

DETECÇÃO E DIAGNÓSTICO DE FALHAS DE SISTEMAS DE REFRIGERAÇÃO A PARTIR DO MONITORAMENTO DE VIBRAÇÃO POR TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Gustavo de Novaes Pires Leite - gustavonovaes@recife.ifpe.edu.br

Melquisedeque Rozendo da Silva - melq.rozendo13@outlook.com

Kilvio Alessandro Ferraz - kilvioferraz@recife.ifpe.edu.br

Angelo Emiliavaca - angeloemiliavaca@recife.ifpe.edu.br

Evandro Pedro Alves de Mendonça - evandromendonca@recife.ifpe.edu.br

Perinaldo Severino Júnior - perinaldoseverino@recife.ifpe.edu.br

Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco, Departamento de Sistemas, Projetos e Controles Industriais, www.ifpe.edu.br

LN REFRIGERAÇÃO – R1 Sistemas, Equipamentos e Componentes

Resumo. Os sistemas de refrigeração e climatização representam, atualmente, sistemas indispensáveis para o funcionamento adequado das instituições. Recentemente, durante a pandemia do COVID-19 os serviços de refrigeração e climatização foram classificados como serviços essenciais. Uma falha inesperada nos componentes desses sistemas pode inviabilizar o funcionamento de edifícios, como hospitais, centros comerciais, supermercados, shopping centers, etc. A recente evolução dos princípios da indústria 4.0 tem promovido o desenvolvimento e a utilização de sistemas de monitoramento eficientes e de baixo custo em máquinas rotativas. Através desses princípios as máquinas podem ser monitoradas eficientemente e os dados são coletados e armazenados em um banco de dados local, ou ainda remotamente nas nuvens. Muitas vezes tem-se uma grande quantidade de dados coletados (Big Data) que necessitarão de um sistema inteligente. Dessa forma, dada a importância dos sistemas de climatização e refrigeração na atualidade e a falta de sistemas e metodologias consolidadas para o desenvolvimento e implementação de sistemas de gerenciamento, detecção e diagnóstico de falhas para esses sistemas, o presente trabalho vem apresentar o desenvolvimento de um protótipo de um hardware de monitoramento de falhas baseado nos princípios da indústria 4.0 para o monitoramento de falhas em sistemas de refrigeração e climatização através de sinais de vibração e outras grandezas operacionais. O protótipo de baixo custo foi construído baseado na plataforma Arduino, que é responsável pela coleta, armazenamento e transmissão de dados, mais um conjunto de sensores das condições operacionais. Uma vez coletados os sinais operacionais e de vibração do sistema, foi desenvolvido um software em Python, para, a partir das ferramentas de inteligência artificial, detectar e diagnosticar os defeitos em sistemas de refrigeração. O sistema desenvolvido foi capaz de identificar o vazamento de fluido refrigerante no sistema a partir da extração de características, nos domínios do tempo e da frequência, nas séries temporais de vibração extraídas de um sistema de refrigeração que tinha monitorado o compressor hermético e o ventilador do compressor.

Palavras-chave: Análise vibracional, Ciência dos dados, Inteligência Artificial, Manutenção Preditiva, Sistemas de refrigeração

1. INTRODUÇÃO

A manutenção de equipamentos e dispositivos de refrigeração tem impacto direto sobre os custos envolvidos na operação dos estabelecimentos ou instituições, nos quais esses equipamentos estejam instalados. A possibilidade de efetuar intervenções em máquinas antes de eventuais falhas ocorrerem e também a possibilidade de se prever a falha é aspecto de muito interesse.

É neste contexto, que o monitoramento de falhas de equipamentos via análise de vibrações se revela especialmente promissor, devido a sua natureza não invasiva e sua eficácia. O custo da implementação dessa análise via vibrações mecânicas está diretamente vinculado às ferramentas computacionais e instrumentação utilizadas no processo.

Hunt *et al.* (2010) em seu trabalho sobre a eficiência da manutenção em sistemas de refrigeração mostrou que existe uma enorme oportunidade desperdiçada pela não aplicação e implementação de sistemas de diagnóstico de falhas (FDD, do inglês *fault detection and diagnosis*) para sistemas de refrigeração e ar condicionado (Springer, 2016).

