

Sistema IoT para monitoramento remoto e prevenção de falhas em ambientes termicamente controlados

Rafael D. R. Almeida * Lucas B. Fonseca Geovane F. B. Lima
Samaherni M. Dias * Kurios I. P. M. Queiroz *

* Programa de Pós-Graduação em Engenharia Mecatrônica,
Universidade Federal do Rio Grande do Norte, UFRN, Natal, RN,
Brasil (e-mail: rafael.almeida.700@ufrn.edu.br).

Abstract: The increasing use of technologies in daily life, such as computers and the internet, has transformed how we communicate, work, entertain ourselves, and take care of our health. The Internet of Things (IoT) is an important innovation in this context, designed to connect devices and systems to improve users' lives. The IoT includes devices like lighting, security, heating systems, refrigeration, household appliances, and entertainment. The proposed project aims to develop a system for monitoring and detecting faults in thermal systems using electronics, micro-controllers, sensors, and Machine Learning (ML). At the end, experimental results of the proposed system will be presented.

Resumo: O uso crescente de tecnologias no cotidiano, como computadores e internet, transformou a maneira como nos comunicamos, trabalhamos, nos divertimos e cuidamos da nossa saúde. A Internet das Coisas (IoT) é uma inovação importante nesse contexto, concebida para conectar dispositivos e sistemas com o objetivo de melhorar a vida dos usuários. A IoT abrange dispositivos como iluminação, segurança, sistemas de aquecimento, refrigeração, eletrodomésticos e entretenimento. O projeto apresentado propõe desenvolver um sistema de monitoramento e detecção de falhas em sistemas térmicos, utilizando eletrônica, microcontroladores, sensores e Aprendizagem de Máquina. Ao final serão apresentados resultados experimentais do sistema proposto.

Keywords: Internet of Things, Predictive Maintenance, System Automation, Machine Learning.

Palavras-chaves: Internet das Coisas, Manutenção Preditiva, Aprendizagem de Máquina, Automação de Sistemas.

1. INTRODUÇÃO

A manutenção de excelência tornou-se um objetivo essencial não apenas para as empresas, mas também para a Academia, em busca de maior eficiência e redução de custos (Robles, 2003; de Jesus de Souza, 2011). Nesse contexto, a automação desempenha um papel fundamental. A adoção de tecnologias automatizadas possibilita uma gestão mais eficiente dos processos de manutenção, permitindo a implementação de estratégias preventivas e preditivas de forma mais precisa e eficaz. A automação fornece ferramentas para o monitoramento contínuo do estado das máquinas, detecção de falhas iminentes e análise de dados em tempo real (Reyes et al., 2012). Com isso, é possível reduzir o tempo de parada das máquinas causado por falhas, otimizando o fluxo produtivo e maximizando os resultados em termos de produtividade e lucratividade.

Dessa forma, a automação, aliada à manutenção preventiva e preditiva, desempenha um papel essencial na busca por uma maior confiabilidade dos equipamentos. A capacidade de planejamento aprimorado, a qualidade e a assertividade proporcionadas pela automação contribuem para a expansão da vida útil dos equipamentos, ao mesmo

tempo em que reduzem os custos de manutenção. Assim, a combinação desses elementos torna-se uma estratégia poderosa para enfrentar os desafios do mercado atual e alcançar uma vantagem competitiva sustentável (Mobleby, 2002).

Yang et al. (2002) afirmam que é possível realizar, com sucesso, a prevenção de falhas em máquinas antes que estas ocorram. Essa abordagem baseia-se no monitoramento constante do estado da máquina, sem interromper seu funcionamento, o que permite evitar substituições prematuras de peças. Com base nessa afirmação, a implementação de um sistema de monitoramento contínuo do estado da máquina pode aprimorar o processo, garantindo maior confiabilidade e disponibilidade dos equipamentos, alinhando-se ao objetivo da gestão da manutenção de minimizar custos e substituições causadas por reparos não programados (Cabral, 2017).

Nesse contexto, envolvendo um grande volume de dados coletados no monitoramento contínuo, existe a necessidade de uma ferramenta capaz de lidar com toda essa informação. Introduce-se então as Redes Neurais Artificiais (RNAs), que são modelos computacionais inspirados no funcionamento do cérebro humano. Elas consistem em

redes de neurônios artificiais interconectados que podem aprender e generalizar a partir de dados. As RNAs têm sido amplamente utilizadas em diversas áreas, incluindo previsão de falhas em sistemas eletromecânicos (Surucu et al., 2023). Esses métodos de análise baseados em RNAs aproveitam os dados coletados por sensores para extrair informações valiosas sobre máquinas e equipamentos. Ao modelar e analisar uma grande quantidade de dados, as RNAs podem lidar com problemas complexos, envolvendo aspectos estatísticos, computacionais e dinâmicos, e são capazes de reconhecer padrões (Krogh, 2008). Com o avanço da tecnologia e a evolução das RNAs, elas se tornaram uma ferramenta poderosa na manutenção voltada para a confiabilidade e estão cada vez mais presentes nas estratégias de manutenção das indústrias (Costa e Gomes, 2013; Robles, 2003).

