

IoT de Baixo Custo com ESP32 e MQ-3 para Redução de Perdas de FLV em Recipientes Dedicados

Pablo Henrique Luiz de Oliveira¹, Luca Atanazio Evangelista¹,
Willgnner Ferreira Santos^{1,2} e Alisson Rodrigues Alves¹

¹ Faculdade SENAI Fatesg
R. 227-A, 95 – Setor Leste Universitário, Goiânia – GO, 74610-155

² Faculdade SENAI Fatesg – Núcleo de Inteligência Artificial Aplicada – NIAA
{eopabro, lucaatanazioevangelista}@gmail.com
{willgnnerferreira, alissonalves.senai}@fieg.com.br

Abstract. *Operational inefficiency in Brazilian retail reaches 5.83% in the Fruits, Vegetables and Greens (FVG) sector, with climacteric products such as tomatoes and bananas as the main sources of loss due to ethylene (C₂H₄) release under inadequate storage. This work proposes a low-cost Internet of Things (IoT) system using ESP32 with temperature, humidity (DHT11) and volatile gas (MQ-3) sensors, applying an Exponential Moving Average (EMA) filter ($\alpha = 0.1$) to keep oscillations below 100 Analog-to-Digital Converter (ADC) points. A machine learning pipeline with SHAPley Additive exPlanations (SHAP) confirmed the MQ-3 as the dominant variable in risk detection, achieving global accuracy of 82% on the independent test set, with cross-validation mean F1-Score of 0.9753 ± 0.0071 and weighted F1-Score of 0.83. The solution aims to reduce losses through risk anticipation, optimize logistics, and support predictive models for remaining shelf-life estimation.*

Resumo. *A ineficiência operacional no varejo brasileiro atinge 5,83% no setor de Frutas, Legumes e Verduras (FLV), com produtos climatéricos como tomate e banana como principais fontes de perda pela liberação de etileno (C₂H₄) sob armazenamento inadequado. Este trabalho propõe um sistema Internet of Things (IoT) de baixo custo com ESP32 e sensores de temperatura (T), umidade relativa (UR) (DHT11) e gases voláteis (MQ-3), com filtro Média Móvel Exponencial (EMA) ($\alpha = 0,1$) para manter oscilações abaixo de 100 pontos conversor analógico-digital (ADC). Pipeline de machine learning com SHAPley Additive exPlanations (SHAP) confirmou o MQ-3 como variável dominante na detecção de risco, alcançando acurácia global de 82% no conjunto independente de teste, com F1-Score médio em validação cruzada de $0,9753 \pm 0,0071$ e Weighted F1-Score de 0,83. A solução visa reduzir perdas por antecipação de risco, otimizar a logística e subsidiar modelos preditivos de vida útil remanescente.*

1. Introdução

O Brasil é uma potência agrícola global, com uma produção expressiva de frutas; apenas em 2024, a safra de banana ultrapassou 7 milhões de toneladas [INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA 2025]. No entanto,

essa produção enfrenta desafios de perdas ao longo do processo logístico de armazenamento de suprimentos, especialmente no varejo. Segundo a Associação Brasileira de Supermercados (ABRAS), o setor FLV registrou uma ineficiência operacional de 5,83% em 2024, um índice superior à média de outros setores do supermercado. Apontando que as frutas são as principais responsáveis por essas perdas, correspondendo à 27% do total.

O problema é manifestado no etileno dos frutos climatéricos, como a banana e o tomate, que são os produtos com maior risco de perda tanto em quilos quanto em valores [ASSOCIACAO BRASILEIRA DE SUPERMERCADOS 2025]. Estes frutos liberam etileno (C_2H_4), gás que acelera drasticamente o amadurecimento e os processos metabólicos dos frutos [Wang et al. 2023], afetando através da interação desses gases o metabolismo de outras frutas. Este processo bioquímico é acelerado por condições ambientais que desfavorecem as condições naturais de cada fruto; uma elevação na temperatura de armazenamento foi influente, em nossos testes, para acelerar em 50% a emissão de gases voláteis. A falta de um monitoramento e conhecimento desses efeitos impedem ações proativas nos supermercados, resultando em perdas financeiras significativas.