A medição da vibração é a medida mais efetiva na detecção na mudança das condições operacionais, em particular da saúde das máquinas rotativas. A Figura 1 apresenta as etapas de caracterização de falhas em máquinas rotativas ao longo do tempo (Tchakoua *et al.*, 2014). Na figura, é possível verificar que as vibrações mecânicas representam as técnicas que conseguem detectar as mudanças de forma mais antecipada. Cabe ainda destacar que, quanto mais tarde se detecta a falha, maiores são os custos com o reparo, pela ocorrência de danos colaterais, além da incidência de lucro cessante considerável em função da parada inesperada do componente. Especificamente no caso dos equipamentos de refrigeração e climatização, um dano ao sistema pode acarretar a perda dos produtos armazenados, que em muitas vezes valem mais do que o próprio equipamento, ou a interrupção do funcionamento de uma instalação.




Figura 1: Diferentes técnicas para caracterização de falhas em componentes mecânicos de máquinas rotativas.
 Fonte: Tchakoua *et al.* (2014).

Para a caracterização de falhas mecânicas em máquinas rotativas através da medição da vibração são necessários os passos da Figura 2 (Leite, 2018). Essas etapas são bastante conhecidas a partir do termo em inglês *data analytics* e são pilares da indústria 4.0 (Ruiz-Sarmiento *et al.*, 2020), mais especificamente da manutenção baseada em condições (CBM) ou manutenção preditiva.



Figura 2: Etapas da caracterização de falhas em componentes mecânicos de máquinas rotativas.

O objetivo deste trabalho é registrar e analisar as vibrações mecânicas de um *freezer* vertical e posteriormente analisá-las a partir de um programa desenvolvido no âmbito da pesquisa. A coleta dos dados deu-se mediante o emprego da plataforma Arduino, associada a sensores de aceleração. Também foram monitoradas grandezas operacionais mais tradicionalmente utilizadas no monitoramento de sistemas de vibração. Algumas dessas medidas são não invasivas, como temperatura e grandezas elétricas, e outras invasivas, como a pressão do fluido.

Diferentes cargas de massa de fluido refrigerante foram consideradas no equipamento, de modo a simular um vazamento de fluido refrigerante. As assinaturas de vibrações mecânicas e as condições operacionais associadas a cada nível de carga de refrigerante permitiram identificar as condições de espectros no domínio da frequência especificamente vinculadas à condição de vazamento.

Para o desenvolvimento do programa computacional foi utilizada a linguagem de código aberto *Python*. Softwares livres e hardware de código aberto podem permitir uma análise eficiente e ao mesmo tempo relativamente barata. Os dados coletados pelo sistema de medição desenvolvido utilizando-se a plataforma Arduino foram analisados através de técnicas de mineração de dados (do inglês *data mining*) e processamento de sinais. Foram utilizadas técnicas de extração de características no domínio do tempo e também técnicas de decomposição como as ferramentas FFT (*Fast Fourier Transform*), proposta inicialmente por Cooley e Tukey (1965), e *Wavelet*.

Uma comparação foi efetivada, entre os resultados fornecidos pela análise via FFT e os resultados fornecidos via *Wavelet*, em termos de esforço computacional e de acurácia. Na condição da quantidade de dados tratada neste trabalho, a análise via FFT permitiu a identificação da falha, a um custo computacional menor que o da *Wavelet*, porém maior que as técnicas no domínio do tempo.

Características estatísticas como desvio *RMS*, desvio padrão, curtose e *skewness* foram extraídas do conjunto de dados disponível com o uso do software de código aberto empregado, com vistas a alimentar uma análise via árvores de decisão, uma rede neural e o algoritmo de k-vizinhos. Essas análises forneceram matrizes de confusão consistentes e robustas o suficiente para se atingir uma acurácia de 100%, assim evidenciando a completa viabilidade do método empregado.

2. MATERIAIS E MÉTODOS

Nesta seção serão apresentados os materiais usados na coleta de dados e os métodos de análise de sinais e caracterização de falhas empregados para gerar os resultados dessa pesquisa.

