,56	0,43	1,10
09/set	98,05	48,55	42,85	55,25	2,80	2,20	2,30	2,60	3,20	2,62	0,43	1,11
10/set	98,30	49,70	43,10	56,50	2,70	2,20	2,30	2,60	3,20	2,60	0,43	1,11
11/set	99,05	49,05	40,65	57,95	2,60	2,00	2,30	2,60	3,30	2,56	0,43	1,10
12/set	97,90	47,90	39,50	56,80	2,60	2,00	2,20	2,60	3,20	2,52	0,43	1,08
13/set	98,65	48,05	42,05	57,15	2,60	2,10	2,20	2,50	3,20	2,52	0,43	1,08
14/set	101,05	50,45	44,45	59,55	2,60	2,10	2,20	2,50	3,20	2,52	0,43	1,08
15/set	103,05	48,45	41,25	57,95	2,60	2,10	2,10	2,60	3,20	2,52	0,43	1,08
16/set	101,70	47,10	39,90	56,60	2,60	2,10	2,00	2,60	3,20	2,50	0,43	1,07
17/set	102,25	49,15	40,65	55,45	3,10	2,20	2,00	2,60	3,20	2,62	0,43	1,07

18/set	102,25	49,15	40,65	55,45	2,80	2,20	2,10	2,60	3,10	2,56	0,43	1,07
19/set	103,00	48,10	42,30	55,60	2,50	2,20	2,10	2,60	3,10	2,50	0,43	1,07
20/set	102,90	48,00	42,20	55,50	2,50	2,20	2,10	2,60	3,10	2,50	0,43	1,07
21/set	104,20	52,50	44,70	61,60	2,70	2,20	2,20	2,60	3,10	2,56	0,43	1,06
22/set	104,70	53,00	45,20	62,10	2,70	2,20	2,20	2,50	3,10	2,54	0,43	1,06
23/set	105,20	51,80	45,40	58,40	2,80	2,20	2,20	2,50	3,10	2,56	0,43	1,06
24/set	106,45	53,05	46,65	59,65	2,80	2,10	2,20	2,50	3,10	2,54	0,43	1,06
25/set	105,70	53,10	45,10	63,10	2,80	2,10	2,10	2,50	3,10	2,52	0,43	1,05
26/set	102,90	50,30	42,30	60,30	2,80	2,10	2,00	2,50	3,10	2,50	0,43	1,05
27/set	102,35	49,45	42,65	56,05	2,80	2,10	2,00	2,40	3,00	2,46	0,43	1,05
28/set	102,95	50,05	43,25	56,65	2,70	2,10	2,00	2,20	3,00	2,40	0,43	1,03
29/set	104,50	51,40	43,80	61,80	2,70	2,00	2,00	2,20	2,90	2,36	0,43	1,01
30/set	104,35	51,25	43,65	61,65	2,60	1,90	1,90	2,00	2,80	2,24	0,43	1,01

Fonte: Autor

4.4 Estruturação do estudo a partir dos dados

Pretende-se elaborar a partir desse estudo um modelo de regressão ao qual identifique de forma eficiente os níveis de vazão do fluido frio do trocador de calor, onde de posse dos dados será possível identificar a incrustação do trocador através de variáveis correlacionadas, auxiliando assim a tomada de decisão para técnicos e gestores de manutenção.

4.4.1 Análise das variáveis

De forma a identificar as variáveis que se correlacionam com a incrustação do trocador, de principio será realizada uma análise exploratória dos dados a qual possibilitará identificar algumas características sobre as variáveis e a correlação entre elas, em seguida será implementado um método de seleção de variáveis.

Segundo Alves, Lotufo e Lops (2013), é possível se obter um conjunto de variáveis representativas utilizando método de seleção de variáveis *stepwise*, de modo que o método verifica de forma interativa a influencia das variáveis de entrada em relação a variável de saída, podendo assim o método adicionar variáveis (passo *forward*) ou remove variáveis (passo *backward*) a partir de um critério de seleção.

Ainda, segundo Alves, Lotufo e Lops (2013), o método *setpwise* pode utilizar alguns critérios de seleção, como por exemplo: Teste F, coeficiente de correlação linear múltipla, erro quadrático total ou ainda o critério de informação de Akaike AIC (*Akaike Inforrmation Criteria*).

Para o modelo em questão, será utilizado o método *setpwise*, com passo *backward* (removendo variáveis) e critério de informação de Akaike de acordo com a Equação 18.

$$AIC = -2 \ln L(q | y) + 2K \quad (18)$$

4.4.2 Modelo de regressão linear

Para a construção do modelo de regressão linear múltipla foi utilizado o software R de modo que as variáveis de entrada foram obtidas através do método de seleção de variáveis *setpwise*, seguidamente foi realizado a regressão com o intuito

de se verificar os estimadores da reta de regressão e conseqüentemente realizar uma avaliação do ajuste do R^2 .

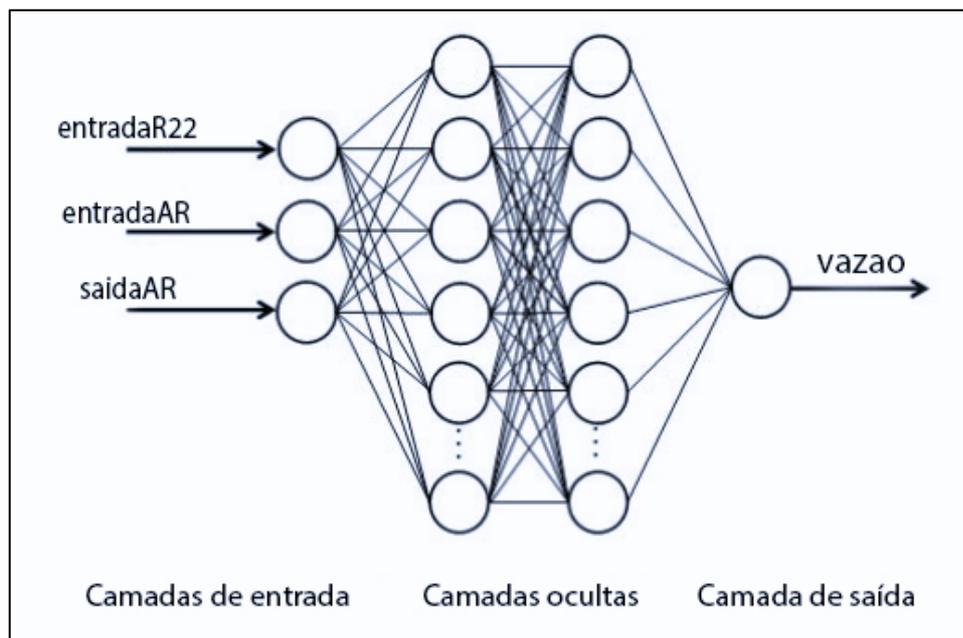
Foram ainda realizadas novas regressões com diversas combinações de variáveis no intuito de se verificar o ajuste do modelo de regressão e a robustez do método *stepwise* em relação a eliminação de variáveis.

Ao fim, foi realizado o teste anova no intuito de se verificar a correlação entre as variáveis e uma análise sobre a normalidade através dos gráficos de dispersão e normalidade dos resíduos.

