

Detecção de Falhas em Bombas Industriais Baseada em Coeficientes Cepstrais de Sinais Acústicos no Domínio Espectral Cicloestacionário

Miguel M. Ferreira e Luiz F. Q. Silveira

Resumo— Este trabalho propõe uma metodologia para detecção de anomalias em bombas industriais baseada no processamento de sinais acústicos, por meio da extração de coeficientes cepstrais no domínio espectral cicloestacionário. A abordagem explora propriedades de cicloestacionariedade de sistemas rotativos para evidenciar componentes espectrais moduladas associadas a falhas. Os descritores são utilizados para modelar o comportamento normal do equipamento e identificar condições anômalas por meio de aprendizado de máquina. A metodologia é avaliada com dados reais de quatro modelos de bombas, considerando diferentes regimes operacionais e níveis de ruído. Os resultados indicam que o método é eficaz e robusto, com acurácia superior a 98% para relação sinal-ruído de +6 dB e mantendo desempenho superior a 89% mesmo em condições mais severas de 0 dB e -6 dB para todos os equipamentos.

Palavras-Chave— Detecção de falhas, Máquinas industriais, Análise cicloestacionária, Densidade espectral cíclica, Coeficientes cepstrais, Aprendizado de máquina.

Abstract— This work proposes a methodology for detecting anomalies in industrial pumps based on acoustic signal processing through the extraction of cepstral coefficients in the cyclostationary spectral domain. The approach exploits the cyclostationary properties of rotating systems to highlight modulated spectral components associated with faults. The descriptors are used to model the normal behavior of the equipment and identify anomalous conditions through machine learning. The methodology is evaluated using real data from four pump models, considering different operating regimes and noise levels. The results indicate that the method is effective and robust, with an accuracy of over 98% for a signal-to-noise ratio of +6 dB and maintaining a performance of over 89% even under more severe conditions of 0 dB and -6 dB for all equipments.

Keywords— Fault detection, Industrial machinery, Cyclostationary analysis, Cyclic spectral density, Cepstral coefficients, Machine learning.

I. INTRODUÇÃO

A manutenção preditiva é uma estratégia fundamental para a gestão de ativos industriais, cujo objetivo é maximizar a disponibilidade por meio do monitoramento contínuo dos equipamentos [1]. Essa abordagem baseada em dados permite identificar falhas incipientes antes que causem danos significativos, contribuindo para evitar paradas não planejadas e reduzir custos operacionais [2], [3]. Além dos benefícios econômicos, a detecção antecipada de falhas reduz a probabilidade de

acidentes, vazamentos e emissões que podem comprometer o meio ambiente e a saúde humana.

Nesse contexto, o monitoramento por meio de sinais acústicos tem ganhado destaque como uma solução não intrusiva e economicamente viável para a detecção de anomalias em larga escala, aproveitando avanços recentes em processamento de sinais e aprendizado de máquina [4]. Sensores acústicos, como microfones, oferecem uma alternativa de baixo custo aos sensores tradicionais de monitoramento, apresentando alta largura de banda e capacidade de detectar anomalias sutis que outros sensores podem ter menor sensibilidade [4].

A complexidade inerente aos sinais de máquinas rotativas, devido, em especial, à variação de carga, regimes transitórios, não-linearidades mecânicas e à presença de ruído severo, exige técnicas avançadas de processamento para revelar padrões associados a falhas incipientes [5]. Representações convencionais de tempo-frequência, como o espectrograma, são comumente empregadas para analisar sinais com estrutura complexa, mas podem não capturar completamente o comportamento não-estacionário associado ao movimento rotativo ou oscilatório dos componentes mecânicos [6].

Diante disso, a análise cicloestacionária surge como uma alternativa, uma vez que explora as propriedades estatísticas periódicas de sinais de vibração e acústicos, sendo particularmente eficaz para identificar padrões de modulação gerados por falhas em componentes rotativos [7], [8]. A Densidade Espectral Cíclica (SCD), principal ferramenta desta técnica de análise, permite isolar componentes moduladas que se manifestam em frequências cíclicas específicas, proporcionando uma caracterização mais detalhada da dinâmica do sistema do que métodos estacionários [9].

