

Diagnóstico de falhas: Uma revisão e análise de dados de vibração e suas aplicações

Fault diagnosis: A review and analysis of vibration data and its applications

Igor Varejão¹, Alexandre Rodrigues Loureiros²,
Thiago Olivera dos Santos³, Flávio Varejão⁴

(1) UFES, Espírito Santo, igor.varejao@edu.ufes.br.

(2) UFES, Espírito Santo, arodrigues.ufes@gmail.com.

(3) UFES, Espírito Santo, todosantos@inf.ufes.br,

(4) UFES, Espírito Santo, flavio.varejao@ufes.br.

Resumo:

Empresas do ramo industrial geralmente têm grandes investimentos em equipamentos modernos de produção, bem como altos custos de manutenção dessas unidades. A identificação rápida e precisa de falhas e problemas nos equipamentos industriais contribui de forma crucial para reduzir os custos de manutenção e melhorar a confiabilidade na produção. O diagnóstico de falhas consiste no monitoramento do funcionamento de um equipamento de modo a identificar a ocorrência de uma falha. Com o aumento do número de sensores instalados a bordo dos equipamentos, os dados adquiridos por eles têm sido mais usados para monitorar os estados desses equipamentos e diagnosticar suas falhas ou mal funcionamento. Avanços nas pesquisas na área de Inteligência Artificial, em especial, na área de Aprendizado de Máquina fornecem meios para aumentar a confiabilidade de sistemas inteligentes de diagnóstico de falhas que resultam em um desempenho mais confiável dos equipamentos e, por consequência, da indústria. Este artigo apresenta uma análise geral, assim como, uma revisão, sobre os dados de vibração que têm sido usados em diversos trabalhos de pesquisa nos últimos 30 anos, aponta um problema comum no uso desses dados, apresenta o que precisa ser feito para resolvê-lo e como a comunidade acadêmica pode contribuir para esta solução.

Palavras-

chave: Diagnóstico de Falhas; Aprendizado de Máquina; Análise de Dados de Vibração; Bias de Similaridade.

Abstract:

Companies in the industrial sector generally have large investments in modern production equipment, as well as high maintenance costs for these units. Fast and accurate detection of failures and problems in industrial equipment makes a crucial contribution to reducing maintenance costs and improving confidence in production. Fault diagnosis consists of monitoring the operation of equipment in order to identify the occurrence of a failure. With the increase in the number of sensors installed on board in equipment, they have been more used to monitor the status of these equipment and diagnose their failures or malfunctions. Advances in research in the area of Artificial Intelligence, especially in the area of Machine Learning, provide ways to increase the reliability of intelligent fault diagnosis systems and result in a more reliable performance of equipment and industry. This article presents an overview of the vibration data that have been used in several works in the last 30 years, points out a common problem in the use of these data, presents what needs to be done to solve it and how the academic community can contribute to this solution.

Keywords: Fault Diagnosis; Machine Learning; Vibrational Data Analysis; Similarity Bias.

1. Introdução

O diagnóstico inteligente de falhas em equipamentos industriais consiste em aplicar técnicas de inteligência artificial para identificar a ocorrência de falhas e qual o tipo de falha que ocorreu. Este é um problema categorizado como de classificação, no qual o modelo é induzido para escolher uma ou mais classes dentre um conjunto de possíveis classes. De modo geral, uma das classes do problema é a classe normal que

apresenta exemplos do equipamento funcionando sem a presença de qualquer falha. As demais classes apresentam exemplos de diferentes tipos de falhas que podem ocorrer durante a operação do equipamento.

Técnicas de Inteligência Artificial aplicadas no diagnóstico inteligente de falhas tipicamente utilizam dados coletados por sensores ao longo do tempo de operação dos equipamentos industriais. Os sensores

mais comumente utilizados são os acelerômetros, que capturam a magnitude da vibração em um determinado instante. A coleta de dados pode ser contínua ou ocorrer em intervalos regulares de tempo. Cada medição pode conter dados de um único instante no tempo ou de um intervalo de tempo. De modo geral, a sequência temporal na qual os dados são coletados têm relevância para o diagnóstico das falhas. As curvas temporais representadas pela sequência de dados indicam padrões de normalidade e falha.