Diante deste cenário, esta pesquisa propõe o desenvolvimento e a aplicação de uma arquitetura de monitoramento de baixo custo baseado em IoT. O nó sensor é composto por um microcontrolador ESP32 (processamento e conectividade Wi-Fi) e pelos sensores DHT11 (temperatura e umidade) e MQ-3 (utilizado como proxy indireto de etileno). Além disso, o estudo busca comparar resultados para assegurar um algoritmo eficiente de predição de qualidade e comprovar influência de condições de armazenamento na qualidade final das frutas. A arquitetura proposta opera em três camadas: aquisição local dos dados com aplicação do filtro EMA no sinal do MQ-3; processamento embarcado no ESP32, com autenticação por *X-API-KEY* e envio dos dados ao servidor; e uma camada em nuvem baseada em Flask, MongoDB e *Random Forest*, responsável pelo armazenamento, classificação e visualização em tempo real.

Além do foco técnico, a proposta também apresenta viabilidade econômica para aplicações no varejo de hortifrúti. O custo estimado do nó sensor baseado em ESP32, DHT11 e MQ-3 é de aproximadamente R\$ 82,58 por unidade. Considerando um lote de 500 kg de banana avaliado em cerca de R\$ 1.500,00, a mitigação inicial de apenas 8% das perdas operacionais já seria suficiente para compensar o custo de implementação de duas unidades de monitoramento. Dessa forma, o modelo apresenta potencial de retorno sobre investimento (ROI) em poucos ciclos de armazenamento, permitindo escalabilidade.

A validação da infraestrutura foi realizada em ambiente de testes controlado (recipientes isolados) para estabelecer a relação direta entre o estado fisiológico (observação manual) e os dados dos sensores. O algoritmo de classificação, validado contra dados reais de monitoramento, alcançou resultados adequados na identificação do estado de risco, fornecendo uma janela de antecipação crucial para a mitigação de perdas. A técnica de *SHAP* foi utilizada para interpretar o modelo, demonstrando que a variável do gás volátil (MQ-3) possui a maior importância preditiva. Este artigo detalha a arquitetura proposta, a metodologia de calibração e análise de dados, e discute o impacto dessa tecnologia na gestão de FLV no varejo.

1.1. Contribuições do projeto

As principais contribuições deste trabalho são: o desenvolvimento de um nó sensor IoT de baixo custo baseado em ESP32, DHT11 e MQ-3; a aplicação de filtro EMA embarcado para estabilização das leituras do sensor de gases; a criação de um pipeline preditivo com *Random Forest*, validado com acurácia superior a 80%; e a interpretação do modelo via *SHAP*, que confirmou a relevância do MQ-3 como indicador indireto do amadurecimento e do risco de perda.

2. Trabalhos Relacionados

O uso de sensores MQ no monitoramento de FLV tem ganhado destaque devido ao baixo custo e à capacidade de detectar VOCs associados ao amadurecimento. Pranav e equipe propuseram um sistema de estimativa de frescor baseado em sensores MQ, validando a viabilidade da análise gasosa em aplicações agrícolas [Pranav et al. 2021]. Diferentemente desse trabalho, a presente proposta incorpora filtragem EMA embarcada, arquitetura IoT com ESP32 e interpretabilidade do modelo via *SHAP*.

Vijay Paul discute as diferenças entre frutos climatéricos e não climatéricos, destacando o papel do etileno no amadurecimento e na degradação pós-colheita [Paul et al. 2012]. Essa base biológica sustenta a arquitetura desenvolvida, especialmente no uso do sensor MQ-3 como *proxy* indireto para detecção de compostos voláteis associados ao climatério respiratório.

Em [Payasi and Sanwal 2010], A.Payasi e G.G.Sanwal investigaram mecanismos de amadurecimento e controle em frutos climatéricos, destacando a influência de T, U e VOCs na vida útil pós-colheita. Com base nisso, o presente trabalho amplia essa abordagem ao integrar monitoramento IoT contínuo com análise preditiva baseada em *machine learning*.

