

# MONITORAMENTO INTELIGENTE EM BOMBAS HIDRÁULICAS UTILIZANDO MACHINE LEARN EMBARCADO

Rafael Gonçalves Sousa<sup>1</sup>

<sup>1</sup> Graduando em Engenharia Elétrica Industrial, Instituto Federal do Maranhão – IFMA, Campus Monte Castelo, e-mail: rafael.sousa@acad.ifma.edu.br

## RESUMO

Este trabalho apresenta o desenvolvimento de um sistema embarcado de baixo custo para monitoramento de bombas hidráulicas utilizando técnicas de Tiny Machine Learning (TinyML). A pesquisa se justifica pela necessidade de soluções tecnológicas acessíveis que contribuam para a gestão sustentável dos recursos hídricos, reduzindo falhas inesperadas em sistemas de bombeamento e minimizando desperdícios em ambientes industriais e residenciais. O objetivo foi implementar um protótipo capaz de identificar o estado operacional de uma bomba periférica a partir da análise de vibração, diferenciando as condições de bomba desligada, em funcionamento normal e em situação de anomalia. O sistema foi construído com um microcontrolador Raspberry Pi Pico W e um sensor MPU6050 para aquisição dos sinais, processados pela Transformada Rápida de Fourier (FFT) e classificados por uma rede neural Perceptron Multicamadas (MLP) treinada em Python e embarcada em linguagem C. Os resultados demonstraram acurácia de 94% na classificação e tempo de resposta inferior a 2 ms durante a inferência embarcada, confirmando a eficiência da solução em tempo real. Conclui-se que a proposta é viável para aplicações de manutenção preditiva em sistemas hidráulicos, fortalecendo práticas de uso racional da água e contribuindo para maior confiabilidade e eficiência no enfrentamento de desafios ambientais contemporâneos.

**Palavras-chave:** TinyML. Manutenção preditiva. Vibração. Rede neural. Bomba hidráulica.

**Financiamento:** Este trabalho foi desenvolvido no âmbito do programa EmbarcaTech, financiado pelo Ministério da Ciência, Tecnologia e Inovação (MCTI) e coordenado pela SOFTEX.

## INTRODUÇÃO

A água constitui um recurso fundamental para a manutenção da vida, o desenvolvimento socioeconômico e a estabilidade ambiental. Contudo, sua disponibilidade vem sendo cada vez mais pressionada por fatores como o crescimento populacional, a expansão urbana, a intensificação agrícola e os efeitos das mudanças climáticas. Nesse contexto, torna-se essencial adotar soluções que permitam o uso racional e eficiente da água, reduzindo perdas e otimizando processos de abastecimento e distribuição.

Entre os diversos componentes envolvidos na gestão hídrica, as bombas hidráulicas desempenham papel central, uma vez que garantem o transporte e a pressurização da água em sistemas residenciais, comerciais e industriais. Falhas inesperadas nesse tipo de equipamento podem ocasionar não apenas interrupções no fornecimento, mas também desperdícios significativos de água e energia elétrica, além de custos elevados com reparos emergenciais. Assim, estratégias de monitoramento inteligente e manutenção preditiva ganham destaque como ferramentas capazes de aumentar a confiabilidade operacional e mitigar impactos ambientais e econômicos (RANDALL, 2021).

A manutenção preditiva baseia-se na análise de dados para prever falhas antes que elas ocorram, permitindo intervenções planejadas e mais eficientes. Tecnologias recentes, como sensores de vibração e algoritmos de aprendizado de máquina, têm ampliado as possibilidades de diagnóstico e acompanhamento em tempo real. Contudo, a aplicação prática desses recursos em equipamentos de pequeno porte, como bombas periféricas, ainda enfrenta desafios relacionados ao custo, à complexidade computacional e à necessidade de operação em ambientes com recursos limitados de hardware.

Nesse cenário, emergem as soluções de Tiny Machine Learning (TinyML), que permitem a execução de modelos de inteligência artificial diretamente em microcontroladores de baixo consumo energético e custo reduzido (WARDEN; SITUNAYAKE, 2019). Essa abordagem abre espaço para o desenvolvimento de sistemas embarcados capazes de realizar análises complexas em tempo real, sem depender exclusivamente de infraestrutura externa de computação em nuvem. Além disso, a combinação de sensores acessíveis, como acelerômetros, com microcontroladores de arquitetura simplificada torna possível o monitoramento distribuído em larga escala, o que contribui para práticas mais sustentáveis na utilização da água (UPTON; HALFACREE, 2022).

