

Implementação de Inteligência Artificial para Otimização e Prevenção de falhas em Sistemas de Refrigeração

Amanda Aparecida Alves Silva, silva.amanda@ufvjm.edu.br^{*},
José Ricardo Ferreira Oliveira, jose.ricardo@ufvjm.edu.br¹,
Euler Guimarães Horta, euler.horta@ufvjm.edu.br¹,
Tiago Mendes, tiago.mendes@ufvjm.edu.br¹

¹Universidade Federal dos Vales do Jequitinhonha e Mucuri, Instituto de Ciência e Tecnologia. Rodovia MGT 367 – Km 583, 5000, Alto da Jacuba, Diamantina/MG, CEP 39100-000.

Resumo. A eficiência dos sistemas de refrigeração comerciais e industriais é de extrema importância para garantir a qualidade dos produtos e a redução dos custos operacionais. No entanto, a detecção de falhas nesses sistemas pode ser de difícil obtenção, sendo muitas vezes necessária a intervenção de técnicos com ferramentas especializadas. Com o avanço da inteligência artificial (IA), é possível desenvolver ferramentas que realizam o diagnóstico de falhas nesses sistemas, permitindo a manutenção preditiva e corretiva de maneira mais rápida e eficiente. Este artigo apresenta o desenvolvimento de uma ferramenta de diagnóstico para sistemas de refrigeração comerciais e industriais utilizando IA. A ferramenta proposta visa identificar tais falhas, podendo assim traçar uma estratégia para correção das mesmas.

Palavras chave: Inteligência artificial. Sistemas de Refrigeração. Detecção e diagnóstico de falhas.

Abstract. The efficiency of commercial and industrial refrigeration systems is extremely important to ensure product quality and reduce operating costs. However, fault detection in these systems can be difficult to achieve, often requiring the intervention of technicians with specialized tools. With the advancement of artificial intelligence (AI), it is possible to develop tools that diagnose faults in these systems, allowing predictive and corrective maintenance to be carried out more quickly and efficiently. This article presents the development of a diagnostic tool for commercial and industrial refrigeration systems using AI. The proposed tool aims to identify such faults, thus being able to outline a strategy for correcting them.

Keywords: Artificial intelligence. Refrigeration systems. Fault detection and diagnosis.

1. INTRODUÇÃO

Os sistemas de refrigeração desempenham um papel vital em inúmeras indústrias, incluindo a alimentícia, química e de processos, representando uma parcela significativa do consumo total de energia elétrica (Mendes, 2018; Abdelaziz et al., 2011). No entanto, estes são suscetíveis a falhas que podem comprometer a sua eficiência, desencadeando diversos problemas, como o aumento do consumo de energia e o desgaste prematuro dos componentes (Katipamula e Brambley, 2005a). Dessa forma, a utilização da inteligência artificial, tem permitido a criação de ferramentas avançadas de monitoramento e diagnóstico, capazes de prever falhas antes que causem prejuízos significativos.

A operação inadequada de sistemas de refrigeração leva a um desgaste prematuro dos componentes e a um maior consumo de energia. Esses problemas são devidos a equipamentos degradados, manutenção incorreta ou até mesmo degradações em sensores. Portanto existe uma crescente necessidade de controlar e operar esses equipamentos com a maior segurança e confiabilidade possível, devido à grande quantidade e a maior complexidade dos mesmos (Mendes, 2018). Essas exigências levam ao desenvolvimento de metodologias para o monitoramento dos sistemas de refrigeração.

A utilização de IA para a análise de dados operacionais desses sistemas possibilita o desenvolvimento de soluções mais inteligentes e ágeis, que não apenas detectam falhas e, mas também sugerem ações corretivas. Esse diagnóstico automatizado melhora a eficiência da manutenção, reduzindo o tempo de estagnação e, consequentemente, os custos operacionais.

Este trabalho propõe o desenvolvimento de uma ferramenta baseada em algoritmos de aprendizado de máquina, capaz de detectar e classificar falhas em sistemas de refrigeração com alta precisão, utilizando dados operacionais

coletados automaticamente.




Figura 1: Representação esquemática de um sistema de refrigeração por compressão mecânica de vapor (Mendes, 2018)

2. METODOLOGIA

O trabalho foi desenvolvido baseado em três etapas principais, sendo elas coleta de dados, desenvolvimento do modelo e da rede neural, e a etapa de treinamento, validação e testes, como é possível observar na Fig 02.



Figura 2: Fluxograma representativo da criação de uma rede neural

A ferramenta de diagnóstico foi desenvolvida utilizando técnicas de aprendizado de máquina (machine learning) aplicadas a um sistema de refrigeração por compressão mecânica de vapor. O sistema modelado inclui os seguintes componentes principais: compressor, condensador, válvula de expansão termostática e evaporador. O sistema opera com HCFC-22 como fluido refrigerante e utiliza uma torre de resfriamento para rejeição de calor. As características técnicas dos componentes foram baseadas em dados de fabricantes, garantindo a representatividade do modelo em relação a sistemas reais (Mendes, 2018).

As especificações foram feitas visto que o resultado do projeto é um problema de classificação, estando voltado para a detecção de degradações de um sistema de refrigeração. Foram estabelecidas 16 condições operacionais: 15 correspondem a situações de testes de degradação e 1 à condição de referência, ou seja, sem degradação. Para essas classes, os 1.196 padrões, todos com um número igual de grandezas operacionais. Isso indica que cada padrão possui um conjunto uniforme de características. Alguns desses padrões mostram a condição de referência e as situações de degradação nos componentes do sistema, como por exemplo, os componentes: compressor, condensador e evaporador.