O time de Xuejun Liu caracterizaram a biossíntese de etileno durante o amadurecimento da banana, evidenciando alterações fisiológicas associadas ao climatério respiratório [Liu et al. 1999]. Neste trabalho, a banana foi utilizada como objeto experimental devido à elevada emissão de compostos voláteis ao longo do amadurecimento.

Xiang Wang e outros demonstraram que a temperatura influencia diretamente a resposta de sensores aplicados ao monitoramento do amadurecimento [Wang et al. 2023]. Os resultados corroboram este trabalho, onde temperaturas acima de 32°C intensificaram as leituras do sensor MQ-3 e aceleraram o metabolismo das bananas monitoradas.

Em [Silva 2020], Jorge Silva desenvolveu um sistema IoT para monitoramento da maturação de frutas utilizando sensores de cor e gás etileno, demonstrando a viabilidade de arquiteturas embarcadas no pós-colheita. O sistema proposto diferencia-se pela aplicação de saneamento analítico, validação com *Stratified K-Fold* e interpretabilidade via *SHAP*.

sugere um dispositivo IoT de detecção gasosa para frutas armazenadas, demonstrando que sensores MQ podem atuar como indicadores indiretos do estado fisiológico dos frutos [Chandrasekaran et al. 2022]. Essa abordagem está alinhada à proposta desenvolvida, que utiliza o MQ-3 como alternativa de baixo custo para monitoramento contínuo do amadurecimento climatérico.

[Ismail et al. 2021] apresentou um sistema IoT para rastreamento e monitoramento da qualidade da banana utilizando Wi-Fi e banco de dados em tempo real. Diferentemente desse estudo, o presente estudo incorpora classificação preditiva com *Random Forest*, filtragem EMA embarcada e interpretabilidade via *SHAP*.

3. Fundamentação Teórica

3.1. A Ineficiência Operacional e a da Qualidade de Frutas no Varejo

O setor FLV no varejo brasileiro é marcado por uma ineficiência operacional crítica. a taxa de ineficiência, um índice significativamente superior à média geral de perdas do supermercado. Essa discrepância sinaliza que a gestão de FLV é o principal gargalo logístico, exigindo intervenção tecnológica urgente. A raiz dessa ineficiência reside na natureza biológica dos frutos climatéricos, como a banana e o tomate. O amadurecimento desses frutos é regido por um aumento transitório e acentuado na taxa respiratória, conhecido como climatério. Este pico metabólico é sinalizado pela produção do fitormônio gasoso Etileno (C_2H_4). O C_2H_4 possui uma ação autocatalítica: uma pequena concentração desencadeia a produção exponencial de mais C_2H_4 pelo próprio fruto, gerando aceleração no processo de maturação em cadeia nos frutos próximos [Paul et al. 2012].

Amadurecimento Acelerado vs. Qualidade da Fruta

A velocidade do amadurecimento, sobretudo quando acelerada por fatores ambientais ou pelo Etileno, compromete diretamente a qualidade (sabor, aroma, textura) do produto. O amadurecimento envolve dois conjuntos principais de processos:

1. **Processos Fisiológicos Acelerados (Degradação):** A síntese de enzimas como a Pectinase e a Celulase é rapidamente ativada, resultando na quebra estrutural das paredes celulares (degradação da firmeza). A atividade da Polifenol Oxidase (PPO) também é intensificada, levando ao escurecimento e ao aparecimento de manchas. Estes são os primeiros indicadores de perda e senescência.
2. **Processos Metabólicos de Sabor (Formação):** A conversão de amido em açúcares (glicose e frutose) e a síntese de ésteres voláteis (aroma) ocorrem simultaneamente.

Em condições ideais, esses processos são sincronizados. No entanto, o estresse térmico ou o excesso de Etileno aceleram desproporcionalmente os processos fisiológicos (amolecimento, escurecimento e coloração), que são termodinamicamente mais rápidos. O resultado é um fruto que adquire a aparência de maduro rapidamente, mas não completou a conversão de amido e a síntese de compostos aromáticos, culminando em produtos com sabor neutro e textura degradada, aumentando o risco de descarte precoce pelo consumidor ou pelo varejo.