2.1 Instrumentação e coleta de dados

Para obter os dados de vibração foram utilizados acelerômetros MPU6050, um Arduino e um módulo Micro SD. O sistema consiste em captar os sinais de vibração (aceleração e giroscópio em três eixos – x, y e z) do compressor de um freezer vertical através dos acelerômetros e gravá-los como um arquivo CSV (*Comma Separated Values* – Valores Separados por Vírgula) num cartão de memória do tipo Micro SD. O que faz a intermediação entre os dois dispositivos é o Arduino. O que foi utilizado neste trabalho foi o Arduino Uno, que possui o microcontrolador ATmega328.

A Figura 3 ilustra o freezer vertical e os diversos instrumentos utilizados para medir as grandezas mencionadas anteriormente. Como pode ser observado na Figura 3, além dos dados de vibração, dados operacionais como temperatura, pressão, grandezas elétricas e pressão também foram monitorados no presente trabalho.




Figura 3: instrumentos utilizados para coleta de dados

2.2 Caracterização de falhas

Dentre as várias possíveis falhas que podem ocorrer num sistema de refrigeração, principalmente no compressor, foi escolhida uma para ser o enfoque desse trabalho: a perda de fluido refrigerante. O freezer, objeto do trabalho, é do tipo vertical e possui uma carga nominal de 250 g de fluido refrigerante. Sendo assim, de modo a simular a perda de fluido no sistema, foram feitas medições com várias cargas deste fluido: 50 g, 100 g, 150 g, 200 g e 250 g, sendo esta última a carga nominal.

2.3 Pré-processamento dos dados

Antes de começar de fato a análise dos dados, é necessária uma etapa de pré-processamento destes. Nesta etapa, os dados salvos no cartão Micro SD são passados para um computador, onde é possível trabalhar com mais ferramentas sobre eles. O MPU6050 fornece as medições de acelerações em três eixos e giroscópios também nos três eixos.

2.4 Análise dos dados

Na etapa de análise dos dados, foram feitas análises no domínio do tempo e no domínio da frequência. No domínio do tempo, das séries temporais foram extraídas as seguintes características (*features*): RMS (*Root Mean Square* ou valor eficaz), desvio padrão, pico-a-pico, curtose e assimetria (*skewness*). No domínio da frequência foram utilizadas as transformadas de Fourier através do algoritmo FFT e também a transformada *Wavelet*.

Após aplicar as transformadas, são extraídas as características dos resultados. No caso da FFT, são coletadas as somas dos valores encontrados em intervalos de frequência específicos, onde se sabe que haverá um pico de frequência (mais detalhes na próxima seção). Já no caso da DWT, foi usada uma técnica de decomposição conhecida como *Wavelet Packet Tree* (WPT), que é uma decomposição em formato de árvore binária, que no caso deste trabalho foi até o nível 3.

Neste nível, temos 8 nós-folha, que representam 8 diferentes bandas de frequência. Para cada uma delas, foram extraídas as mesmas características estatísticas extraídas das séries temporais no domínio do tempo, citadas acima.

As *wavelets* mãe escolhidas para realizar a decomposição foram *Haar*, *Daubechies* e *Symlets*. Todas, exceto *Haar*, têm vários níveis de detalhamento. Obviamente, quanto maior for o nível de detalhamento, maior será o custo computacional. Portanto, foi decidido que o nível de detalhamento seria o nível 5 (db5 e sym5), para que não seja tão custoso computacionalmente e que não seja o nível mínimo de detalhe.

De posse das características, tanto da FFT quanto da DWT, foram criadas as instâncias (linhas) da matriz de características, onde cada coluna é uma característica e a última coluna é a etiqueta de classificação, que indica a que classe aquela linha de *features* pertence. As classes definidas são exatamente as cargas de fluido refrigerante a que o compressor foi submetido.