Existe uma literatura abundante de trabalhos que utilizam dados de vibração para diagnóstico inteligente de falhas em equipamentos industriais os quais utilizam dados de vibração coletados em ensaios laboratoriais ou de equipamentos em operação em campo. Técnicas de Inteligência Artificial são usadas para que o sistema aprenda modelos capazes de realizar o diagnóstico de falhas a partir da coleta de amostras dos dados de vibração do equipamento em operação. Os resultados reportados nestes trabalhos são de modo geral bons ou excelentes, trazendo uma grande esperança de que essas técnicas possam ser aplicadas no dia a dia das indústrias.

Este artigo, contudo, indica que o uso dessas técnicas no dia a dia ainda está distante. Ele aponta e analisa profundamente um problema comum nos trabalhos reportados na literatura, relacionado à forma como os dados são utilizados e na metodologia de avaliação utilizada. O artigo também propõe uma maneira de eliminar esse problema, embora isso envolva um grande esforço da comunidade científica e industrial.

Além desta introdução, este artigo é organizado da seguinte forma: a Seção 2 apresenta uma visão geral e breve das principais técnicas de Inteligência Artificial usadas com dados de vibração em equipamentos industriais para o diagnóstico inteligente de falhas. A Seção 3 apresenta as bases de dados mais frequentemente utilizadas nestes trabalhos, resumindo suas características mais relevantes. A Seção 4 identifica o problema comum existente nestes trabalhos e os categorizam em diferentes

subtipos. A Seção 5 apresenta a nossa proposta para a minimização desses problemas. Finalmente, a seção 6 apresenta as nossas conclusões.

2. Diagnóstico de Falhas em Equipamentos Industriais

A maior parte das técnicas de aprendizado usadas para diagnóstico de falhas em equipamentos industriais é de aprendizado supervisionado, requerendo assim que os exemplos da base indiquem se representam uma condição de operação normal do equipamento ou uma condição que representa uma falha específica. O tipo de dado da base de exemplos mais utilizado no diagnóstico de falhas é o sinal de vibração do equipamento.

2.1. Domínio dos Dados

O sinal de vibração é originalmente extraído como uma série-temporal no domínio do tempo, porém, para a realização do diagnóstico na prática se aplicam transformações no sinal para obter seu espectro no domínio da frequência, o qual permite a identificação de padrões não evidentes no domínio do tempo.

2.1.1. Tempo

O sinal temporal é obtido a partir da coleta de medições de sensores do tipo acelerômetro localizados em posições específicas do equipamento ao longo de um período de tempo. Cada medição consiste da amplitude da vibração em um determinado instante. O sinal extraído no domínio do tempo pode ser utilizado diretamente como entrada nos classificadores, neste caso, cada medição corresponde a uma entrada, ou como é mais comum, são extraídas características do sinal as quais servem como entrada do classificador. Exemplos de características comuns são estatísticas como média da amplitude, desvio padrão, curtose, pico máximo e rms (*root mean square*) do sinal. A figura 1 apresenta um exemplo de um sinal de vibração coletado no domínio do tempo.




Figura 1 - Sinal de vibração no domínio do tempo

2.1.2. Frequência

Em situações do mundo real, máquinas complexas com muitos componentes geram uma gama variada de vibrações. Dessa forma, na prática da engenharia é difícil utilizar os sinais no domínio do tempo para analisar a situação do equipamento. Engenheiros especialistas lançam mão da transformação do sinal para o domínio da frequência, onde pode se identificar picos de amplitude em frequências típicas de defeitos. A transformação pode ser realizada facilmente pela Transformada Rápida de Fourier (TRF). A figura 2 mostra um exemplo de sinal transformado para o domínio da frequência de um defeito de desbalanceamento de bombas centrífugas. Note o pico existente na frequência de rotação do equipamento.




Figura 2 - Sinal de vibração no domínio da frequência

2.2. Técnicas de Aprendizado de Máquina

Várias técnicas de aprendizado de máquina têm sido usadas neste problema, envolvendo desde a extração e seleção de características a variados algoritmos de classificação.

2.2.1. Tradicionais

Métodos de classificação tradicionais como k vizinhos mais próximos (WANG, 2016), máquinas de vetores de suporte (RAUBER et al., 2021) e florestas de árvores de decisão (MELLO et al., 2022) têm sido aplicados com sucesso no diagnóstico inteligente das falhas. Normalmente esses métodos são aplicados a partir de características estatísticas definidas com o auxílio de conhecimento especializado sobre o funcionamento do equipamento específico em foco no problema. A definição dessas características é a etapa mais relevante e trabalhosa para a aplicação dos métodos. Uma revisão ampla sobre a aplicação desses métodos nesse problema pode ser encontrada em (LIU et al., 2018).

