



Deteção de anomalias acústicas em ambientes industriais via aprendizado não supervisionado integrado à plataforma IoT

Ana Laura Ladir de Oliveira Martins | ana.lom@aluno.ifsc.edu.br¹

Gregory Chagas da Costa Gomes | gregory.chagas@ifsc.edu.br²

Trabalho de Pesquisa.
DT 4 - Inovação Tecnológica, Processos Produtivos e Futuro das Tecnologias

Resumo:

O presente trabalho apresenta o desenvolvimento de um sistema de monitoramento de ruídos para manutenção preditiva industrial, utilizando inteligência artificial não supervisionada. O objetivo central foi validar o algoritmo de detecção de anomalias integrado à uma arquitetura de aquisição de dados, capaz de identificar falhas sem a necessidade de rótulos prévios de treinamento. A metodologia envolveu o uso de sensores de ruídos instalados em um ambiente controlado, cujos sinais foram processados por uma lógica de inferência baseada no algoritmo ensemble. O refinamento da agregação temporal no script de análise corrigiu a subestimação de picos anômalos, elevando a sensibilidade do sistema a eventos transitórios. Como resultado, o modelo demonstrou eficácia na detecção em tempo real, com métricas de desempenho satisfatórias.

Palavras-chave: inteligência artificial; detecção de anomalias; manutenção preditiva.

Introdução

No cenário da Indústria 4.0, a manutenção preditiva baseada no monitoramento de condições torna-se essencial para garantir a eficiência produtiva e reduzir custos operacionais com paradas não planejadas. O ruído acústico destaca-se como um indicador crítico no diagnóstico de falhas mecânicas e elétricas de equipamentos de chão de fábrica. No entanto, a análise manual desses sinais é complexa e exige especialistas, o que motivou o desenvolvimento de um sistema automatizado baseado em Inteligência Artificial (IA) para a detecção de anomalias acústicas (DOHI et al., 2022).

Dentro do contexto do projeto PFLN-2507.0024, este resumo expandido apresenta o desenvolvimento de um módulo de IA, integrado a uma arquitetura de aquisição de dados, capaz de detectar anomalias acústicas em ambientes industriais. É caracterizado neste projeto o princípio da indissociabilidade entre o ensino, a pesquisa e a extensão, pois o projeto traduz teorias de aprendizado de máquina em uma solução tecnológica aplicada,

¹ Estudante de Engenharia Mecatrônica do Instituto Federal de Santa Catarina.

² Professor do curso de Engenharia Mecatrônica, DAMM, Campus Florianópolis.

desenvolvida pelo Laboratório de Projetos de Aprendizagem em Eletrônica (LPAE) e pelo Grupo de Sistema Embarcados e Distribuídos (NERsD) em parceria com a Embrapii. Essa iniciativa contribui para o fortalecimento da formação acadêmica na área da engenharia e para a transferência de conhecimento técnico ao setor produtivo, visando a futura implementação prática em cenários industriais reais.

Fundamentação teórica

A detecção de anomalias em sinais acústicos baseia-se na identificação de padrões que não se conformam ao comportamento esperado de um sistema. Academicamente, o desafio em si reside na natureza não supervisionada dos dados industriais, onde a ausência de rótulos de falha impossibilita o uso de classificadores convencionais. Para superar essa limitação, utiliza-se uma combinação de algoritmos por meio da técnica de ensemble, o que permite que o modelo selecione os melhores detectores para diferentes regiões do espaço de dados, aumentando a robustez contra ruídos irrelevantes e variações não estacionárias comuns em ambientes de fábrica (ZHAO et al., 2019).

Embora a arquitetura utilize aprendizado não supervisionado, a validação quantitativa das métricas de desempenho foi viabilizada por uma heurística temporal baseada na dinâmica do laboratório. Nesta abordagem, os dias de semana foram classificados como comportamento normal, enquanto os finais de semana — devido à mudança drástica no padrão acústico e de ocupação — foram utilizados como referência de comportamento anômalo. Essa segmentação permitiu a estruturação de uma matriz de confusão e cálculo de métricas formais (Precisão, *Recall* e *F1-Score*) mesmo diante da ausência de rótulos prévios.

Procedimentos metodológicos

A metodologia baseou-se em um pipeline de processamento de sinais e aprendizado de máquina para monitoramento acústico industrial. O sistema utiliza seis sensores que capturam áudio a 24 kHz por 1 minuto, a cada 15 minutos. Localmente, o sinal bruto é filtrado em sete bandas de frequência (125, 250, 500, 1000, 2000, 4000 e 8000Hz) para extração da Raiz Quadrada Média (*Root Mean Square* — RMS), além de um RMS global (sem filtragem). Cada amostra gerada consiste, portanto, em um vetor de 8 características

por sensor, transmitido via gateway Zigbee para um ambiente computacional externo onde ocorrem as rotinas de análise e inferência.

No módulo de treinamento, os dados históricos passaram por limpeza de valores ausentes, padronização *Z-score* e injeção de ruído gaussiano (0,001). A inteligência do sistema foi estruturada por meio do algoritmo LSCP (*Locally Selective Combination of Parallel Outlier Ensembles*) para detecção de anomalias.

Na etapa de validação, uma matriz de confusão inicial revelou alto índice de Falsos Negativos. Um experimento controlado com sensor USB diagnosticou que o lote (*batch*) original de 96 amostras (~24h) diluía picos sonoros anômalos ao calcular a média do período. Para preservar a sensibilidade a eventos transitórios, o tamanho do lote foi refinado para 10 amostras (~2h30min).