Foram coletadas séries temporais para cada uma das condições de vazamento. Em cada série temporal foram aplicadas janelas de *features* 5.000 pontos e ela foi translada ao longo de toda a série com uma variação de 10 pontos. Isto é representado na Figura 4, onde o retângulo vermelho indica a janela de largura 5.000, que percorrerá a série temporal até chegar no ponto 13.000 do retângulo azul, que é a parte da série temporal que será analisada. A série temporal completa é representada pelo retângulo marrom. Para cada série temporal esse procedimento é feito antes de aplicar a FFT ou DWT e ao final do processo, cerca de 12.000 séries temporais são então geradas.



Figura 4: Ilustração da janela das séries temporais.

2.5 Classificação dos dados

Para realizar a classificação dos dados nas classes definidas, foram usados três modelos de classificação: árvore de decisão, KNN (*K-Nearest Neighbours* – K-Vizinhos Mais Próximos) e DNN (*Deep Neural Network* – Rede Neural Profunda). A fim de avaliar a acurácia dos modelos foi realizada a separação aleatória de conjuntos de treinamento e teste, conforme uma porcentagem definida (neste trabalho, foi definido para todos os casos que o conjunto de treinamento teria 70 % de todos os dados e o de teste, 30 %). Os resultados são avaliados a partir da plotagem de uma matriz de confusão. A matriz de confusão mostra quantos itens do conjunto de teste foram corretamente classificados e quantos não foram. Para uma classificação 100 % acurada, todos os itens devem estar na diagonal principal desta matriz.

3. RESULTADOS E DISCUSSÕES

Esta seção mostra os detalhes dos resultados alcançados e faz discussões ao final acerca deles.

3.1 Medições de temperatura, pressão e grandezas elétricas

Na Figura 5 são mostrados os gráficos das medições de temperatura, pressão, grandezas elétricas e superaquecimento/subresfriamento. Observando, temperatura, pressão, superaquecimento/subresfriamento e fator de potência, é possível identificar tendências de crescimento e decrescimento conforme a carga de fluido refrigerante aumenta (no eixo horizontal). A corrente elétrica também apresenta tendência de aumento, mas a tensão elétrica já não mostra uma tendência de decrescimento tão intuitiva, uma vez que oscila razoavelmente.

Um ponto importante a observar é que, para um intervalo menor de carga de fluido refrigerante, por exemplo, entre 200 g e 250 g, não é tão fácil de identificar variação, pois são mudanças muito sutis entre os valores e o valor das medidas sempre estará sujeito a uma margem de erro, devido à precisão do instrumento de medição. Isto significa que, a partir das grandezas operacionais, não se pode chegar a um diagnóstico acurado nesse caso.