Segundo Frankowiak et al. (2005), com a evolução dos microcontroladores, eles se tornaram a escolha preferida em uma variedade de setores, incluindo automação residencial, eletrônica de consumo, dispositivos médicos, sistemas de segurança e muito mais. Sua capacidade de processamento avançada, menor consumo de energia e recursos integrados, como conversores analógico-digitais e interfaces de comunicação, tornaram possível a criação de sistemas complexos e inteligentes de forma mais eficiente.

Na última década surge uma crescente onda de pesquisas e desenvolvimento na temática aqui abordada, incluindo a criação de patentes e produtos comerciais. Himeur et al. (2021) apresentam que a comunidade de Inteligência Artificial (IA) tem se dedicado intensamente nesse período à detectar consumo anômalo de energia, as novas tendências e desafios envolvidos além de aplicações e funcionalidades que possam impactar na redução do consumo de energia. Sanchez-Sutil e Cano-Ortega (2023) trazem aspectos, limitações e impactos de um dispositivo Smart Plug projetado para medir e controlar a energia consumida por cargas elétricas em residências, escritórios, hotéis, hospitais, etc. com o objetivo de alcançar melhor eficiência energética. No âmbito industrial, Raval et al. (2022) desenvolvem um sistema analisador de falhas observando o perfil energético contido na corrente elétrica de um motor através de uma abordagem baseada em IA.

A integração de sistemas de monitoramento de ambientes dentro de uma rede IoT tem sido amplamente reconhecida por sua capacidade de fornecer informações cruciais em tempo real. Ao monitorar continuamente parâmetros como temperatura, umidade e qualidade do ar, os sistemas podem fornecer dados valiosos para análise e tomada de decisão. Em aplicações industriais, os dados coletados ajudam a melhorar a eficiência energética, detectar falhas em equipamentos críticos e garantir condições ideais para processos produtivos (Chang e Martin, 2021). A inteligência artificial desempenha um papel significativo, possibilitando a identificação de padrões anômalos e ajudando na implementação de estratégias de manutenção preditiva.

Apesar dos avanços na aplicação de técnicas de aprendizado de máquina para a monitoração de parâmetros, desafios significativos persistem, especialmente na precisão da classificação. Este trabalho apresenta um sistema de monitoramento de temperatura eficaz em um ambiente IoT, baseado na coleta de dados térmicos usando sensores

para estabelecer padrões de funcionamento normais e esperados do sistema. Os dados coletados são transmitidos por microcontrolador com acesso Wi-Fi ao servidor do sistema, compondo assim um ambiente IoT, permitindo acesso remoto ao sistema e suas informações para monitoramento contínuo e análise.

2. REFERENCIAL TEÓRICO

Esse tópico enuncia o contexto atual o qual se encontram as tecnologias abordadas neste trabalho, trazendo uma breve imersão dos temas envolvendo automação.

2.1 *Manutenção e Prevenção*

De acordo com A. K. Pinto (2009), a manutenção abrange uma série de cuidados técnicos, como conservação, adequação, restauração, substituição e instalação, com o objetivo de garantir o funcionamento prolongado e regular de máquinas, equipamentos, ferramentas e instalações. Martins e Laugeni (2009) reforçam essa definição, destacando que a função básica da manutenção é manter as instalações operando nas condições de projeto ou trazê-las de volta a essas condições, caso necessário. A. K. Pinto (2009) afirmam que a função da manutenção é assegurar a confiabilidade, segurança e preservação do meio ambiente no processo de produção, com custos adequados. No entanto, embora a aplicação da manutenção melhore os parâmetros de desempenho, confiabilidade e disponibilidade dos equipamentos, os custos também aumentam. Portanto, o equilíbrio entre esses efeitos e sua contribuição para a rentabilidade das empresas é o objetivo da gestão da manutenção.

Pesquisas recentes indicam que a implementação de técnicas de aprendizado de máquina (ML) em sistemas industriais pode melhorar a detecção de falhas, além de prever a vida útil remanescente do equipamento, contribuindo para a redução do tempo de inatividade e otimização da manutenção preditiva, como demonstrado no trabalho de Zhang et al. (2019). O uso de Redes Neurais LSTM (*Long Short-Term Memory*) tem mostrado potencial na identificação de padrões e na previsão do tempo de falha com maior precisão, permitindo intervenções preventivas antes que ocorram falhas críticas (Achouch et al., 2023).

Outra aplicação prática é na manutenção preditiva de trocadores de calor, que são componentes críticos em sistemas térmicos industriais. Empresas especializadas como a Hexxcell Corporation (2024) utilizam IA combinada com modelos físicos para criar gêmeos digitais que identificam o acúmulo de resíduos e otimizam os cronogramas de manutenção.

2.2 *Microcontroladores*

Os microcontroladores surgiram como uma evolução dos CLPs, trazendo consigo uma série de avanços tecnológicos. Os microcontroladores foram desenvolvidos para fornecer uma solução mais versátil e compacta para uma ampla gama de aplicações. Esses dispositivos integrados combinam um microprocessador, memória e periféricos em um único chip (Hintz e Tabak, 1992), oferecendo maior flexibilidade e poder de processamento, além de serem mais econômicos em termos de custo e tamanho físico quando

comparados com os CLPs. O ESP32 (Espressif, 2024) ilustrado na Figura (1), é um modelo de microcontrolador que possui todas essas características e que atualmente integra diversos sistemas digitais.




