

UNIVERSIDADE DE CAXIAS DO SUL
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
COORDENADORIA DE PESQUISA E PÓS-GRADUAÇÃO
STRICTO SENSU
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

MAURICIO DALZOCHIO

**MODELO DE APRENDIZADO DE MÁQUINA PARA DETECÇÃO E
DIAGNÓSTICO DE FALHAS OPERACIONAIS EM SISTEMAS DE
REFRIGERAÇÃO**

CAXIAS DO SUL

2026

MAURICIO DALZUCHIO

**MODELO DE APRENDIZADO DE MÁQUINA PARA DETECÇÃO E
DIAGNÓSTICO DE FALHAS OPERACIONAIS EM SISTEMAS DE
REFRIGERAÇÃO**

Projeto de Trabalho de Conclusão de
Curso apresentado como requisito par-
cial à obtenção do grau de Mestre em
Computação Aplicada da Universidade
de Caxias do Sul.

Orientador: Prof. Dr. André Gus-
tavo Adami

CAXIAS DO SUL

2026

Dados Internacionais de Catalogação na Publicação (CIP)
Universidade de Caxias do Sul
Sistema de Bibliotecas UCS - Processamento Técnico

D153m Dalzochio, Mauricio

Modelo de aprendizado de máquina para detecção e diagnóstico de falhas operacionais em sistemas de refrigeração [recurso eletrônico] / Mauricio Dalzochio. – 2026.

Dados eletrônicos.

Dissertação (Mestrado) - Universidade de Caxias do Sul, Programa de Pós-Graduação em Computação Aplicada, 2026.

Orientação: André Gustavo Adami.

Modo de acesso: World Wide Web

Disponível em: <https://repositorio.ucs.br>

1. Refrigeração. 2. Manutenção. 3. Calor - Transmissão. I. Adami, André Gustavo, orient. II. Título.

CDU 2. ed.: 621.56

Catalogação na fonte elaborada pela(o) bibliotecária(o)
Carolina Machado Quadros - CRB 10/2236

MAURICIO DALZUCHIO

**MODELO DE APRENDIZADO DE MÁQUINA PARA DETECÇÃO E
DIAGNÓSTICO DE FALHAS OPERACIONAIS EM SISTEMAS DE
REFRIGERAÇÃO**

Projeto de Trabalho de Conclusão de
Curso apresentado como requisito par-
cial à obtenção do grau de Mestre em
Computação Aplicada da Universidade
de Caxias do Sul.

Aprovado em 08/05/2026

BANCA EXAMINADORA

Prof. Dr. André Gustavo Adami
Universidade de Caxias do Sul - UCS

Prof. Dr. Leandro Luis Corso
Universidade de Caxias do Sul - UCS

Prof. Dr. Vinícius da Rosa Pepe
Centro Universitário Ritter dos Reis - UniRitter

“ Gostaria de dedicar este prêmio aos perdedores. Porque digo-vos, da minha própria experiência, vencer é uma coisa, mas quando perdi sempre aprendi algo a mais para o futuro.”

Niki Lauda

RESUMO

Desde a invenção das primeiras máquinas de refrigeração por compressão de vapor até os sistemas modernos, a refrigeração tornou-se necessária para a conservação de alimentos. Diante dessa relevância, garantir a continuidade operacional dos sistemas de refrigeração por meio de uma manutenção planejada permite que estabelecimentos e indústrias evitem perdas econômicas e riscos sanitários. Nesse contexto, as abordagens tradicionais apresentam limitações importantes, como a dependência de inspeções manuais, medições pontuais, subjetividade na análise e natureza predominantemente reativa. A utilização de modelos tradicionais pode apresentar limitações em cenários com dados desbalanceados e dificuldades de formulação devido à variabilidade construtiva dos sistemas de refrigeração. Contudo, uma transição para uma manutenção preditiva baseada em dados e aprendizado de máquina pode contornar essas limitações, pois é capaz de antecipar falhas, aumentar a confiabilidade e a viabilizar estratégias eficazes. Esse trabalho tem por objetivo construir um modelo de aprendizado de máquina capaz de detectar e diagnosticar falhas de forma automatizada de uma mini câmara fria de conservação. O sistema proposto utiliza sensores de pressão e temperatura para detectar desvios operacionais (falhas), classificado em operação normal quando há ausência de anomalias ou em três possíveis estados de falha quando o comportamento ultrapassa os limites operacionais estabelecidos de acordo com o equipamento. Na implementação da solução, utilizaram-se dois tipos de classificadores, um paramétrico e outro não paramétrico, com o intuito de identificar o melhor modelo de aprendizado. Para avaliar a solução, uma base de dados foi coletada em tempo real no intervalo de temperatura interna compreendida entre -10 °C a -20 °C e externa entre 18 °C e 35 °C, representando as diferentes condições de operação da mini câmara fria. Dentre os algoritmos avaliados, o classificador *Support Vector Machines* apresentou o melhor desempenho na base de dados experimental, atingindo um *F1-score* de 99,4%, superando o *Multi-Layer Perceptron*. Consequentemente, os resultados demonstram que uma ferramenta de aprendizado de máquina pode detectar e diagnosticar anomalias em sistemas de refrigeração reais, a partir do monitoramento de variáveis de pressão e temperatura.

Palavras-chave: Refrigeração. Detecção e Diagnóstico de Falhas. Manutenção Preditiva. Aprendizado de Máquina e *Support Vector Machines*.

ABSTRACT

Since the invention of the first vapor compression refrigeration machines up to modern systems, refrigeration has become essential for food preservation. Given this importance, ensuring the operational continuity of refrigeration systems through planned maintenance allows businesses and industries to avoid economic losses and sanitary risks. In this context, traditional approaches present important limitations, such as reliance on manual inspections, point based measurements, subjectivity in analysis, and a predominantly reactive nature. The use of generalized mathematical models tends to show low performance in scenarios with unbalanced data and difficulties in formulation due to the constructive variability of refrigeration systems. However, a transition to data driven predictive maintenance based on machine learning can overcome these limitations, as such methods can anticipate failures, increase reliability, and enable more effective strategies. This work aims to build a machine learning model capable of automatically detecting and diagnosing faults in a small cold storage chamber. The proposed system uses pressure and temperature sensors to detect operational deviations (faults), classifying the state as normal operation when no anomalies are present or into three possible fault states when behavior exceeds the operational limits established for the equipment. Data was collected in real time with internal temperature ranging from $-10\text{ }^{\circ}\text{C}$ to $-20\text{ }^{\circ}\text{C}$ and external temperature between $18\text{ }^{\circ}\text{C}$ and $35\text{ }^{\circ}\text{C}$, representing different operating conditions of the mini cold chamber. In the implementation of the solution, two different classifiers were used one parametric and the other nonparametric, with the intent of identifying the best learning model. Among the algorithms evaluated, the Support Vector Machines classifier achieved the best performance on the experimental dataset, reaching an F1-score of 99.4%, outperforming the Multi-Layer Perceptron. Consequently, the results demonstrate that a machine learning tool can detect and diagnose anomalies in a real environment by monitoring pressure and temperature variables.

Keywords: Refrigeration. fault detection and diagnosis. predictive maintenance. machine learning and Support Vector Machines

LISTA DE FIGURAS

Figura 1 – Diagrama do ciclo de refrigeração por compressão de vapor	16
Figura 2 – Vista em corte de uma válvula de expansão termostática	18
Figura 3 – Vista em corte de um compressor	18
Figura 4 – Diagrama de pressão por entalpia do R404a	19
Figura 5 – Exemplo de teste de vazamento	22
Figura 6 – Abordagem hierárquica	25
Figura 7 – Abordagem baseada em estágio único	26
Figura 8 – Esquema básico de um classificador de padrões	31
Figura 9 – Fronteiras de decisão do <i>kernel</i> linear	32
Figura 10 – Arquitetura de um MLP	33
Figura 11 – Arquitetura de uma CNN	35
Figura 12 – Diagrama do sistema de detecção e diagnóstico de falhas	37
Figura 13 – Evaporador com superaquecimento elevado	38
Figura 14 – Formação de gelo normal devido ao processo	39
Figura 15 – Formação excessiva de gelo no evaporador	40
Figura 16 – Acúmulo de sujeira no condensador	40
Figura 17 – Valores definidos para a classificação de falhas	41
Figura 18 – Mini câmara fria	42
Figura 19 – Pontos de aquisição dos parâmetros do sistema de refrigeração	44
Figura 20 – Manômetro e sondas de temperatura	45
Figura 21 – Matriz de correlação	47
Figura 22 – Diagrama do processo de treinamento e teste do sistema de detecção e classificação de falhas.	48
Figura 23 – Divisão de dados por seção.	49
Figura 24 – Diagrama do processo de teste do método proposto.	51
Figura 25 – SVM - RBF com $C = 100$ e $\gamma = 10$	53
Figura 26 – SVM linear com $C = 100$	54
Figura 27 – <i>Shapley Additive exPlanations</i> (SHAP) média entre classes	55
Figura 28 – MLP com $\alpha = 0,001$ e $\eta = 0,001$	57
Figura 29 – Dados estatísticos dos parâmetros	65
Figura 30 – Operação normal seguida das falhas 1, 2 e 3	66
Figura 31 – Comparativo real x previsto entre SVM e MLP	67

LISTA DE TABELAS

Tabela 1	– Estatísticas descritivas das variáveis do sistema de refrigeração	46
Tabela 2	– Valores utilizados por hiperparâmetro.	50
Tabela 3	– Resultados para o sistema utilizando SVM	52
Tabela 4	– Resultados para o sistema utilizando MLP	56
Tabela 5	– Comparativo dos resultados obtidos pelos modelos	57
Tabela 6	– Conjunto parcial de dados	64
Tabela 7	– Saturação do fluido refrigerante R404a	68

LISTA DE QUADROS

Quadro 1	–	Comparação entre classificação binária e multiclasse	24
Quadro 2	–	Matriz de confusão 2×2	27
Quadro 3	–	Resultados do método proposto e dos trabalhos correlatos	58

LISTA DE ABREVIATURAS E SIGLAS

Acur	Acurácia
CBM	<i>Condition-Based Monitoring</i>
COP	<i>Coefficient of Performance</i>
CNN	<i>Convolutional Neural Network</i>
CSV	<i>Comma Separated Values</i>
DWT	<i>Discrete Wavelet Transform</i>
FDD	<i>Fault Detection and Diagnosis</i>
FN	Falso Negativo
FP	Falso Positivo
FFT	<i>Fast Fourier Transform</i>
GWP	<i>Global Warming Potential</i>
LBP	<i>Low Back Pressure</i>
MLP	<i>Multi-Layer Perceptron</i>
NaN	<i>Not a Number</i>
ODP	<i>Ozone Depletion Potential</i>
OVO	<i>One Versus One</i>
PCA	<i>Principal Component Analysis</i>
Pliq	Pressão da Linha de Líquido
Psuc	Pressão de Sucção
Prec	Precisão
RBF	<i>Radial Basis Function</i>
SVM	<i>Support Vector Machines</i>
Sc	Sub-resfriamento
Sh	Superaquecimento
SHAP	<i>Shapley Additive exPlanations</i>
tcd	Temperatura de Condensação
tev	Temperatura de Evaporação
tliq	Temperatura da Linha de Líquido
tsuc	Temperatura de Sucção
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	12
1.1	MOTIVAÇÃO	13
1.2	OBJETIVOS	14
1.3	ESTRUTURA DO TRABALHO	14
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	Transferência de Calor	15
2.2	Ciclo de Refrigeração por compressão de vapor	16
2.3	Composição Básica de um Sistema de Refrigeração	17
2.4	Detecção e Diagnóstico de Falhas	20
2.4.1	Manutenção	21
2.5	Detecção e Diagnóstico de Falhas Automatizado	23
2.5.1	Caracterização do Problema	24
2.5.2	Avaliação de Desempenho	26
2.5.3	Extração de Características	29
2.5.4	Métodos Tradicionais	30
2.5.5	Métodos de Aprendizagem Profunda	34
2.6	Considerações Finais	36
3	DESENVOLVIMENTO DO SISTEMA DE DETECÇÃO E DIAGNÓSTICO DE FALHAS	37
3.1	Proposta do Sistema de Detecção e Diagnóstico de Falhas	37
3.1.1	Pré-processamento	37
3.1.2	Classificação	38
3.2	Coleta de Dados	42
3.2.1	Parâmetros e Condições de Teste	43
3.2.2	Conjunto de dados	45
3.2.3	Redução de Dimensionalidade	46
3.3	Treinamento e Avaliação do Aprendizado de Máquina	47
3.3.1	Divisão dos Dados	48
3.3.2	Etapa de Treinamento	49
3.3.3	Etapa de Teste	50
4	RESULTADOS	52
4.1	<i>Support Vector Machines</i>	52
4.2	<i>Multi-Layer Perceptron</i>	55

4.3	Comparativo entre classificadores	56
5	CONCLUSÃO	59
	REFERÊNCIAS	60
	APÊNDICE A – CONJUNTO DE DADOS	64
	APÊNDICE B – ANÁLISE ESTATÍSTICA DOS DADOS	65
	APÊNDICE C – GRÁFICOS DAS OPERAÇÕES	66
	APÊNDICE D – RESULTADO COMPARATIVO ENTRE SVM E MLP	67
	ANEXO A – PRESSÃO DE SATURAÇÃO DO R404A EM FUNÇÃO DA TEMPERATURA	68

1 INTRODUÇÃO

A história da refrigeração moderna iniciou-se no século XIX, quando o conceito de refrigeração emergiu com a concessão da primeira patente de um refrigerador a vapor em 1803, outorgada a Thomas Moore. Segundo ASHRAE (2024), Oliver Evans propôs formalmente em 1805 um ciclo de compressão de vapor fechado em sua obra *The Young Steam Engineer's Guide*, embora sua máquina nunca tenha sido construída. Após duas décadas, em 1823, Michael Faraday conseguiu liquefazer diversos gases por compressão e expansão. No mesmo ano, John Leslie construiu o primeiro equipamento de laboratório capaz de produzir gelo. Esses avanços foram complementados por Nicolas Léonard Sadi Carnot, que introduziu em 1824 o conceito de ciclo reversível, posteriormente chamado de ciclo de Carnot. Esse ciclo estabeleceu um limite teórico de eficiência máxima para máquinas térmicas e sistemas de refrigeração e fundamentou o desenvolvimento futuro de ciclos de compressão e expansão de fluidos refrigerantes.

Em 1834, Jacob Perkins construiu a primeira máquina de refrigeração funcional, que aplicava o mesmo princípio de compressão de vapor de Evans. O sistema utilizava cilindros de alta pressão para comprimir e expandir o fluido refrigerante (éter), resultando no resfriamento da água até o ponto de congelamento. Conforme descrito por ASHRAE (2024), este experimento comprovou a viabilidade do ciclo de compressão de vapor, estabelecendo-se como a base dos sistemas de refrigeração modernos.

Com a popularização dos equipamentos de refrigeração, a sociedade passou a armazenar alimentos de forma mais eficiente para o consumo. Desde um refrigerador doméstico até mesmo um congelador ou uma câmara de conservação de alimentos, utilizam o mesmo processo de ciclo de refrigeração em sua operação. De acordo com Mourtzis, Angelopoulos e Panopoulos (2021), os sistemas de refrigeração são utilizados para armazenar produtos em diversas aplicações, como em supermercados, na logística da cadeia do frio e nas indústrias farmacêuticas. Consequentemente, há uma necessidade comum de operação ótima e contínua do grupo de refrigeração, incluindo a câmara de congelamento e os compressores. Esses são responsáveis pela conservação de produtos perecíveis, garantindo a integridade e a segurança alimentar.

De acordo com Moubray (1997), a manutenção de um sistema de refrigeração ocorre quando há uma parada no funcionamento do equipamento, ou seja, uma manutenção corretiva. Nesse cenário, os equipamentos sofrem uma paralisação dispendiosa, na qual os produtos armazenados precisam ser realocados para outro equipamento ou descartados por não serem mantidos em condições adequadas de temperatura de conservação. Gerando, assim, um impacto negativo na produtividade de um estabelecimento ou indústria, manifestando-se não apenas na perda direta de mercadorias, mas também em custos logísticos adicionais, aumento da inatividade e desgaste da imagem junto aos clientes.

Na manutenção de sistemas de refrigeração, o emprego de técnicas de aprendizado de máquina tem se mostrado crítico para a detecção e diagnóstico de falhas. Pois possibilita prever a perda de desempenho e antecipar intervenções preditivas, resultando na redução de paradas não planejadas. Segundo Chen *et al.* (2023b), além da detecção de falhas, outras abordagens permitem estimar o tempo de vida útil restante dos componentes, otimizando as janelas de manutenção em função do consumo e do impacto na operação. De acordo com Carvalho *et al.* (2019), o uso de técnicas de aprendizado de máquina transformou a forma de planejamento das manutenções, substituindo as estratégias reativas e baseadas em calendário por abordagens preditivas e orientadas por dados. A eficácia dessas abordagens depende diretamente da seleção adequada de algoritmos, da qualidade dos dados e da integração com as políticas de decisão adotadas.