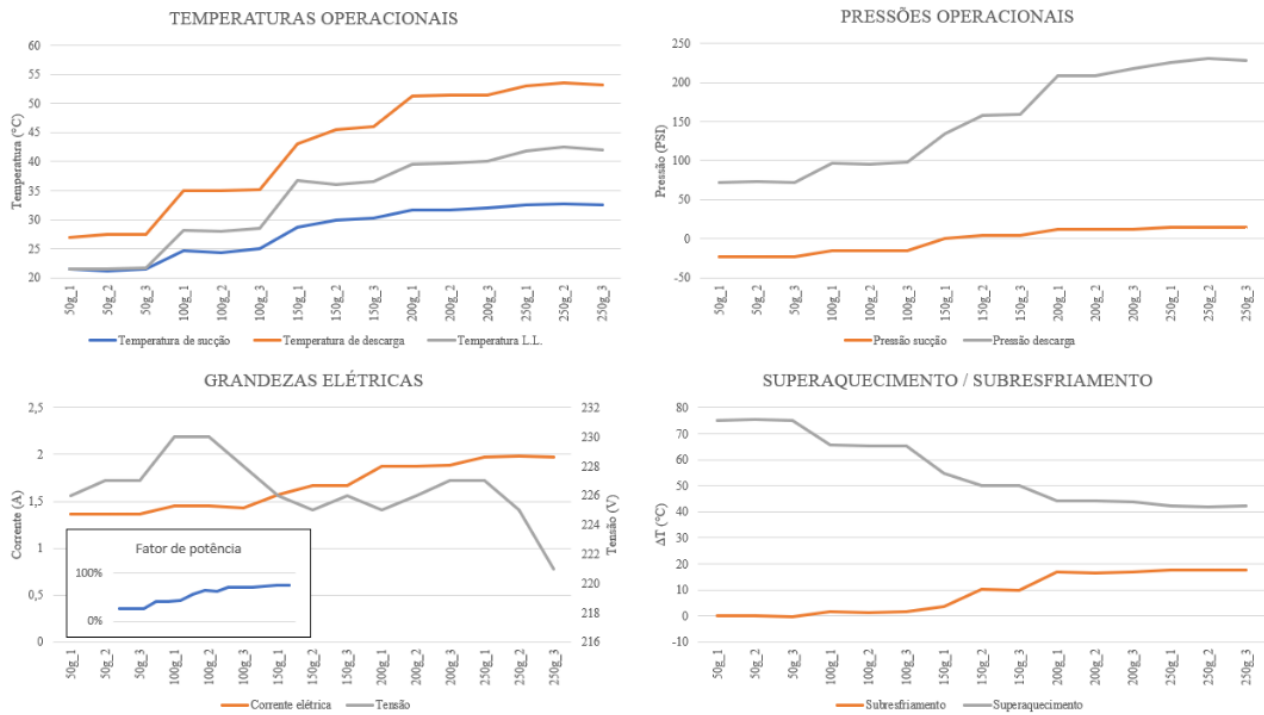


Figura 5: gráficos das medições realizadas, exceto vibração.

3.2 Extração de características nos domínios do tempo e da frequência

Como mencionado anteriormente, na etapa de análise dos dados, quando foi empregada a FFT, as características extraídas das janelas das séries temporais foram os somatórios de faixas específicas de frequências onde se sabia que haveria picos devido às frequências de vibração dos motores do sistema. Essas frequências foram identificadas graças aos testes isolados que foram feitos, isto é, foram coletados dados do sistema quando apenas um motor por vez era ligado, quando nenhum estava ligado e também quando todos estavam ligados. Aplicando a FFT em cada uma dessas séries temporais, foram gerados gráficos para cada uma delas e os picos de frequência de cada motor foram identificados, conforme a Tabela 1.

Tabela 1: picos aproximados de frequência dos motores.

MOTOR	PICOS APROXIMADOS (Hz)
Ventilador externo	25 e 120
Ventilador interno	26
Compressor	59 e 117
Todos	25, 59, 117 e 120

A Figura 6 apresenta o espectro de vibração para cada eixo do MPU 6050 e os picos de todos os motores, compressores e ventiladores ligados simultaneamente, podem ser vistos, conforme valores mostrados na Tabela 1. Dessa forma, para extrair as características do espectro, foi decidido extrair os valores das amplitudes nessas quatro frequências, com uma margem de erro para permitir pequenas variações de frequência. Sendo assim, foram somados os valores dentro de pequenas faixas de frequência (bandas) que continham estas que foram citadas. As bandas escolhidas foram: 23 a 27 Hz, 57 a 61 Hz, 114 a 118 Hz e 118 a 121 Hz.