4.4.3 Modelo de rede neural

As redes neurais fazem parte de uma classe importante dos métodos de otimização, para construção do modelo em questão (vide Figura 19) utilizou-se uma rede neural com estrutura de regressão do tipo MLP (*Multilayer Perceptron*) de modo que as variáveis de entrada foram as mesmas obtidas a partir do método *stepwise* que se mostrou bastante robusto, espera-se também que a rede neural consiga se ajustar melhor ao comportamento das variáveis que possuem maior difusão nas tendências.

Figura 19 - Arquitetura da rede MLP



Fonte: Autor

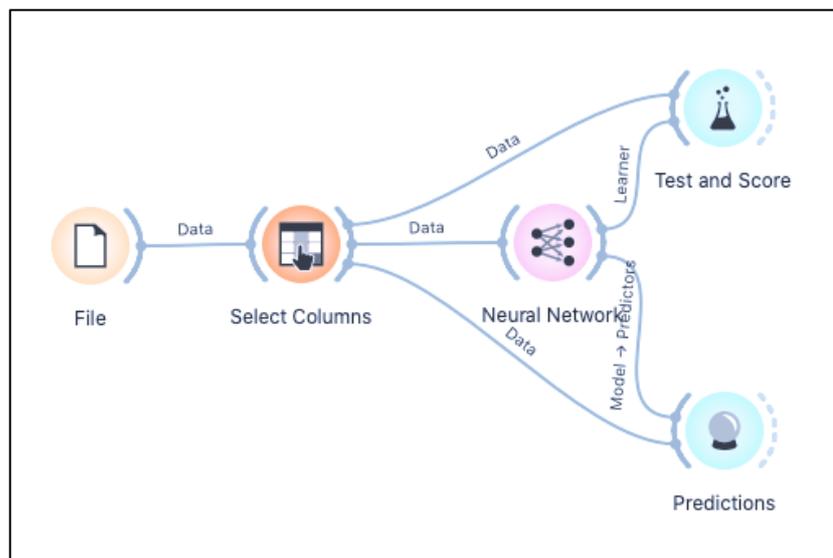
4.4.3.1 Configuração e treinamento da rede

Seguindo a elaboração utilizou-se o software Orange Data Mining, conforme mostrado na Figura 20, para a construção, configuração e treinamento da rede, onde foi possível de forma exaustiva simular a interação entre todas as seguintes configurações:

1. Implementação de uma e duas camadas ocultas variando entre 5 a 100 neurônios ocultos por camada;
2. Interação dos diversos algoritmos de treinamento (L-BFGS-B, GSD, Adam);
3. Ajustes no valor de regularização alfa entre 0,0001 a 5;
4. Interações no algoritmo da função de ativação da camada de saída (Relu, tanh, Logistic, Identity).

Realizou-se ainda simulações afim de se verificar o número máximo de iterações da rede, prevenindo assim que ocorra *overfitting* ou *underfitting*, que é quando ocorre o ajuste excessivo da rede ou a falta de ajuste prejudicando o modelo.

Figura 20 – Construção e configuração do modelo de rede neural



Fonte: Autor

Para o treinamento da rede, o conjunto de dados foi dividido em dados de treino e dados de teste, sendo utilizado 75% do conjunto de dados para treino e 25% dos

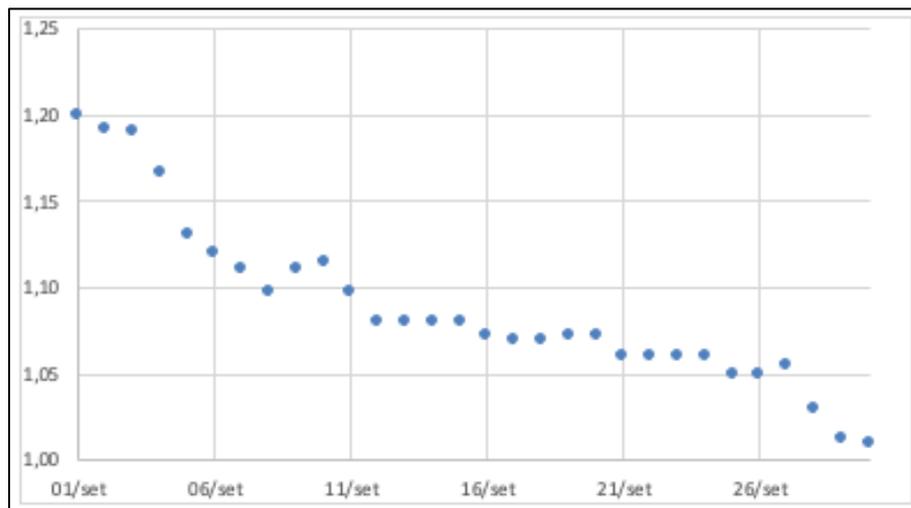
dados para teste, de modo que o treino e o teste foram realizados com 10 repetições para ambos os casos.

4.5 Resultados do estudo

4.5.1 Resultados da análise das variáveis

Realizando uma análise preliminar dos dados foi possível verificar no lado do fluido frio que a vazão do ar diminui ao longo do tempo, conforme mostrado na Figura 21, o que nos leva a considerar que a secção de área por onde o ar passa está ficando cada vez menor, ou seja, o trocador está ficando cada vez mais incrustado e perdendo eficiência ao longo do tempo.

Figura 21 - Vazão do fluido frio Ar (m³/s)



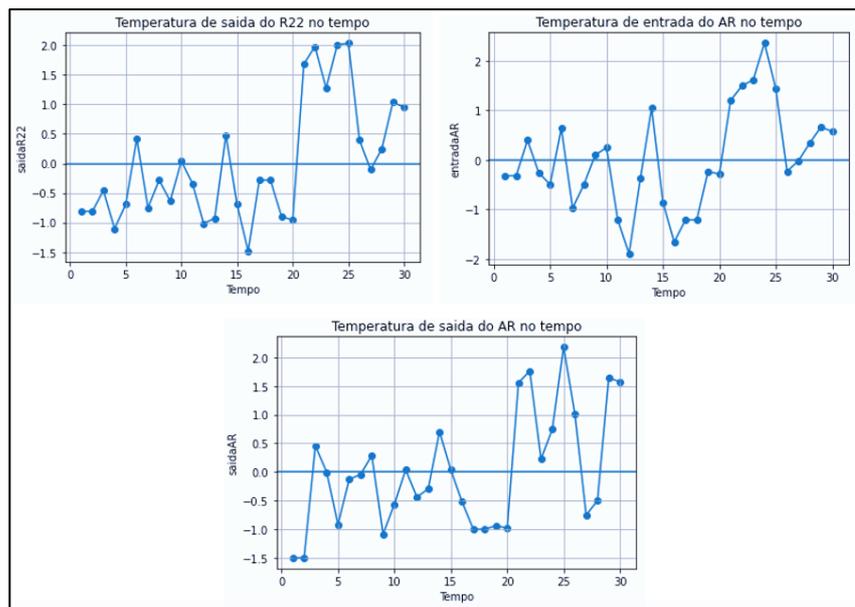
Fonte: Autor

Para uma comparação justa entre as variáveis, realizou-se a normalização das mesmas segundo a Equação (19), uma vez que os dados de vazão possuem valores muito pequenos se comparado aos dados de temperatura e que tal discrepância poderia induzir a erros de avaliações.

$$X_{norm} = \frac{2(X - X_{mín})}{(X_{máx} - X_{mín})} - 1 \quad (19)$$

Após a normalização das variáveis e explorando o comportamento das temperaturas e da vazão ao longo do tempo (em dias) foi possível verificar na Figura 22 que a saída do fluido refrigerante R22 no trocador, a temperatura de entrada do ar e a temperatura de saída do ar do trocador, demonstram muitos picos e não seguem uma tendência de forma clara.