1.1 MOTIVAÇÃO

Este trabalho está voltado para a área da refrigeração, devido ao fato de que esses sistemas são de grande importância para a cadeia de conservação de alimentos congelados. Um exemplo representativo desse processo é a produção do pão francês, que é inicialmente armazenado em uma mini câmara fria para conservação, posteriormente fermentado em uma câmara climática e, por fim, assado e vendido para o consumidor final. Embora esses equipamentos estejam presentes no cotidiano, procedimentos como os de gestão de riscos, operação e manutenção são mandatórios e fundamentais para a segurança operacional (ABRAVA, 2023).

A complexidade na manutenção de um sistema de refrigeração, como a mini câmara fria, sublinha a vulnerabilidade inerente a esses equipamentos e a necessidade de um plano de manutenção preditiva para garantir a integridade operacional, bem como a dos alimentos nele armazenados. Conforme Matetić *et al.* (2023), o emprego de sensores e algoritmos de aprendizado de máquina permite a supervisão desses sistemas, com o objetivo principal de realizar o reconhecimento antecipado de falhas, evitando perdas, elevando a confiabilidade e utilizando estratégias de manutenção baseadas na condição. A título de ilustração, em um supermercado, uma falha inesperada pode comprometer produtos perecíveis, exigindo realocação imediata e gerando perdas. Similarmente, na indústria farmacêutica, a interrupção da refrigeração afeta medicamentos que requerem conservação constante. Esses exemplos demonstram como a falha de um único componente pode gerar impactos financeiros e operacionais em diferentes setores. De forma a evitar esses cenários ou antecipá-los, adotar um método de monitoramento contínuo desses sistemas, com o intuito de implementar um plano de manutenção preditiva eficaz.

Em suma, a motivação para o desenvolvimento deste trabalho combina o interesse tecnológico no campo de aprendizado de máquina à viabilidade de solucionar desafios dessa complexidade computacional por meio de recursos acessíveis. Possibilitando a expansão para a implementação em sistemas embarcados sem a necessidade de intervenção humana.

O intuito desta pesquisa consiste na possibilidade de utilizar quatro sensores (sendo dois de pressão e dois de temperatura) para alimentar um modelo de aprendizado de máquina. Dessa forma, busca-se realizar a classificação correta entre as distintas condições operacionais e os regimes de falha de um sistema de refrigeração a partir de dados reais.

1.2 OBJETIVOS

O objetivo do presente trabalho é projetar e implementar um modelo de aprendizado de máquina, a partir de dados de sensores, capaz de detectar e realizar o diagnóstico de falhas operacionais em uma mini câmara fria de conservação. Essa mini câmara escolhida é um sistema de refrigeração *Low Back Pressure* (LBP) que utiliza o fluido refrigerante R404a e possui uma capacidade frigorífica de até 2 kW.

De forma a atingir o objetivo geral, podem-se destacar os objetivos específicos:

1. Definir os sensores de interesse para a coleta de dados;
2. Coletar os dados em diferentes situações de carga térmica;
3. Produzir o conjunto de dados;
4. Realizar o tratamento dos dados;
5. Selecionar e aplicar um modelo de aprendizado de máquina;
6. Validar o modelo por meio de testes.

1.3 ESTRUTURA DO TRABALHO

O conteúdo subsequente está organizado da seguinte forma:

- O Capítulo 2 apresenta os conceitos fundamentais de sistemas de refrigeração, transferência de calor e técnicas de detecção e diagnóstico de falhas, com ênfase no uso de aprendizado de máquina;
- O Capítulo 3 descreve a proposta do sistema e a metodologia utilizada para realizar a coleta, o tratamento dos dados e o treinamento e a avaliação dos modelos.;
- O Capítulo 4 apresenta a implementação e analisa os resultados obtidos da ferramenta proposta para a detecção e diagnóstico de sistemas de refrigeração;
- O Capítulo 5 sintetiza as principais contribuições, limitações e sugestões para futuras pesquisas decorrentes do projeto desenvolvido.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os principais conceitos sobre o sistema de refrigeração e como os processos de detecção e diagnóstico de falhas são realizados. Na Seção 2.1, é definida como ocorre a transferência de calor. A Seção 2.2 descreve o funcionamento do ciclo de compressão de vapor. A Seção 2.3 apresenta os principais componentes de um sistema de refrigeração que utiliza o ciclo de compressão de vapor. A Seção 2.4 descreve os procedimentos manuais de detecção e diagnóstico de falhas, assim como o procedimento de manutenção do sistema. A Seção 2.5 caracteriza o problema, o processo de detecção e diagnóstico de forma automatizada, apresentando como os modelos de aprendizado de máquina tradicionais e profundos podem ser utilizados para essa aplicação, assim como as métricas de avaliação. Por fim, a Seção 2.6 apresenta as considerações finais do capítulo.

2.1 TRANSFERÊNCIA DE CALOR

De acordo com Çengel e Ghajar (2012), a transferência de calor e massa é uma ciência fundamental que estuda a taxa de transferência de energia térmica. Com diversas áreas de aplicação, a transferência de calor ocorre por meio de três mecanismos:


- **Condução:** é a transferência de energia das partículas com maior potencial energético para as adjacentes de menor potencial. Na condução, a taxa de calor por um meio depende da sua geometria, espessura, tipo de material e da diferença de temperatura a qual ele está submetido. Isso significa que, quanto maior for o isolamento térmico, menor será a perda de calor do corpo. A condução pode ocorrer em sólidos, líquidos e gases, sendo que a taxa de transferência de calor pode ser medida através de uma superfície plana, na qual a diferença de temperatura e a área de transferência de calor são inversamente proporcionais à espessura do material.
- **Convecção:** é o modo de transferência de energia entre uma superfície (líquida ou gasosa) em movimento. Esse processo envolve os efeitos combinados de condução e o movimento da massa de um fluido. A presença e a velocidade do movimento de um fluido aumentam a taxa de transferência de calor, de modo que, quanto maior for a velocidade, maior será a transferência por convecção. A convecção é classificada como forçada quando o fluido é forçado a fluir sobre uma superfície por meios externos, e natural (ou livre) ocorre quando o movimento do fluido é causado por forças de flutuação induzidas por diferenças de densidade decorrentes da variação da temperatura.
- **Radiação:** é a energia emitida pela matéria sob a forma de ondas eletromagnéticas, como resultado de mudanças nas configurações eletrônicas de átomos ou moléculas. A transfe-

rência de calor por radiação não exige a presença de um meio físico intermediário, sendo um fenômeno volumétrico em que todos os sólidos, líquidos e gases emitem, absorvem ou transmitem energia. Ela ocorre à velocidade da luz e não sofre atenuação no vácuo. O corpo negro define a taxa máxima de emissão de energia radiante por uma superfície a uma temperatura específica. Esse limite teórico serve como referência para a análise da emissão de radiação por corpos reais.

2.2 CICLO DE REFRIGERAÇÃO POR COMPRESSÃO DE VAPOR

O ciclo de refrigeração por compressão de vapor consiste em uma sequência de quatro processos termodinâmicos ideais (STOECKER; JABARDO, 2018). Inicialmente, o fluido refrigerante é submetido a uma compressão isentrópica, que eleva a pressão até o nível de condensação (2). Em seguida, o vapor superaquecido tem sua temperatura reduzida em uma condensação isotérmica, alcançando o estado líquido saturado sob pressão constante (3'). O terceiro processo é uma expansão isoentálpica que, ao passar por um dispositivo de expansão, reduz a pressão até o nível de evaporação (4). Por fim, ocorre a evaporação isotérmica do líquido saturado (1') até o estado de vapor saturado, mantendo a pressão constante, o que completa o ciclo e retorna ao estado inicial (1). O diagrama do ciclo de refrigeração é ilustrado na Figura 1.

Figura 1 – Diagrama do ciclo de refrigeração por compressão de vapor



Fonte: Adaptado de Beghi, Cervato e Rampazzo (2015)

De acordo com Stoecker e Jabardo (2018), a determinação dos estados termodinâmicos do ciclo de refrigeração permite uma avaliação precisa da vazão mássica do fluido refrigerante e o volume deslocado pelo compressor. Essa análise propicia uma estimativa adequada das pressões, temperaturas, potência e eficiência do compressor. Adicionalmente, Stoecker e Jabardo (2018) destacam que o incremento dos níveis de eficiência e a redução do consumo energético constituem as tendências contemporâneas no campo da refrigeração.

Uma dessas métricas de avaliação é o *Coefficient of Performance* (COP), que mede a eficiência de um sistema de refrigeração. Para o ciclo de compressão de vapor, o COP é definido como a razão entre a taxa de calor absorvida no evaporador $\dot{Q}_E$ e a potência consumida pelo compressor $\dot{W}$. De acordo com Miller e Miller (2006) a entalpia do vapor na saída do evaporador é representada por h_1 . Enquanto h_2 corresponde a entalpia do vapor na linha de descarga e h_4 a entalpia após a válvula de expansão. O COP pode ser obtido através da Equação 2.1.

$$\text{COP} = \frac{\dot{Q}_E}{\dot{W}} = \frac{h_1 - h_4}{h_2 - h_1} \quad (2.1)$$


2.3 COMPOSIÇÃO BÁSICA DE UM SISTEMA DE REFRIGERAÇÃO

De acordo com a *American Society of Heating, Refrigerating and Air-Conditioning Engineers* ASHRAE (2017), um sistema de refrigeração tem como objetivo realizar uma troca de calor, levando a energia térmica de um ambiente para outro. Para realizar esse processo, o sistema possui componentes que desempenham funções e têm construções específicas para o correto funcionamento.

Stoecker e Jones (2002) referem-se de forma que os componentes presentes no sistema de refrigeração interagem em um circuito fechado, implicando na interdependência dos parâmetros de funcionamento. Adicionalmente, Dossat (2007) define quatro componentes fundamentais para a constituição do ciclo termodinâmico básico:

- **Condensador:** os condensadores são compostos por aletas e tubos de cobre ou alumínio, os quais formam o conjunto denominado serpentina. Essa, por sua vez, realiza a troca de fase do fluido refrigerante do estado gasoso para o estado líquido. Este processo ocorre quando um fluxo de ar passa pelas aletas da serpentina. De acordo com Miller e Miller (2006), o calor liberado pelo fluido refrigerante para o meio de condensação abrange tanto o calor absorvido pelo evaporador quanto o calor do trabalho realizado pelo compressor;
- **Evaporador:** assim como o condensador, o evaporador também é constituído por aletas e tubos. Este componente é responsável por realizar a troca de fase do fluido refrigerante de líquido para o estado gasoso. O fluido refrigerante entra na serpentina evaporadora a baixa pressão e temperatura, sendo distribuído ao longo da serpentina, permitindo a remoção de calor do ambiente e, assim, evaporando-se no processo (STOECKER; JONES, 2002);
- **Dispositivo de expansão:** de acordo com Stoecker e Jones (2002), é um componente que possui a finalidade de reduzir a pressão e regular a vazão do fluido refrigerante no estado líquido que entra no evaporador. Os dispositivos de expansão podem ser um tubo capilar, uma válvula de expansão a pressão constante, uma válvula de expansão eletrônica ou uma válvula de expansão termostática (Figura 2);


Figura 2 – Vista em corte de uma válvula de expansão termostática



Fonte: Adaptado de Danfoss (2024)

- **Compressor:** na refrigeração, são utilizados diversos tipos de compressores, tais como: alternativo (Figura 3), rotativo (parafuso ou de palhetas) e centrífugo. Segundo Dossat (2007), o compressor mantém o fluxo contínuo de fluido refrigerante no circuito, fornecendo a diferença de pressão necessária para realizar a mudança de fase. O desempenho do compressor define a capacidade frigorífica e a eficiência energética do ciclo.


Figura 3 – Vista em corte de um compressor



Fonte: Adaptado de Miller e Miller (2006).

O fluido refrigerante é uma substância que permite o processo de remoção de calor. Segundo Miller e Miller (2006), essa substância absorve calor latente quando há uma troca de fase de líquido para vapor (evaporação) e libera esse calor quando ocorre outra troca de fase, a condensação. Quando uma substância absorve calor latente (adquire energia do ambiente), a entalpia do sistema aumenta; quando essa substância libera calor latente, a entalpia diminui, ou seja, o sistema está liberando energia para o ambiente. O diagrama de pressão por entalpia do refrigerante R404a é ilustrado na Figura 4, enquanto a tabela de temperatura por pressão está disponível no Apêndice A.

Figura 4 – Diagrama de pressão por entalpia do R404a



- *Ozone Depletion Potential* (ODP): indica o impacto do refrigerante na destruição da camada de ozônio (UNEP, 1987);
- *Global Warming Potential* (GWP): indica o potencial de contribuição do refrigerante para o efeito estufa (IPCC, 1990; United Nations, 1997).

2.4 DETECÇÃO E DIAGNÓSTICO DE FALHAS

Por várias décadas, as metodologias de detecção e diagnóstico de falhas (*Fault Detection and Diagnosis* (FDD)) foram estudadas por fabricantes e cientistas, pois o desenvolvimento dessas ferramentas aumenta a eficiência e a confiabilidade do produto, reduzindo, assim, os custos relacionados à manutenção (HECTOR; PANJANATHAN, 2024). No entanto, desenvolver um modelo matemático para esse sistema torna-se uma tarefa difícil, devido a não padronização do regime de trabalho, tipos e formatos dos componentes e características construtivas do sistema (CHEN *et al.*, 2023a).

A detecção de problemas em um sistema de refrigeração envolve a análise de diversos sinais e indicadores, tais como a percepção de desempenho, variações de pressão, temperatura e eficiência energética. Segundo Miller e Miller (2006), técnicas comuns incluem a verificação das pressões de sucção e descarga, que podem indicar sobrecarga ou falta de fluido refrigerante. O monitoramento das temperaturas no evaporador e no condensador ajudam a identificar problemas relacionados à troca de calor. Tais problemas podem afetar significativamente a capacidade frigorífica, diminuindo a vida útil dos componentes do sistema. De acordo com Pereira, Horta e Mendes (2015), a detecção é um problema de classes desbalanceadas, devido à quantidade de possíveis falhas que ocorrem com menor frequência. Em problemas dessa natureza, os algoritmos tradicionais de aprendizagem favorecem a classe predominante e acabam ignorando os casos de menor frequência (THEODORIDIS; KOUTROUMBAS, 2008; WEBB, 2011).

Por outro lado, Stoecker e Jones (2002) detalham que o diagnóstico em um sistema de refrigeração fundamenta-se no monitoramento de variáveis operacionais, como a temperatura e a pressão durante os ciclos de operação. Essas variáveis são continuamente comparadas com valores de referência que indicam condições ideais de operação. Desvios nesses valores podem apontar problemas, como vazamentos, falta de carga de refrigerante ou falhas no compressor. Stoecker e Jones (2002) e Miller e Miller (2006) sugerem o uso de instrumentos de medição como manômetro, termômetro, multímetros e também algoritmos para a interpretação dos dados, para identificar rapidamente anomalias e garantir a estabilidade do sistema.

As abordagens utilizadas em um sistema de refrigeração para a detecção e diagnóstico de falhas podem ser classificadas em:

- Baseadas em inspeções manuais: onde as detecções são realizadas através de instrumentos como o manômetro, para realizar as medições de pressões e termopares para as medições

de temperaturas de operação dos equipamentos. Segundo o manual disponibilizado pelo Ministério do Meio Ambiente (BRASIL, 2015), o técnico deve assegurar que o sistema esteja livre de vazamentos, com a carga adequada de fluido refrigerante e o funcionamento conforme as especificações de cada fabricante. Além disso, deve-se manter os registros de serviços, assim como o histórico;

- Servo-assistidas: são controladores microprocessados que possuem códigos de falhas realizando a autoverificação. Como exemplo, em um equipamento de ar-condicionado, o sistema de detecção de anomalias executa tentativas de eliminação da falha, desligando e religando o equipamento por até três vezes antes de realizar o desligamento permanente, caso a condição anômala persista. Um código de falha é mostrado no *display* do controlador (detecção), a descrição detalhada do código de falha (diagnóstico) pode ser encontrada no manual de instruções do fabricante (KOMEKO, 2024);
- Baseadas em modelos e dados: são amplamente utilizadas para a detecção de falhas em sistemas dinâmicos. Essas arquiteturas dependem de modelos matemáticos ou físicos que descrevem o comportamento normal do sistema, permitindo a detecção de falhas quando há desvios entre o modelo e os dados observados. Wang e Xiao (2004) utilizam um método de análise de componentes principais para detectar falhas de sensores em unidades de tratamento de ar. Essas falhas dos sensores são detectadas usando estatística ou o erro de previsão quadrático. O modelo permite identificar desvios no padrão de funcionamento dos sensores, sinalizando potenciais falhas no sistema. Soltani, Soerensen e Leth (2021) utilizam aprendizado de máquina para detecção de falhas em sistemas de refrigeração de supermercados. A abordagem principal envolve simulações de falhas em sensores e componentes específicos, como *offsets* em sensores de temperatura e pressão, e falhas em compressores, ventiladores e válvulas de expansão. Jardine, Lin e Banjevic (2006) utilizam um sistema de monitoramento baseado em condição, *Condition-Based Monitoring* (CBM) em que as características mais relevantes dos dados são extraídas para reduzir a complexidade e melhorar a eficiência.