Por tratar-se de uma etapa preliminar do projeto, o objetivo central fixou-se na validação do fluxo do processo (aquisição, transmissão e viabilidade da inferência), e não no diagnóstico definitivo de falhas mecânicas. Assim, adotou-se uma avaliação quantitativa heurística baseada na ocupação do laboratório: dias úteis (ruído padrão) foram rotulados como normais e finais de semana (silêncio) como anômalos. Embora o silêncio não equivalha a uma avaria mecânica, a abordagem mostrou-se eficaz nesta fase para testar a capacidade do algoritmo em discriminar cenários acústicos distintos, validando o pipeline para futuros treinamentos com dados reais de defeitos industriais.

Resultados e discussões

Os resultados obtidos demonstram a viabilidade do sistema de detecção de anomalias acústicas no ambiente do laboratório, cumprindo com o objetivo de validar um módulo de IA integrado ao monitoramento industrial. Inicialmente, a análise dos 2.553 registros históricos apontou uma taxa global de predição de anomalias de 7,1% com uma distribuição uniforme entre as bandas espectrais, o que sugeria uma sensibilidade equilibrada do modelo ao longo do espectro sonoro. Contudo, a aplicação de uma matriz de confusão revelou um desempenho insatisfatório na configuração original de produção, que utilizava um *batch* de 96 amostras, apresentando um elevado índice de Falsos Negativos (FN). Conforme evidenciado na Figura 1, a configuração antiga possuía um *Recall* de apenas 16,67%, falhando em detectar a maioria dos eventos anômalos reais

devido à diluição de picos sonoros em janelas de tempo excessivamente longas (aproximadamente 24h).

Figura 1 – Comparativo de desempenho entre janelas de inferência: Batch 96 vs. Batch 10.



A investigação técnica permitiu a otimização do sistema por meio da redução da janela de análise para 10 amostras (cerca de 2,5 horas), preservando as variações sonoras transitórias sem perder o contexto temporal necessário. Esta alteração resultou em um salto qualitativo nas métricas de desempenho, com o Recall elevando-se para 84,31% e a Precisão atingindo 82,69%, o que elevou o *F1-Score* para 83,50%. Como resultado desta etapa, tem-se a consolidação de um sistema funcional de inferência independente e uma base de dados histórica robusta, essenciais para o suporte à tomada de decisão. Cabe destacar, contudo, que a validação foi realizada em ambiente de laboratório, com base em uma heurística temporal que associa finais de semana a comportamento anômalo — uma aproximação que pode não refletir com fidelidade falhas mecânicas ou elétricas reais em equipamentos industriais. Portanto, os resultados apresentados são promissores e indicam o potencial da solução para aplicações industriais, mas estudos futuros em cenários reais serão necessários para confirmar a generalização do modelo. A discussão dos dados evidencia que a combinação dos algoritmos com o refinamento da estratégia de agregação temporal representa um avanço relevante para o contexto da Indústria 4.0.

Considerações finais

O presente trabalho alcançou o objetivo de desenvolver e validar um sistema funcional de detecção de anomalias acústicas para o contexto industrial. A escolha dos procedimentos metodológicos, centrada no algoritmo ensemble e no refinamento da agregação temporal via *batch*, mostrou-se acertada ao permitir que o sistema operasse de forma robusta mesmo diante da ausência de dados rotulados. A principal dificuldade técnica encontrada — a diluição de anomalias em janelas de tempo extensas — foi superada por meio de experimentação controlada, o que resultou em um sistema com sensibilidade superior a 84% para eventos sonoros críticos. É importante ressaltar, no entanto, que a validação quantitativa baseou-se em uma heurística temporal — dias úteis como normais e finais de semana como anômalos — que representa uma aproximação metodológica ao problema, e não a ocorrência de falhas mecânicas ou elétricas reais. Além disso, os experimentos foram conduzidos em ambiente de laboratório, o que limita a generalização direta dos resultados para ambientes industriais reais, onde variáveis como ruído de fundo,



temperatura e ciclos de operação são distintos. Essas limitações apontam para a necessidade de validação futura em campo como etapa essencial para consolidar a robustez da solução proposta.

No âmbito da formação profissional, a participação ativa no projeto permitiu a consolidação de competências essenciais na área da engenharia, desde a integração de *hardware* e protocolos de comunicação como Zigbee e HTTP, até o domínio de ferramentas avançadas de Ciência de Dados e IA. O desafio de diagnosticar e corrigir falhas de inferência em tempo real proporcionou uma vivência prática que extrapola a teoria de sala de aula, preparando a bolsista para enfrentar problemas complexos em cenários de alta incerteza tecnológica.

Por fim, a indissociabilidade entre ensino, pesquisa e extensão concretizou-se na aplicação prática de teorias de aprendizado de máquina em um sistema de monitoramento acústico. O projeto integrou o aprendizado acadêmico ao desenvolvimento científico de algoritmos e à entrega de uma ferramenta com potencial de uso industrial. As projeções futuras focam na validação dos modelos globais em cenários industriais reais e no refinamento de hiperparâmetros, consolidando o papel do IFSC como polo de inovação tecnológica aplicada.

Referências

PUROHIT, H. et al. Hierarchical Conditional Variational Autoencoder Based Acoustic Anomaly Detection. **2022 30th European Signal Processing Conference (EUSIPCO)**, p. 274–278, 29 ago. 2022.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python Gaël Varoquaux Bertrand Thirion Vincent Dubourg Alexandre Passos PEDREGOSA, VAROQUAUX, GRAMFORT ET AL. Matthieu Perrot Edouard Duchesnay. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

LSCP: Locally Selective Combination in Parallel Outlier Ensembles. Disponível em:

<<https://ar5iv.labs.arxiv.org/html/1812.01528>>. Acesso em: 25 maio. 2026.