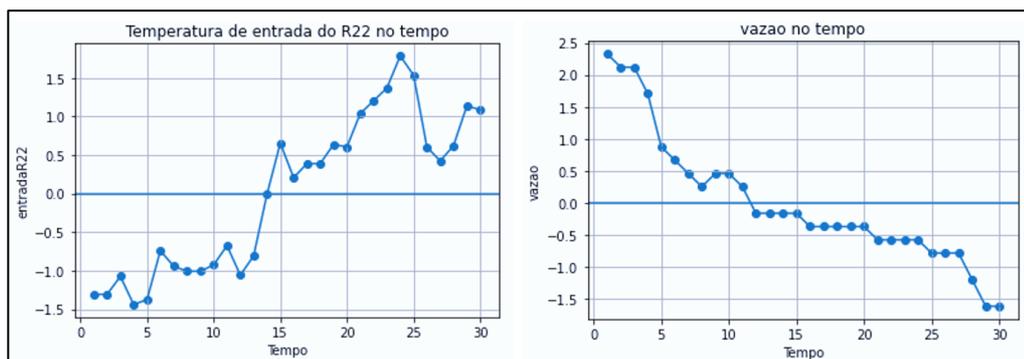
Figura 22 - Picos e difusidade na tendência



Fonte: Autor

Já a temperatura de entrada do fluido refrigerante R22 no trocador e a vazão do fluxo de ar que passa no trocador descrevem um comportamento mais linear conforme mostrado na Figura 23, o que sugere que um modelo de regressão linear possa ser aplicado.

Figura 23 - Comportamento de tendência



Fonte: Autor

4.5.1.1 Correlação entre as variáveis

Realizando o teste de correlação com auxílio do software R Studio foi possível verificar uma correlação negativa da variável vazão em relação as demais (vide Figura 24), isso demonstra que a medida com que a vazão diminui, as variáveis de temperatura aumentam, mais uma vez confirmando que a medida com que a incrustação aumenta o trocador perde a eficiência.

Figura 24 - Teste de correlação entre as variáveis

```
> cor(trocador)
```

	entradaR22	saidaR22	entradaAR	saidaAR	vazao
entradaR22	1.0000000	0.7165320	0.5382330	0.5694221	-0.8040911
saidaR22	0.7165320	1.0000000	0.8456474	0.7822761	-0.5040797
entradaAR	0.5382330	0.8456474	1.0000000	0.5975859	-0.2301122
saidaAR	0.5694221	0.7822761	0.5975859	1.0000000	-0.4891874
vazao	-0.8040911	-0.5040797	-0.2301122	-0.4891874	1.0000000

Fonte: Autor

4.5.1.2 Seleção das variáveis

Definindo a vazão como variável de interesse e utilizando o software R Studio foi possível implementar o método *stepwise*, de forma interativa partindo do maior número de variáveis para um menor número de variáveis (passo *backward*), onde de acordo com a Figura 25 é possível verificar que à medida que o valor de AIC diminui o método remove uma variável, ao fim é possível observar que as variáveis: vazão, entradaR22, entradaAR, saidaAR foram as variáveis escolhidas pelo método.

Figura 25 - Método *stepwise* com *backward* e critério de informação de Akaike

```

> #Backward
> step(full, direction = "backward", trace=TRUE)
Start: AIC=-211.47
vazao ~ entradaR22 + saidaR22 + entradaAR + saidaAR

      Df Sum of Sq    RSS    AIC
- saidaR22  1 0.0002417 0.018905 -213.09
- saidaAR   1 0.0005860 0.019249 -212.54
<none>                                0.018663 -211.47
- entradaAR 1 0.0038032 0.022467 -207.91
- entradaR22 1 0.0232968 0.041960 -189.17

Step: AIC=-213.09
vazao ~ entradaR22 + entradaAR + saidaAR

      Df Sum of Sq    RSS    AIC
<none>                                0.018905 -213.09
- saidaAR  1 0.001634 0.020539 -212.60
- entradaAR 1 0.005551 0.024456 -207.36
- entradaR22 1 0.033530 0.052435 -184.48

Call:
lm(formula = vazao ~ entradaR22 + entradaAR + saidaAR, data = cod)

```

Fonte: Autor

4.5.2 Resultados da regressão linear

Ainda, utilizando o R Studio e a partir das variáveis definidas pelo método de *stepwise*, foi realizado a implementação do modelo de regressão linear múltipla onde, de acordo com a Figura 26, o modelo é estatisticamente significativo ($p\text{-value} < 0,05$), sendo que para decidirmos o melhor modelo devemos ainda considerar que nos modelo regressão linear múltipla o R^2 sofre influência da adição de variáveis, para isso o melhor estimador é o R^2 ajustado, a qual verifica-se um R^2 ajustado de 0.6965, conferindo assim uma acurácia um pouco baixa para o modelo.

Figura 26 - Regressão linear múltipla

```

> reg1 <- lm (vazao ~ entradaR22+entradaAR+saidaAR)
> summary(reg1)

Call:
lm(formula = vazao ~ entradaR22 + entradaAR + saidaAR)

Residuals:
    Min       1Q   Median       3Q      Max
-0.042431 -0.022862  0.003588  0.014048  0.053650

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.308254    0.171466  13.462 3.15e-13 ***
entradaR22  -0.014182    0.002088  -6.791 3.31e-07 ***
entradaAR    0.010576    0.003828   2.763  0.0104 *
saidaAR     -0.004116    0.002746  -1.499  0.1459
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.02697 on 26 degrees of freedom
Multiple R-squared:  0.7279,    Adjusted R-squared:  0.6965
F-statistic: 23.19 on 3 and 26 DF,  p-value: 1.621e-07

```

Fonte: Autor

Após a implementação do modelo de regressão linear múltipla se obteve a seguinte expressão para reta de regressão Equação (20)

$$vazao = -0,014182 * entradaR22 + 0,010576 * entradaAr - 0,004116 * saidaAr \quad (20)$$

Como foi identificada, uma baixa acurácia do modelo realizou-se algumas experimentações extras com combinações distintas das variáveis no intuito de investigar se o método *stepwise* realmente encontrou uma boa combinação de variáveis, onde de acordo com a Tabela 2 após os ensaios observou-se que todos os modelos foram estatisticamente significantes ($p\text{-value} < 0,05$), porém o R^2 ajustado para todos os demais modelos foram menores que os resultados encontrados utilizando o método *stepwise*, comprovando assim a robustez do método.

Tabela 2 – Variáveis utilizadas no modelo de regressão

Vaiáveis	p-value	R2	R2 ajustado
Vazão~entradaR22	8.669e-08	0.6466	0.6339
Vazão~entradaR22 + saidaR22	5.277e-07	0.6572	0.6318
Vazão~entradaR22 + saidaR22 + saidaAr	1.479e-06	0.6766	0.6393
Vazão~entradaR22 + saidaR22 + saidaAr + entradaAR	7.418e-07	0.7314	0.6884

Fonte: Autor

4.5.2.1 Avaliação da variância e da normalidade dos erros

Realizando ainda mais alguns testes para avaliar melhor o modelo foi possível observar na Figura 27 que existe um efeito significativo das variáveis (entradaR22 e entradaAR) sobre a variável (vazão), e que a variável (saidaAr) não possui um efeito tão significativo sobre a variável (vazão) quanto as outras variáveis.