2.4.1 Manutenção


A manutenção de um sistema de refrigeração é fundamental para garantir a eficiência, prolongar a vida útil dos componentes e prevenir possíveis falhas operacionais. Pode ser dividida em dois tipos principais: a manutenção preventiva e a corretiva. Segundo Miller e Miller (2006), a manutenção preventiva envolve atividades de inspeção de rotina, como a limpeza de filtros, serpentinas e ventiladores, além da verificação dos níveis de fluido refrigerante, das pressões do sistema e da análise das condições dos componentes mecânicos e elétricos. Essas inspeções programadas visam evitar situações que comprometam o desempenho do sistema. A manutenção corretiva ocorre quando o sistema apresenta uma falha ou anomalia, como vazamento de fluido refrigerante, obstrução no fluxo de ar nas serpentinas ou problemas no com-

pressor. Essa abordagem requer uma manutenção imediata e não planejada do sistema, gerando custos com uma parada não programada do equipamento.

Segundo o Ministério do Meio Ambiente (BRASIL, 2015), um procedimento de manutenção deve ser iniciado a partir do recolhimento do fluido refrigerante do sistema para um cilindro de armazenamento. Uma recolhedora de refrigerante extrai o fluido do sistema (fase de vapor), passa por uma serpentina que realiza a troca de fase, armazenando-o na fase líquida. Somente após o recolhimento completo do fluido refrigerante é que se dá início ao processo de manutenção do sistema, como a troca do filtro secador, da válvula de expansão ou de uma união por brasagem. A próxima etapa deve ser a detecção de vazamentos, que consiste em avaliar a estanqueidade dos componentes e dos processos de fabricação, instalação e manutenção. Diversos métodos e fluidos são utilizados para a verificação de estanqueidade, incluindo nitrogênio e hélio. Contudo, o uso de ar comprimido é inadequado para realizar o teste, por conter umidade, gases não condensáveis e resquícios de óleo.

A introdução de nitrogênio no sistema deve ser feita até um nível de pressão compatível com os componentes, como o representado na Figura 5. Esse teste pode ser realizado pelo método indireto, por meio do monitoramento da queda de pressão, assim como pelo método direto, que inclui a aplicação de uma solução de água e sabão para formar bolhas no ponto de vazamento. Ainda, pode-se empregar detectores eletrônicos, que são instrumentos dedicados a identificar a presença de gases que escapam dos sistemas de refrigeração.

Figura 5 – Exemplo de teste de vazamento



Fonte: Adaptado de (BRASIL, 2015)

De acordo com Honeywell (2007), a detecção de vazamentos é importante para a conservação do fluido refrigerante, para a redução do risco de emissão de poluentes e para a proteção tanto do equipamento quanto das pessoas que possam entrar em contato direto com o sistema. A partir do monitoramento da pressão pelo manômetro, quando não houver uma queda de pressão no sistema em relação à pressão inicial do teste, pode ser realizado o processo de desidratação.

A partir do uso de uma bomba de vácuo, é realizado o processo de desidratação (vácuo), que visa remover os gases não condensáveis e a umidade presentes no sistema. O processo de vácuo é realizado até que o valor indicado no manômetro ou vacuômetro esteja abaixo de 500 microns de coluna de mercúrio. Após o processo de desidratação, pode ser realizada a carga de fluido refrigerante com os valores de massa especificados pelo fabricante, com o auxílio de uma balança de precisão. Após, o sistema deve ser monitorado por meio de manômetro e sensores de temperatura, onde podem ser avaliados os parâmetros de funcionamento do sistema (BRASIL, 2015).

2.5 DETECÇÃO E DIAGNÓSTICO DE FALHAS AUTOMATIZADO

O avanço da indústria moderna deve-se à automação de processos, possibilitando que operações manuais sejam substituídas por modelos de forma assistida ou automática¹. Segundo Fujisawa *et al.* (2022), a instrumentação é uma parte de grande importância no processo de automação industrial para realizar leituras necessárias a fim de estabelecer uma comparação entre diferentes metodologias. Essas leituras são obtidas através de sensores e instrumentos capazes de medir as diferentes grandezas físicas presentes no processo.

A instrumentação possibilitou o monitoramento em tempo real, permitindo que os dados coletados fossem utilizados na identificação dos problemas de um equipamento de refrigeração, minimizando o risco de inatividade. Isso permite a criação de um plano de manutenção preventiva para evitar paradas não planejadas e dispendiosas².

Conforme Widodo e Yang (2007), a manutenção tem impactos significativos na indústria, onde se observa um aumento na necessidade de ferramentas para otimizar o processo de manutenção. Ainda Widodo e Yang (2007) descreve que essa otimização de processo consistia em um *hardware* treinado por um modelo de aprendizado de máquina, com o intuito de realizar uma tarefa de forma semelhante à de um ser humano. Esse *hardware* oferecia maior precisão, velocidade e escalabilidade na análise de falhas em relação a uma inspeção manual.

O aprendizado de máquina é uma ferramenta que permite que sistemas computacionais aprendam e façam previsões baseadas em dados (MITCHELL, 1997; MURPHY, 2012). Esse processo envolve algoritmos que ajustam seus parâmetros internos para melhorar seu desempenho em uma tarefa específica ao longo do tempo. Segundo Bishop (2006), a essência do

¹ <https://maestrovirtuale.com/automacao-industrial-historia-caracteristicas-e-tipos/>

² <https://www.danfoss.com/pt-br/about-danfoss/our-businesses/drives/knowledge-center/condition-monitoring-with-intelligent-drives/predictive-maintenance/>

aprendizado de máquina está na capacidade de um modelo identificar padrões e fazer previsões baseadas em um conjunto de dados. Essa capacidade permite que os sistemas se tornem progressivamente mais precisos, sem a necessidade de serem explicitamente programados para cada tarefa específica. Esse aprendizado pode ocorrer de forma supervisionada, não supervisionada ou semi-supervisionada.

2.5.1 Caracterização do Problema

A detecção e o diagnóstico de falhas podem ser definidos como um problema de classificação, em que algoritmos de aprendizado supervisionado identificam se o sistema opera em regime normal ou sob condições específicas de falha. O problema pode ser abordado por duas estratégias principais, de acordo com Boutahri e Tilioua (2024). A primeira, conhecida como hierárquica, consiste em uma abordagem em duas etapas, na qual inicialmente é realizada a detecção de falhas por meio de um classificador de duas classes (operação normal versus falha) e, posteriormente, os casos identificados como falha são submetidos a um segundo modelo responsável pela classificação multiclasse, que determina o tipo específico de falha. A segunda estratégia baseia-se em um modelo de estágio único de classificação multiclasse, capaz de distinguir diretamente entre o regime de operação normal e os diferentes tipos de falhas. O Quadro 1 mostra uma comparação entre a classificação binária e a multiclasse.

Quadro 1 – Comparação entre classificação binária e multiclasse


Abordagem	Vantagens	Desvantagens
Classificação binária	Simplificação do problema de classificação (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; BISHOP, 2006). Redução da complexidade computacional (GOODFELLOW; BENGIO; COURVILLE, 2016). Emissão rápida de alertas de falha (KATIPAMULA; BRAMBLEY, 2005). Menor impacto do desbalanceamento entre tipos de falha (DUDA; HART; STORK, 2001).	Não identifica o tipo específico de falha. Necessidade de etapa adicional de diagnóstico. Menor suporte à tomada de decisão corretiva (HASTIE; TIBSHIRANI; FRIEDMAN, 2009).
Classificação multiclasse	Detecção e diagnóstico simultâneos (HASTIE; TIBSHIRANI; FRIEDMAN, 2009; SOLTANI, 2023). Eliminação da propagação de erros entre etapas (GOODFELLOW; BENGIO; COURVILLE, 2016). Arquitetura de sistema mais simples. Maior suporte à tomada de decisão (BISHOP, 2006).	Maior sensibilidade ao desbalanceamento de classes (DUDA; HART; STORK, 2001). Necessidade de maior volume de dados rotulados. Treinamento mais complexo (GOODFELLOW; BENGIO; COURVILLE, 2016).

Fonte: O Autor (2026)

Na abordagem hierárquica (Figura 6), o objetivo é reduzir a complexidade do problema por meio de sua decomposição em duas tarefas distintas: inicialmente, a detecção de falhas, tra-

tada como um problema de classificação binária (operação normal versus falha), e, em seguida, a classificação das falhas identificadas, realizada por um modelo multiclasse (AL-KHAZRAJI, 2025). Uma das principais vantagens dessa abordagem é a mitigação do desbalanceamento entre as classes de operação normal e falha, uma vez que, na etapa inicial, todas as ocorrências de falha são agrupadas em uma única classe. Além disso, a etapa inicial de detecção binária permite a emissão imediata de alertas de falha, enquanto o diagnóstico específico é realizado em uma etapa posterior, aumentando a robustez e reduzindo a ocorrência de alarmes incorretos associados à classificação de falhas específicas (KATIPAMULA; BRAMBLEY, 2005). Por outro lado, essa estratégia apresenta como limitação a propagação de erros entre as etapas, uma vez que falhas não detectadas na primeira fase não são posteriormente classificadas, comprometendo o desempenho global do sistema (KATIPAMULA; BRAMBLEY, 2005).

Figura 6 – Abordagem hierárquica




Fonte: O Autor (2026)

Na abordagem baseada em estágio único, o problema é tratado diretamente como uma tarefa de classificação multiclasse (HASTIE; TIBSHIRANI; FRIEDMAN, 2009), na qual o sistema é responsável por distinguir simultaneamente entre o regime de operação normal e os diferentes tipos de falhas (Figura 7). Esse tipo de abordagem é fundamental em sistemas que apresentem diferentes tipos de falhas e requerem estratégias corretivas específicas. Por exemplo, em sistemas de refrigeração, além de detectar se o sistema está em falha, realiza o diagnóstico, identificando a fonte da falha, que pode ser classificada em diferentes categorias, como um vazamento de fluido refrigerante, uma obstrução na válvula de expansão ou um superaquecimento elevado (SOLTANI, 2023). Essa abordagem elimina a propagação de erros entre etapas, uma vez que não há dependência de uma fase prévia de detecção, permitindo uma otimização global do modelo. Além disso, essa abordagem simplifica a arquitetura do sistema, reduzindo a complexidade do *pipeline* e o tempo de inferência. Por outro lado, pode apresentar maior sensibilidade ao desbalanceamento entre as classes, especialmente quando a classe de operação normal é predominante, o que pode comprometer o desempenho na identificação de falhas menos frequentes.

Independentemente da estratégia utilizada, o problema de detecção e diagnóstico de fa-

Figura 7 – Abordagem baseada em estágio único



Fonte: O Autor (2026)

lha sofre do desbalanceamento de classes, isto é, a probabilidade de ocorrência das classes é desigual (KATIPAMULA; BRAMBLEY, 2005; PEREIRA; HORTA; MENDES, 2015; SOLTANI, 2023). De acordo com Duda, Hart e Stork (2001), o desbalanceamento de classes pode influenciar o desempenho, destacando que os classificadores treinados em conjuntos de dados tendem a minimizar o erro geral, favorecendo a classe majoritária e ignorando a minoritária. Para mitigar o desbalanceamento, Pereira, Horta e Mendes (2015) utilizaram o *EasyEnsemble* para dividir a classe majoritária em subgrupos do mesmo tamanho da classe minoritária, equilibrando os dados durante a etapa de treinamento. O autor também salienta que os classificadores tradicionais costumam não apresentar um desempenho satisfatório nesse cenário, em que há a necessidade do emprego de alguma técnica para o tratamento do desbalanceamento de classes.

2.5.2 Avaliação de Desempenho

A avaliação de desempenho dos modelos é uma etapa importante no processo de aprendizado de máquina, pois permite medir a eficácia de um modelo em realizar a tarefa para a qual foi desenvolvido. Conforme Duda, Hart e Stork (2001), a partir da avaliação de desempenho, é possível verificar se um modelo captura os padrões nos dados ou se apenas memoriza os exemplos de treinamento (*overfitting*). Além disso, a seleção adequada de métricas possibilita uma compreensão mais detalhada do comportamento do modelo em diversos aspectos, evidenciando seus pontos fortes e possíveis limitações.

Segundo Hastie, Tibshirani e Friedman (2009), cada método de avaliação possui características distintas e pode apresentar desempenhos variados dependendo da natureza dos dados e da tarefa. Por meio de uma avaliação criteriosa, utilizando métricas apropriadas, é possível identificar qual algoritmo oferece o melhor equilíbrio entre precisão, robustez e eficiência computacional para o cenário específico.

Uma representação comumente utilizada para a avaliação do desempenho de sistemas de classificação é a matriz de confusão. Conforme Theodoridis e Koutroumbas (2008), a matriz de confusão permite uma análise detalhada do desempenho de um modelo de classificação, além de servir como base para o cálculo de métricas. A matriz é uma tabela de dimensão $C \times C$, onde C é o número de classes no problema de classificação.

De acordo com Sicsu, Samartini e Barth (2023), a matriz de confusão se resume nas classificações para dado ponto de corte. O ponto de corte é o valor limite utilizado para transformar as probabilidades estimadas em classificações binárias. A partir dele, se as probabilidades estimadas como positivas forem maiores ou iguais ao ponto de corte, serão classificadas como positivas. Caso contrário, serão classificadas como negativas. Para um problema de classificação binária, a matriz é organizada na dimensão de 2×2 , conforme mostrado no Quadro 2 e pode apresentar os seguintes cenários:

- Verdadeiro Positivo (VP): ocorre quando o modelo prevê corretamente a presença de uma característica ou condição. Por exemplo, em um sistema de refrigeração, o modelo identifica corretamente uma falha;
- Falso Negativo (FN): acontece quando o modelo deixa de identificar uma condição que realmente está presente. O modelo não detecta a falha em um sistema de refrigeração em funcionamento anormal;
- Falso Positivo (FP): ocorre quando o modelo indica a presença de uma condição em uma situação onde ela não existe. Seria quando o diagnóstico foi realizado de forma errônea, uma falha presente em um sistema de refrigeração quando está operando normalmente (sem falhas);
- Verdadeiro Negativo (VN): representa o caso em que o modelo identifica corretamente a ausência de uma condição. Quando um sistema de refrigeração que está operando sem falhas é corretamente classificado como operação normal.

Quadro 2 – Matriz de confusão 2×2

Classe Prevista	Classe Verdadeira	
	Positiva	Negativa
Positiva	VP	FP
Negativa	FN	VN

Fonte: Adaptado de Webb (2011)

Segundo Theodoridis e Koutroumbas (2008), a probabilidade de erro não é suficiente para avaliar o desempenho de um modelo. Por exemplo, para uma tarefa de classificação de M classes, é necessário identificar se algumas classes são mais propensas a serem confundidas do que outras. Nessa matriz, cada elemento $A(i, j)$ representa o número de exemplos que, na verdade, pertenciam à classe i , mas foram classificados como pertencentes à classe j . A partir da matriz de confusão, pode-se extrair diretamente as seguintes métricas:

- Acurácia (Acur): utilizada geralmente em problemas com classes balanceadas, mede a proporção de previsões corretas sobre o total de exemplos (THEODORIDIS; KOUTROUMBAS, 2008). A precisão pode ser obtida através da Equação 2.2;

$$Acur = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.2)$$

- Precisão (Prec): é a proporção de verdadeiros positivos entre todas as previsões positivas feitas pelo modelo (Equação 2.3). De acordo com Theodoridis e Koutroumbas (2008), é importante em cenários onde os falsos positivos têm um peso determinante;

$$Prec = \frac{VP}{VP + FP} \quad (2.3)$$

- Sensibilidade (*recall*): utilizado em cenários onde há desbalanceamento de classes. Webb (2011) define o *recall* como a fração de amostras da classe positiva corretamente classificadas. Essa métrica é utilizada quando há a necessidade de minimizar os falsos negativos. O *recall* pode ser obtido conforme a Equação 2.4;

$$Recall = \frac{VP}{VP + FN} \quad (2.4)$$

- F1-score: tem como objetivo proporcionar um equilíbrio entre a precisão e o *recall*, por meio de uma média harmônica entre ambas as métricas (Equação 2.5). Segundo Goodfellow, Bengio e Courville (2016), essa métrica é utilizada quando há um desbalanceamento entre classes por considerar os falsos positivos e os falsos negativos;

$$F1_{Score} = 2 \times \frac{Prec \times Recall}{Prec + Recall} \quad (2.5)$$

- Média macro: é a média aritmética das métricas de cada classe individual, utilizada para avaliar o desempenho do modelo de aprendizado de máquina, considerando igualmente todas as classes, independentemente do tamanho. De acordo com Sammut e Webb (2011) essa avaliação é ideal para evitar o viés em classes mais frequentes e assegurar que o desempenho nas classes menos representadas seja igualmente valorizado.