2.2.2. Aprendizado Profundo

Mais recentemente, técnicas de aprendizado profundo (MELLO et al., 2022) têm obtido resultados ainda mais promissores nesta tarefa. Uma grande vantagem destas técnicas é extrair diretamente as características relevantes a partir da entrada do sinal bruto no domínio do tempo ou da frequência, dispensando a necessidade de uso de conhecimento especializado prévio, o que proporciona maior capacidade de generalização da aplicação.

As técnicas de aprendizado profundo têm sido usadas tanto como extratores automático de características, neste caso, as características extraídas são depois usadas como entradas para classificadores tradicionais, como também como métodos de classificação, neste caso uma camada adicional de classificação é adicionada para que a própria rede neural profunda possa realizar a classificação.

Uma ampla revisão sobre a aplicação desses métodos de aprendizado profundo para diagnóstico inteligente de falhas baseada em sinais de vibração pode ser encontrada em (ZHANG et al., 2020).

3. Análise de Dados de Vibração

Os métodos de aprendizado de máquina dependem fundamentalmente dos dados usados como entrada. Dessa forma, torna-se necessário garantir que os métodos

usados recebam dados de qualidade e numerosos, garantindo uma diversidade suficiente entre os dados para que o modelo possa abstrair as informações e aprender a generalizar a tarefa de diagnóstico. Contudo, apesar da evolução na aquisição dos dados em equipamentos o processo ainda é demorado e caro dado que a máquina leva um longo tempo para falhar. Sendo assim, instituições ao redor do mundo realizaram experimentos em ambientes controlados induzindo falhas em máquinas ou acelerando o processo para, assim, proporcionar à comunidade *datasets* para treinar seus modelos. Todavia, cada experimento tem sua particularidade que deve ser levada em conta, como o tipo de equipamento, a frequência de rotação, e as condições de operação. Dado isso, apresentamos a seguir os principais *datasets* públicos no contexto de equipamentos industriais dividido por graus de similaridade.

3.1. Mesmo Equipamento, Mesmas Condições e Diferentes Estados

Há *datasets* em que os sinais de diferentes classes são adquiridos em contextos iguais, ou seja, o sinal de normal e o de falhas é adquirido a partir de um único equipamento usando-se as mesmas condições, por exemplo, a mesma frequência de rotação e a mesma carga a qual o equipamento é submetido. O *dataset* disponível desse tipo é o *Intelligent Maintenance Systems* (IMS)(QIU et al., 2003).

Os dados do IMS foram coletados a partir de 3 experimentos *run-to-failure*, cada um utilizando um equipamento de teste composto por 4 rolamentos atrelados a uma haste, a qual estava acoplada a um motor. Assim, o instituto acelerou o processo de degradação dos rolamentos e, dessa forma, conseguiu obter 4 estados: normal, falha da pista interna, falha da pista externa e falha da roldana.

3.2. Mesmo Equipamento, Diferentes Condições

O CWRU (*Case Western Reserve University*) (CWRU, 2021) é provavelmente o *dataset* mais referenciado na literatura no contexto de detecção de falhas em

equipamentos. Os dados disponibilizados neste *dataset* foram adquiridos por meio de um equipamento de teste que consiste em um motor elétrico no qual falhas foram simuladas e testadas, incluindo falha na pista interna, falha na pista externa e falha na bola do rolamento, assim como o estado normal da máquina.

Outro *dataset* nesta categoria é o MFPT (*Mechanical Failures Prevention Group*)(MFPT, 2012) *bearing dataset*. O MFPT é composto por 4 estados de rolamento, todos obtidos com a mesma frequência de rotação, utilizando o mesmo equipamento de teste. Os estados englobados são as condições dos rolamentos normais, falha na pista interna e falha na pista externa.

Além desses, tem-se o *dataset* MAFAULDA (*Machinery Fault Database*) (MAFAULDA, 2021) disponibilizado pelo SMT(*Signals, Multimedia, and Telecommunications Laboratory*) da UFRJ composto por experimentos feitos em um simulador de falhas de máquinas basicamente composto de rolamentos conectados por uma haste, atrelada a um motor. Nesse experimento foram simulados seis estados diferentes: estado normal, falha de desbalanceamento, desalinhamento vertical e horizontal e falha no rolamento externo e interno.