Adicionalmente, a utilização da SCD combinada a extração de descritores cepstrais busca capturar a estrutura envolvente do sinal modulado, potencializando a discriminação de padrões anômalos em ambientes ruidosos [10]. Por outro lado, a combinação de técnicas de processamento de sinais avançadas com algoritmos de aprendizado de máquina tem se mostrado uma estratégia poderosa para o diagnóstico de falhas, permitindo estimar a ocorrência de degradações em fase inicial e programar intervenções de manutenção que evitam perdas de produção e danos aos equipamentos.

Este artigo, portanto, propõe uma metodologia para detecção de falhas em máquinas industriais, a partir de sinais acústicos, baseada na extração de Coeficientes Cepstrais (CC) no domínio espectral cicloestacionário, obtidos por meio da Densidade Espectral Cíclica (SCD). As características extraídas

são utilizadas como entrada para um modelo de aprendizado de máquina *Random Forest*, visando a discriminação entre condições normais e anômalas de operação. A abordagem, avaliada experimentalmente utilizando dados reais, considera múltiplas seções de operação do equipamento do tipo bomba, o que permite analisar a robustez do método frente a diferentes regimes operacionais e condições de ruído.

II. METODOLOGIA

A metodologia neste trabalho é composta, inicialmente, pelas etapas de pré-processamento e extração de características no domínio cicloestacionário. Os descritores obtidos são, então, empregados como entrada de um modelo de *Random Forest*, previamente treinado a partir de amostras rotuladas segundo as condições operacionais do equipamento, permitindo a detecção automática de falhas.

A. Base de Dados e Organização Experimental

Os experimentos foram conduzidos utilizando sinais acústicos da base de dados *Malfunctioning Industrial Machine Investigation and Inspection (MIMII)*, a qual disponibiliza registros de operação normal e anômala de equipamentos operando sob diferentes condições de carga e regimes operacionais [11].

Dentre os equipamentos disponíveis, foram utilizadas amostras de áudio provenientes de diferentes tipos de bombas industriais instaladas em um sistema de sucção e descarga conectado a um reservatório de água. As gravações contemplam condições de falha, como vazamentos, entupimentos, contaminações e obstruções no sistema hidráulico.

No conjunto de dados da base publicamente disponibilizado, são fornecidas apenas as seções pares, 00, 02, 04 e 06. Portanto, este trabalho considera as gravações da categoria de bombas industriais associadas a essas seções, cada uma delas correspondente a um tipo específico de bomba. A quantidade de gravações de áudio disponível para cada tipo de bomba (seção) é apresentada na Tabela I. Nota-se uma distribuição desbalanceada entre as classes normal e anômala, característica típica de cenários reais de monitoramento industrial.

TABELA I: Detalhes do conjunto de dados.

ID do Equipamento	Áudios para condição normal	Áudios para condição anômala	Total
00	1006	143	1149
02	1005	111	1116
04	702	100	802
06	1036	102	1138
Total	3749	456	4205

A fim de evitar vazamento de informação e garantir uma avaliação realista do desempenho durante a detecção de anomalias, todas as etapas da metodologia foram realizadas de forma independente para cada tipo de equipamento bomba.

B. Pré-processamento do Sinal

A metodologia foi avaliada utilizando os sinais acústicos sob condição de Relação Sinal-Ruído (SNR) de +6 dB, 0 dB e -6 dB, processados por meio das etapas de segmentação

temporal com taxa de amostragem de 16 kHz, aplicação de técnicas de análise cicloestacionária para obtenção da SCD, extração de CC e, por último, seleção dos coeficientes mais adequados.

C. Cálculo da Densidade Espectral Cíclica

Os sinais provenientes de máquinas industriais frequentemente violam a hipótese de estacionariedade, o que limita a aplicação de técnicas clássicas e computacionalmente eficientes, como a Transformada Rápida de Fourier (FFT) e métodos espectrais convencionais, em condições reais de operação [12].

