

DETECÇÃO DE FOLGA EM CORRENTE DE TRANSMISSÃO POR FUSÃO VIBROACÚSTICA E APRENDIZADO DE MÁQUINA EM MÁQUINAS FORMADORAS DE COPOS DE PAPEL

Pedro Augusto Matelli Antunes de Oliveira – d2024103713@unifei.edu.br
Matheus Brendon Francisco – matheus_brendon@unifei.edu.br

Palavras-chave: Detecção de falhas, Indústria 4.0, Inteligência Artificial

1. INTRODUÇÃO

A detecção precoce de defeitos em máquinas industriais é essencial para garantir a eficiência operacional, reduzir custos de manutenção e evitar paradas inesperadas no processo de fabricação. Nesse contexto, a manutenção preditiva consolidou-se como pilar da Indústria 4.0 por viabilizar a identificação antecipada de falhas e o planejamento otimizado de intervenções; estudos reportam reduções de até 30% nos custos de manutenção, com ganhos de produtividade e confiabilidade (Matelli A. de Oliveira et al., 2025). Entre as abordagens, a análise de sinais acústicos e de vibração tem se destacado por permitir monitoramento contínuo e não invasivo, detectando anomalias antes de se tornarem falhas críticas; além disso, a fusão desses sinais eleva significativamente a precisão dos modelos de diagnóstico em relação ao uso isolado (Li et al., 2024; Praveen Kumar et al., 2019). Complementarmente, algoritmos de aprendizado de máquina — como Random Forest, XGBoost, SVM e redes neurais — capturam padrões complexos associados a diferentes condições operacionais, apresentando resultados promissores em aplicações industriais (Cakir; Guvenc; Mistikoglu, 2021).

À luz desse cenário, este estudo aborda a detecção de folga nas correntes do sistema de transmissão em máquinas formadoras de copos de papel. Esses elementos são essenciais para o sincronismo entre os principais conjuntos do equipamento e, quando apresentam folga, podem comprometer a estabilidade

operacional e a qualidade do produto. Propõe-se aplicar algoritmos de aprendizado de máquina a sinais acústicos e de vibração coletados em operação real, visando identificar assinaturas de falha de forma antecipada. O estudo busca avançar as práticas de manutenção preditiva e fortalecer a transformação digital na indústria.

2. DESENVOLVIMENTO

2.1 Referencial teórico

A manutenção preditiva, difundida desde a década de 1980 como alternativa mais eficiente aos métodos reativos e preventivos, busca detectar anomalias antes que se tornem críticas, permitindo intervenções apenas quando necessárias — o que reduz custos e eleva a confiabilidade. Alavancada pelos avanços da Indústria 4.0, ela substitui abordagens convencionais por sistemas de monitoramento que coletam grandes volumes de dados provenientes de sensores. Isso viabiliza a automação do diagnóstico de falhas por meio de algoritmos como os de *Machine Learning* (Cakir et al., 2021). Os principais modelos empregados neste contexto estão sintetizados no Quadro 1.

Quadro 1 - Principais algoritmos de aprendizado de máquina aplicados ao diagnóstico de falhas em máquinas industriais.

Algoritmo	Características principais	Vantagens
<i>Support Vector Machines (SVM)</i>	Constrói hiperplanos que separam classes maximizando a margem	Alta precisão em bases pequenas e de alta dimensionalidade; boa generalização.

<i>Random Forest (RF)</i>	Combina múltiplas árvores de decisão geradas por <i>bagging</i> e amostragem aleatória de atributos.	Robusta a ruído; reduz sobreajuste; fornece importância das variáveis.
<i>Extreme Gradient Boosting (XGBoost)</i>	Constrói árvores de forma sequencial, corrigindo erros residuais.	Alta acurácia e eficiência; controle de complexidade; boa escalabilidade.
<i>Multilayer Perceptron (MLP)</i>	Rede neural com múltiplas camadas ocultas e funções de ativação não lineares.	Capta relações complexas entre variáveis.
<i>Ensemble</i>	Combina previsões probabilísticas de diferentes modelos ponderando seus desempenhos.	Maior estabilidade e precisão; reduz viés e variância.