3.3. Mesmo Tipo de Equipamento, Diferentes Equipamentos, Diferentes Condições

O *dataset* ESPset (*Electrical Submersal Pump dataset*) executa a coleta dos dados de vibração em experimentos realizando em bombas centrífugas submersas (BCS), equipamento de grande importância na indústria do petróleo. O *dataset* contém dados de vibrações de 12 BCSs diferentes, nas quais uma BCS é testada com diferentes frequências de rotação e monitorada por 36 acelerômetros localizados em diferentes posições da BCS. Foram identificados 5 estados no *dataset* inteiro, o sinal normal, falha no sensor/acelerômetro, desalinhamento, roçamento e desbalanceamento, totalizando 6032 sinais de vibração.

4. Bias de Similaridade

Uma parte essencial do aprendizado de máquina é saber avaliar o desempenho do algoritmo de tal forma que o resultado apresentado seja consistente e desempenhe de acordo quando exposto a dados nunca vistos do mundo real. Entretanto, muitos trabalhos de diagnósticos inteligentes de falhas baseadas na análise de sinais de vibração pecam em garantir essa consistência na amostragem e seus trabalhos ficam sensíveis ao chamado **bias de similaridade** (RAUBER et al., 2021). Isso ocorre porque a aquisição de dados é feita por meio de séries temporais as quais são divididas em janelas para gerar instâncias diferentes para o treinamento dos classificadores. Dessa forma, deveria ser garantido que a divisão entre treino e teste não contém padrões extraídos de um mesmo sinal em períodos de tempo similares já que, caso isso ocorra, a tarefa de classificação se torna relativamente simples. É importante ressaltar que, mesmo que o pesquisador realize a amostragem meticulosamente tentando evitar o bias de similaridade, há casos que o *dataset* não permite que o bias seja totalmente evitado. Tendo em vista esse cenário há vários graus de bias que podem ocorrer.

4.1. Máximo

Quando os conjuntos de treino e teste levam em conta sinais de um mesmo equipamento testado com as mesmas condições, a pesquisa fica extremamente enviesada e o bias de similaridade está em seu grau máximo uma vez que, como apontado acima, a tarefa de classificação se torna trivial dado que há uma grande dependência entre conjunto de treino e teste. Conforme ilustrado em (RAUBER et al., 2021), esse caso acaba ocorrendo na maioria dos artigos de aprendizado de máquina aplicado ao diagnóstico de falhas baseada em dados de vibração, os quais rotineiramente reportam taxa extremamente elevadas de acerto, beirando à 100% de acurácia. (RAUBER et al., 2021) realiza um experimento usando validação cruzada aninhada na base de dados CWRU no qual exemplos dos conjuntos de treino e teste provêm das mesmas séries temporais e,

como esperado, atingem resultados muito próximos a 100% de acurácia. Por conseguinte, os métodos usados nesses artigos tendem a não funcionar até mesmo em equipamentos utilizados na pesquisa mas em condições diferentes.

4.2. Intermediário

Pesquisas que utilizam técnicas de amostragem nos quais o conjunto de treino possui instâncias de sinais temporais obtidos em determinadas condições e o conjunto de teste possui instâncias de sinais temporais oriundos de outras condições reduzem o bias de similaridade, porém quando os dados são obtidos a partir de um mesmo equipamento e as condições não variam de forma significativa, acabam por manter um grau intermediário de bias de similaridade. (RAUBER et al., 2021) realizou dois outros experimentos com a base de dados CWRU no qual os conjuntos de treino e teste foram separados de forma a garantir que os exemplos de teste não provenham das mesmas séries temporais utilizadas para obter os exemplos de treino.

No primeiro deles, a diferença entre os exemplos dos conjuntos de treino e teste foi alcançada usando diferentes cargas no equipamento. Neste experimento as diferenças de carga não tinham muito impacto na forma das séries temporais e os resultados ficaram próximos de 95% de acurácia, indicando um bias de similaridade intermediário, porém ainda alto.

No segundo experimento, as diferenças foram obtidas com variação de carga e variação da severidade da falha. Os resultados caíram significativamente, para próximo de 50% de acurácia, mostrando o decaimento significativo do desempenho dos métodos avaliados quando se reduz o bias .