Entre as classes de sinais não estacionários, destacam-se os sinais cicloestacionários, cuja principal característica é a periodicidade de seus momentos estatísticos.

Um sinal X_t é cicloestacionário de segunda ordem se o seu momento de primeira ordem, isto é, a média do sinal atende a relação:

$$m_X(t) \cong E\{X(t)\} = m_X(t + T_0), \quad (1)$$

e o seu momento de segunda ordem, isto é, a função de autocorrelação do sinal, atende à relação:

$$R_x(t, \tau) = E\left[x\left(t + \frac{\tau}{2}\right) x\left(t - \frac{\tau}{2}\right)\right] = R_x(t + T_0, \tau), \quad (2)$$

com T_0 sendo o período fundamental. O inverso do período fundamental define a frequência cíclica fundamental, $\alpha_0 = 1/T_0$, enquanto as demais frequências cíclicas são seus múltiplos inteiros, $\alpha_k = k\alpha_0$, com $k \in \mathbb{Z}$ [5], [13].

Como $R_x(t, \tau)$ é periódica em t , com período T_0 , ela admite a expansão em série de Fourier

$$R_x(t, \tau) = \sum_{k \in \mathbb{Z}} R_x^{\alpha_k}(\tau) e^{j2\pi\alpha_k t}, \quad \alpha_k = \frac{k}{T_0}. \quad (3)$$

Por simplicidade de notação, no restante do texto denota-se uma frequência cíclica genérica α_k simplesmente por α . Os coeficientes $R_x^{\alpha}(\tau)$, denominados Função de Autocorrelação Cíclica (CAF), são dados por

$$R_x^{\alpha}(\tau) = \frac{1}{T_0} \int_{t_0}^{t_0+T_0} R_x(t, \tau) e^{-j2\pi\alpha t} dt. \quad (4)$$

Assim, cada CAF representa a componente da autocorrelação associada à frequência cíclica α , sendo $\alpha = 0$ correspondente ao caso estacionário. A SCD é então obtida pela Transformada de Fourier da CAF em relação ao atraso τ :

$$S_x^{\alpha}(f) = \int_{-\infty}^{\infty} R_x^{\alpha}(\tau) e^{-j2\pi f \tau} d\tau, \quad (5)$$

em que f é a frequência espectral e α é a frequência cíclica.

D. Extração de Coeficientes Cepstrais Cíclicos

A partir da SCD, foram extraídos os coeficientes cepstrais, com o objetivo de obter uma representação compacta e robusta das estruturas espectrais moduladas associadas ao comportamento dinâmico do equipamento [14].

Inicialmente, a magnitude ao quadrado da SCD foi filtrada por um banco de filtros uniformemente espaçados na escala Mel, projetado especificamente para o domínio espectral em

análise [15]. Esse banco foi construído com 128 filtros triangulares, cujas frequências centrais correspondem aos valores na escala Mel obtidos por:

$$M(f) = 2595.0 \times \log \left(1.0 + \frac{f}{700.0} \right). \quad (6)$$

Em seguida, aplicou-se a transformação logarítmica para compressão dinâmica da energia filtrada E_{Mel} :

$$E_{\log} = \log(E_{\text{Mel}} + \varepsilon), \quad (7)$$

em que ε é um termo de estabilização numérica, introduzido para evitar instabilidades nos cálculos, uma vez que bandas de frequência dominadas por ruído podem assumir valores nulos ou extremamente pequenos. Além disso, a energia em algumas bandas Mel pode ser zero ou muito baixa, especialmente em condições de baixo SNR ou quando não há componentes cicloestacionárias com energia significativa na faixa espectral coberta pelo respectivo filtro.