Fonte: Adaptado de Cortes; Vapnik, 1995; Breiman, 2001; Chen; Guestrin, 2016.

Entre tipos de informações utilizadas na manutenção preditiva, sinais de vibração e acústicos destacam-se como indicadores do comportamento dinâmico das máquinas. Os primeiros, captados por acelerômetros, são amplamente usados no diagnóstico de falhas em rolamentos, engrenagens e eixos por refletirem diretamente variações mecânicas e estruturais; já os sinais acústicos, captados por microfones (ou sensores de emissão acústica), oferecem caráter não invasivo, baixo custo e a capacidade de detectar falhas incipientes antes mesmo de se tornarem perceptíveis na vibração (Matelli A. de Oliveira et al., 2025). Cada tipo tem limitações: a vibração exige contato e é sensível a ruídos estruturais, enquanto a acústica sofre com ruído ambiental. A fusão vibroacústica mitiga essas limitações ao combinar a robustez da vibração com a sensibilidade da acústica, resultando em desempenho superior; estudos recentes indicam acurácia acima de 96% em tarefas de classificação de falhas (Inturi et al., 2023; Pacheco-Chérrez et al., 2022). Assim, o uso de sinais multissensoriais possibilita soluções robustas para diagnóstico automático no contexto da Indústria 4.0.

2.2 Metodologia

O experimento focou a máquina PT80 (Zhejiang New Debao), com destaque para a Corrente 1, mais suscetível a folgas mecânicas que aumentam a vibração e reduzem a estabilidade. A Figura 1 mostra a máquina e a localização da Corrente 1.

Figura 1 - Máquina de Fabricação de Copos de Papel (PT80 Debao) e Corrente 1



Fonte: Elaboração própria (2025).

Os dados foram coletados em operação real. O delineamento considerou a Corrente 1 como alvo do diagnóstico e as Correntes 2 e 3 como variáveis de interação. Além disso, a velocidade de operação entrou como fator adicional: adotaram-se 20 Hz (baixa) e 35 Hz (alta) para treino/validação, e 27,5 Hz (média) apenas para teste, a fim de verificar a generalização dos modelos em uma condição inédita (não vista no treinamento).


Para montar as bases consolidadas de treinamento e teste dos modelos, os sinais acústicos e de vibração foram sincronizados e segmentados em janelas de 5 s com 50% de sobreposição. De cada janela extraíram-se características estatísticas e espectrais (p. ex., RMS, energia e frequência de pico), padronizadas antes da aplicação dos modelos. Separou-se 30% dos dados da base de treino para validação. A Figura 2 ilustra o janelamento e extração de *features*.

Figura 2 - Janelamento e extração de *features* dos sinais de Áudio e Vibração

Features por Janela

média, desvio padrão, skewness, kurtosis, energia, frequência de pico, e Zero Crossing Rate (ZCR),

valor de pico, média, desvio padrão, skewness, kurtosis, energia, e frequência de pico.




Fonte: Elaboração própria (2025).

Foram implementados os modelos: RF, XGBoost, SVM, MLP e um *Ensemble* combinando os anteriores. A avaliação considerou dois cenários: (i) apenas áudio e (ii) áudio + vibração (fusão multissensorial). Essa comparação quantificou o ganho de acurácia decorrente da integração multissensorial.

3. RESULTADOS E DISCUSSÃO

Os resultados obtidos evidenciaram desempenhos distintos em ambos os cenários. Para os testes considerando apenas os dados de áudio, os resultados estão apresentados na Figura 3, que compara as acurácias de validação e teste para cada modelo.