Figura 1. Microcontrolador ESP32. Fonte: Espressif (2024)

Segundo Frankowiak et al. (2005) com a evolução dos microcontroladores, eles se tornaram a escolha preferida em uma variedade de setores, incluindo automação residencial, eletrônica de consumo, dispositivos médicos, sistemas de segurança e muito mais. Sua capacidade de processamento avançada, menor consumo de energia e recursos integrados, como conversores analógico-digitais e interfaces de comunicação, tornaram possível a criação de sistemas complexos, inteligentes e interconectados de forma mais eficiente.

2.3 Internet das Coisas

A Internet das Coisas (IoT) é fundamentada na integração de diversos processos, como identificação, monitoramento, atuação, redes e computação. Essa tecnologia possibilita inovações em larga escala e serviços de valor agregado que personalizam a interação dos usuários com diversos dispositivos interconectados. A IoT possui uma ampla gama de aplicações que abrangem diversos setores, como: saúde, tráfego, logística, varejo, agricultura, cidades inteligentes, medição inteligente, monitoramento remoto, automação de processos, entre outros. Apesar dos avanços significativos em áreas como arquitetura, modelos de negócios, tecnologias emergentes e segurança, acredita-se que a IoT ainda esteja em estágio inicial de desenvolvimento, com potencial para evoluir e se expandir cada vez mais (Čolaković e Hadžialić, 2018).

De acordo com Borgia (2014), para tornar o conceito da IoT mais concreto, vamos considerar o ecossistema urbano como exemplo e como a cidade do futuro poderá ser. A cidade é o núcleo da vida econômica e social de uma nação. Hoje, metade da população global está concentrada nas cidades e consome seus recursos (como luz e água) todos os dias. A população urbana está em constante crescimento, o que inevitavelmente resulta em aumento do consumo de recursos que afeta o meio ambiente. Qualidade, sustentabilidade e segurança são questões cruciais e inevitáveis para a cidade. A realização de cidades sustentáveis e seguras requer soluções inteligentes que garantam eficiência em múltiplos níveis, visando:

- Uso mais consciente e otimizado dos recursos oferecidos;

- Minimização do impacto ambiental, por exemplo, reduzindo as emissões de CO₂;
- Aumento tangível na qualidade de vida em termos de segurança, saúde e bem-estar.

Segundo Liu. Ximei (2020), Internet das Coisas (IoT) no monitoramento é uma ferramenta importante para garantir o estado ideal do produto ou serviço, enfatizando também que, para garantir a operação segura de um sistema, é necessário monitorar e detectar o estado operacional. Eles propõem um sistema de monitoramento baseado em IoT que pode coletar, registrar, processar e armazenar dados de operação de maneira inteligente e carregar esses dados para a plataforma IoT. Isso fornece uma base digital para a gestão subsequente das informações.

2.4 Aprendizagem de Máquina em Automação e Manutenção Preditiva

A integração de técnicas de Aprendizagem de Máquina (ML) nos sistemas de automação e manutenção preditiva tem revolucionado a maneira como as indústrias gerenciam e mantêm seus equipamentos. Com o advento de algoritmos avançados e o aumento da disponibilidade de grandes volumes de dados, a ML tem se mostrado fundamental para a detecção proativa de falhas e para a otimização dos processos de manutenção.

Detecção e Diagnóstico de Falhas: A aplicação de modelos de ML na detecção e diagnóstico de falhas em equipamentos industriais tem permitido às empresas reduzir significativamente os tempos de inatividade não planejados. Modelos preditivos, como RNAs e Máquinas de Vetores de Suporte (SVMs), são treinados com dados históricos de operação para aprender e identificar padrões ou anomalias que precedem falhas. Por exemplo, Zhang et al. (2019) demonstraram como as ANNs podem prever falhas em equipamentos com alta precisão, permitindo intervenções preventivas antes que ocorram danos maiores.

Manutenção Preditiva: Na manutenção preditiva, a ML é empregada para prever quando um equipamento falhará, permitindo que a manutenção seja planejada antes da ocorrência de uma falha. Isso é alcançado através da análise de padrões complexos nos dados de operação que são difíceis de detectar manualmente. Por exemplo, a utilização de Redes Neurais LSTM (*Long Short-Term Memory*) tem sido eficaz na modelagem e previsão de falhas em sistemas dinâmicos e em ambientes com variações temporais significativas (Zhang et al., 2019; Achouch et al., 2023).

Otimização de Recursos e Custos: Além da detecção de falhas e manutenção preditiva, a ML também contribui para a otimização dos recursos e redução de custos. Modelos de aprendizagem profunda podem ser utilizados para otimizar os ciclos de manutenção, ajustando-os de acordo com as necessidades reais dos equipamentos, em vez de seguir um cronograma fixo. Essa abordagem não só economiza recursos como também prolonga a vida útil dos equipamentos (Ren, 2021).