Figura 27 – Teste de correlação entre as variáveis

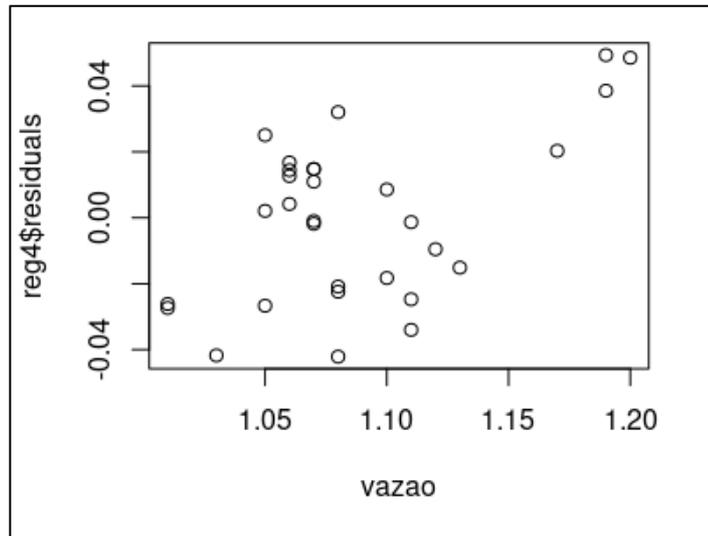
```
> anova(lm(vazao ~ entradaR22+entradaAR+saidaAR))
Analysis of Variance Table

Response: vazao
      Df Sum Sq Mean Sq F value Pr(>F)
entradaR22  1 0.044923 0.044923 61.7823 2.458e-08 ***
entradaAR   1 0.004018 0.004018  5.5260  0.0266 *
saidaAR     1 0.001634 0.001634  2.2467  0.1459
Residuals  26 0.018905 0.000727
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Fonte: Autor

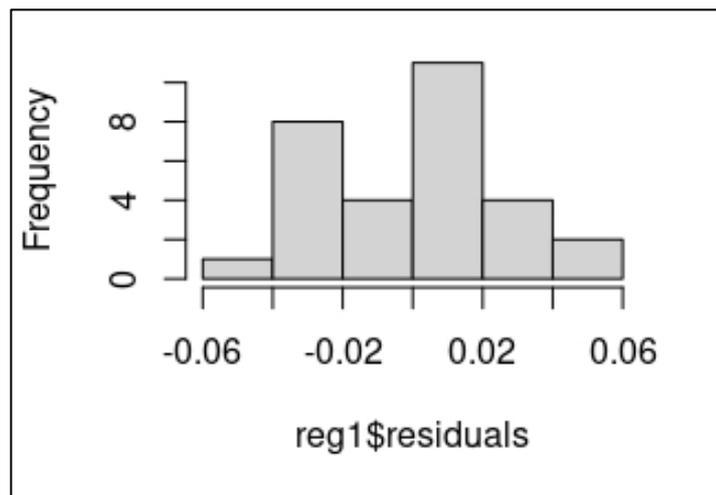
Já avaliando os resíduos observa-se que os mesmos não possuem uma boa distribuição aleatória entorno do zero (vide Figura 28) e conseqüentemente demonstram assim que os resíduos não tenham um bom ajuste para uma distribuição normal como pode ser observado na Figura 29.

Figura 28 – Distribuição dos resíduos



Fonte: Autor

Figura 29 – Normalidade dos resíduos



Fonte: Autor

Como pode ser observado o modelo de regressão linear múltipla não obteve resultado expressivos, o que nos leva a considerar que a implementação de algum outro modelo mais robusto seja necessária.

4.5.3 Resultados da rede neural (validação e teste)

Utilizando o software Orange, foi possível realizar várias simulações para validar o modelo, foram testadas diversas combinações utilizando os principais

parâmetros da rede, sempre com o intuito de avaliar o aumento ou a diminuição dos erros.

Ao fim, foi possível verificar que o melhor ajuste foi obtido utilizando uma única camada oculta com 50 neurônios, um algoritmo de treinamento do tipo L-BFGS-B com ajuste de regularização $\alpha=0,04$, com a função de ativação da camada de saída ReLu e com o número máximo de interações de 34. De modo que tais configurações podem ser observadas na figura 30.

Figura 30 - Configurações da rede neural

Fonte: Autor

Como resultado de treinamento, observa-se na Figura 31 que os erros do modelo são extremamente baixos e que a raiz quadrada do erro médio RMSE (*Root Mean Squared Error*) é pouco maior que o erro médio absoluto MAE (*Mean Absolute Error*) o que demonstra que os *outliers* são pouco representativos.

Figura 31 – Estatística de treinamento da rede neural

Model	MSE	RMSE	MAE
Neural Network	0.001	0.024	0.019

Fonte: Autor

Agora, verificando o resultado para as predições, conforme mostrado na Figura 32, observa-se um bom ajuste com R^2 de 0,74 a qual é possível observar ainda que

os erros da predição são exatamente iguais ou levemente maiores que o erros obtidos no treinamento, isso demonstra que o modelo foi bem treinado e que não sofre problemas com *overfitting*, um vez que é esperado um leve aumento dos erros ao generalizar o modelo para novos dados.

Figura 32 - Estatística de teste da rede neural

Data & Predictions					
	Neural Network	vazao	entradaR22	saidaR22	saidaAR
1	1.15	1.20	97.15	48.25	54.25
2	1.15	1.19	97.15	48.25	54.25
3	1.13	1.19	97.85	48.85	58.95
4	1.15	1.17	96.75	47.75	57.85
5	1.15	1.13	96.95	48.45	55.65
6	1.12	1.12	98.85	50.35	57.55
7	1.12	1.11	98.25	48.35	57.75
8	1.13	1.10	98.05	49.15	58.55
9	1.13	1.11	98.05	48.55	55.25
10	1.13	1.11	98.30	49.70	56.50
11	1.10	1.10	99.05	49.05	57.95
12	1.12	1.08	97.90	47.90	56.80
13	1.11	1.08	98.65	48.05	57.15
14	1.07	1.08	101.05	50.45	59.55
15	1.04	1.08	103.05	48.45	57.95
16	1.06	1.07	101.70	47.10	56.60
17	1.07	1.07	102.25	49.15	55.45
18	1.07	1.07	102.25	49.15	55.45
19	1.06	1.07	103.00	48.10	55.60
20	1.06	1.07	102.90	48.00	55.50
21	1.06	1.06	104.20	52.50	61.60
22	1.06	1.06	104.70	53.00	62.10
23	1.04	1.06	105.20	51.80	58.40
24	1.05	1.06	106.45	53.05	59.65
25	1.06	1.05	105.70	53.10	63.10
26	1.04	1.05	102.90	50.30	60.30
27	1.07	1.05	102.35	49.45	56.05
28	1.06	1.03	102.95	50.05	56.65
29	1.04	1.01	104.50	51.40	61.80
30	1.04	1.01	104.35	51.25	61.65

Scores				
Model	MSE	RMSE	MAE	R2
Neural Network	0.001	0.025	0.019	0.740

Fonte: Autor

Como a rede neural teve um desempenho levemente maior que a regressão linear, justifica-se a implementação do modelo de rede neural para auxílio na tomada de decisão.

4.5.4 Implantação e consolidação do modelo de rede neural

Com a rede neural treinada foi possível salvar o modelo e verificar assim todos os parâmetros que o Orange usou para ajustar a rede, de posse dessa informação torna-se simples a construção de novas redes em outras plataformas e ambientes de desenvolvimento, uma vez que o modelo já está validado.

Para pôr em prática o modelo do Orange, foi desenvolvido um *script* em linguagem Python onde foi implementada uma rede neural *multilayer perceptron* com os mesmos ajustes obtidos no Orange, ao fim a rede foi treinada e exportada como modelo em formato (.pkl).

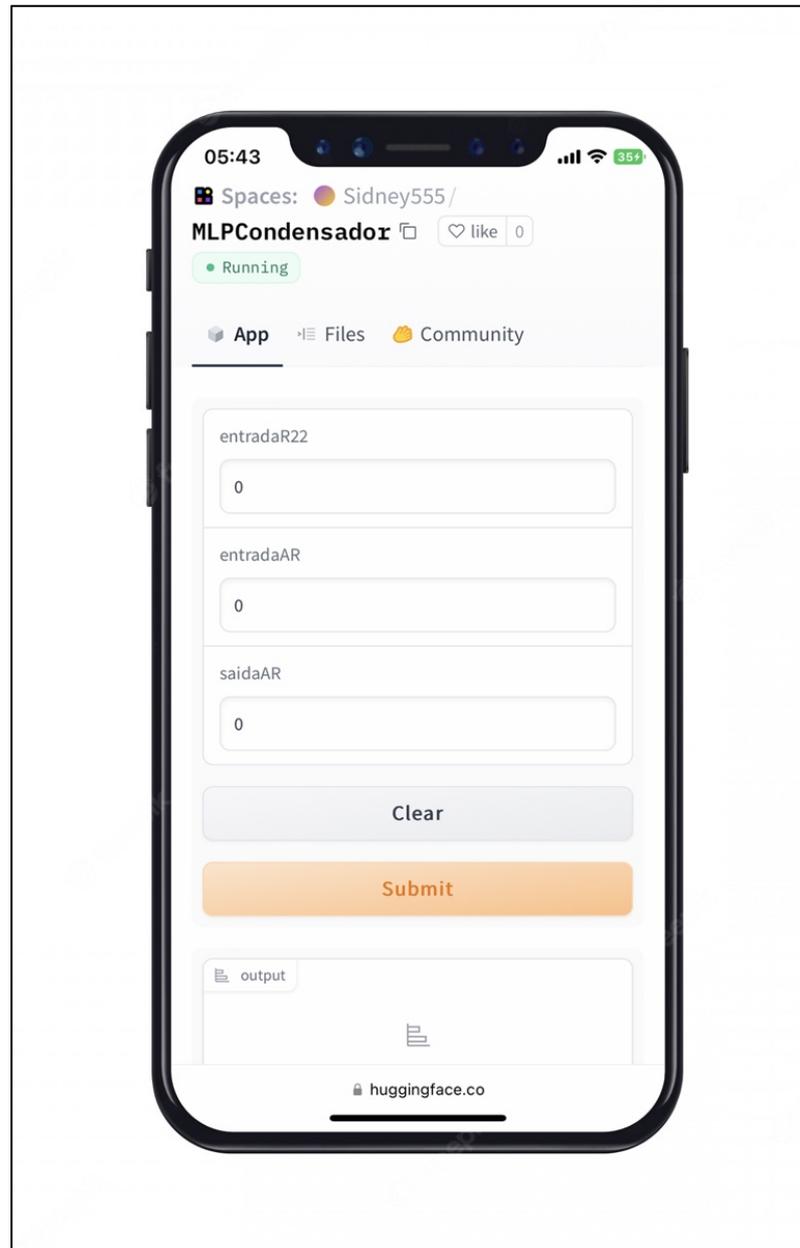
A partir das variáveis de entrada descritas, o modelo consegue prever o resultado da vazão de ar, contudo deve-se estabelecer alguns limites de segurança para a limpeza do trocador uma vez que a vazão de ar muito baixa eleva a temperatura de condensação do fluido refrigerante R22 o que pode acarretar em sérios danos ao compressor do equipamento.

Segundo dados do fabricante do compressor Danfoss (2022), o limite máximo de temperatura no lado de alta pressão é de 150°C, em consultas realizadas a profissionais da área recomenda-se trabalhar com uma temperatura segura na faixa de 70% da temperatura limite, onde com isso teremos uma temperatura 105°C, sendo possível observar durante a coleta de dados que a essa temperatura a vazão de ar estará próxima de 1,05 m³/s, ou seja, define-se assim este valor como valor limite para a limpeza do trocador.