Li, Hu e Spanos (2016) utilizaram como métrica principal para a avaliação do modelo a acurácia, na qual avaliaram a proporção de predições corretas em relação ao total de amostras. A acurácia foi analisada nos cenários de classificação binária e multiclasse, onde se observou uma variação com a quantidade de amostras do conjunto de dados para teste. Também foi utilizada a precisão de forma implícita para avaliar a capacidade do modelo em identificar as falhas sem classificá-las falsamente. A taxa de falsos positivos e a capacidade do modelo em associar corretamente os dados de teste às classes de falha específicas foram avaliadas em uma matriz de confusão. Segundo Bishop (2006), ao analisar os erros cometidos, como falsos positivos e falsos negativos, é possível compreender as limitações do modelo e ajustá-lo, como a reponderação de classes e o uso de técnicas de pré-processamento para melhorar o desempenho.

A avaliação do modelo proposto por Zhengxiong *et al.* (2021) foi realizada através da precisão. Esta foi utilizada para medir a capacidade do modelo de identificar corretamente todas as categorias de dados. Sendo aplicada nas categorias de falha de nível de componente, como redução de fluxo de água para o condensador, gases não condensáveis no fluido refrigerante e também no nível de sistema, como sobrecarga de fluido refrigerante ou óleo. Uma precisão elevada reduz o risco de manutenções não programadas e garante que falhas sejam diagnosticadas corretamente.

2.5.3 Extração de Características

A extração de características visa selecionar e transformar as informações brutas em representações úteis para modelos preditivos na análise de dados e aprendizado de máquina (DUDA; HART; STORK, 2001; MURPHY, 2012). Este processo é essencial para a redução da dimensionalidade dos dados, melhorando a interpretabilidade e aumentando o desempenho dos algoritmos (BISHOP, 2006). Hastie, Tibshirani e Friedman (2009) destacam técnicas de extração, tais como *Principal Component Analysis* (PCA) e transformações baseadas em *wavelets*, utilizadas na detecção e diagnóstico para identificar padrões relevantes, minimizar redundâncias e eliminar ruídos no conjunto de dados.

Li, Hu e Spanos (2016) coletaram dados de sensores de temperatura, pressão e vazão para identificar tipos e níveis de severidade das falhas. Primeiramente, os dados foram normalizados e pré-processados, com a remoção de valores atípicos, a fim de garantir consistência na escala e qualidade para o treinamento do modelo. Na etapa de extração de características, foram calculadas estatísticas descritivas, como a média e o desvio padrão, com o objetivo de representar o comportamento das séries temporais em diferentes condições de operação. As médias, obtidas a partir dos dados brutos, foram utilizadas como estimativas do comportamento esperado do sistema em regime normal, além de servirem como base para a identificação de padrões associados a estados de falha. Durante o treinamento, essas estatísticas foram empregadas na definição dos centros de agrupamentos, estabelecendo pontos de referência para a classificação dos dados e a distinção entre condições normais e anômalas. Adicionalmente, médias foram calculadas para diferentes níveis de severidade de falhas, contribuindo para a identificação do tipo e da gravidade das anomalias.

Soltani *et al.* (2020) utilizaram dados brutos de pressão de sucção, superaquecimento, velocidade e fluxo mássico do compressor para alimentar um modelo de rede neural convolucional, permitindo que as características fossem extraídas e processadas automaticamente. Dessa forma, as camadas convolucionais puderam identificar padrões e correlações não triviais entre as variáveis, eliminando a necessidade de definir manualmente quais características poderiam ser relevantes. Além disso, o uso de dados brutos preservou as dinâmicas temporais do sistema, como oscilações e tendências, fundamentais para a detecção de falhas que se manifestam de forma sutil e progressiva.


Soltani, Soerensen e Leth (2021) aplicaram um modelo combinado de PCA e *Support Vector Machines* (SVM) para a detecção de falhas em sistemas de refrigeração. O PCA foi empregado como etapa de pré-processamento, com o objetivo de reduzir a dimensionalidade dos dados, mitigando o aumento da complexidade computacional associado ao uso direto de múltiplas variáveis. Esse processo permitiu identificar correlações entre as variáveis, preservando as informações mais relevantes e eliminando redundâncias e ruídos. Como resultado, observou-se uma redução significativa da complexidade computacional, mantendo elevado desempenho do modelo e reduzindo a dependência da seleção manual de características por especialistas. Esta técnica também foi utilizada por Wang e Xiao (2004) com o intuito de substituir o uso de *Fast Fourier Transform* (FFT) ou *Discrete Wavelet Transform* (DWT) ao capturar variações nos dados para classificá-los de forma eficiente.

2.5.4 Métodos Tradicionais

Conforme Hastie, Tibshirani e Friedman (2009), os métodos tradicionais formam a base do aprendizado supervisionado e oferecem abordagens diferentes para resolver problemas de classificação e regressão. Os métodos tradicionais consistem em algoritmos estatísticos ou baseados em regras que realizam o aprendizado a partir de um conjunto de dados. Webb (2011) define que um método tradicional possui três elementos, como ilustrado na Figura 8:

1. **Sensor:** primeira etapa do método, consiste na coleta de dados através de sensores. Esses dados são transformados em um formato de representação que pode ser processado pelas próximas etapas. Como destacado por Duda, Hart e Stork (2001), a qualidade da representação dos dados influencia diretamente na capacidade do sistema de identificar padrões úteis para construir um modelo robusto.
2. **Extrator/Seletor de Características:** os dados brutos são transformados em vetores de características que visam descrever as relevâncias do problema. Conforme Bishop (2006), essas características devem ser informativas e discriminativas, permitindo que o modelo separe efetivamente as classes de interesse. Técnicas como PCA ou análise espectral são amplamente utilizadas para reduzir a dimensionalidade e remover redundâncias, enquanto métodos baseados em estatísticas ou aprendizado supervisionado identificam as características mais relevantes.
3. **Classificador:** responsável por decidir a classe do padrão de entrada. Essa etapa do processo envolve o treinamento de modelos tradicionais, como regressão logística ou árvores de decisão, para associar as características às categorias. Hastie, Tibshirani e Friedman (2009) descrevem que o sucesso dessa etapa depende tanto da qualidade dos dados e características quanto da escolha do modelo e das métricas de desempenho empregadas para sua validação. O classificador gera uma decisão final baseada no padrão das características de entrada.

Figura 8 – Esquema básico de um classificador de padrões



Fonte: Adaptado de Webb (2011)

Segundo Murphy (2012), os métodos tradicionais oferecem vantagens, como a facilidade de interpretação dos modelos matemáticos, necessitando de uma quantidade menor de dados, utilizando menos poder de processamento e podendo ser treinados rapidamente. Isso os torna úteis para a resolução de problemas em que a coleta de dados em larga escala é difícil ou possui um custo elevado.


Em aprendizado de máquina, classificadores são algoritmos que categorizam dados em classes predefinidas, a partir de padrões extraídos de conjuntos de treinamento. De acordo com Duda, Hart e Stork (2001), a tarefa de classificação consiste em atribuir um vetor de características a uma das categorias predefinidas com base em um modelo estatístico ou determinístico. Um classificador adequado depende de fatores como a dimensionalidade, a distribuição dos dados e a presença de ruído. Os classificadores tradicionais são:

- Máquina de Vetores de Suporte - SVM: são classificadores binários, que buscam um hiperplano que maximize a margem entre as classes conforme mostrado na Figura 9. Conforme Webb (2011), um hiperplano representa uma superfície de separação que melhor discrimina as classes no espaço de características. Essa superfície é determinada pelos vetores de suporte, que são os pontos mais próximos à fronteira de decisão, no qual influenciam diretamente sua posição e orientação.

Segundo Cristianini e Shawe-Taylor (2000), o objetivo é resolver um problema de otimização que minimiza a norma do vetor de pesos, de forma que cada exemplo seja classificado corretamente ou se encontre próximo à fronteira de decisão, por meio da introdução de variáveis de folga quando necessário. Esse classificador foi utilizado por Chen *et al.* (2023a) para realizar a classificação de oito possíveis falhas em um sistema de ar condicionado residencial. Com o objetivo de avaliar se um modelo treinado em um determinado sistema poderia ser aplicado a um diferente, para reduzir a necessidade de conjuntos de dados com volume elevado. O modelo foi treinado com um de ar condicionado (S1) e testados em outros dois diferentes (S2 e S3), onde a base de dados utilizada foi gerada a partir de uma simulação e apresentando um resultado de 99% de acurácia.

Embora seja originalmente um algoritmo de classificação linear, a Máquina de Vetores de Suporte pode ser aplicada com sucesso a problemas de classificação não linear por

Figura 9 – Fronteiras de decisão do *kernel* linear




Fonte: Adaptado de Scikit-Learn (2025)

meio do uso do *kernel trick*. Essa abordagem consiste em mapear implicitamente os dados para um espaço de características de maior dimensão, no qual a separação linear entre as classes se torna possível (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Esse mapeamento é realizado por meio de funções de *kernel*, que permitem capturar relações não lineares entre as variáveis sem a necessidade de explicitar a transformação dos dados. Soltani, Soerensen e Leth (2021) utilizaram esse classificador em um problema de duas classes linearmente separáveis com rótulos diferentes a partir de um conjunto de dados balanceado. Onde os classificadores apresentaram acurácias de entre 95% e 86% com o SVM e 55% com o PCA-SVM;

- *Multi-Layer Perceptron* (MLP): constitui um dos modelos fundamentais dentro do campo das redes neurais artificiais, sendo apresentada como uma rede *feedforward*, composta por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída (Figura 10). De acordo com Goodfellow, Bengio e Courville (2016), cada unidade (neurônio) em uma camada realiza uma combinação linear das saídas da camada precedente, seguida de uma função de ativação não linear. Esse arranjo de transformações lineares e não lineares confere ao MLP a capacidade de modelar mapeamentos complexos entre as variáveis de entrada e saída. A estrutura é inspirada no funcionamento do cérebro humano, buscando simular a capacidade de aprender padrões a partir de um conjunto de dados.

O MLP pode ser formalizado como uma função paramétrica $f(x; \theta)$, onde θ representa o

Figura 10 – Arquitetura de um MLP



Fonte: Adaptado de Scikit-Learn (2025)

conjunto de pesos e vieses que conectam as unidades entre as camadas (GOODFELLOW; BENGIO; COURVILLE, 2016). A escolha do número de camadas intermediárias, de neurônios, das funções de ativação e do esquema de inicialização dos pesos determina tanto a capacidade de representação quanto o comportamento numérico do treinamento. O treinamento do MLP baseia-se na minimização de uma função objetivo por métodos baseados em gradiente, como a entropia cruzada para classificação. O algoritmo de retropropagação (*backpropagation*) aplica a regra da cadeia para calcular as derivadas parciais ao longo da rede, o que permite obter o gradiente do custo relativamente a todos os parâmetros de forma computacionalmente eficaz.

Embora o MLP possua uma capacidade elevada de representação, essa flexibilidade implica o risco de *overfitting* quando o número de parâmetros é elevado em relação à informação disponível no conjunto de dados para treinamento (BISHOP, 2006; HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Para contornar esse risco, aplicam-se técnicas de regularização explícita (penalização L2), estocástica (*dropout*, normalização de ativação e procedimentos de monitoramento, como *early stopping*, usando a validação cruzada. Paralelamente, estratégias como *data augmentation* e validação cruzada são recomendadas por Hastie, Tibshirani e Friedman (2009) para avaliar e melhorar a capacidade de generalização do modelo.

2.5.5 Métodos de Aprendizagem Profunda

Conforme Bishop (2006), os métodos tradicionais enfrentam limitações quando submetidos a problemas de complexidade elevada, devido à incapacidade de capturar padrões complexos e não lineares nos conjuntos de dados. Essas limitações ocorrem especialmente em problemas de visão computacional e linguagem natural, onde se destaca o uso das redes neurais.

A aprendizagem profunda é uma subárea da inteligência artificial que usa redes neurais artificiais, permitindo a modelagem de dados complexos e hierárquicos. A implementação de métodos de aprendizado profundo envolve a construção de redes neurais artificiais compostas por múltiplas camadas de neurônios interconectados, característica que justifica o termo “profundo”. Durante o processo de treinamento, os pesos das conexões são iterativamente ajustados com o objetivo de minimizar uma função de perda, permitindo que o modelo aprenda representações hierárquicas dos dados (GOODFELLOW; BENGIO; COURVILLE, 2016). O processo começa com a definição da arquitetura da rede, incluindo o número de camadas, os tipos de ativação e os métodos de inicialização de pesos. Essa estrutura de camadas é responsável pela extração das características relevantes dos dados de entrada, como padrões e variações.

O treinamento, por sua vez, é realizado utilizando algoritmos de otimização, como o gradiente descendente estocástico e suas variantes, que ajustam iterativamente os parâmetros da rede com base no erro observado entre a previsão e a saída desejada. Ainda Goodfellow, Bengio e Courville (2016) definem três etapas principais no processo de treinamento:


- Propagação direta (*forward pass*): os dados de entrada passam camada por camada, gerando uma previsão de saída;
- Cálculo de erro: a função de perda é calculada de forma a quantificar o erro da previsão;
- Retropropagação (*backpropagation*): o gradiente da função de perda é calculado em relação aos parâmetros da rede. Esses gradientes são utilizados para atualizar os pesos da rede, com o intuito de reduzir o erro nas iterações subsequentes.

No modelo proposto por Soltani *et al.* (2020), as três etapas foram aplicadas durante o processo de treinamento. Na primeira etapa, os dados de entrada foram transformados em uma representação mais abstrata e discriminativa, com o intuito de gerar uma probabilidade de classificação binária. Na etapa seguinte, o erro foi apurado confrontando o resultado obtido com o resultado esperado, utilizando uma função específica de custo: a entropia cruzada binária. Por fim, utilizou-se a regra da cadeia para o cálculo recursivo dos gradientes do erro em relação aos pesos sinápticos atribuídos. Esses gradientes indicam a direção e a magnitude das alterações necessárias para minimizar o erro e atualizar os pesos a cada novo ciclo.

As Redes Neurais Convolucionais ou *Convolutional Neural Network* (CNN) representam um modelo de classificador de aprendizagem profunda. Sua arquitetura é projetada para

processar dados com estrutura em grade, utilizando a operação matemática de convolução. De acordo com Sejnowski (2020), as CNNs são baseadas na estrutura do córtex humano e usam camadas de convolução para detectar padrões em diferentes escalas, como ilustrado na Figura 11. Goodfellow, Bengio e Courville (2016) destacam que a convolução integra três conceitos importantes para aprimorar os sistemas de aprendizado de máquina: conexões esparsas, uso compartilhado de parâmetros e representações equivalentes, além de trabalhar com entradas de tamanho variável.

Figura 11 – Arquitetura de uma CNN



Fonte: Adaptado de Phung e Rhee (2019)

Goodfellow, Bengio e Courville (2016) relatam que a principal inovação de uma CNN é o uso de filtros (*kernels*) compartilhados em toda a entrada, reduzindo de forma significativa o número de parâmetros em comparação com redes densamente conectadas. Dessa forma, obtêm-se uma melhor generalização do modelo, reduzindo assim o risco de *overfitting*.

Ainda Goodfellow, Bengio e Courville (2016) citam que uma camada típica de uma rede convolucional consiste em três estágios. No primeiro estágio, a camada executa várias convoluções em paralelo para produzir um conjunto de ativações lineares. No segundo estágio, cada ativação linear é passada por uma função de ativação não linear, como a função de ativação retificada linear. No terceiro estágio, é utilizada a função de *pooling*, que substitui a saída da rede em um determinado local por uma estatística resumida das saídas próximas.