Desafios e Perspectivas Futuras: Embora a aplicação de ML em automação e manutenção preditiva ofereça muitos benefícios, existem desafios, como a necessidade de grandes volumes de dados de boa qualidade e a interpretação dos modelos de ML, que podem ser bastante complexos. Além

disso, a integração efetiva de sistemas de ML em ambientes industriais ainda requer desenvolvimento contínuo em termos de infraestrutura e conhecimento técnico (Wang et al., 2018). A aprendizagem de máquina está desempenhando um papel transformador na automação e manutenção preditiva, com potencial para melhorar ainda mais à medida que as tecnologias evoluem e as bases de dados se tornam mais abrangentes e precisas (Čolaković e Hadžialić, 2018).

3. SISTEMA PROPOSTO

O presente trabalho descreve um sistema destinado ao monitoramento remoto da temperatura ambiente, utilizando o sensor de temperatura DS18B20 (Dallas Semiconductor, 2008) em conjunto com o microcontrolador ESP32 DevKit V1 (Espressif, 2024). Este sistema é projetado para oferecer uma solução eficiente e acessível para o monitoramento em diversos ambientes, com foco especial em locais onde a temperatura é um ponto crítico para o correto funcionamento de aplicações. Exemplos desses ambientes incluem *datacenters*, centrais de pontos de presença (POPs) de provedores de internet, bem como locais como frigoríficos, restaurantes e hospitais, onde o controle preciso da temperatura é essencial para garantir a qualidade e a segurança dos produtos e serviços oferecidos.

3.1 Software e Arquitetura

O software do projeto está dividido em duas partes. A primeira, escrita em linguagem C++, é responsável por realizar a leitura do sensor de temperatura e gerenciar todos os sistemas de comunicação, incluindo a comunicação com a interface *Web* escrita em Linguagem de Marcação de HiperTexto (HTML), o Protocolo Simples de Gerenciamento de Redes (SNMP), o módulo de comunicação para software de monitoramento *Zabbix* e o módulo de comunicação para outras aplicações externas *Webhook*. Além disso, essa parte do software é responsável por gerenciar alertas, configurar a rede onde o dispositivo será instalado e executar todas as funcionalidades do dispositivo. A segunda parte do software é responsável pelo funcionamento da *front-end*, desenvolvido em *JavaScript* para criação de conteúdo dinâmico, com estilização a partir de Folhas de Estilo em Cascata (CSS) e construção em HTML. O *front-end* representa o conteúdo visual e interativo da aplicação web criado pelo dispositivo, onde os usuários conseguem realizar as configurações do sistema, criar alertas personalizados e acompanhar as medições em tempo real.

O fluxo de funcionamento do sistema proposto começa a partir do sensor DS18B20, que é responsável por coletar os dados de temperatura, os quais são então lidos e processados em um dos núcleos do microcontrolador ESP32. Cada núcleo de processamento tem tarefas independentes, onde o **core0** é responsável por realizar as tarefas de gerenciar o *timestamp* da leitura, atualizar parâmetros, verificar *reset* no sistema e atualizar a interface *Web* enquanto o **core1** faz a aquisição do dado, atualiza as definições dos módulos de comunicação (SNMP, *Zabbix* e *Webhook*) e verifica a conexão com a rede. Para habilitar o envio dos dados para as aplicações externas, o usuário deve realizar as configurações por meio da interface *Web*, utilizando o Endereço de Protocolo da Internet (IP) do sensor. A Figura 2 detalha esse fluxo.

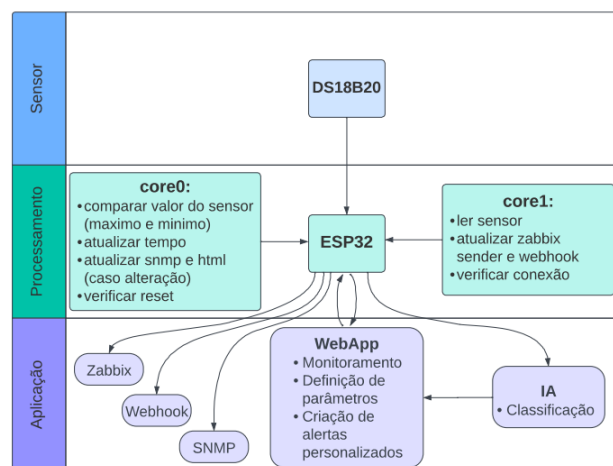


Figura 2. Fluxograma do sistema proposto

Nesse sistema o ESP32 atua como ponto de acesso Wi-Fi, possibilitando que os usuários se conectem à rede local e acessem os dados do sensor DS18B20 (Figura: 3). O sistema foi projetado com ênfase na facilidade de uso e acessibilidade, permitindo a configuração e monitoramento do sistema por meio de uma interface web simples e intuitiva, se tornando especialmente útil em ambientes onde o acesso remoto é essencial para o monitoramento em tempo real da temperatura.