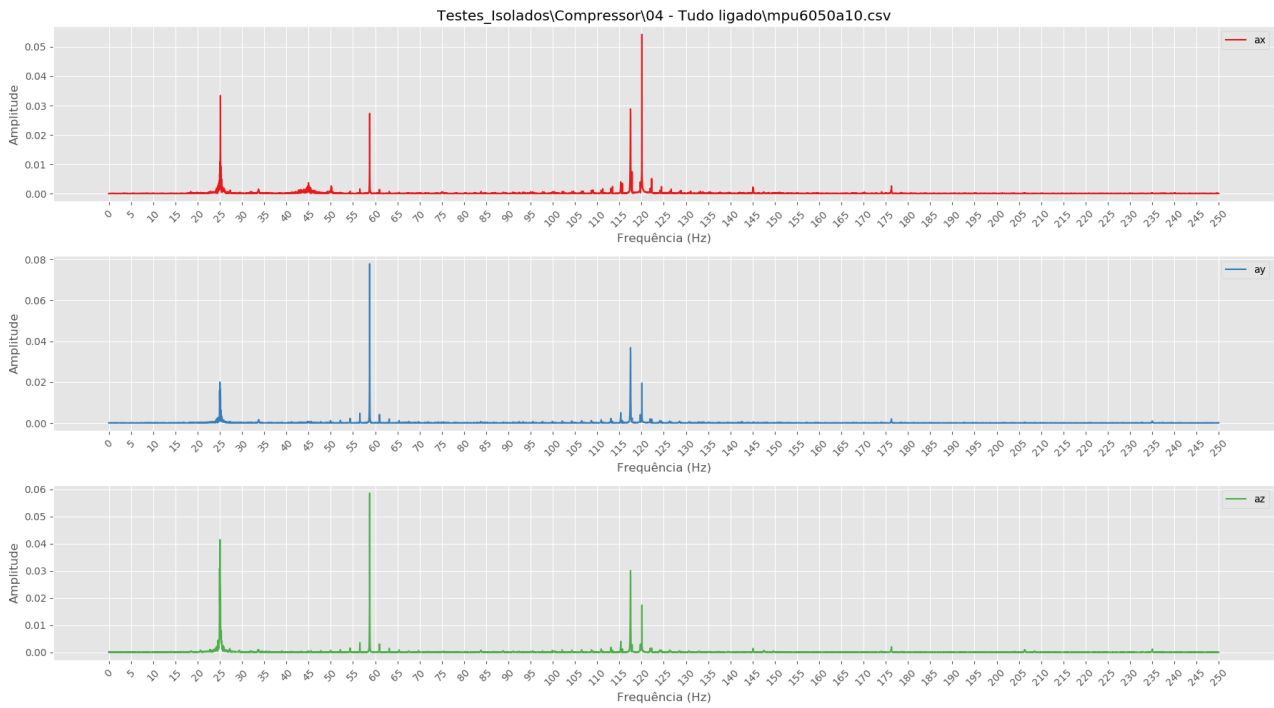


Figura 6: espectro contendo as FFTs das acelerações.

As instâncias de características foram formadas, portanto, com as somas dos valores das bandas citadas acima para as três acelerações, totalizando 12 características e a última é a etiqueta de classificação, nesse caso, a carga de fluido refrigerante associada à série temporal que está sendo analisada.

Conforme descrito na Seção 2 foi feita também a decomposição da série temporal usando a *Wavelet Packet Tree* até o nível 3. A cada nível, é aplicado um filtro passa-baixa e um filtro passa-alta no sinal, que na verdade são o resultado da aplicação da DWT, isto é, o resultado gerado são dois *arrays* contendo os coeficientes de aproximação e de detalhe. Se a cada nível os sinais duplicam, no nível 3 teremos 8 sinais, e para o nível N teremos 2^N sinais. A decomposição usada neste trabalho é ilustrada na Figura 7.




Figura 7: Decomposição *Wavelet Packet Tree* até o nível 3

A decomposição é feita em cada janela do sinal e, após esse processo, são extraídos de cada nó do nível 3 (nó folha) as características estatísticas: RMS, desvio padrão, pico-a-pico, curtose e *skewness*. A matriz de características é, então, formada com 12.015 linhas (instâncias) e 121 colunas (8 nós \times 5 *features* \times 3 acelerações + 1 etiqueta). É importante destacar aqui que este mesmo procedimento foi realizado utilizando as *wavelets* mãe *Haar*, *Daubechies* (db5) e *Symlets* (sym5).

Na última coluna os valores numéricos de 0 a 4 representam cada classe de vazamento, indo de “50g” a “250g”, na ordem crescente.

Por fim, as mesmas *features* extraídas dos nós da decomposição *wavelet* foram extraídas somente dos sinais originais (das janelas dos sinais originais, mais especificamente). Portanto, a matriz de características dos sinais no domínio do tempo é formada pelo mesmo número de linhas, porém com 16 colunas ($5 \text{ features} \times 3 \text{ acelerações} + 1 \text{ etiqueta}$).

Para a análise dos dados no domínio do tempo foi utilizado procedimento semelhante. Neste caso, a extração das características foi realizada diretamente em cada uma das cerca de doze mil séries temporais.

A partir da definição das matrizes com as características para cada técnica de extração para os domínios do tempo de frequência, FFT e *wavelet*, tem-se então os dados de entrada para os algoritmos de classificação: árvore de decisão, kNN e rede neural.