No trabalho desenvolvido por Soltani *et al.* (2020), uma CNN foi adaptada para processar dados de um sistema de refrigeração de um supermercado. A organização foi estruturada para extrair as características mais importantes dos dados originais, como padrões e alterações. Nessa abordagem, o modelo identifica cinco classes: operação normal, vazamento na válvula do compressor, restrição na linha de líquido, acúmulo de sujeira no condensador, no evaporador, identificação de gases não condensáveis, sub-carga e sobrecarga do fluido refrigerante. Por trabalhar diretamente com os dados brutos, a CNN possui uma capacidade maior de identificar padrões em diferentes situações de uso. Essa forma de trabalho favorece a adaptação a diversos

contextos, como alterações nos pontos de funcionamento, dados com ruído ou mudanças na taxa de amostragem. A coleta desses dados ocorreu em taxas de amostragem específicas e foi dividida em pequenos grupos, cada um com diversas amostras seguidas para registrar mudanças ao longo do tempo nos padrões do sistema. Esses pequenos grupos foram analisados pela CNN um após o outro, permitindo que as fases de convolução identificassem tanto as mudanças graduais quanto as oscilações evidentes associadas ao estado operacional do sistema, no qual obteve um resultado de *F1-score* de 99%.

2.6 CONSIDERAÇÕES FINAIS

A escolha do uso de um modelo SVM para realizar a detecção e diagnóstico de falhas em um sistema de refrigeração deve-se à eficiência, à capacidade de generalização e à robustez quando utilizado com dados complexos. Como analisado no estudo de Cristianini e Shawe-Taylor (2000), a SVM é fundamental para identificar padrões em dados coletados por sensores de temperatura e pressão. O modelo permite trabalhar com classificações não lineares, possibilitando a identificação de falhas sutis, como demonstrado no estudo de Soltani, Soerensen e Leth (2021). Essa abordagem foi validada no estudo conduzido por Chen *et al.* (2023a) onde o SVM demonstrou um desempenho elevado na classificação de diferentes falhas em sistemas de ar-condicionado, destacando-se pela sua eficiência, mesmo quando aplicado em cenários de conjuntos de dados limitados. Além disso, possui a capacidade de operar com conjuntos de dados desbalanceados, o que foi um ponto relatado por Pereira, Horta e Mendes (2015) como um problema comum na detecção de falhas.

Embora uma CNN seja amplamente utilizada em problemas de classificação, sua aplicação na detecção e diagnóstico de falhas em sistemas de refrigeração apresenta algumas limitações significativas. De acordo com Pereira, Horta e Mendes (2015), essas limitações podem ser a quantidade de dados disponíveis para treinamento e a necessidade de um *hardware* de elevado desempenho devido à complexidade do modelo. Dessa forma, Soltani, Soerensen e Leth (2021) optaram por um modelo SVM, que consegue generalizar melhor mesmo com conjuntos de dados reduzidos. Isso é importante para a aplicação em sistemas de refrigeração industrial, onde a confiabilidade e a rastreabilidade das decisões são fundamentais para a manutenção preditiva. Conforme Cristianini e Shawe-Taylor (2000), modelos como o SVM são preferíveis por oferecerem maior transparência e explicabilidade dos resultados.


3 DESENVOLVIMENTO DO SISTEMA DE DETECÇÃO E DIAGNÓSTICO DE FALHAS

Este capítulo descreve a metodologia empregada no desenvolvimento da ferramenta de detecção e diagnóstico de falhas em um sistema de refrigeração. A Seção 3.1 apresenta a proposta do sistema de detecção e classificação de falhas baseado em aprendizado de máquina. Na Seção 3.2, são descritos o equipamento utilizado e o processo de aquisição do conjunto de dados. Por fim, a Seção 3.3 descreve os procedimentos de treinamento e avaliação dos modelos.

3.1 PROPOSTA DO SISTEMA DE DETECÇÃO E DIAGNÓSTICO DE FALHAS

Baseado em um sistema tradicional de aprendizado de máquina, ele é estruturado em três etapas principais, conforme ilustrado na Figura 12: aquisição (responsável pela coleta dos sinais dos sensores), pré-processamento (responsável pelo tratamento dos dados) e classificação (responsável pela detecção e identificação das falhas). O sistema utiliza medições de pressão e temperatura para realizar a detecção e diagnóstico de três tipos de falhas.

Figura 12 – Diagrama do sistema de detecção e diagnóstico de falhas



Fonte: O autor (2026)

3.1.1 Pré-processamento

A etapa de pré-processamento tem por objetivo normalizar as variáveis coletadas. Considerando que o conjunto de dados é composto por parâmetros como temperatura e pressão, que possuem magnitudes naturalmente diferentes, a padronização foi necessária para garantir o desempenho adequado do modelo.

A normalização dos dados foi realizada utilizando o método z-score (WEBB, 2011), conforme definido na Equação 3.1. Os parâmetros média ($\bar{x}$) e desvio padrão (s) são estimados a partir dos dados de treinamento para cada uma das variáveis.


$$z = \frac{x - \bar{x}}{s} \quad (3.1)$$

3.1.2 Classificação

Neste trabalho, o classificador deve determinar, com base nas medições de pressão e temperatura, se o sistema está operando em condição normal (isto é, ausência de anomalias no sistema) ou em um dos três possíveis estados de falha (funcionamento anômalo do sistema de refrigeração, ou seja, quando o comportamento ultrapassa os limites operacionais estabelecidos de acordo com o tipo de fluido refrigerante e aplicação). Assim, o sistema deve atribuir cada amostra a uma das quatro classes definidas a seguir:

1. Operação normal: caracteriza-se por uma condição na qual os parâmetros do sistema permanecem nos limites operacionais estabelecidos para o fluido refrigerante utilizado. Neste estado, não há anomalias detectáveis e os dados podem ser usados para caracterizar o comportamento nominal do equipamento;
2. Superaquecimento elevado: de acordo com Dossat (2007), isso ocorre após o fluido refrigerante mudar de fase e apresentar uma temperatura acima do ponto de saturação referente à pressão de sucção. Isso indica que parte do trocador de calor está sem a presença do fluido refrigerante no estado líquido, como pode ser visto na Figura 13, reduzindo assim a eficiência de troca térmica e aumentando o trabalho do compressor.

Figura 13 – Evaporador com superaquecimento elevado



Fonte: O autor (2026)

A faixa de superaquecimento tipicamente compreendida para um sistema de refrigeração é entre 4 K e 20 K. A falta de fluido refrigerante no evaporador, orifício da válvula de expansão inadequado, válvula de expansão danificada, filtro secador saturado, fluxo de ar excessivo e a carga térmica elevada devido aos produtos armazenados são possíveis indicadores de um superaquecimento elevado;

3. Superaquecimento e temperatura de sucção baixa: segundo Arora (2010), ocorre quando o sistema apresenta um valor de superaquecimento e uma temperatura abaixo da operação normal. Isso sinaliza que o evaporador possui uma quantidade elevada de fluido refrigerante (evaporador inundado), não realizando a troca de fase e absorvendo uma quantidade de calor sensível menor do que a necessária. Valores de superaquecimento inferiores a 1,5 K e temperatura de sucção, nesta aplicação em específico menores do que -26°C , indicam uma condição de sobrecarga de fluido refrigerante ou uma troca térmica ineficiente do evaporador. Quando o superaquecimento atinge um valor próximo a 0 K, isso significa que não está realizando uma troca de calor suficiente com o ambiente, impedindo a mudança de fase do fluido refrigerante. Devido o evaporador também remover calor latente do ambiente, é normal que se formem gotículas de água ao longo da serpentina evaporadora e que se crie uma película de gelo quando a temperatura atinge valores abaixo de 0°C , como pode ser visto na Figura 14.

Figura 14 – Formação de gelo normal devido ao processo



Fonte: O autor (2026)

Como resultado, parte desse fluido refrigerante chega até o compressor em fase líquida, o que pode causar danos, como calço hidráulico e principalmente a remoção da película de óleo das partes móveis. Esse efeito pode ser causado por um fluxo de ar baixo no evaporador, devido à sujeira, sobrecarga de fluido refrigerante, válvula de expansão travada na posição aberta, ou ainda bulbo mal fixado na tubulação, além da presença de umidade no interior do ambiente refrigerado formando gelo, mostrado na Figura 15.

Figura 15 – Formação excessiva de gelo no evaporador



Fonte: O autor (2026)

4. Temperatura de condensação elevada: Arora (2010) relata que a temperatura de condensação é o reflexo da pressão elevada, forçando o compressor a trabalhar em condições mais severas e reduzindo a capacidade frigorífica do sistema. Esse efeito ocorre devido o fluido refrigerante que sai do condensador estar com a temperatura acima da saturação, ou seja, parte da energia térmica não foi removida. Um exemplo desse efeito pode ocorrer devido à obstrução por acúmulo de sujeira nas aletas da serpentina condensadora pode ser visto na Figura 16.

Figura 16 – Acúmulo de sujeira no condensador




Fonte: O autor (2026)

Outros fatores que se destacam por elevar a temperatura de condensação são: acúmulo de gases não condensáveis, excesso de carga de fluido refrigerante e fluido refrigerante inadequado. Adicionalmente, falhas mecânicas, como a falta de fluxo de ar na serpentina, devido à obstrução ou ventiladores parados, resultam em uma troca de calor ineficiente. Contudo, em cenários de temperatura externa e com a carga térmica no evaporador elevadas, pode ocorrer um instante em que a temperatura de condensação ultrapasse esse limiar, retornando à operação normal após a redução da carga térmica. Para o fluido refrigerante R404a, uma temperatura de condensação superior a 46 °C sinaliza uma troca ineficiente de calor.

Com o intuito de classificar e delimitar as condições de operação normal do sistema, assim como identificar as falhas, definiram-se limiares conforme a literatura e as características termodinâmicas do fluido refrigerante R404a. Foram avaliados os seguintes parâmetros: Pressão de Sucção (P_{suc}), Pressão da Linha de Líquido (P_{liq}), Temperatura de Condensação (t_{cd}), Temperatura de Evaporação (t_{ev}), Temperatura de Sucção (t_{suc}), Temperatura da Linha de Líquido (t_{liq}), Sub-resfriamento (Sc) e Superaquecimento (Sh). Os valores estabelecidos para essa classificação e o código identificador para o algoritmo são apresentados na Figura 17. Ressalta-se que a operação normal compreende todos os valores que não foram classificados como falha, sendo-lhes atribuído o código identificador 1.

Figura 17 – Valores definidos para a classificação de falhas




Fonte: O autor (2026)

O SVM foi selecionado como o modelo de aprendizado de máquina com base nos resultados apresentados nos trabalhos correlatos. A escolha justifica-se pela eficácia que o modelo demonstra na detecção e no diagnóstico de falhas em sistemas de refrigeração.

3.2 COLETA DE DADOS

O sistema de refrigeração escolhido para realizar as coletas de dados foi uma mini câmara fria destinada à conservação de alimentos congelados, conforme ilustrado na Figura 18. Este equipamento, comumente utilizado em restaurantes, açougues e padarias, conta com um volume interno de 2,5 m³, uma faixa de operação entre as temperaturas de -10 °C a -20 °C e uma capacidade frigorífica de 1,16 kW.

Figura 18 – Mini câmara fria



Fonte: O autor (2026)

O sistema de refrigeração é composto por uma unidade condensadora de baixa temperatura de evaporação que utiliza o fluido refrigerante R404a, um evaporador de convecção de ar forçada com vazão de 1100 m³/h e uma válvula de expansão do tipo termostática. O controle operacional do sistema é realizado por um controlador eletrônico, responsável pelo monitoramento contínuo das condições internas da mini câmara fria através da leitura de dois sensores de temperatura distintos. Um sensor realiza a leitura da temperatura interna da câmara, enquanto

o outro tem a função de monitorar a formação de gelo nas aletas do evaporador, atuando como um mecanismo de proteção e para iniciar e finalizar o ciclo de degelo.

3.2.1 Parâmetros e Condições de Teste

Para realizar uma avaliação abrangente do desempenho de um sistema de refrigeração, é necessário compreender o seu comportamento em resposta às variações da carga térmica imposta. Nesse sentido, o funcionamento adequado do sistema é definido conforme as propriedades termodinâmicas do fluido refrigerante empregado e da faixa de temperatura de evaporação estabelecida para a aplicação. De acordo com Miller e Miller (2006), os parâmetros fundamentais de um sistema de refrigeração por compressão de vapor são:

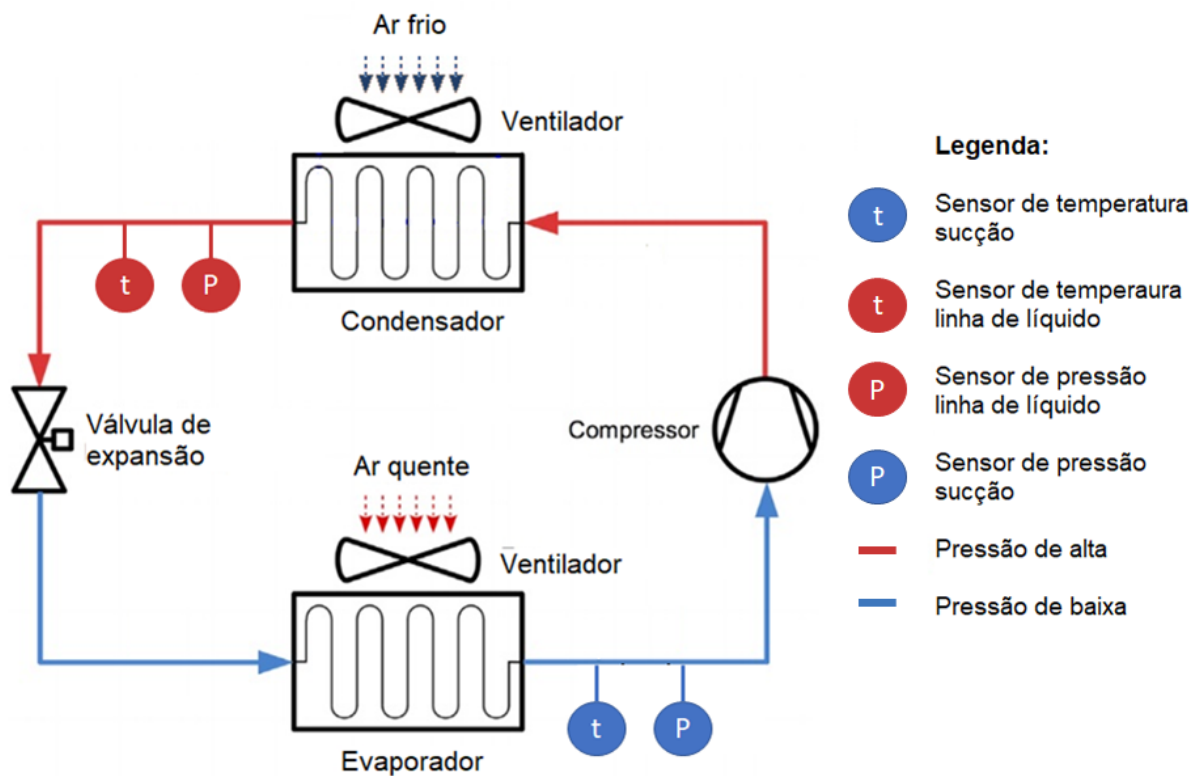
- Temperatura de evaporação: temperatura na qual o fluido refrigerante muda de fase no evaporador, garantindo que o refrigerante absorva o calor necessário no evaporador, maximizando a capacidade de refrigeração;
- Temperatura de condensação: temperatura na qual o fluido refrigerante muda de fase no condensador, refletindo na capacidade de troca de calor para o ambiente;
- Pressão de condensação: pressão na qual o fluido refrigerante realiza a troca de fase no condensador. Uma temperatura de condensação elevada gera uma pressão elevada, resultando em um aumento do consumo de energia e desgaste prematuro do compressor;
- Pressão de sucção: pressão na qual o fluido refrigerante retorna ao compressor, diretamente relacionada a temperatura de evaporação;
- Superaquecimento: este é utilizado como um mecanismo de segurança, garantindo que o compressor succione apenas o vapor, evitando a entrada de refrigerante no estado líquido. Um nível de superaquecimento adequado estabiliza o ponto de operação do ciclo, ajudando a manter o equilíbrio entre a carga de calor e a capacidade do compressor;
- Sub-resfriamento: aumenta a quantidade de calor que o fluido refrigerante perde após a fase de condensação, aumentando a capacidade frigorífica do sistema.

Com os parâmetros definidos, a etapa de teste de avaliação do sistema de refrigeração (mini câmara fria) foi conduzida em um ambiente onde a temperatura externa variou entre 18 °C e 35 °C, representando as variações reais nas quais o equipamento possa ser submetido. Inicialmente, colocou-se o equipamento em operação com uma temperatura positiva no interior da câmara, a qual foi levado para a temperatura de operação normal, na faixa entre -10 °C e -25 °C. Os dados coletados durante este período de regime transitório foram descartados da análise, focando-se exclusivamente no comportamento do sistema em regime permanente. A

velocidade do compressor não sofreu alterações durante os testes, devido à utilização de um do tipo convencional (velocidade fixa).