Posteriormente, a Transformada Discreta do Cosseno (DCT) foi utilizada para a obtenção dos CC. Para cada frequência cíclica, foram mantidos os 5 (cinco) primeiros coeficientes, que representam as variações de baixa ordem da envoltória log-espectral da SCD nas bandas Mel. Portanto, cada amostra é representada por uma matriz C de dimensão $N_{\alpha} \times N_{\text{ceps}}$:

$$\mathbf{C} = \begin{pmatrix} c_{1,1} & c_{1,2} & \cdots & c_{1,N_{\text{ceps}}} \\ c_{2,1} & c_{2,2} & \cdots & c_{2,N_{\text{ceps}}} \\ \vdots & \vdots & \ddots & \vdots \\ c_{N_{\alpha},1} & c_{N_{\alpha},2} & \cdots & c_{N_{\alpha},N_{\text{ceps}}} \end{pmatrix} \in \mathbb{R}^{N_{\alpha} \times N_{\text{ceps}}}. \quad (8)$$

A quantidade de coeficientes foi definida empiricamente por meio de testes preliminares com diferentes números de termos da DCT. Em cada configuração, avaliou-se o compromisso entre a dimensionalidade do vetor de características e a capacidade dos coeficientes de discriminar as condições normal e anômala. Com base nessa análise, foram selecionados os cinco primeiros coeficientes, que preservam as variações de baixa ordem da envoltória log-espectral da SCD sem ampliar desnecessariamente a dimensionalidade da representação. Os CC extraídos para todas as frequências cíclicas foram empilhados formando um vetor unidimensional, resultando em uma representação de alta dimensionalidade $\mathbf{x} \in \mathbb{R}^{N_{\alpha} \cdot N_{\text{ceps}}}$.

É válido destacar que este método proposto pode ser interpretado como uma generalização cicloestacionária do método para a análise de Coeficientes Cepstrais de Frequência Mel (MFCC) clássico, na qual a energia espectral é substituída pela densidade espectral cíclica, permitindo capturar estruturas de modulação de segunda ordem associadas a fenômenos mecânicos periódicos.

E. Classificação Supervisionada

Após a etapa de extração e organização dos CC, entre as diferentes alternativas avaliadas, o classificador *Random Forest* foi selecionado por apresentar elevada robustez à presença de ruído, capacidade de modelar relações não lineares complexas e desempenho consistente em cenários caracterizados por alta dimensionalidade e desbalanceamento entre classes.

Além da matriz de confusão, as principais métricas de avaliação utilizadas foram a Área sob a Curva (AUC), Acurácia, Precisão, *Recall*, *F1-Score*. A decisão final de classificação foi baseada na probabilidade estimada pelo modelo, permitindo a análise do compromisso entre precisão e *recall* por meio do ajuste do limiar de decisão.

III. RESULTADOS

Nesta seção são apresentados os resultados obtidos a partir da aplicação da metodologia proposta aos dados reais considerados neste trabalho. Os resultados são analisados considerando diferentes modelos de equipamentos e condições operacionais, de modo a avaliar a capacidade do método de detectar anomalias.

A. Extração de coeficientes cepstrais

Na Figura 1 e Figura 2, estão ilustradas as funções SCD correspondentes a exemplos de sinais acústicos capturados em condição normal e anômala para o equipamento 00, sob SNR de 6 dB, respectivamente.




Fig. 1: Função SCD do sinal para o equipamento 00 em condição normal.

Foram considerados os valores positivos das frequências cíclica e espectral na representação em magnitude da SCD. Essa escolha explora as redundâncias de simetria presentes para sinais reais e reduz o custo computacional, preservando as componentes utilizadas na etapa de extração de descritores.

A partir da representação da SCD, procedeu-se à extração de coeficientes cepstrais ao longo das frequências cíclicas. Tal abordagem permitiu reduzir a dimensionalidade dos dados, ao mesmo tempo em que manteve informações relevantes relacionadas às propriedades cicloestacionárias do sinal.

A Figura 3a ilustra os coeficientes cepstrais extraídos para um exemplo de sinal em condição normal, enquanto a Figura 3b ilustra os coeficientes cepstrais extraídos para um exemplo de sinal em condição anômala para o equipamento 00. Observa-se que esses coeficientes apresentam padrões distintos que, em média, se mantém discriminativo para as condições normal e anômala de operação do equipamento.