3.2. Monitoramento e a Base Tecnológica da Proposta

A detecção precoce do pico de C_2H_4 e do estresse térmico é, portanto, a estratégia central para a mitigação de perdas e garantia de qualidade. Este desenvolvimento se fundamenta na combinação entre o fenômeno climatérico e a tecnologia IoT de baixo custo. Segundo [Payasi and Sanwal 2010], o monitoramento e o controle do amadurecimento de frutos climatéricos são fundamentais para reduzir perdas pós-colheita e preservar a qualidade fisiológica durante o armazenamento.

Seleção de Sensores e *Edge Computing*

O monitoramento baseia-se no DHT11 para variáveis ambientais e no MQ-3 como *proxy* de compostos orgânicos voláteis (VOCs), conforme discutido na metodologia: Fatores ambientais que regulam a taxa respiratória do fruto. MQ-3 (Gases Voláteis): Embora não seja um sensor dedicado ao Etileno, o MQ-3 detecta uma ampla gama de VOCs e álcoois que são subprodutos da respiração e do processo metabólico [Chandrasekaran et al. 2022]. O uso do MQ-3 foi adotado como alternativa de baixo custo a sensores de etileno e pela sua capacidade de atuar como um *proxy* confiável do pico metabólico em um modelo de baixo custo onde a classificação final de risco é dada pelo *random forest*. A relevância das variáveis (T, UR e VOCs) para o estado de maturação é validada post-hoc através da técnica de SHAP, que garante que o modelo de *random forest* priorize os biomarcadores gasosos mais significativos

A arquitetura proposta adota *Edge Computing*, onde o ESP32 atua como o Módulo Edge. Esta escolha é crítica para a performance operacional: Pré-Processamento de Dados: O *firmware* (*'DadosMedia.ino'*) implementa o Filtro EMA no sinal do MQ-3. Esta técnica de suavização é essencial para remover ruídos e picos de gases [Wang et al. 2023], garantindo que a oscilação do sinal bruto seja inferior a 100 pontos ADC. Otimização de Comunicação: A filtragem local e o envio do payload JSON estruturado via *HTTP POST* minimizam a latência e otimizam o uso de banda, permitindo que o mecanismo envie apenas dados de alta qualidade e com baixa latência.

3.3. Classificação Preditiva e Validação

No servidor central (Flask/MongoDB), a inteligência é gerada a partir dos dados limpos. A plataforma utiliza um *Rule-Based System* para classificar o estado do fruto, com base em faixas calibradas de T, U e MQ-3_raw. Esta calibração considera as *baselines* de diferentes frutos (e.g., tomate com 1300 ADC vs. ambiente com 900 ADC). O algoritmo de classificação validado demonstrou uma desempenho consistente em validação estratificada, com *Recall* de 0,94 para a classe crítica “Risco de Perda” e *F1-Score* médio de $0,9753 \pm 0,0071$., transformando o dado bruto em uma informação acionável para a equipe do varejo.

4. Metodologia

A metodologia adotou uma arquitetura IoT com *Edge Computing*, organizada em três etapas: aquisição e pré-processamento dos dados, processamento central e aplicação de inteligência preditiva para apoio à decisão no varejo..

4.1. Aquisição e Módulo Edge

O ponto de coleta de dados, denominado Módulo Edge, foi instalado em recipientes que simulam as condições de exposição de ambiente. O módulo é centralizado no microcontrolador ESP32, escolhido por sua capacidade de processamento embarcado e conectividade Wi-Fi. O sensor de DHT11 é utilizado para monitorar as condições ambientais, identificadas como fatores críticos para a aceleração metabólica do fruto. Paralelamente, o sensor de Gases Voláteis MQ-3 é empregado como *proxy* de Etileno (C₂H₄). Essa escolha tecnológica é justificada pela busca de equipamentos de baixo custo, uma vez que o MQ-3 detecta VOCs correlacionados diretamente com o pico respiratório e o amadurecimento dos frutos climatéricos. A conexão física para a leitura analógica do MQ-3 foi

estabelecida no pino GPIO 34 do ESP32, enquanto o DHT11 foi conectado ao GPIO 19, garantindo a leitura simultânea das variáveis ambientais e de gases.