Cada teste consistiu em realizar a operação normal do equipamento, seguida de uma falha natural ou induzida. A mini câmara fria foi instrumentada com dois sensores de temperatura e pressão. A localização específica dos pontos de medição de pressão e temperatura ao longo do sistema de refrigeração pode ser visualizada na Figura 19.

Figura 19 – Pontos de aquisição dos parâmetros do sistema de refrigeração



Fonte: Adaptado de Beghi, Cervato e Rampazzo (2015)

Os dados foram coletados por meio de um manômetro digital (Testo 570s) juntamente com o aplicativo oficial, onde foi possível acompanhar os parâmetros do sistema em tempo real. Este instrumento conta com dois sensores de pressão integrados ao manômetro e duas sondas de temperatura para realizar as medições no sistema, como ilustrado na Figura 20. As sondas de temperatura operam na faixa de $-50\text{ }^{\circ}\text{C}$ a $150\text{ }^{\circ}\text{C}$, com uma exatidão de $\pm 0,5\text{ }^{\circ}\text{C}$ e resolução de $0,1\text{ }^{\circ}\text{C}$. Enquanto os sensores de pressão possuem uma faixa de operação de -1 a 60 bar , com uma exatidão de $\pm 0,25\%$ e uma resolução de 10 mbar^1 . No aplicativo, pode-se realizar as configurações de medição, tais como: unidades de medida de pressão, temperatura e taxa de amostragem. A taxa de amostragem escolhida para os testes foi de 1 Hz (isto é, uma amostra por segundo), sendo esta a taxa padrão do equipamento para fins de manutenção ou desen-

¹ <https://www.testo.com/pt-BR/testo-570s/p/0564-5701>

volvimento. Ao término de cada teste, os dados coletados foram armazenados no aplicativo e exportados em um arquivo no formato *Comma Separated Values* (CSV).

Figura 20 – Manômetro e sondas de temperatura



Fonte: O autor (2026)

3.2.2 Conjunto de dados

Com o auxílio de uma ferramenta computacional e da linguagem de programação *Python*, descartaram-se os dados coletados em regime transitório, caracterizado pelo tempo em que a temperatura no interior da câmara permaneceu acima de 0 °C. Para a análise do regime permanente, considerou-se o período em que a temperatura interna da câmara se manteve na faixa de 0 °C a -20 °C, correspondente à faixa nominal de operação do equipamento. Durante essa etapa, foi realizada a inspeção dos dados para identificar a presença de valores ausentes, representados por *Not a Number* (NaN), que poderiam comprometer a qualidade e a confiabilidade das análises.

Para garantir a integridade do conjunto de dados, optou-se pela remoção desses valores faltantes utilizando a função *dropna*, disponibilizada pela biblioteca *Pandas*. Essa função permite eliminar linhas ou colunas que contenham valores nulos, garantindo que o conjunto de dados final esteja livre de inconsistências e pronto para as etapas subsequentes. O conjunto de dados resultante compreende 8 parâmetros do sistema de refrigeração, cada um com 379.206

amostras, totalizando um período de monitoramento de 105 horas. O conjunto de dados parcial pode ser visto no Apêndice A.

De acordo com Montgomery e Runger (2014), a caracterização da distribuição dos dados através de um sumário estatístico possibilita a identificação das tendências e a compreensão da dispersão dos valores atípicos que podem influenciar modelos preditivos. Dessa forma, elaborou-se um sumário estatístico para obter uma visão geral dos dados. A análise preliminar do conjunto de dados, conforme Tabela 1 revelou que os parâmetros não apresentaram um desvio padrão elevado, indicando uma dispersão relativamente baixa em torno de suas respectivas médias. Entretanto, a temperatura de sucção, o sub-resfriamento e o superaquecimento exibiram uma maior disparidade entre a média e a mediana, devido à maior amplitude e desvio padrão quando comparados entre si. Para validar essa constatação, obteve-se o coeficiente de variação, que resultou em 26,6%, 21,1% e 22,8%, respectivamente, mostrando uma dispersão moderada. No Apêndice B, podem ser encontrados os gráficos que ilustram a distribuição de cada um desses parâmetros.

Tabela 1 – Estatísticas descritivas das variáveis do sistema de refrigeração

Variável	Média	Desvio P.	Mín.	Máx.	Mediana	Moda
Baixa pressão [psi]	24,629	10,405	1,1	72,5	21,8	15,8
Temp. de evaporação [°C]	-23,27	6,381	-44,0	0,0	-24,6	-29,1
Temp. da linha de sucção [°C]	-8,06	12,012	-30,6	36,8	-10,2	-7,6
Superaquecimento [K]	15,21	12,060	0,0	72,0	12,0	10,4
Alta pressão [psi]	244,59	42,88	118,6	409,5	235,8	217,5
Temp. de condensação [°C]	38,65	6,54	13,6	60,6	37,6	34,5
Temp. da linha do líquido [°C]	35,42	6,16	23,2	57,6	34,5	24,5
Sub-resfriamento [K]	3,24	2,37	0,0	21,1	2,5	1,7

Fonte: O autor (2026).


3.2.3 Redução de Dimensionalidade

A partir da análise dos parâmetros, elaborou-se uma matriz de correlação com o objetivo de caracterizar o comportamento individual de cada parâmetro do sistema de refrigeração e investigar as interdependências existentes entre eles. Essa matriz se baseia no coeficiente de correlação de Pearson entre cada preditor e a variável alvo para identificar quais atributos apresentam maior associação. Segundo Ghiselli (1964), esse coeficiente mede a força e a direção da relação linear entre duas variáveis, sendo -1 uma correlação perfeita negativa, +1 perfeita positiva e 0 a ausência de correlação linear. Esse método permite definir um limiar para o valor absoluto da correlação, selecionando apenas as variáveis cuja associação com o alvo é considerada relevante. Os valores gerados pela matriz de correlação podem ser vistos na Figura 21.

Na sequência, foi realizada a redução da dimensionalidade com base no limiar de coeficiente de correlação superior a 0,95. Um novo conjunto de dados foi gerado, no qual três parâ-

metros foram removidos, restando apenas cinco do conjunto original. Este abrange as seguintes variáveis: baixa pressão, temperatura da linha de sucção, superaquecimento, temperatura de condensação e sub-resfriamento.

Figura 21 – Matriz de correlação



Fonte: O autor (2026)


O novo conjunto de dados passou por um processo de verificação da duração dos eventos, onde cada evento foi padronizado em um intervalo de 200 a 600 amostras, removendo os dados que encontravam-se fora dessa faixa. De forma que, ao eliminar os eventos de duração variável, evita-se uma possível introdução de vieses no aprendizado dos modelos. Para contornar isso, cada evento foi padronizado em um intervalo de 200 a 600 amostras, removendo os dados que se encontravam fora dessa faixa. Esse procedimento garante uma escala temporal uniforme, permitindo que o modelo se concentre nos padrões relevantes de cada classe, em vez de aprender as diferenças de duração. Ao uniformizar a duração dos eventos, as variações arbitrárias foram eliminadas, permitindo que o foco permanecesse apenas nas diferenças estruturais. Isso facilita a comparação direta entre as diferentes situações, contribuindo para a estabilidade e a capacidade de generalização dos classificadores. No Apêndice C, são apresentados os gráficos das grandezas monitoradas na mini câmara fria.

3.3 TREINAMENTO E AVALIAÇÃO DO APRENDIZADO DE MÁQUINA

A concepção do sistema de detecção e classificação de falhas pode ser dividida em duas etapas, denominadas treinamento e teste, conforme ilustrado na Figura 22. A etapa de treinamento tem como objetivo identificar as características relevantes e estimar os parâmetros do classificador, resultando na construção do modelo capaz de distinguir entre as diferentes

condições operacionais do sistema. A etapa de teste tem como finalidade avaliar o desempenho do modelo previamente treinado, verificando sua capacidade de generalização ao ser aplicada a dados não utilizados durante o treinamento. Para garantir uma avaliação imparcial, o conjunto de dados coletados é inicialmente dividido em dois subconjuntos mutuamente exclusivos: um destinado ao treinamento do modelo e outro reservado exclusivamente para a etapa de teste.

Figura 22 – Diagrama do processo de treinamento e teste do sistema de detecção e classificação de falhas.




Fonte: O autor (2026)

3.3.1 Divisão dos Dados

O conjunto de dados foi particionado em dois subconjuntos mutuamente exclusivos, sendo 70% das amostras destinadas à etapa de treinamento e os 30% restantes reservados para a etapa de teste. Essa divisão foi realizada para garantir que o modelo fosse treinado utilizando apenas o subconjunto de treinamento, enquanto o subconjunto de teste foi mantido completamente independente e utilizado exclusivamente para a avaliação de desempenho.

Como os dados coletados são uma série temporal, a divisão entre treinamento e teste não pode ser realizada selecionando as amostras de forma aleatória. Essa decisão deve-se à dependência temporal entre as amostras, na qual a ordem cronológica é fundamental para representar fielmente o comportamento do sistema. Para garantir a independência dos dados de treinamento e teste, os dados foram divididos com base nas sessões de coleta (segmento normal seguido pelo de falha). Essa estratégia assegura que todas as amostras de um mesmo grupo permaneçam juntas, prevenindo o vazamento de dados e evitando que amostras correlacionadas apareçam em ambos os conjuntos. Assim, preserva-se a coerência temporal, os padrões locais da série e evita-se *overfitting* decorrente da contaminação entre os conjuntos (Figura 23).

Figura 23 – Divisão de dados por seção.



Fonte: O autor (2026)

3.3.2 Etapa de Treinamento

Para a construção do modelo, foram avaliados dois algoritmos de aprendizagem: SVM e MLP. A seleção desses classificadores baseia-se em seu uso em trabalhos correlatos.

No caso do SVM, a seleção dos hiperparâmetros foi realizada a partir dos próprios dados de treinamento, utilizando o *F1-Score*, uma medida que fornece uma avaliação balanceada do desempenho, ponderando igualmente em classes majoritárias e minoritárias. Para cenários com classes desbalanceadas, essa métrica é mais apropriada. Após identificar a melhor combinação de hiperparâmetros, o modelo completo é executado e treinado novamente, utilizando todo o conjunto de dados de treinamento disponível.

O treinamento foi ajustado com o parâmetro *class_weight= 'balanced'*, que atribui pesos inversamente proporcionais à frequência das classes, forçando o algoritmo a focar nas classes minoritárias durante o processo de aprendizagem. Nesta etapa, ainda foi explorada a utilização de *kernels* distintos para determinar a fronteira de decisão mais adequada. Foram avaliados os *kernels* linear e o *Radial Basis Function* (RBF), cada um com características específicas para diferentes cenários de separação de classes. De acordo com Cristianini e Shawe-Taylor (2000), o *kernel* linear opera no espaço de entrada original, sendo eficaz quando as classes são aproximadamente separáveis por uma fronteira linear. Além disso, apresenta a vantagem da interpretabilidade, o que permite a inspeção direta dos coeficientes do modelo para analisar a importância de cada característica. Por outro lado, o RBF projeta os dados em um espaço de alta dimensão, o que viabiliza a separação de classes por fronteiras complexas e não lineares, essenciais para dados com relações intrínsecas mais complexas (scikit-learn developers, 2024).

A grade de valores definida para avaliação (C e γ) é apresentada na Tabela 2. O parâmetro γ do RBF controla a influência de cada ponto de treinamento, sendo que valores baixos resultam em uma influência de longo alcance, gerando fronteiras mais suaves, enquanto valores

mais altos criam fronteiras locais e intrincadas. O parâmetro de regularização (C) controla os *trade offs* entre a maximização dos erros de classificação. Valores baixos de C favorecem uma margem de separação de maior largura, priorizando a generalização, enquanto valores altos penalizam de forma mais severa os erros, o que pode levar a um ajuste excessivo (*overfitting*) aos dados de treinamento.

Tabela 2 – Valores utilizados por hiperparâmetro.

Parâmetro	Valores Avaliados
C	0,01; 0,1; 1; 10; 100
γ	0,01; 0,1; 1; 10

Fonte: O autor (2026)

Devido ao SVM ser um classificador binário, utilizou-se o método *One Versus One* (OVO) para classificar as múltiplas classes. Neste método, treina-se um classificador binário para cada par de classes.

No caso do MLP, a rede é definida como uma sequência de camadas densas (ocultas e de saída), que utiliza funções de ativação não lineares que permitem aprender relações complexas entre as entradas e os rótulos de cada classe. Para este estudo, a arquitetura foi parametrizada com diferentes configurações de camadas ocultas, sendo o número de neurônios por camada testado conforme a seguir:

- Uma camada oculta com 50 neurônios;
- Uma camada oculta com 100 neurônios;
- Duas camadas ocultas, sendo a primeira com 50 e a segunda com 100 neurônios.

A função de ativação adotada foi a *ReLU*, enquanto o treinamento foi realizado com o otimizador *Adam*, que ajusta dinamicamente a taxa de aprendizado de cada parâmetro por meio de médias móveis de primeira e segunda ordens, tornando o processo de descida do gradiente mais estável e eficiente. O tamanho do *batch* foi definido automaticamente pela implementação utilizada. Para a redução do *overfitting*, foi empregada a regularização L2, controlada pelo parâmetro α , juntamente com a parada antecipada (*early stopping*), interrompendo o treinamento caso não houvesse avanço no desempenho no conjunto de validação após 10 épocas. Nesse procedimento, foi utilizada uma fração de validação de 10% do conjunto de treinamento.

3.3.3 Etapa de Teste


Após a etapa de treinamento, o modelo foi submetido a um processo de teste para avaliar sua capacidade de generalização, ou seja, sua habilidade de classificar corretamente dados que

não foram utilizados durante o treinamento. Para isso, foram utilizados 30% dos dados não utilizados na etapa de treinamento.

O desempenho foi avaliado por meio de métricas amplamente utilizadas em trabalhos correlatos, incluindo acurácia, precisão, *recall* e *F1-Score*. Além dessas métricas, foi utilizada a matriz de confusão para a identificação de falsos positivos e negativos, bem como os padrões de confusão específicos entre pares de classes, fornecendo subsídios para a interpretação do comportamento do classificador.

Para avaliar comparativamente o desempenho do modelo proposto, o classificador SVM foi comparado a um modelo paramétrico amplamente utilizado, a rede neural MLP. Essa comparação permite verificar a eficácia do SVM em relação a uma abordagem baseada em redes neurais, fornecendo uma análise mais abrangente sobre a adequação do modelo para o problema de detecção e diagnóstico de falhas em sistemas de refrigeração. Na Figura 24, podem ser observadas as etapas utilizadas durante o teste, como a separação dos dados, a distribuição das amostras, a avaliação e a comparação.

Figura 24 – Diagrama do processo de teste do método proposto.



Fonte: O autor (2026)

4 RESULTADOS

O objetivo deste capítulo é apresentar e analisar o desempenho do sistema em dados novos, isto é, amostras que não foram utilizadas nas etapas de treinamento nem na seleção de parâmetros, de modo a garantir uma avaliação imparcial de sua capacidade de generalização. A Seção 4.1 apresenta os resultados obtidos com o classificador SVM, enquanto a Seção 4.2 descreve o desempenho do classificador MLP. Por fim, a Seção 4.3 apresenta uma análise comparativa entre os classificadores, destacando seus respectivos desempenhos.

4.1 SUPPORT VECTOR MACHINES

A Tabela 3 mostra os resultados utilizando o SVM. Os resultados foram separados de acordo com os hiperparâmetros: coeficiente do *kernel* (γ), regularização (C) e a técnica utilizada. Conforme Hastie, Tibshirani e Friedman (2009), a sintonia fina entre esses dois parâmetros define o equilíbrio entre viés e variância.