Fig. 2: Função SCD do sinal para o equipamento 00 em condição anômala.




Fig. 3: Coeficientes cepstrais do sinal para o equipamento 00 nas condições normal e anômala.

Por fim, os coeficientes cepstrais foram organizados em vetores com o intuito de viabilizar o uso desses descritores em algoritmos de aprendizado de máquina. Na sequência, descreve-se o procedimento adotado para particionamento dos dados, o treinamento e a avaliação do classificador utilizado.

B. Treinamento do Classificador

Aleatoriamente, os dados foram divididos em conjuntos de treino e teste, seguindo a proporção de 70% e 30%, respectivamente. A aleatoriedade foi controlada por uma semente fixa, garantindo a reprodutibilidade dos resultados. O conjunto de teste foi mantido isolado durante todo o processo de ajuste do modelo, sendo utilizado apenas para a avaliação final de desempenho.

O classificador *Random Forest* teve seus hiperparâmetros definidos com base no desempenho médio no conjunto de treinamento, por meio de validação cruzada. O modelo foi configurado com 200 árvores, profundidade máxima de 10 níveis e critério de divisão baseado em log-loss, além da seleção aleatória de atributos em cada nó definido como $\log_2$ do número total de atributos.

Para a avaliação do desempenho durante a etapa de treinamento e para a redução de viés estatístico, foi empregada validação cruzada estratificada repetida (*Repeated Stratified K-Fold*), utilizando 5 divisões e 15 repetições. Esse processo permitiu estimar de forma mais estável o desempenho do classificador e selecionar a configuração final do modelo.

Após o processo de validação cruzada, o modelo final foi treinado utilizando todo o conjunto de treinamento. Para a tomada de decisão, foram utilizadas as probabilidades estimadas pelo classificador, adotando-se um limiar de detecção ajustado a partir dos resultados de validação, com o objetivo de maximizar a métrica F1-score e aumentar a sensibilidade à identificação de falhas. Por fim, o desempenho final da metodologia foi avaliado no conjunto de teste previamente separado.

C. Desempenho do Classificador

O desempenho do método proposto foi avaliado considerando-se a capacidade do classificador de identificar corretamente condições anômalas a partir dos descritores extraídos. A Tabela II apresenta o desempenho do classificador.

TABELA II: Resumo do desempenho do classificador para diferentes níveis de SNR.

SNR (dB)	Seção	AUC	Acurácia	Precisão	Recall	F1-Score
+6	00	0.9944	0.9884	0.9535	0.9530	0.9535
	02	0.9956	0.9910	1.0000	0.9091	0.9524
	04	1.0000	1.0000	1.0000	1.0000	1.0000
	06	0.9953	0.9912	0.9667	0.9355	0.9508
0	00	0.9768	0.9594	0.8919	0.7674	0.8250
	02	0.9893	0.9731	0.8529	0.8788	0.8657
	04	0.9998	0.9959	0.9677	1.0000	0.9836
	06	0.9853	0.9708	0.8182	0.8710	0.8438
-6	00	0.9131	0.9565	0.9375	0.6977	0.8000
	02	0.9120	0.8955	0.4783	0.6667	0.5570
	04	0.9918	0.9876	1.0000	0.9000	0.9474
	06	0.8902	0.9357	0.6552	0.6129	0.6333

Para o cenário sob $\text{SNR} = +6$ dB, o classificador apresentou desempenho elevado em todas as seções, com valores de acurácia superiores a 98%, indicando excelente separabilidade entre condições normais e anômalas. As métricas refletem uma baixa taxa de falsos positivos, enquanto os altos valores de *recall* indicam boa capacidade de detecção das anomalias. Esse comportamento é corroborado pela matriz de confusão na Figura 4 com a predominância de classificações corretas.




Fig. 4: Matriz de confusão para o equipamento 00 no conjunto de teste com SNR de 6dB.