Figura 3 - Comparativo de Acurácia entre Modelos utilizando Áudio




Fonte: Elaboração própria (2025).

Observa-se que o RF foi o mais consistente (84% validação, 76% teste), o *XGBoost* liderou na validação (85%) mas caiu no teste (71%).

Com áudio + vibração, o desempenho melhorou (ver Figura 4): *XGBoost* (97% validação, 94% teste) liderou, seguido de RF (96%/92%), *Ensemble* (95%/91%), MLP (96%/89%) e SVM (90%/88%).

Figura 4 - Comparativo de Acurácia entre Modelos utilizando Áudio e Vibração



Fonte: Elaboração própria (2025).

De forma geral, os resultados confirmam que a inclusão dos sinais de vibração aumenta o desempenho dos modelos, tornando-os mais confiáveis para identificar folgas na Corrente 1 sob diferentes condições operacionais. A abordagem multissensorial mostrou-se, portanto, mais robusta e generalizável, representando um avanço importante em relação ao uso isolado de áudio.

4. CONSIDERAÇÕES FINAIS

O estudo comprovou a eficácia da utilização de sinais combinados de áudio e vibração para a detecção de folgas mecânicas na Corrente 1 da máquina formadora de copos de papel, especialmente aplicando o *XGBoost*, que apresentou o melhor desempenho nos dados de validação e teste. Os resultados reforçam o potencial dessa abordagem para aplicações em manutenção preditiva e indicam caminhos promissores para o desenvolvimento de sistemas de monitoramento contínuo.

AGRADECIMENTOS

Agradeço ao meu orientador pelo apoio técnico, bem como ao IEPGE e à UNIFEI pela oportunidade e ambiente acadêmico que viabilizaram esta pesquisa.

REFERÊNCIAS

- BREIMAN, Leo. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.
- CAKIR, M.; GUVENC, M. A.; MISTIKOGLU, S. The experimental application of popular machine learning algorithms on predictive maintenance and the design of IIoT based condition monitoring system. **Computers and Industrial Engineering**, v. 151, 2021.
- CHEN, Tianqi; GUESTRIN, Carlos. XGBoost: A scalable tree boosting system. *In: PROCEEDINGS OF THE ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING. Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.* Association for Computing Machinery, 2016.
- CORTES, Corinna; VAPNIK, Vladimir. Support-Vector Networks. **Machine Learning**, v. 20, n. 3, p. 273–297, 1995.
- INTURI, V. *et al.* An integrated condition monitoring scheme for health state identification of a multi-stage gearbox through Hurst exponent estimates. **Structural Health Monitoring**, v. 22, n. 1, p. 730–745, 2023.
- LI, X. *et al.* Multi-sensor fusion fault diagnosis method of wind turbine bearing based on adaptive convergent viewable neural networks. **Reliability Engineering and System Safety**, v. 245, 2024.
- MATELLI A. DE OLIVEIRA, Pedro Augusto; BRENDON FRANCISCO, Matheus; MONFREDINI SILVA, Kevin Henrique. Revisão do Diagnóstico de Falhas em Equipamentos Industriais Utilizando Redes Neurais e Análise de Sinais Acústicos. *In: 13TH BRAZILIAN CONGRESS ON MANUFACTURING ENGINEERING. Proceedings of the 13th Brazilian Congress on Manufacturing Engineering.*

ABCM, 2025. Disponível em: <<http://abcm.org.br/anais-de-eventos/COF25/0477>>.

Acesso em: 22 out. 2025

PACHECO-CHÉRREZ, J. *et al.* Bearing fault detection with vibration and acoustic signals: Comparison among different machine learning classification methods.

Engineering Failure Analysis, v. 139, 2022.

PRAVEEN KUMAR, T. *et al.* A multi-sensor information fusion for fault diagnosis of a gearbox utilizing discrete wavelet features. **Measurement Science and Technology**, v. 30, n. 8, 2019.