Diante dessa realidade, este trabalho tem como objetivo desenvolver e avaliar um sistema embarcado para monitoramento inteligente de bombas hidráulicas, utilizando técnicas de TinyML aplicadas à análise de sinais de vibração. A proposta consiste em implementar um protótipo baseado em microcontrolador Raspberry Pi Pico W e sensor MPU6050, capaz de classificar automaticamente três condições de operação da bomba: desligada, funcionamento normal e anomalia. O sistema busca demonstrar a viabilidade de soluções de baixo custo para manutenção preditiva, alinhadas a práticas de uso racional da água e enfrentamento de desafios ambientais contemporâneos.

## **METODOLOGIA**

A pesquisa foi conduzida por meio do desenvolvimento de um protótipo experimental voltado ao monitoramento de bombas hidráulicas com aplicação de técnicas de Tiny Machine Learning (TinyML) (WARDEN; SITUNAYAKE, 2019). O procedimento metodológico seguiu quatro etapas principais: coleta de dados, processamento de sinais, treinamento do modelo de rede neural e implementação embarcada.

**Configuração experimental** – Para simulação de condições reais de operação, foi utilizada uma bomba periférica Hammer MP-500, amplamente empregada em aplicações residenciais de abastecimento. O microcontrolador adotado foi o Raspberry Pi Pico W, devido ao baixo custo, reduzido consumo de energia e suporte a conectividade sem fio (UPTON; HALFACREE, 2022). O sensor de vibração empregado foi o MPU6050, que combina acelerômetro e giroscópio em um único módulo, permitindo a captura de sinais em três eixos com boa resolução para análises de dinâmica de funcionamento (IFEACHOR; JERVIS, 2018).

**Coleta de dados** – Os sinais de vibração foram coletados em diferentes condições de operação da bomba: desligada, funcionamento normal e funcionamento anômalo (obtido por meio da simulação de falhas mecânicas simples, como obstruções parciais) (RANDALL, 2021). Os dados foram transmitidos via protocolo MQTT para um computador, onde foram armazenados em formato CSV para posterior processamento.

**Processamento de sinais** – O conjunto de dados coletado foi submetido a pré-processamento utilizando a Transformada Rápida de Fourier (FFT), com o objetivo de extrair informações no domínio da frequência (IFEACHOR; JERVIS, 2018). De cada amostra foram extraídos dez coeficientes representativos, considerados suficientes para capturar as principais características de vibração associadas ao estado operacional da bomba. Essa escolha buscou

equilibrar a representatividade dos dados com a necessidade de otimização do processamento embarcado (HAN; MAO; DALLY, 2016).

**Treinamento da rede neural** – Para a classificação dos estados da bomba, foi implementado em Python um modelo de rede neural Perceptron Multicamadas (MLP) (PINHEIRO, 2021), composto por uma camada de entrada de dez neurônios, uma camada oculta com função de ativação ReLU e uma camada de saída com três neurônios correspondentes às classes definidas (GÉRON, 2022). O treinamento foi realizado a partir do conjunto de dados rotulados, dividido em subconjuntos de treino e teste. Como métrica de avaliação, utilizou-se a acurácia de classificação. O modelo final atingiu desempenho médio de 94%, considerado satisfatório para aplicações de monitoramento em tempo real.

**Implementação embarcada** – Após o treinamento, os pesos e vieses da rede neural foram exportados para arquivos em linguagem C, permitindo a integração direta ao firmware desenvolvido para o Raspberry Pi Pico W (WARDEN; SITUNAYAKE, 2019). A execução da inferência foi organizada em dois núcleos do microcontrolador: o Core 0 ficou responsável pela coleta dos sinais e envio via MQTT, enquanto o Core 1 realizou a aplicação da FFT e a inferência da rede neural. A comunicação entre os núcleos foi realizada por meio de FIFO, garantindo sincronização eficiente entre coleta e processamento. Essa estratégia de processamento paralelo permitiu latência inferior a 2 ms por amostra.

**Validação e comunicação** – O protótipo embarcado foi testado em diferentes cenários de funcionamento da bomba, confirmando a capacidade de identificar corretamente os três estados de operação. Adicionalmente, a comunicação via MQTT foi mantida ativa, permitindo a integração do sistema com interfaces externas de supervisão e armazenamento em nuvem.