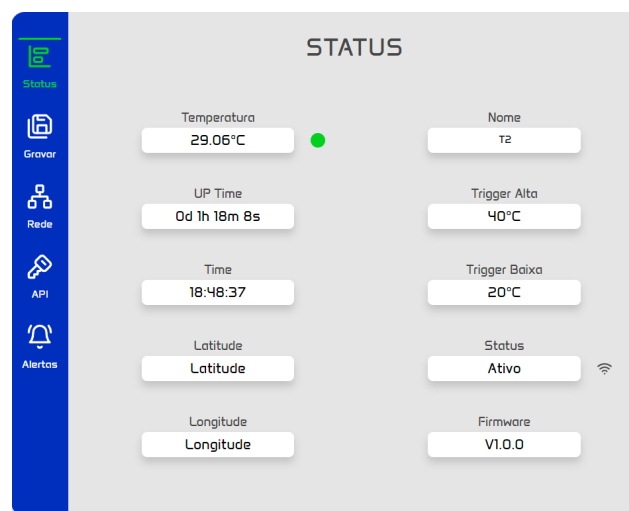


Figura 3. Menu para monitoramento

3.2 Hardware

A parte elétrica do projeto foi desenvolvida em bancada, com testes iniciais realizados utilizando protoboards e diversos componentes eletrônicos, como resistores, fios, sensores e módulos. Em seguida, o projeto eletrônico (Figura 4) foi elaborado no *software* Altium Designer, uma ferramenta especializada em projetos de circuitos eletrônicos e desenvolvimento de placas de circuito impresso (PCB). Com o projeto finalizado no Altium Designer, foram produzidas placas de circuito impresso de prototipagem para realizar testes mais aprofundados. Após uma série de testes de *software* e *hardware*, o projeto demonstrou ser totalmente funcional e eficaz, estando pronto para

ser implementado em ambiente real de monitoramento de temperatura.

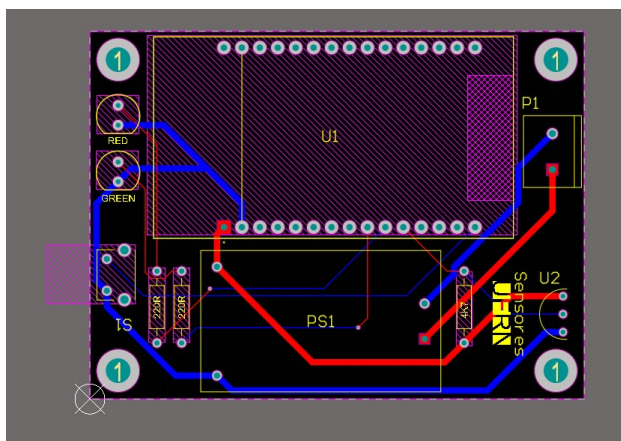


Figura 4. Projeto da Placa de Circuito Impresso

3.3 Testes e Validação

O processo de análise e classificação inicia-se com a coleta e padronização dos dados de temperatura, capturados dentro de uma sala termicamente controlada em intervalos uniformes de dez segundos. Manter esse intervalo de amostragem é crucial para assegurar uma representação temporal contínua e precisa dos dados ao longo do tempo. Foi utilizada uma abordagem de segmentação da série temporal dos dados em janelas de 10 minutos, permitindo a captura e análise das características de cada janela. O período total de coleta de dados para treinamento foi de cerca de 1 mês, gerando mais de 260.000 dados.

Para o modelo de classificação, as características (*features*) extraídas dos dados incluem a temperatura média, desvio padrão, variação máxima, e a taxa de mudança ao longo da janela de medição. Essas métricas servem para identificar padrões de comportamento do sistema, podendo indicar falhas ou condições de operação prejudiciais.

São utilizados rótulos (*labels*) para categorizar o estado operacional do equipamento em 'Normal', 'Atenção' e 'Crítico', baseados em limiares pré-definidos de temperatura e variação. Esses estados são essenciais para o treinamento do modelo, permitindo que ele aprenda a reconhecer sinais precoces de deterioração do equipamento antes que falhas significativas ocorram.

A etiquetagem manual desses segmentos foi realizada com base em critérios pré-definidos, identificando diferentes eventos térmicos, tais como: Aquecimento rápido, Esfriamento rápido, Anomalia, Estabilidade, Aquecimento leve, Resfriamento leve, Temperatura alta e Temperatura baixa, a partir dos padrões observados nas características.

A eficácia do modelo de aprendizado de máquina em tarefas de classificação é medida através de métricas. Neste trabalho foram utilizadas as métricas: Precisão (*Precision*), mede a proporção de previsões corretas para uma classe específica em relação a todas as previsões feitas para essa classe, indicando quão confiáveis são as previsões positivas do modelo; *Recall*, avalia a capacidade do modelo de identificar todas as instâncias reais de uma classe específica, sendo crucial em situações onde é importante capturar

todos os casos positivos; *F1-Score*, uma média harmônica entre precisão e *recall*, proporcionando um balanço entre essas duas métricas, especialmente útil quando as classes estão desbalanceadas; Acurácia (*Accuracy*), mostra a proporção total de previsões corretas em relação ao total de casos, sendo uma medida geral de desempenho; Suporte, indica o número de ocorrências de cada classe no conjunto de dados, serve para entender o impacto de cada classe nas métricas globais do modelo; Finalmente, as médias macro e ponderada, fornecem uma visão do desempenho geral do modelo ao considerar o suporte de cada classe, ajudando a avaliar a eficácia do modelo em lidar com o desequilíbrio entre classes.