4.2. Tratamento de Dados e Comunicação

O conjunto de dados passou por um processo de saneamento analítico e auditoria biológica para corrigir inconsistências entre as leituras do sensor MQ-3 e os estágios reais de maturação da banana. Durante o tratamento, foram removidos registros corrompidos, ajustadas transições incompatíveis do ciclo climatérico e padronizadas as classes biológicas monitoradas. Na etapa de aquisição, a ESP32 aplicou filtragem por Média Móvel Exponencial (EMA) em 100 leituras sucessivas para reduzir ruídos analógicos e oscilações elétricas do sensor. Posteriormente, os dados foram organizados temporalmente e submetidos à validação estatística utilizando divisão hold-out (80/20) e validação cruzada estratificada (*K-Fold*), garantindo maior robustez, estabilidade e capacidade de generalização ao modelo *Random Forest*.

4.3. Processamento Embarcado (*Edge Computing*)

O firmware do ESP32 executa o Filtro de Média Móvel Exponencial (EMA) no sinal analógico do MQ-3. A função principal desse filtro é suprimir o ruído elétrico e as oscilações bruscas do sensor, assegurando que a variação do sinal no nó sensor seja inferior a 100 pontos ADC. Este pré-processamento de borda é fundamental para a precisão da classificação posterior.

4.4. Comunicação e Frequência

A transmissão dos dados é realizada através de requisições HTTP POST via Wi-Fi para o servidor central. Embora o sensor realize leituras internas continuamente para o cálculo do filtro EMA, o envio externo do pacote de dados JSON completo é otimizado e ocorre em intervalos fixos de 225 segundos (3,75 minutos). Essa frequência de envio equilibra a responsividade da estrutura com a eficiência no uso da rede e da energia.

4.5. Processamento Central e Geração de Inteligência

O servidor central concentra a infraestrutura de dados e o mecanismo de análise inteligente da aplicação, funcionando como responsável pela coleta, tratamento e interpretação das medições. Após receber os valores já filtrados dos dispositivos IoT, o modelo de classificação executa a lógica preditiva que converte medições brutas em informação contextualizada e útil, possibilitando a identificação de tendências, estados de risco e ações estratégicas de antecipação.

4.6. Infraestrutura e Banco de Dados

O servidor Flask (Python) atua como o *backend* da aplicação, recebendo os dados via API REST. A persistência dos dados é realizada no MongoDB, um banco de dados NoSQL que armazena os registros de sensores por “tipo de fruta” e “lote”, facilitando a segmentação e a calibração específica.

4.7. Calibração e Classificação Inteligente

O servidor processa os dados através de um modelo de classificação do estado fisiológico e o risco é determinado por um modelo de *random forest* pré treinado. O modelo foi calibrado para considerar a variável 'tipo fruta' como uma variável categórica, levando a tecnologia a diferenciar *baselines* heterogêneas, como o patamar de 1300 ADC do tomate contra 900 ADC do ambiente limpo. A interpretabilidade do modelo foi validada via *SHAP*, assegurando que as decisões de classificação estejam fundamentadas nas variações químicas detectadas pelo sensor MQ-3.

4.8. Protocolo Experimental e Configuração do Modelo

O experimento foi conduzido em ambiente controlado, utilizando uma banana climatérica armazenada em recipiente plástico lacrado por doze dias. A escolha da banana deve-se à sua elevada atividade respiratória e produção de etileno durante o amadurecimento [Liu et al. 1999]. O monitoramento foi realizado por um nó sensor baseado em ESP32, com leituras periódicas de T, UR e VOCs por meio do sensor MQ-3. As transmissões ocorreram a cada 225 segundos, totalizando 4298 registros temporais, caracterizando uma análise longitudinal exploratória de um exemplar.

As classes biológicas (“Sem Risco”, “Madura”, “Alerta” e “Risco de Perda”) foram rotuladas manualmente com base em observações diárias de coloração da casca, manchas, textura superficial e intensidade do odor. Para treinamento e validação, utilizou-se divisão hold-out estratificada 80/20, complementada por validação cruzada estratificada *Stratified K-Fold* com $k = 5$. O modelo *Random Forest* foi configurado com 100 árvores de decisão ($n_estimators=100$) e $random_state=42$, garantindo reprodutibilidade.