Nos cenários em que a potência do ruído é igual ou maior a potência do sinal, isto é, com $\text{SNR} = 0$ dB e $\text{SNR} = -6$ dB, observa-se uma degradação esperada no desempenho do classificador, especialmente nas métricas de precisão e *recall*. Embora os valores de acurácia permaneçam acima de 89% para todos os equipamentos, há um aumento perceptível de falsos positivos e, principalmente, falsos negativos. Esse efeito é mais evidente nas Seções 02 e 06, evidenciando maior

difículdade do modelo em identificar anomalias sob condições de ruído elevado.

D. Análise Comparativa

Para avaliar a contribuição específica da extração cepstral, os resultados foram inicialmente comparados aos de um trabalho anterior do mesmo grupo [16]. Nesse estudo, o perfil de magnitude máxima da SCD por frequência cíclica foi utilizado diretamente como vetor de características, sem a extração de coeficientes cepstrais. Para $\text{SNR} = +6\text{ dB}$, foram obtidas acurácias de 96.52%, 95.54% e 95.65% nas Seções 00, 02 e 04, respectivamente, com F1-Score médio de 0.80. Nas mesmas condições, a metodologia proposta alcançou acurácias entre 98.84% e 100% e F1-Score superior a 0.95 em todas as seções. Essa evolução sugere que os CC fornecem ao classificador uma representação com maior separabilidade entre as condições normal e anômala.

O desempenho obtido com o método proposto também pode ser contextualizado com base nos resultados do trabalho que introduziu a base MIMII, no qual foram avaliados autoencoders treinados com Espectrogramas Mel [11]. Para $\text{SNR} = +6\text{ dB}$, os valores de AUC reportados foram de 84% para a Seção 00, 45% para a Seção 02, 99% para a Seção 04 e 94% para a Seção 06. Embora diferenças metodológicas impeçam uma comparação direta, a Seção 02 oferece um contraste expressivo: nessa seção, a abordagem proposta atingiu AUC de 99%, enquanto o método baseado em autoencoder obteve 45%.

IV. CONCLUSÕES

Este trabalho propôs uma abordagem para a detecção de anomalias em máquinas industriais, baseada na extração de coeficientes cepstrais no domínio espectral cicloestacionário. A metodologia explorou o potencial da SCD para representar fenômenos periódicos associados a falhas mecânicas, mesmo em condições ruidosas, superando limitações inerentes às técnicas clássicas baseadas na hipótese de estacionariedade.

Os resultados obtidos demonstraram que os coeficientes cepstrais extraídos a partir da SCD são capazes de codificar, de forma compacta, variações de baixa ordem da envoltória log-espectral cicloestacionária que distinguem as condições normal e anômala, mesmo em cenários de alta dimensionalidade e baixo SNR.

A utilização do classificador *Random Forest* mostrou-se adequada ao problema, apresentando elevado desempenho em termos de acurácia, precisão e *recall* além de boa capacidade de generalização. Observou-se, entretanto, variação no *recall* entre diferentes seções e níveis de SNR, indicando que a complexidade dinâmica do sistema influencia diretamente a detectabilidade de falhas sutis. Ainda assim, mesmo nos cenários mais desafiadores, o classificador manteve desempenho superior ao esperado para sinais fortemente degradados por ruído.

Como continuidade deste trabalho, serão investigados autoencoders semissupervisionados para modelagem do comportamento nominal e detecção de anomalias por desvio em relação a esse padrão. Pretende-se, ainda, expandir a metodologia para

um cenário multiclasse, no qual, além de detectar a presença de anomalias, o modelo seja capaz de identificar o tipo de falha e classificar seu nível de severidade.

AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, e do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), no âmbito dos processos 445158/2024-7 e 421235/2025-0.