4. RESULTADOS E DISCUSSÃO

O protótipo executou corretamente todas as funcionalidades a que foi projetado. Na Figura 5 é possível ver o protótipo do sistema proposto em funcionamento.




Figura 5. Protótipo do sistema proposto em funcionamento

Os resultados obtidos com a implementação do sistema de monitoramento de temperatura IoT são apresentados a seguir.

4.1 Desempenho do Monitoramento de Temperatura

Os dados utilizados para treinamento e classificação dos modelos foram coletados diretamente de ambiente controlado, utilizando o sistema desenvolvido com o sensores de temperatura. A coleta foi realizada em uma sala de aproximadamente 12m², com variações de temperatura induzidas artificialmente para simular diferentes condições operacionais.

Os testes de desempenho do sensor de temperatura mostraram uma relevante precisão nas leituras, com uma margem de erros mínima. A Figura 6 apresenta a série temporal das leituras de temperatura capturadas usando o sistema ao longo do dia 02/11/2023 dentro do ambiente controlado. O controle da temperatura do ambiente recebeu entradas distintas ao longo do dia.

No período entre 00:00h e 10:30h a temperatura do ambiente foi definida para 22.0°C, após, entre 10:30h e 15:30h, a temperatura foi ajustada para 20.5°C. A partir das

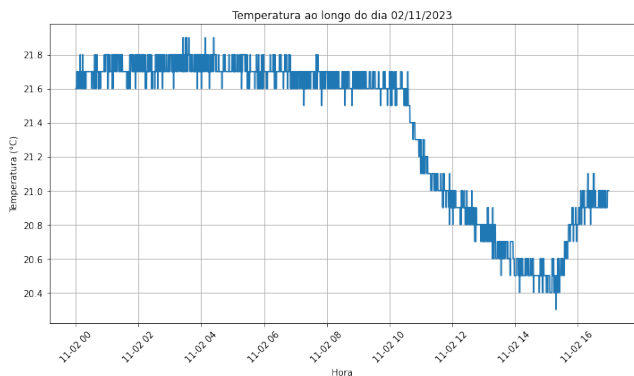


Figura 6. Serie de temperatura do dia 02/11/2023

15:30h até 17:00h o ajuste de temperatura foi de 21.0°C. A Figura 6 demonstra como as medidas captadas pelo sensor seguiram os ajustes na entrada, evidenciando a coerência e precisão do sistema desenvolvido.

4.2 Funcionalidade de Alertas e Notificações

Os alertas foram testados usando os diferentes canais, e-mail, SMS, Telegram e WhatsApp. A Figura 7 ilustra a interface do sistema de alertas, enviando a temperatura medida e a classificação do conjunto recente de dados.

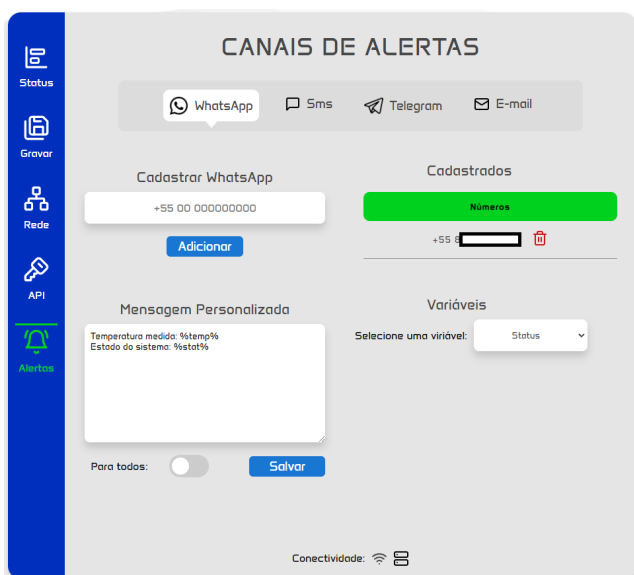


Figura 7. Exemplo de alerta de temperatura e classificação

4.3 Classificação com Aprendizagem de Máquina

Após agrupamento dos dados em janelas de 10 minutos e extração das características, o conjunto de mais de 260.000 medições foi reduzido para 4476 amostras. O conjunto de treinamento foi separado com 3133 amostras (70%), enquanto o de teste com 1343 amostras (30%). No trabalho foi utilizada a biblioteca Scikit-learn para treinar um modelo de Floresta Aleatória com 100 árvores e valor inicial de estado aleatório (*random state*) fixado em 42 para garantir a reprodutibilidade dos resultados, esse valor de estado afeta a maneira como as amostras são selecionadas para construir as árvores e como as

características são escolhidas para as divisões. O modelo constrói várias árvores de decisão durante o treinamento, cada uma aprendendo características de uma amostra dos dados, o que ajuda a melhorar a precisão geral e reduzir o risco de sobre-ajuste.

O resultado do modelo de Floresta Aleatória é exibido na Tabela 1.