Tabela 3 – Resultados para o sistema utilizando SVM

Parâmetros			Média Macro			
<i>Kernel</i>	C	γ	Precisão	Recall	F1-score	Acurácia
Linear	0,01	–	0,908	0,906	0,897	0,907
Linear	0,1	–	0,927	0,931	0,924	0,933
Linear	1	–	0,928	0,936	0,929	0,938
Linear	10	–	0,930	0,940	0,934	0,942
Linear	100	–	0,933	0,940	0,934	0,942
RBF	0,1	0,01	0,888	0,882	0,868	0,884
RBF	0,1	0,1	0,922	0,923	0,916	0,925
RBF	0,1	1	0,945	0,948	0,944	0,948
RBF	0,1	10	0,972	0,976	0,974	0,976
RBF	1	0,01	0,921	0,922	0,915	0,924
RBF	1	0,1	0,944	0,949	0,945	0,951
RBF	1	1	0,970	0,973	0,971	0,974
RBF	1	10	0,988	0,990	0,989	0,990
RBF	10	0,01	0,945	0,950	0,946	0,951
RBF	10	0,1	0,962	0,950	0,963	0,966
RBF	10	1	0,981	0,984	0,982	0,984
RBF	10	10	0,993	0,994	0,993	0,994
RBF	100	0,01	0,952	0,958	0,954	0,959
RBF	100	0,1	0,969	0,973	0,971	0,974
RBF	100	1	0,989	0,990	0,989	0,990
RBF	100	10	0,993	0,994	0,993	0,994

Fonte: O autor (2026)

Os resultados mostram a capacidade de modelagem diante de problemas de fronteira complexa (não linear). Quando foi utilizado o kernel RBF combinado com os hiperparâmetros elevados ($C = 100$ e $\gamma = 10$), o modelo atingiu 99,4% de acurácia, indicando que apenas 0,6% foram classificados incorretamente. Esse desempenho superior decorre da capacidade do RBF de mapear os dados para um espaço de alta dimensionalidade, onde as classes se tornam facilmente separáveis. Em termos de precisão e *recall*, o SVM com kernel RBF demonstra ser uma combinação mais adequada, pois o classificador consegue minimizar tanto os falsos positivos quanto detectar os verdadeiros positivos. De acordo com os resultados da matriz de confusão da Figura 25, observa-se que houve falhas que foram confundidas com a operação normal. O erro mais frequente aparece na distinção entre a operação normal e as falhas 1 e 3. Isso se deve a transição de estados de operação de forma abrupta.

Figura 25 – SVM - RBF com $C = 100$ e $\gamma = 10$

	Normal	Falha1	Falha2	Falha3
Normal	3538	11	44	1
Falha1	14	4060	0	0
Falha2	11	0	2456	0
Falha3	5	1	0	4519
	Normal	Falha1	Falha2	Falha3

Fonte: O autor (2026)

Em contraste, quando utilizado o SVM linear, mesmo após aumentar o coeficiente de regularização até 100, resultou em uma acurácia de 94,2%. Esse valor penaliza fortemente os erros, tentando classificar todas as amostras corretamente, resultando em um modelo de menor margem, mais complexo e com maior risco de *overfitting*. A matriz de confusão na Figura 26 revela onde ocorreram classificações incorretas, como a operação normal, que enfrentou um número elevado de falsos negativos, com 4,7% das amostras classificadas como falha 1, 12,4% como falha 2 e 0,8% como falha 3. Essa dispersão indica que o hiperplano linear não foi capaz de capturar as fronteiras não lineares presentes nos dados. Para as classes de falhas, o modelo também apresentou um desempenho inferior ao do modelo não linear. A falha 1 obteve 2,5% falsos negativos classificados como normais, o que reduziu o *recall*, embora tenha mantido um

valor elevado de precisão quando predito corretamente. As falhas 2 e 3 também apresentaram classificações errôneas, porém em menor quantidade.

Figura 26 – SVM linear com $C = 100$

	Normal	Falha1	Falha2	Falha3
Normal	2952	170	445	27
Falha1	81	3993	0	0
Falha2	67	0	2400	0
Falha3	59	1	0	4465
	Normal	Falha1	Falha2	Falha3


Fonte: O autor (2026)

Para avaliar os indicadores operacionais associados aos estados monitorados, foi realizado um estudo utilizando o método SHAP agregado (média do valor absoluto entre as classes) no classificador SVM. A técnica utiliza os valores de *Shapley* para medir a importância das variáveis, baseada nos conceitos da teoria dos jogos, onde os valores das variáveis atuam como jogadores em coalizões. O artigo de Lundberg e Lee (2017) define que o objetivo da técnica é realizar uma distribuição justa do valor da predição entre os atributos de entrada, permitindo identificar com precisão o peso de cada componente na decisão final do classificador. De acordo com Molnar (2023), define-se como o método mais completo e teoricamente fundamentado de interpretabilidade em aprendizado de máquina.

Empregando, como explicador principal, a interface *shap.Explainer* aplicada sobre à função de predição do modelo. Como o objetivo era interpretar a saída probabilística do classificador, foi utilizada a função *predict_proba*; quando o modelo não disponibilizava essa saída de forma direta, recorreu-se à calibração probabilística por meio de *CalibratedClassifierCV*. Para a construção da referência (*background*), foram selecionadas amostras aleatórias do conjunto de treinamento, com tamanho definido de forma automática entre 50 e 200 instâncias, limitado a aproximadamente 5% do conjunto de treino, utilizando semente aleatória fixa igual a 42. As amostras explicadas também foram obtidas por amostragem aleatória do conjunto de teste, com limite de 300 observações. Em razão da natureza multiclasse do problema, os valores foram

tratados separadamente para cada classe, onde os positivos indicam que determinada variável contribui para aumentar a evidência da classe analisada, enquanto os negativos indicam uma contribuição contrária, reduzindo a propensão do modelo a atribuir aquela classe à amostra. Porém, foi gerada somente uma representação agregada multiclasse, mostrada na Figura 27. Permitindo identificar que a temperatura de condensação é a variável com o maior impacto médio nas previsões do modelo, seguida pelo superaquecimento e pela temperatura da linha de sucção. Stoecker e Jones (2002) relatam que essas variáveis devem se manter dentro do envelope operacional especificado; caso contrário, isso indica que o equilíbrio do ciclo foi alterado por algum agente externo ou falha. Em conjunto, essas três variáveis concentram a maior parte da variabilidade explicativa do classificador, na medida em que as variações de seus valores produzem os maiores deslocamentos nas probabilidades previstas. Por outro lado, as variáveis de baixa pressão e sub-resfriamento apresentaram uma importância média inferior, o que pode indicar menor informação preditiva direta ou redundância.

Figura 27 – SHAP média entre classes



Fonte: O autor (2026)

Durante a etapa de testes, constatou-se que as variáveis de baixa pressão e sub-resfriamento não apresentaram uma redução no desempenho preditivo do modelo. Dessa forma, o conjunto de dados pode ser novamente reduzido de cinco para três parâmetros para a detecção e classificação de falhas, tornando-o menos suscetível ao *overfitting*.

4.2 MULTI-LAYER PERCEPTRON

O MLP emprega uma arquitetura de *perceptron* de múltiplas camadas com regularização L2 (penalização *Ridge* - α) e diferentes taxas de aprendizado (η) para avaliar a robustez frente às configurações de treinamento. A Tabela 4 apresenta os resultados para diferentes configurações.

Com $\alpha = 0,001$ e $\eta = 0,001$, a rede neural alcançou 97,8% de acurácia, mantendo a precisão e o *recall* em torno de 98%. Esses resultados demonstram que o MLP não conseguiu

capturar a separação não linear inerente dos dados com a mesma precisão que o SVM com RBF. Adicionalmente, observou-se que o MLP é mais sensível a escolhas como o número de camadas, a quantidade de neurônios, o tamanho do *batch* e o critério de parada.

Tabela 4 – Resultados para o sistema utilizando MLP

Classe			Média Macro			
MLP α	MLP η	Nº de neurônios	Precisão	Recall	F1-score	Acurácia
0,0001	0,001	50	0,968	0,969	0,968	0,971
0,0001	0,001	100	0,965	0,968	0,966	0,969
0,0001	0,01	50	0,967	0,970	0,969	0,971
0,0001	0,01	100	0,970	0,973	0,971	0,974
0,001	0,001	50	0,968	0,970	0,969	0,972
0,001	0,001	100	0,965	0,968	0,966	0,969
0,001	0,01	50	0,967	0,970	0,968	0,971
0,001	0,01	100	0,964	0,968	0,966	0,969
0,0001	0,001	50-100	0,977	0,976	0,977	0,978
0,0001	0,01	50-100	0,973	0,977	0,974	0,977
0,001	0,001	50-100	0,977	0,976	0,977	0,978
0,001	0,01	50-100	0,969	0,970	0,969	0,972


Fonte: O autor (2026)

Em termos gerais, o classificador apresenta um índice elevado de acertos (Figura 28). Para as quatro classes de operação, a maior ficou na diagonal principal, indicando previsões corretas. No caso da falha 1, o classificador identificou corretamente 95% dos casos. Porém, houve algumas classificações falsas para as falhas 2 e 3. Esses erros indicam que o MLP, embora seja preciso para a falha 1, confunde um pequeno subconjunto de exemplos que estão próximos à fronteira de decisão com as classes vizinhas, em especial com a falha 2. Para essa falha, o classificador demonstrou um desempenho ótimo, indicando uma delimitação clara do espaço de características. Quanto à falha 2, foram observados 2,5% dos casos de classificação errônea, sendo confundida com a operação normal, mostrando similaridade ou pontos de transição entre essas categorias. Não houve confusões com as falhas 1 e 3. Este padrão reforça a ideia de que a falha 2 se sobrepõe minimamente às demais, mas ainda compartilha algumas regiões de características com a operação normal. Por fim, a falha 3 apresentou um índice elevado de desempenho. O fato de todas as confusões ocorrerem unicamente durante a operação normal indica que, embora separáveis, existem regiões onde as características se aproximam.

4.3 COMPARATIVO ENTRE CLASSIFICADORES

Os classificadores mostraram um padrão recorrente, onde ambos apresentam erros significativos envolvendo a operação normal e as falhas 1 e 2. Esse comportamento mostrou que a fronteira entre os eventos foi o principal ponto de dificuldade na separabilidade, resultando

Figura 28 – MLP com $\alpha = 0,001$ e $\eta = 0,001$



Fonte: O autor (2026)

em interpretações por parte de cada modelo. Essa diferença sugere que o SVM encontrou uma melhor fronteira de decisão para separar as regiões críticas no espaço de características. No caso do MLP, notou-se o aumento de falsos positivos e negativos, onde a operação normal foi erroneamente caracterizada como falha 1 e 2, reduzindo o *recall*, conforme apresentado na Tabela 5. No SVM, esses erros também existem, mas com uma frequência consideravelmente menor. A falha 3 apresentou um desempenho ótimo em ambos os modelos, sugerindo que as características que a definem são altamente discriminantes. Consequentemente, a maioria dos erros de classificação não se origina dessa classe, mas sim da região de interseção entre eventos.

Tabela 5 – Comparativo dos resultados obtidos pelos modelos

Classe	Média Macro SVM			Média Macro MLP		
	Precisão	Recall	F1-score	Precisão	Recall	F1-score
Normal	0,992	0,984	0,988	0,957	0,955	0,956
Falha 1	0,997	0,997	0,997	0,983	0,989	0,986
Falha 2	0,982	0,996	0,989	0,977	0,967	0,972
Falha 3	1,000	0,999	0,999	0,992	0,994	0,993

Fonte: O autor (2026)

Os resultados obtidos neste trabalho demonstram um desempenho competitivo em relação aos autores citados no referencial teórico. O modelo SVM alcançou um F1-score de 99%, índice equiparável aos resultados de Chen *et al.* (2023a), que obteve acurácia entre 95% e 99%.

Além disso, o desempenho superou o reportado por Soltani, Soerensen e Leth (2021), cujos classificadores apresentaram acurácias entre 86% e 95% com o SVM e por fim, 55% com o PCA-SVM. Nesse caso, os autores citados utilizaram um conjunto de dados balanceado, enquanto o trabalho desenvolvido utilizou um conjunto de dados desbalanceado.

Adicionalmente, o MLP apresentou um *F1-score* de 97%, o que foi muito próximo do obtido pelo modelo de CNN Soltani *et al.* (2020), que apresentou 99%. É relevante observar, contudo, que os classificadores reportados por Soltani, Soerensen e Leth (2021), Soltani *et al.* (2020), Chen *et al.* (2023a) foram submetidos a cenários de maior complexidade, classificando 2, 5 e 8 classes, respectivamente, em contraste com as 4 avaliadas neste trabalho. Soma-se a isso o fato de que o volume superior de amostras e a diversidade operacional dos sistemas de refrigeração testados exercem influência direta no desempenho dos classificadores. Uma vez que uma arquitetura específica impõe padrões distintos de comportamento às variáveis monitoradas. O Quadro 3 apresenta os resultados dos autores citados no referencial teórico e os índices alcançados no presente trabalho.

Quadro 3 – Resultados do método proposto e dos trabalhos correlatos

Autor	Modelo	Nº de classes	Conjunto de dados	Avaliação e Desempenho
Chen	SVM	8	Balanceado	Acurácia 0,99
O autor	SVM	4	Desbalanceado	F1-score 0,99
O autor	MLP	4	Desbalanceado	F1-score 0,97
Soltani	CNN	5	Desbalanceado	F1-score 0,99
Soltani	PCA-SVM	2	Balanceado	Acurácia 0,55
Soltani	SVM	2	Balanceado	Acurácia 0,94

Fonte: O autor (2026)

Resumidamente, os erros apresentados são uma combinação da sobreposição da operação normal e das falhas (Apêndice D), somadas às diferenças na capacidade de treinamento e generalização dos classificadores. Enquanto o SVM demonstrou maior robustez ao estabelecer fronteiras de decisão precisas, o MLP evidenciou uma vulnerabilidade às regiões de interseção, resultando na redução do *recall*. Os resultados validam a escolha do SVM para este problema, mas posicionam a metodologia de forma competitiva em relação aos trabalhos de referência.

Destaca-se que os resultados obtidos neste trabalho limitam-se ao sistema avaliado, operando nas condições específicas do regime de operação da mini câmara fria. Embora o modelo proposto tenha apresentado elevado desempenho na detecção e diagnóstico de falhas, sua aplicação a outros sistemas de refrigeração deve ser conduzida com cautela, avaliando a capacidade de generalização do modelo devido às diferenças construtivas e cenários operacionais.

5 CONCLUSÃO

A partir do estudo teórico apresentado neste trabalho, foi possível reforçar a relevância da aplicação de técnicas de aprendizado de máquina na detecção e diagnóstico em sistemas de refrigeração, especialmente no que tange à transição de modelos de manutenção corretiva para um baseado em dados, como o preditivo. O conjunto de dados estudado mostra que variáveis como temperatura, pressão e superaquecimento são fundamentais para caracterizar o estado operacional, pois apresentam correlações e padrões distintos dos estados de operação de um sistema de refrigeração, sendo possível tomar as devidas decisões de manutenção.

Para viabilizar a aplicação dos modelos, foi utilizado um sistema de aquisição de dados que coletou medições periódicas de uma mini câmara fria, formando o conjunto de dados. Esse conjunto de dados, utilizado para o treinamento e validação, garantiu a representatividade das condições de regime permanente estudadas. Os parâmetros de operação e os limiares para a caracterização do estado normal de operação e das falhas detectadas (Superaquecimento elevado, Superaquecimento baixo e Temperatura de Condensação elevada) foram definidos com base nas propriedades termodinâmicas do fluido refrigerante R404a, permitindo rotular os eventos e construir um conjunto de dados consistente para o problema de classificação multiclasse.

Este trabalho comparou classificadores tradicionais, tais como o SVM e o MLP. O SVM com o *kernel* RBF alcançou o melhor desempenho com um *F1-Score* de 0,994, demonstrando que as falhas no equipamento podem ser detectadas e diagnosticadas com eficácia a partir de sensores de temperatura e pressão coletadas no ambiente real. Diante disso, optou-se pelo uso do SVM, que generaliza bem cenários com o conjunto de dados moderados.

O sistema proposto mostrou-se capaz de suportar a detecção automatizada de anomalias, validando a proposta como uma ferramenta para a manutenção preditiva em sistemas de refrigeração. Para ampliar o impacto e a aplicabilidade do trabalho, sugere-se, como complementos e trabalhos futuros:

- Implementar uma solução embarcada com *hardware* dedicado e uma interface;
- Expandir a base de dados coletada com diferentes fluidos refrigerantes;
- Validar o sistema em sistemas de refrigeração de maior escala;
- Integrar previsões de vida útil restante dos componentes.

REFERÊNCIAS

AL-KHAZRAJI, M. M. M. H. A two-stage model for condition-based maintenance using machine learning algorithms. **International Journal of Performability Engineering**, Int J Performability Eng, v. 21, n. 8, p. 422, 2025. Disponível em: <https://www.ijpe-online.com/EN/abstract/article_4950.shtml>.

AMERICAN SOCIETY OF HEATING AND AIR-CONDITIONING ENGINEERS (ASHRAE). **Historical Timeline of Refrigeration**. 2024. Disponível em: <<https://www.ashrae.org/about/mission-and-vision/ashrae-industry-history/air-conditioning-and-refrigeration-timeline/>>. Acesso em: 21 fev 2026.

ARORA, C. P. **Refrigeration & Air Conditioning**. 1ª. ed. New Delhi, India: Prentice Hall, 2010.