A Tab. 01 apresenta as condições de cada dispositivo em relação as condições de degradação apresetadas.

Tabela 1: Condições operacionais *of-design* do sistema de refrigeração, (adaptada de Mendes,2018.)

Condição	Degradação(Classificação)
0 referência	Sem degradação
1 teste(cmp)	Degradação no compressor
2 teste(cnd)	Degradação no condensador
3 teste(vlv)	Degradação na válvula
4 teste(evap)	Degradação no evaporador
5 teste	Degradação no compressor e condensador
6 teste	Degradação no compressor e válvula
7 teste	Degradação no compressor e evaporador
8 teste	Degradação no condensador e válvula
9 teste	Degradação no condensador e no evaporador
10 teste	Degradação na válvula e evaporador
11 teste	Degradação no compressor, condensador e válvula
12 teste	Degradação no compressor, condensador e evaporador
13 teste	Degradação no compressor, válvula e evaporador
14 teste	Degradação no condensador, válvula e evaporador
15 teste	Degradação no compressor, condensador, válvula e evaporador

Além disso, a ferramenta foi programada para aprender continuamente a partir de novos dados operacionais, melhorando sua capacidade de detecção e diagnóstico ao longo do tempo.

3. RESULTADOS E DISCUSSÃO

Tendo sido definido as 16 classes operacionais, sendo elas 01 de referência(sem nenhum tipo de degradação) e 15 representando diferentes condições de falha, a rede neural foi treinada com um total de 1.196 padrões de operação. Cada padrão foi composto por um conjunto de grandezas operacionais, que asseguram consistência nos dados de entrada, onde esse equilíbrio contribuiu para a solidez do treinamento e a eficácia da classificação.

Durante os testes, a rede demonstrou bom desempenho na identificação das diferentes condições de operação, apresentando taxas de acerto elevadas, especialmente para as classes mais distintas da condição de referência. O modelo conseguiu distinguir com precisão degradações localizadas em componentes críticos como o compressor, o condensador e o evaporador, evidenciando sua capacidade de detectar falhas específicas no sistema de refrigeração.

As confusões observadas entre algumas classes de degradação similares indicam a necessidade de pequenos ajustes no pré-processamento de dados, como a normalização ou também a ampliação do conjunto de treinamento. Ainda assim, os resultados preliminares são promissores e indicam que a abordagem baseada em redes neurais é viável para o diagnóstico automatizado de falhas em sistemas de refrigeração comerciais e industriais.

A ferramenta proposta permite a detecção de padrões de falhas complexos, que seriam difíceis de identificar por meio de métodos tradicionais. A análise dos resultados também revelou a importância da seleção de grandezas operacionais relevantes para o diagnóstico, destacando a necessidade de uma abordagem criteriosa na escolha dos sensores e na coleta de dados (Mendes, 2018).




Figura 3: Gráfico do desempenho do sistema com a ferramenta de diagnóstico em relação ao número de épocas utilizadas.

4. CONCLUSÃO

A ferramenta de diagnóstico baseada em IA desenvolvida neste estudo demonstrou-se eficiente na detecção antecipada de falhas em sistemas de refrigeração comerciais e industriais. Com o uso contínuo e a adaptação do sistema, espera-se que a ferramenta melhore gradativamente, oferecendo uma solução cada vez mais precisa para empresas que dependem de sistemas de refrigeração. A implementação de IA na manutenção preditiva é uma tendência que deve se intensificar nos próximos anos, trazendo benefícios significativos para a indústria.

A metodologia proposta pode ser estendida para outros tipos de sistemas de refrigeração e adaptada para diferentes tipos de falhas, tornando-a uma ferramenta versátil e aplicável em diversos contextos industriais. Além disso, a integração da ferramenta com sistemas de gestão de energia pode otimizar ainda mais o desempenho dos sistemas de refrigeração, contribuindo para a redução do consumo de energia e a sustentabilidade ambiental.

5. AGRADECIMENTOS

Os autores gostariam de agradecer ao ICT - Instituto de Ciência e Tecnologia da UFVJM, FAPEMIG (Pela concessão de bolsa de iniciação científica a discente Amanda Aparecida Alves Silva), CAPES, CNPq, a PRPPG da UNIFEI e a PRPPG e a UFVJM pelo apoio financeiro. O suporte oferecido por essas entidades foi fundamental para o desenvolvimento desta pesquisa.

6. REFERÊNCIAS

- Abdelaziz, O., Said, S. A., & El-Said, E. M. S. (2011). *A review on energy saving strategies in industrial sector. Renewable and Sustainable Energy Reviews*, 15(1), 150-168.
- Katipamula, S., & Brambley, M. R. (2005a). *Methods for Fault Detection, Diagnostics, and Prognostics for Building Systems-A Review*, Part I. HVAC&R Research, 11(1), 1-24.
- Mendes, T. (2018). Desenvolvimento de um Sistema de Diagnóstico Termoeconômico para Sistemas de Refrigeração Industrial Utilizando Redes Neurais Artificiais. Tese de Doutorado, Universidade Federal de Itajubá.

7. RESPONSABILIDADE PELAS INFORMAÇÕES

Os autores são os únicos responsáveis pelas informações incluídas neste trabalho.