Classe	Precisão	Recall	F1-Score	Suporte
Aquecimento leve	0.99	1.00	0.99	204
Aquecimento rápido	0.00	0.00	0.00	3
Estabilidade	1.00	1.00	1.00	801
Indefinido	0.98	1.00	0.99	114
Resfriamento leve	1.00	1.00	1.00	169
Temperatura alta	1.00	0.95	0.98	21
Temperatura baixa	1.00	1.00	1.00	31
Acurácia	1.00			
Média macro	0.85	0.85	0.85	1343
Média ponderada	0.99	1.00	1.00	1343

Tabela 1. Métricas de desempenho do modelo

A avaliação do modelo de Floresta Aleatória, utilizando as métricas de desempenho citadas na sessão 3.3, demonstra sua eficácia na classificação dos eventos térmicos capturados. As métricas de precisão e *recall* destacam sua acurácia e cobertura entre diferentes classes, com altas pontuações sugerindo capacidades de detecção confiáveis — precisão de 99% para a classe “Aquecimento Leve” e *recall* de 95% para “Temperatura Alta”. O *F1-Score*, que combina precisão e *recall*, indica um equilíbrio ideal, especialmente para a classe “Estabilidade”, que alcançou a pontuação máxima de 1.00, sinalizando a detecção precisa e consistente de condições estáveis. A precisão geral de 100% reafirma a eficiência do modelo em prever corretamente as classes com base no conjunto de dados utilizado.

No entanto, o desempenho do modelo não é uniforme em todas as categorias de eventos, especialmente aquelas com menos instâncias, como “Aquecimento Rápido”, que mostra precisão e *recall* de 0.00 devido à representação insuficiente de dados. Isso destaca a necessidade de dados adicionais ou ajustes no modelo para classes sub-representadas. O contraste entre as médias macro e ponderada (0.85 vs. 1.00, respectivamente) ressalta ainda mais essa discrepância, sugerindo que, embora o modelo se saia bem em classes com dados substanciais, ele enfrenta dificuldades com eventos raros, indicando uma área para possível aprimoramento para garantir a robustez e generalizabilidade do modelo. É importante considerar a possibilidade de sobreajuste (*overfitting*), especialmente porque algumas classes com muitos dados podem induzir o modelo a aprender demais as peculiaridades do conjunto de treinamento em vez de generalizar a partir de novos dados. O alto desempenho em classes bem representadas e a precisão de 100% podem ser indicativos de que o modelo está excessivamente ajustado aos dados de treino, o que pode comprometer sua aplicabilidade em dados externos ou em condições reais de operação.

5. CONCLUSÃO

Os resultados obtidos com a implementação do sistema de monitoramento de temperatura IoT confirmam a eficácia do protótipo em executar as funcionalidades proje-

tadas, como demonstrado pelas medições de temperatura e pela funcionalidade de alertas e notificações. A precisão do sistema foi especialmente evidente durante o teste de desempenho do sensor de temperatura, que mostraram uma capacidade notável do sistema em seguir ajustes pré-definidos de temperatura em um ambiente controlado. Para trabalhos futuros será incluído métrica de quantificação do erro de medição e calibração precisa do sensor. A funcionalidade de alertas e notificações foi validada em todos os canais, garantindo que o sistema é capaz de comunicar efetivamente as condições detectadas ao usuário final.

O modelo de Floresta Aleatória, apesar de geralmente robusto, enfrentou dificuldades específicas devido à baixa quantidade de amostras em algumas classes, além de ter demonstrado possível sobreajuste na identificação de outras. Esse resultado revelou uma limitação crítica do modelo em contextos onde o desbalanceamento de classes é significativo. Para mitigar o risco de sobreajuste, podem ser utilizadas técnicas como validação cruzada durante o treinamento para garantir que o modelo seja validado em diferentes subconjuntos de dados. Além disso, ajustar os parâmetros do modelo, como o número de árvores na Floresta Aleatória e a profundidade máxima das árvores, pode ajudar a controlar a complexidade do modelo. A inclusão de mais dados, especialmente para as classes sub-representadas, também será capaz de melhorar a generalização do modelo, garantindo que ele seja robusto e eficaz em uma variedade de cenários de uso. Ainda assim, o modelo conseguiu lidar relativamente bem com esse desafio, evidenciando sua capacidade de generalizar a partir de um número limitado de dados, um ponto forte que destaca a versatilidade das Florestas Aleatórias em aplicações de monitoramento.