4.3. Mínimo

Quando o conjunto de treino e teste é amostrado de tal forma que os dados do conjunto de teste são adquiridos de um equipamento distinto dos equipamentos usados para obter os exemplos de treino, preferencialmente sob várias condições de uso, o bias de similaridade é mínimo e, neste caso, os resultados obtidos são mais prováveis de serem generalizáveis.

5. Integração e Ampliação das Bases de Dados

Mesmo se tomando cuidados para minimizar o bias de similaridade, a capacidade de generalização dos resultados continua questionável, visto que, na prática, as condições reais são bem variadas e normalmente distintas das condições usadas nos experimentos.

Uma maneira de avançar na solução desse problema seria montar uma grande base de dados composta pela integração das bases de dados públicas em uma única base usada para treinamento e teste dos classificadores. Classificadores com bons resultados teriam maior possibilidade de generalização considerando que o conjunto de dados usado para treinamento é bem mais variado e distinto do conjunto usado no teste. Atualmente, temos investido na formação dessa base de dados e avaliado o impacto de usá-la junto aos métodos de diagnóstico inteligente de falhas.

Um projeto mais desafiador e promissor nesta direção seria criar uma base de dados integrada e ampliada coletando sinais em diferentes condições de diferentes tipos de equipamentos para várias tarefas de diagnóstico de falhas, como o *dataset* ImageNet (DENG et al., 2009) da comunidade de visão computacional. Dessa forma, haveria dados suficientes para que a divisão entre treino e teste fosse feita sem qualquer *bias* de similaridade. Este é um projeto desafiador que vai requisitar um grande esforço da comunidade científica e industrial.

6. Considerações Finais

Até o momento da publicação desse artigo não há *dataset* público que utilize diferentes tipos de equipamentos com diferentes equipamentos para aquisição de dados de vibração. Dessa forma, torna-se um esforço necessário a divulgação para a comunidade acadêmica um *dataset* integrado de dados de vibração, como proposto nesse artigo, para que futuros trabalhos sejam feitos de forma que a amostragem seja montada de modo que vários tipos de equipamentos sejam utilizados e que, no conjunto de teste, haja tipos de

equipamentos não encontrados no conjunto de treino. Isto posto, não haveria *bias* de similaridade na pesquisa e, portanto, caso algum artigo reporte bons resultados satisfazendo essas condições, indicaria que o uso dessas técnicas no dia a dia é bastante viável.

7. Referências

CWRU. **Case Western Reserve University Bearing Dataset Center**. Disponível em: <<https://engineering.case.edu/bearingdatacenter>>. Acesso em: 17 set. 2022.

DENG, J. et al. **ImageNet: A large-scale hierarchical image database**. 2009 IEEE Conference on Computer Vision and Pattern Recognition. **Anais...** Em: 2009 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION. jun. 2009.

LIU, R. et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. **Mechanical Systems and Signal Processing**, v. 108, p. 33–47, 1 ago. 2018.

MAFAULDA. **Machinery Fault Database**. Disponível em: <http://www02.smt.ufrj.br/~offshore/mfs/page_01.html#SEC1>. Acesso em: 17 set. 2022.

MELLO, L. H. S. et al. Ensemble of metric learners for improving electrical submersible pump fault diagnosis. **Journal of Petroleum Science and Engineering**, v. 218, p. 110875, 1 nov. 2022.

MFPT. **Fault Data Sets - Society For Machinery Failure Prevention Technology**. Disponível em: <<https://www.mfpt.org/fault-data-sets/>>. Acesso em: 17 set. 2022.

QIU, H. et al. Robust performance degradation assessment methods for enhanced rolling element bearing prognostics. **Advanced Engineering Informatics**, Intelligent Maintenance Systems. v. 17, n. 3, p. 127–140, 1 jul. 2003.

RAUBER, T. W. et al. An experimental methodology to evaluate machine learning methods for fault diagnosis based on vibration signals. **Expert Systems with Applications**, v. 167, p. 114022, 1 abr. 2021.

WANG, D. K-nearest neighbors based methods for identification of different gear crack levels under different motor speeds and loads: Revisited. **Mechanical Systems and Signal Processing**, v. 70–71, p. 201–208, 1 mar. 2016.

ZHANG, S. et al. Deep Learning Algorithms for Bearing Fault Diagnostics—A Comprehensive Review. **IEEE Access**, v. 8, p. 29857–29881, 2020.