Com esta informação, foi então desenvolvido mais um *scrip* em *python*, dessa vez para criar um aplicativo com uma pequena interface gráfica que executa as rotinas e as consultas ao modelo de rede neural. Tal script compara a vazão prevista pela rede com a vazão limite de 1,05 m³/s e estabelece assim a decisão de se proceder a limpeza ou não do trocador.

Ao fim utilizando a ferramenta de versionamento de código Git foi possível realizar o *deploy* do modelo e do *script* na plataforma gratuita de serviço de computação em nuvem denominada Huggin Face, conforme mostrado na Figura 33, de modo que a consulta ao modelo de *machine learning* pode ser realizado de forma acessível através de um smartfone.

Figura 33 - Tela final do App para consulta do modelo



Fonte: Autor

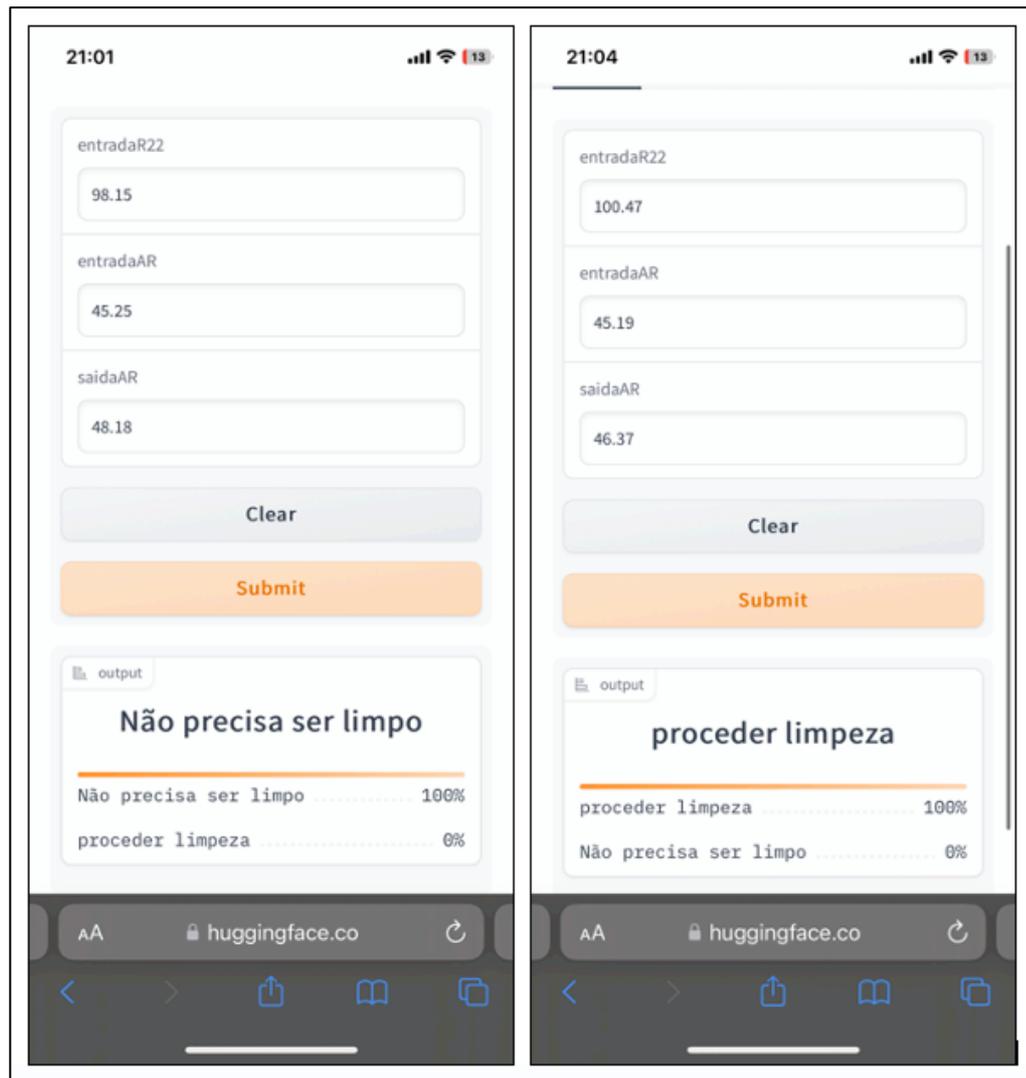
Após a implantação do modelo foi possível realizar alguns testes e verificar o correto funcionamento da ferramenta, para isso se realizou alguns testes inserindo valores na ferramenta de acordo com a Tabela 3, os valores em questão foram inseridos de forma estratégica para simular as duas situações distintas uma vez que a temperatura de entrada do fluido quente (entradaR22) acima do normal sinaliza que o trocador está sujo. Após a inserção foi possível comprovar de acordo com figura 34 o perfeito funcionamento da ferramenta.

Tabela 3 – Valores de teste inseridos na ferramenta

EntradaR22	entradaAr	saidaAr	Resposta esperada
98.15	45.25	48.18	Não precisa ser limpo
100.47	45.19	46.37	Proceder limpeza

Fonte: Autor

Figura 34 - Recomendações obtidas com a inserção de alguns valores teste



Fonte: Autor

5 CONCLUSÃO E TRABALHOS FUTUROS

Diante do tema, conclui-se que foi possível realizar um estudo significativo sobre os métodos de incrustação e que os resultados obtidos para a identificação das variáveis referentes ao processo de incrustação foram um sucesso, uma vez que dentre as variáveis coletadas apenas uma foi descartada utilizando o método *setpwise*, a qual se demonstrou ser bastante robusto e confiável.

O estudo também demonstrou a implementação de um modelo de regressão linear múltipla e um modelo de regressão utilizando redes neurais artificiais, de modo que conseguiu resultados satisfatórios tanto na regressão linear como na modelagem da rede neural.

Vale salientar ainda que a maior dificuldade em se tratando de redes neurais *multilayer perceptron* ocorre em se determinar os ajustes que melhor se adequaram ao modelo, onde quanto maior o número de variáveis no modelo, mais testes devem ser realizados para conseguir um melhor ajuste. Desta forma, a redução de variáveis como foi aplicada utilizando o método *setpwise*, foi de fundamental importância para obtenção dos bons resultados nos ajustes da rede neural, a qual se mostrou adequada com 74% de acerto nas previsões.

Contudo uma das limitações desse estudo se deve ao fato de que o tempo para a realização da pesquisa foi um pouco curto, de modo que a quantidade de amostras coletadas no mês de setembro foram apenas de 30, e que talvez um número maior de amostras possibilite uma melhor performance dos modelos.

Entretanto, o modelo foi significativo e pode ser implementado em uma plataforma gratuita de serviço de computação em nuvem denominada Hugging Face, de modo que técnicos de manutenção possam utilizar o serviço e se beneficiar da aplicação. Entretanto, vale ressaltar que servidores em nuvem para consultas em grandes escalas, como servidores *Azure da Microsoft*, *AWS da Amazon* ou ainda o *Vertex AI da google*, possuem serviços para computação em nuvem de forma paga o que dependendo da aplicação pode ser vantajoso ou não.

5.1 Proposta de trabalhos futuros

Para trabalhos futuros torna-se interessante o desenvolvimento de um método de sensoriamento em algum tipo de plataforma IOT (*Internet Of Things*) para captação

de dados a longos períodos, pois mudanças climáticas durante as estações do ano podem alterar sensivelmente os dados de temperatura de entrada da rede, desta forma mais dados com sazonalidades distintas ao longo do ano podem aumentar a acurácia da rede.

Fica também como sugestão a apuração dos custos com manutenção corretiva e manutenção preventiva do equipamento, onde os custos possam ser utilizados como base para a elaboração de uma política ótima de manutenção através na minimização dos custos totais do equipamento.

Por ultimo, sugere-se que a rede neural monitore o sistema de forma continua através de sensoriamento remoto online, com o objetivo de que o equipamento juntamente com o sistema se torne autônomos, invertendo assim a lógica, de modo que o equipamento possa informar para o técnico quando ele deverá passar por manutenção.

REFERÊNCIAS

- ALVES, M. F.; LOTUFO, A. D. P.; LOPES, M. L. M. Seleção de variáveis stepwise aplicadas em redes neurais artificiais para previsão de demanda de cargas elétricas. In: Simpósio Brasileiro de Automação Inteligente, 11., 2013, Fortaleza. **Anais [...]**. Fortaleza: UFC, 2013. p. 1–6. Disponível em: <<http://www.sbai2013.ufc.br/pdfs/5928.pdf>>. Acesso em: 4 out. 2022
- AMARAL, M. C. **Emprego e otimização de redes neurais artificiais na classificação de trincas detectadas por ultrassom em engates metálicos de vagões ferroviários**, 2021. Dissertação (Mestre em Engenharia Metalúrgica e de Materiais) – Instituto Federal do Espírito Santo, Vitória, 2021. Disponível em: <https://repositorio.ifes.edu.br/bitstream/handle/123456789/1490/DISSERTAÇÃO_Emprego_Otimizaç_ão_Red_Neural_Artificiais.pdf?sequence=1&isAllowed=y>. Acesso em: 09 nov. 2022.
- AROUCHA, A. L. DO C.; PEREIRA, F. L.; NOGUEIRA, É. Análise teórica versus experimental de um trocador de calor compacto do tipo tubo chato aletado (radiador automotivo). **Cadernos UniFOA**, Volta Redonda, n. 44, p. 07-24, 17 dez. 2020.