ASHRAE. **ASHRAE Handbook: Fundamentals (IP Edition)**. Atlanta, GA: American Society of Heating Refrigerating and Air-Conditioning Engineers, 2017.

ASHRAE. **ANSI/ASHRAE Standard 34: Designation and Safety Classification of Refrigerants**. Atlanta: American Society of Heating, Refrigerating and Air-Conditioning Engineers, 2022.

ASSOCIAÇÃO BRASILEIRA DE REFRIGERAÇÃO, AR CONDICIONADO, VENTILAÇÃO E AQUECIMENTO. **Revista ABRAVA: Climatização e Refrigeração**. 2023. Disponível em: <<https://abrava.com.br/wp-content/uploads/2023/07/Revista-ABRAVA-Julho2023.pdf>>. Acesso em: 23 mar 2026.

BEGHI, A.; CERVATO, A.; RAMPAZZO, M. A remote refrigeration laboratory for control engineering education. **IFAC-PapersOnLine**, 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896315024660>>.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. Nova Iorque: Springer, 2006.

BOUTAHRI, Y.; TILIOUA, A. Machine learning-based predictive model for thermal comfort and energy optimization in smart buildings. **Results in Engineering**, 2024. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S259012302400402X>>.

BRASIL. Ministério do Meio Ambiente. **Programa Brasileiro de eliminação dos HCFCs-PBH: treinamento e capacitação para boas práticas em sistemas de ar condicionado do tipo Split**. [S.l.], 2015. Disponível em: <<https://boaspraticasrefrigeracao.com.br/upload/publicacao/publicacao-1591955146.pdf>>.

CARVALHO, T. P. *et al.* A systematic literature review of machine learning methods applied to predictive maintenance. **Computers and Industrial Engineering**, 2019. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835219304838>>.

CHEN, Y. *et al.* Generalizability of machine learning-based fault classification for residential air-conditioners. **Energy and Buildings**, 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378778823004930>>.

CHEN, Z. *et al.* A review of data-driven fault detection and diagnostics for building hvac systems. **Applied Energy**, 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S030626192300394X>>.

CRISTIANINI, N.; SHAW-TAYLOR, J. **An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods**. 1ª. ed. Cambridge, UK: Cambridge University Press, 2000.

DANFOSS. **Overview Brochure Thermostatic Expansion Valves**. [S.l.], 2024. Disponível em: <<https://assets.danfoss.com/documents/94277/AD135086437198pt-000404.pdf>>.

DOSSAT, R. J. **Princípios de Refrigeração**. 1ª. ed. São Paulo, SP: Hemus, 2007.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. [S.l.]: Wiley, 2001.

FUJISAWA, C. H. *et al.* **Instrumentação e Automação Industrial**. Porto Alegre: SAGAH, 2022. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9786556902081/>>.

GHISELLI, E. E. **Theory of Psychological Measurement**. New York: McGraw-Hill, 1964.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. [S.l.]: MIT press, 2016.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning**. [S.l.]: Springer, 2009.

HECTOR, I.; PANJANATHAN, R. Predictive maintenance in industry 4.0: a survey of planning models and machine learning techniques. **PeerJ Computer Science**, v. 10, 2024. Disponível em: <<https://doi.org/10.7717/peerj-cs.2016>>.

HONEYWELL. **Genetron® 404A Technical Datasheet**. [S.l.], 2007. Disponível em: <<https://www.honeywell-refrigerants.com/europe/wp-content/uploads/2013/03/honeywell-genetron-404a-technical-datasheet.pdf>>.

IPCC. **Climate Change: The IPCC Scientific Assessment**. Cambridge, UK: Cambridge University Press, 1990.

JARDINE, A. K.; LIN, D.; BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, 2006. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0888327005001512>>.

KATIPAMULA, S.; BRAMBLEY, M. R. Review article: Methods for fault detection, diagnostics, and prognostics for building systems—a review, part ii. **HVAC&R Research**, Taylor & Francis, v. 11, n. 2, p. 169–187, 2005. Disponível em: <<https://doi.org/10.1080/10789669.2005.10391133>>.

KOMEKO. **Auto Diagnóstico de Condicionadores de ar**. [S.l.], 2024. Disponível em: <<https://www.komeco.com.br/portaltecnico/LINHA%20DE%20CONDICIONADORES%20DE%20AR/Auto%20Diagnostico/AUTO%20DIAGNOSTICO%20CONDICIONADORES%20AR%20SPLIT.pdf>>.

LI, D.; HU, G.; SPANOS, C. J. A data-driven strategy for detection and diagnosis of building chiller faults using linear discriminant analysis. **Energy and Buildings**, 2016. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378778816306107>>.

LUNDBERG, S. M.; LEE, S.-I. A unified approach to interpreting model predictions. **Advances in Neural Information Processing Systems**, v. 30, 2017.

MATETIĆ, I. *et al.* A review of data-driven approaches and techniques for fault detection and diagnosis in hvac systems. **Sensors**, v. 23, 2023. Disponível em: <<https://www.mdpi.com/1424-8220/23/1/1>>.

MILLER, R.; MILLER, M. R. **Ar Condicionado e Refrigeração**. 2ª. ed. [S.l.]: Editora McGraw-Hill Education, 2006.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997. ISBN 9780070428072.

MOLNAR, C. **Interpreting Machine Learning Models with SHAP: A Guide with Python Examples and Theory on Shapley Values**. München, Germany: Christoph Molnar, 2023.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. 6th. ed. [S.l.]: Wiley, 2014.

MOUBRAY, J. **Manutenção Centrada em Confiabilidade**. [S.l.]: Industrial Press, 1997.

MOURTZIS, D.; ANGELOPOULOS, J.; PANOPOULOS, N. Design and development of an iot enabled platform for remote monitoring and predictive maintenance of industrial equipment. **Procedia Manufacturing**, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S235197892100161X>>.

MURPHY, K. P. **Machine Learning: A Probabilistic Perspective**. Cambridge, MA: MIT Press, 2012. ISBN 9780262018029.

PEREIRA, J. F.; HORTA, E. G.; MENDES, T. Detecção de falhas em um sistema de refrigeração por compressão de vapor. In: **Anais do XII Congresso Brasileiro de Inteligência Computacional (CBIC)**. Sociedade Brasileira de Inteligência Artificial, 2015. Disponível em: <https://sbic.org.br/wp-content/uploads/2016/01/cbic2015_submission_45.pdf>.

PHUNG, V. H.; RHEE, E. J. A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. **Applied Sciences**, 2019. Disponível em: <<https://www.mdpi.com/2076-3417/9/21/4500>>.

SAMMUT, C.; WEBB, G. I. **Encyclopedia of Machine Learning**. [S.l.]: Springer, 2011.

SCIKIT-LEARN. **Guia do usuário de aprendizado supervisionado**. 2025. Disponível em: <https://scikit-learn.org/stable/supervised_learning.html>. Acesso em: 10 out 2025.

scikit-learn developers. **scikit-learn: Support Vector Machines**. [S.l.], 2024.

SEJNOWSKI, T. **A Revolução do Aprendizado Profundo**. Rio de Janeiro: Editora Alta Books, 2020.

SICSU, A. L.; SAMARTINI, A.; BARTH, N. L. **Técnicas de machine learning**. São Paulo: Editora Blucher, 2023. Disponível em: <<https://integrada.minhabiblioteca.com.br/reader/books/9786555063974/>>.

- SOLTANI, Z. Automatic fault detection and diagnosis in refrigeration systems, a data-driven approach. **Ph.d.-serien for Det Tekniske Fakultet for IT og Design, Aalborg Universitet**, Aalborg Universitetsforlag, 2023. Disponível em: <<https://vbn.aau.dk/en/publications/automatic-fault-detection-and-diagnosis-in-refrigeration-systems/>>.
- SOLTANI, Z.; SOERENSEN, K. K.; LETH, J. Robustness analysis of pca-svm model used for fault detection in supermarket refrigeration systems. In: **2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)**. [S.l.]: IEEE (Institute of Electrical and Electronics Engineers), 2021.
- SOLTANI, Z. *et al.* Fault detection of supermarket refrigeration systems using convolutional neural network. In: **IECON 2020 - The 46th Annual Conference of the IEEE Industrial Electronics Society**. [S.l.]: IEEE, 2020. p. 231–238.
- STOECKER, W. F.; JABARDO, J. M. S. **Refrigeração Industrial**. 3ª. ed. Editora Blucher, 2018. Acesso em: 27 jun. 2024. Disponível em: <<https://integra-da.minhabiblioteca.com.br/#/books/9788521212652/>>.
- STOECKER, W. F.; JONES, J. W. **Refrigeração e Ar Condicionado**. 2ª. ed. [S.l.]: Editora McGraw-Hill, 2002.
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4ª. ed. [S.l.]: Academic Press, 2008.
- UNEP. **Montreal Protocol on Substances that Deplete the Ozone Layer**. Montreal, 1987.
- United Nations. **Kyoto Protocol to the United Nations Framework Convention on Climate Change**. Kyoto: [s.n.], 1997.
- WANG, S.; XIAO, F. Ahu sensor fault diagnosis using principal component analysis method. **Energy and Buildings**, 2004. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378778803001178>>.
- WEBB, A. R. **Statistical Pattern Recognition**. [S.l.]: John Wiley & Sons, 2011.
- WIDODO, A.; YANG, B.-S. Support vector machine incondition monitoring and fault diagnosis. **Mechanical Systems and Signal Processing**, 2007.
- ZHENGXIONG, R. *et al.* Application of pso-lssvm and hybrid programming to fault diagnosis of refrigeration systems. **Science and Technology for the Built Environment**, 2021. Disponível em: <<https://doi.org/10.1080/23744731.2020.1859933>>.
- ÇENGEL, Y.; GHAJAR, A. **Transferência de Calor e Massa: Uma Abordagem Prática**. 4ª. ed. [S.l.]: Editora McGraw-Hill, 2012.

APÊNDICE A – CONJUNTO DE DADOS


Tabela 6 – Conjunto parcial de dados

Amostra	Psuc [psi]	tev [°C]	tsuc [°C]	Sh [K]	Pliq [psi]	tcd [°C]	tliq [°C]	Sc [K]
1	28.1	-20.4	-2.5	17.9	215.2	34.1	24.3	9.9
2	28.1	-20.5	-2.7	17.8	215.2	34.1	24.3	9.9
3	28.1	-20.5	-2.7	17.8	215.2	34.1	24.3	9.9
4	28.1	-20.5	-2.8	17.7	215.2	34.1	24.3	9.9
5	28.1	-20.5	-2.8	17.7	215.2	34.1	24.3	9.9
6	28.0	-20.5	-2.9	17.6	215.3	34.1	24.3	9.9
7	28.0	-20.5	-2.9	17.6	215.3	34.1	24.3	9.9
8	28.0	-20.5	-2.9	17.6	215.3	34.1	24.3	9.9
9	28.0	-20.5	-3.0	17.5	215.1	34.1	24.3	9.8
10	28.0	-20.5	-3.0	17.5	215.1	34.1	24.3	9.8
11	28.0	-20.5	-3.0	17.5	215.1	34.1	24.3	9.8
12	28.0	-20.5	-3.0	17.5	215.1	34.1	24.3	9.8
13	28.0	-20.5	-3.1	17.4	215.0	34.1	24.3	9.8
14	28.0	-20.5	-3.1	17.4	215.0	34.1	24.3	9.8
15	28.0	-20.5	-3.2	17.3	214.9	34.1	24.3	9.8
16	28.0	-20.5	-3.2	17.3	214.9	34.1	24.2	9.8
17	28.0	-20.5	-3.2	17.3	214.8	34.1	24.2	9.8
18	28.0	-20.5	-3.2	17.3	214.8	34.1	24.2	9.8
19	27.9	-20.6	-3.3	17.3	214.7	34.0	24.2	9.8
20	27.9	-20.6	-3.4	17.2	214.6	34.0	24.2	9.8
21	28	-20.5	-3.2	17.3	214.8	34.1	24.2	9.8
22	27.9	-20.6	-3.3	17.3	214.7	34.0	24.2	9.8
23	27.9	-20.6	-3.4	17.2	214.6	34.0	24.2	9.8
24	27.8	-20.6	-3.4	17.2	214.5	34.0	24.2	9.8
25	27.8	-20.6	-3.4	17.2	214.5	34.0	24.2	9.8
26	27.8	-20.7	-3.5	17.2	214.4	34.0	24.2	9.7
27	27.7	-20.7	-3.5	17.2	214.3	34.0	24.2	9.7
28	27.7	-20.7	-3.6	17.1	214.3	34.0	24.2	9.7
29	27.7	-20.7	-3.6	17.1	214.2	34.0	24.2	9.7
30	27.7	-20.7	-3.6	17.1	214.1	33.9	24.2	9.7
31	27.7	-20.7	-3.6	17.1	214.0	33.9	24.2	9.7
32	27.7	-20.7	-3.7	17.0	214.0	33.9	24.2	9.7
33	27.7	-20.7	-3.7	17.0	213.9	33.9	24.2	9.7
34	27.7	-20.7	-3.7	17.0	213.8	33.9	24.2	9.6
35	27.7	-20.7	-3.8	16.9	213.8	33.9	24.2	9.6
36	27.7	-20.7	-3.8	16.9	213.8	33.9	24.2	9.6
37	27.7	-20.7	-3.8	16.9	213.7	33.9	24.2	9.6
38	27.7	-20.7	-3.9	16.8	213.7	33.9	24.2	9.6
39	27.7	-20.7	-3.9	16.8	213.7	33.9	24.2	9.6
40	27.7	-20.7	-4.0	16.7	213.6	33.9	24.2	9.6
41	27.7	-20.7	-4.0	16.7	213.6	33.8	24.2	9.6
...	...	...	...	...	...	...	...	...
379194	22.0	-24.4	-20.8	3.6	269.4	42.9	36.2	6.7
379195	22.0	-24.4	-20.8	3.6	269.4	42.9	36.2	6.7
379196	22.0	-24.5	-20.8	3.7	269.4	42.9	36.2	6.7
379197	22.0	-24.5	-20.9	3.6	269.5	42.9	36.2	6.7
379198	22.0	-24.5	-20.9	3.6	269.5	42.9	36.2	6.7
379199	21.9	-24.5	-21.0	3.5	269.5	42.9	36.2	6.7
379200	21.9	-24.5	-21.1	3.4	269.5	42.9	36.2	6.7
379201	21.9	-24.5	-21.1	3.4	269.5	42.9	36.2	6.7
379202	21.9	-24.5	-21.1	3.4	269.5	42.9	36.2	6.7
379203	21.9	-24.5	-21.2	3.3	269.5	42.9	36.2	6.7
379204	21.9	-24.5	-21.2	3.3	269.5	42.9	36.2	6.7
379205	21.9	-24.5	-21.2	3.3	269.5	42.9	36.2	6.7
379206	21.9	-24.5	-21.3	3.2	269.5	42.9	36.2	6.8

Fonte: O autor (2025)

APÊNDICE B – ANÁLISE ESTATÍSTICA DOS DADOS


Figura 29 – Dados estatísticos dos parâmetros



Fonte: O autor (2025)

APÊNDICE C – GRÁFICOS DAS OPERAÇÕES


Figura 30 – Operação normal seguida das falhas 1, 2 e 3



Fonte: O autor (2025)

APÊNDICE D – RESULTADO COMPARATIVO ENTRE SVM E MLP

Figura 31 – Comparativo real x previsto entre SVM e MLP



Fonte: O autor (2025)

ANEXO A – PRESSÃO DE SATURAÇÃO DO R404A EM FUNÇÃO DA TEMPERATURA

Tabela 7 – Saturação do fluido refrigerante R404a

Temperatura de saturação [°C]	Pressão em estado líquido [psig]	Pressão em estado de vapor [psig]
-30	15.1	14.2
-28	18.3	17.4
-26	20.9	19.7
-24	23.7	22.8
-22	26.3	25.3
-20	29.8	28.8
-18	33.7	32.6
-16	37.5	36.3
-14	40.9	39.8
-12	45.0	43.9
-10	49.0	47.9
-8	52.7	50.6
-6	57.9	56.4
-4	63.7	61.7
-2	67.8	66.4
0	73.8	71.8
2	80.2	78.7
4	88.0	86.0
6	92.2	90.6
8	97.6	96.3
10	105.3	103.6
12	113.3	111.6
14	119.5	117.8
16	128.2	126.4
18	135.0	133.2
20	144.4	142.6
22	154.3	152.4
24	162.0	160.1
26	172.7	170.8
28	181.0	179.0
30	192.5	190.4
32	204.5	202.4
34	213.8	211.7
36	226.7	224.6
38	239.0	236.9
40	250.6	248.5

Fonte: Adaptado de Honeywell (2007)