REFERÊNCIAS

- [1] M. H. Londoño, Álvaro A. Orozco, G. A. H. Londoño, and M. A. Álvarez, "Optimal state selection and tuning parameters for a degradation model in bearings using mel-frequency cepstral coefficients and hidden markov chains," *Ingeniare. Revista chilena de ingeniería*, vol. 24, pp. 570–580, 10 2016.
- [2] B. G. Joung, C. Nath, Z. Li, and J. W. Sutherland, "Bearing anomaly detection in an air compressor using an lstm and rnn-based machine learning model," *Research Square (Research Square)*, 04 2024.
- [3] M. C. S. Pereira, M. L. V. Araújo, E. A. R. D. Oliveira, V. B. Guimarães, H. Saba, E. M. de Freitas Jorge, A. S. N. Filho, and J. S. Ferreira, "Estudo da aplicação de algoritmos de machine learning na manutenção preditiva de motores elétricos," *Revista de Gestão e Secretariado (Management and Administrative Professional Review)*, vol. 14, pp. 16542–16561, 10 2023.
- [4] S. Kilickaya, M. Ahishali, C. Celebioglu, F. Sohrab, L. Eren, T. İnce, M. Aşkar, and M. Gabbouj, "Audio-based anomaly detection in industrial machines using deep one-class support vector data description," pp. 1–5, 03 2025.
- [5] S. Tang, S. Yuan, and Y. Zhu, "Cyclostationary Analysis towards Fault Diagnosis of Rotating Machinery," *Processes*, vol. 8, p. 1217, Sept. 2020.
- [6] A. Drewnicka, A. M. Michalak, R. Zimroz, A. Kumar, A. Wyłomańska, and J. Wodecki, "A method for signal components identification in acoustic signal with non-gaussian background noise using clustering of data in time-frequency domain," *arXiv (Cornell University)*, 02 2025.
- [7] Z. Chen, A. Mauricio, W. Li, and K. Gryllias, "Multi-label fault diagnosis based on convolutional neural network and cyclic spectral coherence," *HAL (Le Centre pour la Communication Scientifique Directe)*, 07 2019.
- [8] W. Żuławiński, J. Antoni, R. Zimroz, and A. Wyłomańska, "Applications of robust statistics for cyclostationarity detection in non-gaussian signals for local damage detection in bearings," *Mechanical Systems and Signal Processing*, vol. 214, pp. 111367–111367, 03 2024.
- [9] D. Herath, C. Abeyrathne, C. Adithya, and C. Seneviratne, "Fusing spectral correlation density imaging with deep learning for intelligent fault diagnosis in rotating machinery," *arXiv (Cornell University)*, 09 2025.
- [10] B. Peng, D. Li, K. I. Wang, and W. H. Abdulla, "Acoustic-based industrial diagnostics: A scalable noise-robust multiclass framework for anomaly detection," *Processes*, vol. 13, pp. 544–544, 02 2025.
- [11] H. Purohit, R. Tanabe, K. Ichige, T. Endo, Y. Nikaido, K. Suefusa, and Y. Kawaguchi, "Mimii dataset: Sound dataset for malfunctioning industrial machine investigation and inspection," Sept. 2019.
- [12] Y. Niu, J. Fei, Y. Li, and D. Wu, "A novel fault diagnosis method based on EMD, cyclostationary, SK and TPTSR," *Journal of Mechanical Science and Technology*, vol. 34, pp. 1925–1935, May 2020.
- [13] C. M. Vicuña and D. Q. Acuña, *Cyclostationary Processing of Vibration and Acoustic Emissions for Machine Failure Diagnosis*, pp. 141–156. Cham: Springer International Publishing, 2014.
- [14] C. Velandia-Cardenas, Y. Vidal, and F. Pozo, "Wind turbine gearbox early fault detection using mel-frequency cepstral coefficients of vibration data," *Structural Control and Health Monitoring*, vol. 2024, no. 1, p. 7733730, 2024.
- [15] Z. K. Abdul and A. K. Al-Talabani, "Mel Frequency Cepstral Coefficient and its Applications: A Review," *IEEE Access*, vol. 10, pp. 122136–122158, 2022.
- [16] D. M. Silva and L. F. Q. Silveira, "Detecção de falhas em bombas industriais usando frequências cíclicas com random forest," in *Anais do XLIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBTr2025)*, 2025.