- AWAD, M. M. **Fouling of heat transfer surfaces, heat transfer - Theoretical analysis, experimental investigations and industrial systems**. Rijeka: InTech, 2011.
- BAPTISTELLA, M.; STEINER, M. T. A.; NETO, A. C. O uso de redes neurais e regressão linear múltipla na engenharia de avaliações: Determinação dos valores venais de imóveis urbanos. In: Simpósio Brasileiro de Pesquisa Operacional, 38., 2006, Goiânia. **Anais [...]**. Goiânia: Universidade Católica de Goiás. 2006. p. 1402–1412. Disponível em: <<http://www.din.uem.br/~ademir/sbpo/sbpo2006/pdf/arq0172.pdf>>. Acesso em: 13 out. 2022.
- BATISTA, L. DOS S.; KUMADA, K. M. O. Análise metodológica sobre as diferentes configurações da pesquisa bibliográfica. **Rev. Bras. de Iniciação Científica**, IFSP Itapetinga, v.8, e021029, p. 1–17, 2021. Disponível em: <<https://periodicoscientificos.itp.ifsp.edu.br/index.php/rbic/article/view/113/235>>. Acesso em: 21 set. 2022.
- BOUZON, M. F. **Estudo de algoritmos de otimização inspirados na natureza aplicados ao treinamento de redes neurais artificiais**. 2021. Dissertação (Mestre em Engenharia Elétrica) – Centro Universitário FEI, São Bernardo do Campo, 2021.
- CARLESSO, C. L.; DUTRA, E. J. B.; ROSA, J. S. Desenvolvimento de uma bancada didática de um ciclo de refrigeração por compressão de vapor. **Revista Liberato**, v. 21, n. 36, p. 131–142, 30 dez. 2020. Disponível em: <<https://revista.liberato.com.br/index.php/revista/article/view/663/pdf>>. Acesso em: 24 ago. 2022
- CHEIN, F. **ntrodução aos modelos de regressão linear**: Um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas. Brasília: Enap, 2019.
- DOMINGUES, C. V. A importância do programa de tratamento químico em águas de condensação e sua influencia na variação de approach dos condensadores. In: Congresso Brasileiro de Refrigeração, Ar-condicionado, Ventilação, Aquecimento e Tratamento de Ar, 16., 2019, São Paulo. **Anais [...]**. São Paulo: ABRVA. 2019. p. 1-12. Disponível em: <http://schenautomacao.com.br/abrava/anais/files/trabalhocompleto_75.pdf>. Acesso em: 22 ago. 2022
- FARIAS, N. F. **Desenvolvimento de analisador virtual para predição de pressão de fundo em poços de petróleo utilizando rede neural**. 2018. Monografia (Bacharel em Engenharia Química) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.
- FERREIRA, A. C. Estudo comparativo da troca térmica em trocadores de calor dos tipos casco/tubos e de placas. **Revista Unoesc & Ciência – ACET**, Joaçaba, p. 57– 66, 2014. Disponível em <<https://periodicos.unoesc.edu.br/acet/article/view/1750>>. Acesso em: 12 out. 2022.

- FREITAS, S. A. **Aumento na eficiência de equipamentos com o uso da ferramenta de qualidade análise de falhas**. 2018. Monografia (Bacharel em Engenharia Mecânica) – Centro Universitário UNIFACVEST, Lages, 2018.
- GAIDEX, C. D. **A influência da manutenção no desempenho térmico de um trocador de calor de placas**. 2019. Monografia (Bacharel em Engenharia Mecânica) – Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2019.
- GENIÊR, F. S.; COSTA, A. O. S.; JUNIOR, E. F. DA C. J. Ciclos de refrigeração: Conceitos e estudos de eficiência. **Enciclopédia Biosfera, Centro Científico Conhecer**, v. 9, n. 16, p. 2878–2893, 2013. Disponível em: <<https://www.conhecer.org.br/enciclop/2013a/engenharias/Ciclos%20de%20refrigeracao.pdf>>. Acesso em: 13 out. 2022.
- GIARDINI, L. F. M. R.; TIBIRIÇA, Á. M. B. Modelagem e simulação CFD de trocadores de calor para condicionamento de ar. **Journal of Chemical Engineering and Chemistry**, v. 2, n. 4, p. 40–42, 2016. Disponível em: <<https://periodicos.ufv.br/jceec/article/view/2446941602042016040/pdf>>. Acesso em: 23 out. 2022.
- GROCHOVSKI, E.; SANTOS, G.; MARQUES, N. **Regressão linear múltipla com dados do censo populacional de 2010 tendo como variável resposta a mortalidade infantil**. Curitiba, 2019. Disponível em: <<https://docs.ufpr.br/~taconeli/CE07119/G3.pdf>>. Acesso em: 13 out. 2022.
- GUT, J. A. W. et al. **Estudo experimental de perda de carga em trocadores de calor a placas com placas lisas e corrugadas**. 2004. Universidade de São Paulo. São Paulo, 2004. Disponível em: <<http://sites.poli.usp.br/pqi/lea/docs/cbcta2004h.pdf>>. Acesso em: 09 nov. 2022.
- HAGHIGHI-KHOSHKOO, R.; MCCLUSKEY, F. M. J. Air-side fouling of compact heat exchangers for discrete particle size ranges. **Heat Transfer Engineering**, v. 28, n. 1, p. 58–64, 2007. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01457630600985675>>. Acesso em: 24 out. 2022.
- INCROPERA, F. P. **Fundamentos de transferência de calor e de massa**. Rio de Janeiro: LTC, 2008.
- JERONYMO, V. **Implementando método de otimização para treinamento de redes neurais com Pytorch**. 2019. Monografia (Obtenção de Crédito Projeto Supervisionado) – Universidade Estadual de Campinas, Capinas, 2019. Disponível em: <<https://www.ime.unicamp.br/~mac/db/2019-2S-157490.pdf>>. Acesso em: 13 out. 2022.
- JÚNIOR, L. C. M. A. **Predição de comportamento de ações no mercado financeiro usando redes neurais recorrentes LSTM**. 2021. Monografia (Bacharel em Ciência da Computação) – Pontifícia Universidade Católica de Goiás, Goiânia, 2021. Disponível em: <https://repositorio.pucgoias.edu.br/jspui/bitstream/123456789/3537/1/TCC- Luis_Carlos-2021.pdf>. Acesso em: 13 out. 2022.
- LOURENÇO, V. H. M. **Análise qualitativa da política de manutenção dos sistemas de um PWR típico por redes neurais artificiais**. 2010. Dissertação (Mestre em Engenharia de Reatores) – Instituto de Engenharia Nuclear, PPGIEN, Rio de Janeiro, 2010.
- MACIEL, A. J. C. et al. Estudo do desempenho de um trocador de calor em escala de laboratório. **Exatas Online**, v. 12, n. 2, p. 140–152, 2021. Disponível em: <<https://www.researchgate.net/publication/356652892>>. Acesso em: 09 nov. 2022.