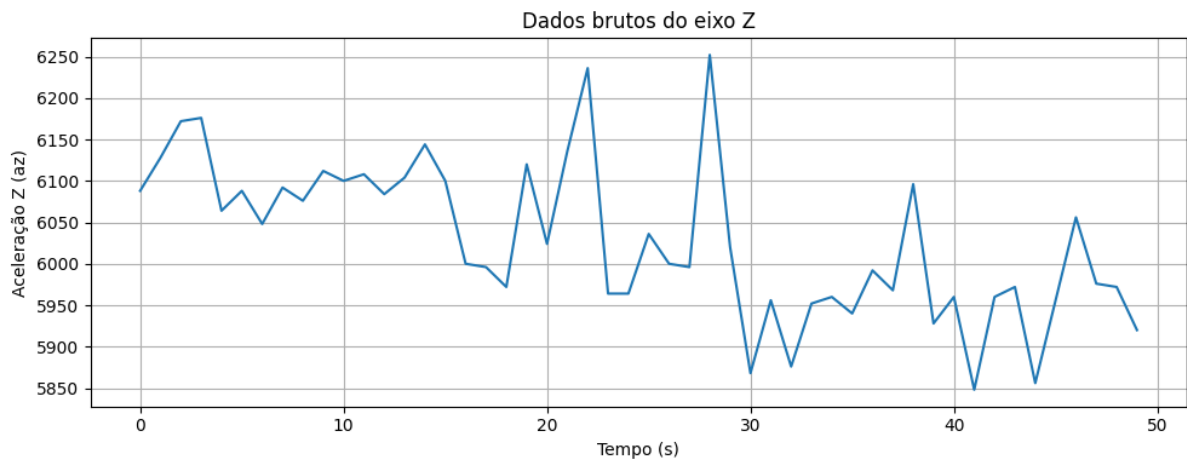
Assim, a metodologia proposta combina sensores de baixo custo, técnicas de pré-processamento baseadas em FFT e redes neurais leves para aplicação em sistemas embarcados. Essa abordagem pode ser replicada em diferentes contextos de bombeamento, com potencial de escalabilidade para outros equipamentos hidráulicos sujeitos a monitoramento preditivo.

## **RESULTADOS E DISCUSSÃO**

A análise inicial dos sinais coletados evidencia a relevância do pré-processamento para o monitoramento de bombas hidráulicas. O sinal bruto do eixo z em função do tempo (Figura 1) apresenta as variações de vibração em um dos estados da bomba. A aplicação da


Transformada Rápida de Fourier (FFT) sobre esse mesmo sinal (Figura 2) revela padrões no domínio da frequência que não são perceptíveis no sinal bruto, demonstrando a importância da análise espectral (IFEACHOR; JERVIS, 2018).

Figura 1 – Gráfico do sinal bruto coletado no domínio do tempo



Fonte: (AUTOR, 2025)

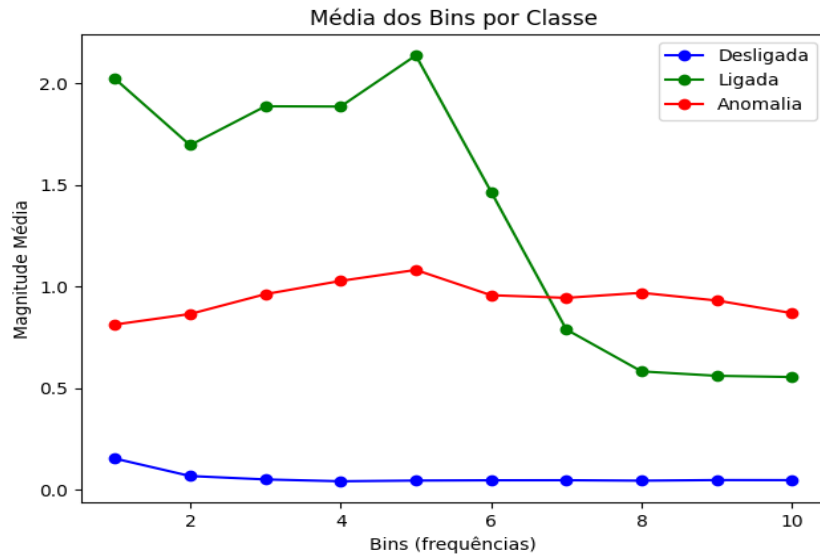
Figura 2 – Transformada Rápida de Fourier (FFT) das amostras coletadas



Fonte: (AUTOR, 2025)

A FFT permitiu identificar bins de frequência onde há maior discriminação entre as classes, servindo como insumo direto para o processo de seleção de atributos (HAN; MAO; DALLY, 2016). A análise estatística das médias desses bins reforçou o potencial de separação entre os estados, conforme demonstrado a seguir.