3.3 Classificação

Os modelos foram criados e treinados. As matrizes de características com as *features* de FFT e DWT, foram usadas para treinar o modelo de árvore de decisão. Já a matriz com as *features* dos sinais originais, no domínio do tempo, foi usada para treinar três modelos diferentes: árvore de decisão, KNN e DNN.

Após essa etapa, foi feita a avaliação de todos os modelos com os respectivos conjuntos de teste, o que resultou, para todos os casos, em 100 % de acurácia.

A Figura 8 mostra a matriz de confusão plotada depois das classificações com dados no domínio do tempo.




Figura 8: matriz de confusão (árvores de decisão, KNN e DNN / domínio do tempo).

A Figura 9 mostra as matrizes de confusão plotadas depois das classificações com dados no domínio da frequência.




Figura 9: matrizes de confusão (árvore de decisão / domínio da frequência). À esquerda, FFT; à direita, DWT.

A matriz de confusão exibe no eixo vertical as classes verdadeiras dos dados, enquanto que no eixo horizontal são exibidas as classes que foram categorizadas pelo modelo de predição. Os números que aparecem na diagonal principal são a quantidade de instâncias que foram classificadas corretamente e os demais elementos da matriz, as que foram classificadas incorretamente, isto é, indicam que o modelo se confundiu e classificou uma instância com uma classe que não deveria (por isso o nome “matriz de confusão”). A quantidade de acertos dividida pela quantidade total de instâncias é a acurácia do modelo. Como todas as instâncias estão concentradas na diagonal principal, todas elas foram classificadas corretamente e, assim, diz-se que os modelos obtiveram 100 % de acurácia.

3.4 Discussões dos resultados

Como pode ser visto nas subseções anteriores, todas as técnicas de análise de vibração foram capazes de classificar corretamente, com acurácia de 100 %, os dados coletados do compressor. Isso indica que, para a falha em questão (vazamento de fluido refrigerante), os modelos usados foram eficazes.

Para esta situação específica, o modelo que se saiu melhor em questão de desempenho foi o de árvore de decisão treinado com dados da matriz de características dos sinais originais no domínio do tempo, porque o modelo de predição é mais simples que o KNN e o DNN e porque não foi necessário aplicar algoritmos de transformadas integrais como a de Fourier e a *Wavelet*.

Contudo, as condições estabelecidas nesse trabalho são muito específicas, o que torna o problema não tão complexo quanto o que se encontra na realidade, de forma que, ao acrescentar outros tipos de falha ou acrescentar ou retirar carga térmica do sistema de refrigeração, os resultados aqui encontrados provavelmente não serão os mesmos.

Outro ponto importante a ser discutido é que, com as medições de outras grandezas, como pressão e corrente elétrica (entre outras), os dados até mostram tendência de subida ou descida, que ajudam no processo do diagnóstico, porém não dão um respaldo muito forte para diagnosticar satisfatoriamente o vazamento de fluido refrigerante, principalmente quando a carga de fluido está próxima da nominal. O diagnóstico feito pelas medidas de vibração e técnicas de inteligência artificial conseguem atingir patamares de certeza muito maiores. Em termos de instrumentação, o sistema aqui proposto também é mais simples.

4. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

À luz dos resultados obtidos, aponta-se, portanto, que, após extrair os dados de vibração do sistema de refrigeração, realizar pré-processamento de dados, aplicar técnicas de decomposição e, finalmente, realizar a classificação dos dados, foi possível identificar a falha de vazamento de fluido refrigerante utilizando os dados de vibração e as técnicas de inteligência artificial.

Vale ressaltar que não foi usada nenhuma medida invasiva no sistema de refrigeração para poder classificar corretamente a falha de vazamento de fluido refrigerante, o que é uma grande vantagem. Além disso, as medidas de outras grandezas nem sempre fornecem indicadores precisos para a identificação da falha analisada.