- MARTÍNEZ, L. C. C. **Otimização dos circuitos de refrigerante nos trocadores de calor de sistemas de refrigeração por compressão de vapor**. 2009. Tese (Doutorado em Engenharia Mecânica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

- MARTINS, B. R. **Análise experimental e teórica de um trocador de calor de tubos e aletas para uma unidade de tratamento de ar**. 2018. Monografia (Bacharel em Engenharia Mecânica) – Universidade do Vale do Rio dos Sinos, São Leopoldo, 2018.
- MATOS, M. A. **Manual operacional para a regressão linear**. 1995. Faculdade de Engenharia Universidade do Porto. Porto, 1995. Disponível em: <<https://paginas.fe.up.pt/~mam/regressao.pdf>>. Acesso em: 12 out. 2022
- MATOS, R. S. **Otimização e comparação de desempenho de trocadores de calor de tubos circulares e elípticos aletados**. 2003. Tese (Doutorado em Energia e Ciências Térmicas) – Universidade Federal do Paraná, Curitiba, 2003. Curitiba: Universidade Federal do Paraná, 2003.
- MELLO, R. S.; COSTA, A. L. H. Simulação numérica de um condensador a ar. In: Congresso Brasileiro de Engenharia Química, 20., 2014, Florianópolis. **Anais [...]**. Florianópolis: COBEQ. 2014. p. 1–8. Disponível em <<https://pdfs.semanticscholar.org/b6ab/85641588d55d336d209e4f11715fb13fed38.pdf>>. Acesso em: 13 out. 2022.
- MELONI, B. D. B.; SOUSA, L. G. L. **Proposta de metodologia preditiva para otimização da limpeza de trocadores de calor resfriado a água**. 2019. Monografia (Bacharel em Engenharia Mecânica) – Universidade de Brasília, Brasília, 2019.
- MENDES, T. **Diagnóstico termodinâmico aplicado a um sistema de refrigeração por compressão de vapor**, 2012. Dissertação (Mestre em Engenharia mecânica) – Instituto de Engenharia Mecânica, Itajubá, 2012. Disponível em: <https://repositorio.unifei.edu.br/xmlui/bitstream/handle/123456789/1292/dissertacao_0038923.pdf?sequence=1&isAllowed=y>. Acesso em: 09 nov. 2022.
- MONTGOMERY, D. C. **Design and analysis of experiments**. USA: John Wiley & Sons, Inc., 2012.
- NETO, J. H. M.; VELOSO, A. H. DE B.; FERNANDES, A. F. C. **Simulação computacional simplificada de sistemas de refrigeração por compressão à vapor**. In: Simpósio de Pós-Graduação em Engenharia Mecânica, 16., 2006, Uberlândia. **Anais [...]**. Uberlândia: Universidade Federal de Uberlândia. 2006. p. 1– 10. Disponível em: <<http://web.posfemec.org/posmec/16/PDF/PM16-0125.pdf>>. Acesso em: 13 out. 2022.
- PARISE, B. DE F.; GODKE, L. M. **Desenvolvimento de um sensor virtual neural para predição de incrustação em trocadores de calor**. 2018. Monografia (Bacharel em Engenharia Química) – Universidade Federal de São Paulo, Diadema, 2018.
- PIRES, K. P. N.; BASTOS, J. B. V; NIKIEL, J. M. Previsão do tempo de campanha de trocadores de calor do sistema de gás de reciclo de reatores de polimerização de eteno em leite fluidizado. In: XI Congresso Brasileiro de Engenharia Química em Iniciação Científica.11., 2015. **Anais [...]**. Campinas: Unicamp. 2015 p. 1-6. Disponível em: <<http://pdf.blucher.com.br.s3-sa-east-1.amazonaws.com/chemicalengineeringproceedings/cobeqic2015/291-33205-264270.pdf>>. Acesso em: 8 nov. 2022.
- PITANGA, Â. F. Pesquisa qualitativa ou pesquisa quantitativa: refletindo sobre as decisões na seleção de determinada abordagem. **Revista Pesquisa Qualitativa**, São Paulo, v. 8, n. 17, p. 184–201, 2020. Disponível em <<https://editora.sepq.org.br/rpq/article/view/299/201>>. Acesso em: 21 set. 2022.
- PU, H. et al. Effects of biofouling on air-side heat transfer and pressure drop for finned tube heat exchangers. **International Journal of Refrigeration**, v. 32, n. 5, p. 1032–1040, 2009. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0140700708001990>>. Acesso em: 24 ago. 2022.
- RAMETTA, R. S. **Avaliação teórica e experimental da utilização de condensadores de microcanais em refrigeradores domésticos**. 2017. Dissertação (Mestre em Engenharia Mecânica)

– Universidade Federal de Santa Catarina, Florianópolis, 2017. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/185695>>. Acesso em: 11 out. 2022.

REQUIÃO, R.; KALID, R. A.; SOARES, R. P. **Uso da incerteza no acompanhamento de processos: Determinação do coeficiente global de transferência de calor.** In: XIX Congresso Brasileiro de Engenharia Química. 19., 2012, Búzios. **Anais [...]**. Búzios: COBEQ2012. 2012 p. 1–10. Disponível em < <https://www.researchgate.net/publication/262688893>>. Acesso em: 09 nov. 2022.

RIZZO, I. V.; CANATO, R. L. C. Inteligência artificial: Funções de ativação. **Revista Prospectus**, Itapira, v. 2, n. 2, p. 51–65, 2020. Disponível em <<https://prospectus.fatecitapira.edu.br/index.php/pst/article/view/37/34>>. Acesso em: 13 out. 2022.

SELL, I. Utilização da regressão linear como ferramenta de decisão na gestão de custos. In: Congresso internacional de custos, 9., 2005, Florianópolis. **Anais [...]**. Florianópolis: Associação Brasileira de Custos. 2005 p. 1–14. Disponível em <<https://anaiscbc.emnuvens.com.br/anais/article/view/2224/2224>>. Acesso em: 13 out. 2022.

SOUZA, Y. DOS R. **Análise teórica e experimental do resfriamento e desumidificação do ar em trocador de calor tubo aletado.** 2019. Monografia (Bacharel em Engenharia Mecânica) – Universidade do Vale dos Rios dos Sinos, São Leopoldo, 2019.

ZHU, C.; BYRD, R. H. Algorithm 778: L-BFGS-B: Fortran subroutines for large-scale bound-constrained optimization. **Revista ACM Transactions on Mathematical Software**, V. 23, n. 4, p. 550–560, 1997. Disponível em: <<https://dl.acm.org/doi/pdf/10.1145/279232.279236>>. Acesso em: 13 out. 2022.

APÊNDICES

APÊNDICE A – CÓDIGO DA REDE NEURAL EM PYTHON