Figura 3 – Gráfico com as médias dos bins mais discriminantes entre as classes




Fonte: (AUTOR, 2025)

Esses resultados confirmam que o pré-processamento no domínio da frequência foi eficiente para destacar padrões ocultos no sinal bruto, justificando sua utilização como etapa fundamental na pipeline do modelo (GÉRON, 2022).

A visualização dos dados utilizando o método t-SNE possibilitou uma análise exploratória mais intuitiva (PINHEIRO, 2021).

Figura 4 – Visualização t-SNE para dispersão das classes no espaço reduzido



Fonte: (AUTOR, 2025)

Os pontos referentes às amostras de cada classe mostraram tendência de agrupamento, ainda que com alguma sobreposição entre as condições de “bomba ligada normal” e “bomba ligada com anomalia”. Essa proximidade pode explicar parte dos erros de classificação observados posteriormente.

O desempenho do modelo MLP foi avaliado por meio de métricas de classificação e relatórios de acurácia (GÉRON, 2022).

Figura 5 – Relatório de acurácia e métricas do modelo MLP

```
Epoch 26: early stopping
Restoring model weights from the end of the best epoch: 6.

[Relatório de Classificação]
4/4 ----- 0s 18ms/step
      precision    recall  f1-score   support

     0       0.98      1.00      0.99         43
     1       0.90      0.95      0.92         37
     2       0.95      0.88      0.91         40

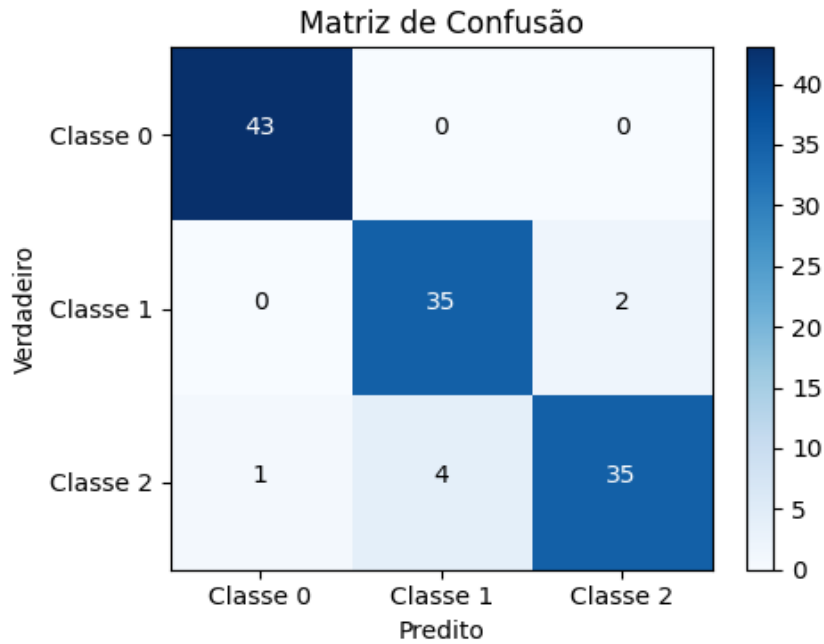
 accuracy                   0.94         120
 macro avg       0.94      0.94      0.94         120
 weighted avg    0.94      0.94      0.94         120
```

Fonte: (AUTOR, 2025)

O modelo alcançou resultados satisfatórios, apresentando acurácia global elevada. Destaca-se que a convergência ocorreu em 6 épocas, com early stopping aplicado após 20 épocas para evitar sobreajuste, conforme indicado na própria figura.

Para compreender com maior clareza os erros e acertos entre as classes, analisou-se a matriz de confusão resultante (PINHEIRO, 2021).

Figura 6 – Matriz de confusão

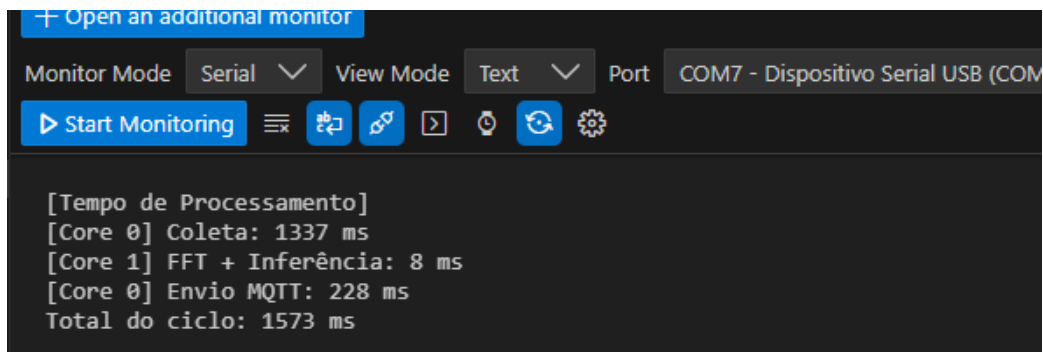


Fonte: (AUTOR, 2025)

Observa-se que a classe “bomba desligada” foi a mais facilmente distinguida, enquanto ocorreram confusões pontuais entre “bomba ligada normal” e “bomba com anomalia”. Esse resultado é coerente com a proximidade entre os sinais dessas duas condições.