Outros trabalhos que podem ser feitos futuramente como extensão desse são:

- Aplicar também a Transformada Wavelet Contínua para gerar escalogramas e usá-los para realizar a classificação dos dados;
- Usar outros modelos de classificação, buscando melhor desempenho;
- Usar a programação paralela (*multithreading*) para otimizar o processamento dos dados;
- Aumentar a discretização da falha de vazamento de fluido refrigerante, isto é, realizar medições em mais níveis e com intervalos mais próximos;
- Acrescentar outros tipos de falhas para aumentar a complexidade e chegar cada vez mais próximo de situações reais.

Agradecimentos

Os autores agradecem ao Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (IFPE) e à Coordenação de Refrigeração e Climatização pela oportunidade do desenvolvimento do trabalho. Especificamente, o primeiro autor agradece ao IFPE pelo suporte através do Edital nº 10/2019/Propesq.

5. REFERÊNCIAS

- Cooley, J. W., & Tukey, J. W. 1965. An Algorithm for the Machine Calculation of Complex Fourier Series. *Mathematics of Computation*, 19(90), 297–301. <https://doi.org/10.2307/2003354>
- Hunt, M., Heinemeier, K., Hoeschele, M., & Weitzel, E. 2010. CALMAC. *HVAC Energy Efficiency Maintenance Study Appendices*. http://www.calmac.org/%5Cpublications/HVAC_EE_Maintenance_Final.pdf
- Leite, G. de N. P. 2018. *Diagnóstico de falhas em componentes de turbinas eólicas através da aplicação de quantificadores da teoria da informação* [DoctoralThesis, UFPE]. <https://repositorio.ufpe.br/handle/123456789/31677>
- Ruiz-Sarmiento, J.-R., Monroy, J., Moreno, F.-A., Galindo, C., Bonelo, J.-M., & Gonzalez-Jimenez, J. 2020. A predictive model for the maintenance of industrial machinery in the context of industry 4.0. *Engineering Applications of Artificial Intelligence*, 87, 103289. <https://doi.org/10.1016/j.engappai.2019.103289>
- Springer, D. 2016. *Expert Meeting Report: HVAC Fault Detection, Diagnosis, and Repair/Replacement*. May. <https://doi.org/10.2172/1254918>
- Tchakoua, P., Wamkeue, R., Ouhrouche, M., Hasnaoui, F., Theubou Tameghe, T. A., & Ekemb, G. 2014. Wind Turbine Condition Monitoring: State-of-the-Art Review, New Trends, and Future Challenges. *Energies*, 7, 2595–2630. <https://doi.org/10.3390/en7042595>

FAULT DETECTION AND DIAGNOSIS OF COOLING SYSTEMS FROM VIBRATION MONITORING BY ARTIFICIAL INTELLIGENCE TECHNIQUES

Abstract. *Refrigeration systems represent, currently, indispensable systems to the proper functioning of the institutions. Recently, during the COVID-19 pandemic, cooling and air conditioning services were classified as essential services. An unexpected fault in these systems' components can prevent buildings' functioning, such as hospitals, supermarkets, shopping centers, etc. The recent evolution of the principles of industry 4.0 has promoted the development and use of efficient and low-cost monitoring systems in rotating machines. Through these principles, machines can be efficiently monitored, and data can be collected and stored in a local database or even remotely in the clouds. Often there is a large amount of data collected (Big Data) that will require an intelligent system. Thus, given the importance of refrigeration systems and the lack of consolidated systems and methodologies for the development and implementation of systems for the management, detection and diagnosis of faults for these systems, this paper presents the development of a prototype of a failure monitoring hardware based on the principles of industry 4.0 for monitoring failures in cooling and air conditioning systems through vibration signals and other operational quantities. The low-cost prototype was built based on the Arduino platform, responsible for collecting, storing and transmitting data, plus a set of sensors for operating conditions. Once the system's operational and vibration signals were collected, a Python code was developed to detect and diagnose defects in refrigeration systems using artificial intelligence tools. The developed system was able to identify the leakage of refrigerant in the system from the extraction of features, in both time and frequency domains, in the various time series of vibration extracted from a refrigeration system that had its hermetic compressor and compressor fan monitored.*

Keywords: *Vibration Analysis, Data Science, Artificial Intelligence, Predictive Maintenance, Refrigeration Systems*