```
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score
from sklearn.neural_network import MLPRegressor

dataset = pd.read_csv("DadosCondensador.csv")
dataset.head()

x = dataset[["entradaR22", "entradaAR", "saidaAR"]]
y = dataset[["vazao"]]

xtrain, xtest, ytrain, ytest = train_test_split(x, y, train_size= 0.25, random_state=42)

rna = MLPRegressor(hidden_layer_sizes= (50,),
                    activation= 'relu',
                    solver='lbfgs',
                    alpha=0.01,
                    batch_size= 'auto',
                    learning_rate= 'constant',
                    learning_rate_init= 0.001,
                    power_t= 0.5,
                    max_iter= 300,
                    shuffle=True,
                    random_state= 1,
                    tol= 0.0001,
                    verbose= False,
                    warm_start= False,
                    momentum= 0.9,
                    nesterovs_momentum= True,
```

```
early_stopping= False,  
validation_fraction= 0.1,  
beta_1= 0.9,  
beta_2= 0.999,  
epsilon= 1e-08)
```

```
rna.fit(xtrain, ytrain)  
y_rna_previsao = rna.predict(xtest)  
r2_rna = r2_score(ytest, y_rna_previsao)  
print("R2 RNA:", r2_rna)
```

```
import joblib  
import os  
rna = rna.fit(x,y)  
joblib.dump(rna, os.path.join("MLPCondensador","model.pkl"))
```

APÊNDICE B – CÓDIGO APP ESCRITO EM PYTHON

```
import gradio as gr
import joblib as jb
from mdit_py_plugins.footnote import index

def predict (entradaR22, entradaAR, saidaAR):
    model = jb.load('model.pkl')
    p = model.predict([[entradaR22, entradaAR, saidaAR]])

    if p >= 1.02:
        r = [1,0]
    else:
        r = [0,1]

    return {"Não precisa ser limpo": r[0], "proceder limpeza": r[1]}

demo = gr.Interface(fn=predict,
                    inputs=["number", "number", "number"],
                    outputs="label")
demo.launch()
```