Por fim, foi avaliado o tempo de execução do sistema em ambiente embarcado. A medição foi realizada por meio do console do software de desenvolvimento, sendo que os registros apresentados indicam o tempo de processamento de cada tarefa. Esses dados permitem observar a duração individual de cada etapa, bem como o tempo total por ciclo, evidenciando a viabilidade do sistema para monitoramento em tempo real.

Figura 8 – Tempo de processamento



Fonte: (AUTOR, 2025)

Os resultados indicaram que as etapas de coleta, aplicação da FFT, inferência da rede neural e envio via MQTT ocorrem em tempo compatível com aplicações de monitoramento em tempo real, confirmando a viabilidade do sistema proposto para uso em campo.

De forma geral, os experimentos demonstraram que a combinação de técnicas de processamento de sinais com modelos de aprendizado de máquina embarcados pode oferecer resultados confiáveis para manutenção preditiva de bombas de baixo custo. Embora existam limitações, como a proximidade entre classes em alguns cenários, os resultados confirmam o potencial do TinyML para aplicações de diagnóstico em tempo real (WARDEN; SITUNAYAKE, 2019).

## **CONCLUSÃO**

O trabalho apresenta um sistema embarcado baseado em TinyML para monitoramento de bombas hidráulicas, capaz de identificar diferentes estados operacionais a partir de sinais de vibração. Os resultados indicam que a Transformada Rápida de Fourier (FFT) evidencia padrões discriminantes entre as classes e que o modelo MLP implementado em linguagem C no Raspberry Pi Pico W apresenta desempenho consistente, com acurácia elevada e baixo tempo de processamento.

O sistema demonstra viabilidade para aplicações em manutenção preditiva de baixo custo, reforça o potencial de integrar aprendizado de máquina em dispositivos de recursos limitados e confirma a aplicabilidade da abordagem. Embora ainda ocorra confusão entre estados de funcionamento normal e anomalia, o trabalho aponta para melhorias futuras, como o uso de arquiteturas mais robustas ou a integração de múltiplos sensores.

## **AGRADECIMENTOS**

Agradeço ao Ministério da Ciência, Tecnologia e Inovação (MCTI) pelo financiamento do programa EmbarcaTech, à SOFTEX e ao Instituto Federal do Maranhão (IFMA) pelo apoio institucional e pelos recursos disponibilizados durante a realização desta pesquisa.

## **REFERÊNCIAS**

GÉRON, Aurélien. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 3. ed. Sebastopol: O'Reilly Media, 2022.

HAN, Song; MAO, Huizi; DALLY, William J. **Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding**. In: *International Conference on Learning Representations – ICLR*, San Juan, 2016. Disponível em: <https://arxiv.org/abs/1510.00149>. Acesso em: 17 jul. 2025.

IFEACHOR, Emmanuel C.; JERVIS, Barrie W. **Digital Signal Processing: A Practical Approach**. 2. ed. Harlow: Pearson, 2018. ISBN 978-0201596199.

PINHEIRO, Maquise de Medeiros. **Perceptron Multicamadas: uma ferramenta de aprendizado supervisionado**. 2021. 44 f. Trabalho de Conclusão de Curso (Graduação em Estatística) – Instituto de Matemática e Estatística, Universidade Federal Fluminense, Niterói, 2021. Disponível em: <http://app.uff.br/riuff/handle/1/26200>. Acesso em: 17 jul. 2025.

RANDALL, Robert B. **Vibration-Based Condition Monitoring: Industrial, Aerospace and Automotive Applications**. 2. ed. Chichester: Wiley, 2021.

UPTON, Eben; HALFACREE, Gareth. **Raspberry Pi Pico W: A Beginner's Guide**. Cambridge: Raspberry Pi Press, 2022.

WARDEN, Pete; SITUNAYAKE, Daniel. **TinyML: Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers**. Sebastopol: O'Reilly Media, 2019.