O projeto destacou a importância de uma etapa de design cuidadosa para garantiu uma implementação precisa em sistemas IoT, além de ressaltar a necessidade de abordagens adaptativas no treinamento de modelos de aprendizado de máquina para lidar com a variabilidade e o desbalanceamento das classes. A implementação bem-sucedida deste sistema demonstra a viabilidade da tecnologia IoT para aplicações de monitoramento de variáveis ambientais, além de evidenciar características valiosas para futuras melhorias e desenvolvimentos.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- A. K. Pinto, J.A.N.X. (2009). *Manutenção: função estratégica*. Qualitymark.
- Achouch, M., Dimitrova, M., Dhouib, R., Ibrahim, H., Adda, M., Sattarpanah Karganroudi, S., Ziane, K., e Aminzadeh, A. (2023). Predictive maintenance and fault monitoring enabled by machine learning: Experimental analysis of a ta-48 multistage centrifugal plant compressor. *Applied Sciences*, 13(3).
- Borgia, E. (2014). The internet of things vision: Key features, applications and open issues. *Computer Communications*, 54, 1–31. doi:10.1016/j.comcom.2014.09.008.
- Cabral, M.A.L. (2017). Classificação automatizada de falhas tribológicas de sistemas alternativos com o uso de redes neurais artificiais não supervisionadas. *Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Natal*.
- Chang, V. e Martin, C. (2021). An industrial iot sensor system for high-temperature measurement. *Computers and Electrical Engineering*, 95, 107439. doi:10.1016/j.compeleceng.2021.107439.
- Costa, J.A.F. e Gomes, G. (2013). Process modeling and monitoring using selforganizing maps. Anais São Paulo: CONTECSI, 2013.
- Dallas Semiconductor (2008). Ds18b20. URL <https://html.alldatasheet.com/html-pdf/58557/DALLAS/DS18B20/181/1/DS18B20.html>. Acessado: 20-jul-2024.
- de Jesus de Souza, C. (2011). Desgaste abrasivo em compostos metal/cerâmicos: estudo aplicado ao desenvolvimento de coroas de perfuração. Dissertação (Mestrado em Engenharia de Materiais).
- Espressif (2024). Espressif esp32devkitm-1. URL <https://docs.espressif.com/projects/esp-idf/en/latest/esp32/hw-reference/esp32/user-guide-devkitm-1.html>. Acessado: 04-mai-2024.
- Frankowiak, M., Grosvenor, R., e Prickett, P. (2005). A review of the evolution of microcontroller-based machine and process monitoring. *International Journal of Machine Tools and Manufacture*, 45(4), 573–582. doi: 10.1016/j.ijmachtools.2004.08.018.
- Hexxcell Corporation (2024). Hexxcell: Heat exchanger monitoring | predictive maintenance. <https://www.hexxcell.com/>. Acessado: 04-mai-2024.
- Himeur, Y., Ghanem, K., Alsalemi, A., Bensaali, F., e Amira, A. (2021). Artificial intelligence based anomaly detection of energy consumption in buildings: A review, current trends and new perspectives. *Applied Energy*, 287, 116601. doi:10.1016/j.apenergy.2021.116601.
- Hintz, K. e Tabak, D. (1992). *Microcontrollers: architecture, implementation, and programming*. McGraw-Hill, Inc.
- Krogh, A. (2008). What are artificial neural networks? *Nature biotechnology*, 26(2), 195–197.
- Liu. Ximei, M.J. (2020). Application of the ubiquitous power internet of things in state monitoring of power equipment.
- Martins, P.G. e Laugeni, F.P. (2009). *Administração da produção*. Saraiva.
- Mobley, R.K. (2002). *Plant Engineering*. Butterworth-Heinemann.
- Raval, P.D., Rajagopalan, N., Khariya, V., e Sudha, R. (2022). Development of an ai-based fsa for real-time condition monitoring for industrial machine. *Neural Computing and Applications*, 34. doi:10.1007/s00521-021-06741-w.
- Ren, Y. (2021). Optimizing predictive maintenance with machine learning for reliability improvement. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering*, 7(3), 030801.
- Reyes, J., Velasco, M., e Tanscheit, R. (2012). *Monitoring and diagnosis of multiple sensors by auto-associative neural networks*. Sba: Controle & Automação Sociedade

- Brasileira de Automatica, [S. l.], v. 23, n. 2, p. 121-137.
- Robles, A. (2003). *Custos da qualidade: aspectos econômicos da gestão da qualidade e da gestão ambiental*. Atlas, São Paulo.
- Sanchez-Sutil, F. e Cano-Ortega, A. (2023). Smart plug for monitoring and controlling electrical devices with a wireless communication system integrated in a lorawan. *Expert Systems with Applications*, 213, 118976. doi:10.1016/j.eswa.2022.118976.
- Surucu, O., Gadsden, S.A., e Yawney, J. (2023). Condition monitoring using machine learning: A review of theory, applications, and recent advances. *Expert Systems with Applications*, 221, 119738. doi:10.1016/j.eswa.2023.119738.
- Wang, J., Ma, Y., Zhang, L., Gao, R.X., e Wu, D. (2018). Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems*, 48, 144–156. doi:10.1016/j.jmsy.2018.01.003. Special Issue on Smart Manufacturing.
- Yang, D.M., Stronach, A.F., MacConnell, P., e Penman, J. (2002). Third-Order Spectral Techniques for the Diagnosis of Motor Bearing Condition Using Artificial Neural Networks. *Mechanical Systems and Signal Processing*, 16(2-3), 391–411. doi:10.1006/mssp.2001.1469.
- Zhang, W., Yang, D., e Wang, H. (2019). Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, 13(3), 2213–2227. doi:10.1109/JSYST.2019.2905565.
- Čolaković, A. e Hadžialić, M. (2018). Internet of things (iot): A review of enabling technologies, challenges, and open research issues. *Computer Networks*, 144, 17–39. doi:10.1016/j.comnet.2018.07.017.