Os experimentos configuram uma prova de conceito inicial, voltada à validação da arquitetura IoT e da viabilidade preditiva do monitoramento fisiológico. Estudos futuros deverão ampliar o número de frutos, ciclos experimentais e condições ambientais para fortalecer a validade estatística do modelo.

4.9. Camada de Aplicação

A camada final transforma os insights em ferramentas de gestão, incluindo um *dashboard* desenvolvido em Flask/SocketIO para visualização em tempo real do estado de risco e uma funcionalidade de exportação de dados via API em formato CSV. A implementação disponibiliza alertas visuais para o risco de perda e séries temporais das variáveis ambientais e gasosas. A capacidade de gerar alertas preditivos permite que a equipe operacional realize intervenções proativas, como a realocação ou o ajuste de preço do lote, mitigando o gargalo operacional.

Para fins de reprodutibilidade e transparência técnica, o código-fonte completo da implementação, encontra-se disponível em repositório público ¹

¹Repositório oficial disponível em: https://github.com/LucaAtanazio/PI-Monitoramento_Frutas.git.

5. Resultados e Discussão

5.1. Viabilidade Econômica

Tabela 1. Custo estimado do nó sensor IoT

Componente	Preço Médio (R\$)
ESP32 ²	40,75
MQ-3 ³	13,20
DHT11 ⁴	13,09
Cabos Jumpers ⁵	6,55
Container plástico ⁶	8,99
Total	82,58

A Tabela 1 apresenta os componentes do nó sensor IoT e seus respectivos custos médios de mercado. Os valores apresentados foram obtidos a partir de plataformas comerciais.

5.2. Desempenho do Algoritmo e Importância dos Atributos

A validação do modelo de Inteligência Artificial foi estruturada em duas frentes analíticas: a consistência estatística do algoritmo sob diferentes subconjuntos de dados e a sua exatidão preditiva para cada estágio de maturação.

A Figura 1 ilustra a distribuição do Weighted F1-Score obtido por meio da validação cruzada estratificada (Stratified K-Fold). Esta análise comprova a baixa variabilidade entre os folds e a estabilidade estatística do modelo de Random Forest, demonstrando sua robustez na generalização dos dados mesmo diante do desbalanceamento natural entre as classes de degradação.

Em complemento à validação estatística, a Figura 2 apresenta a matriz de confusão resultante da aplicação do modelo em ambiente controlado. Destaca-se, a alta taxa de acertos e a minimização de falsos negativos para a classe crítica de "Risco de Perda". Esse rigor na classificação é o que garante a utilidade prática do sistema para alertas logísticos confiáveis antes que a degradação atinja níveis irreversíveis no varejo.

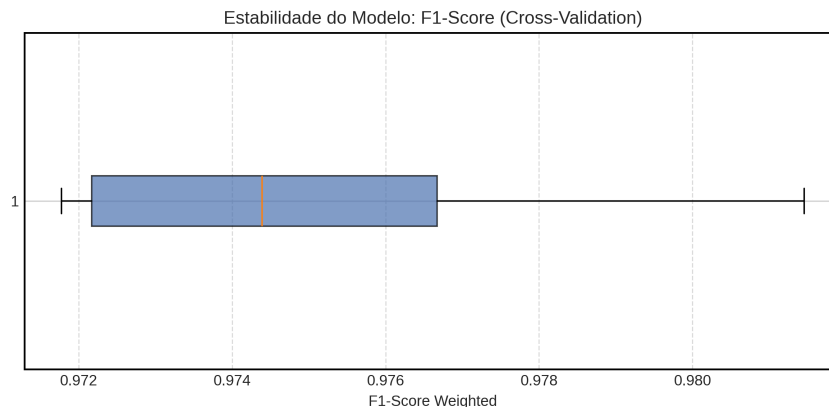


Figura 1. Distribuição do Weighted F1-Score obtido por validação cruzada estratificada (Stratified K-Fold).

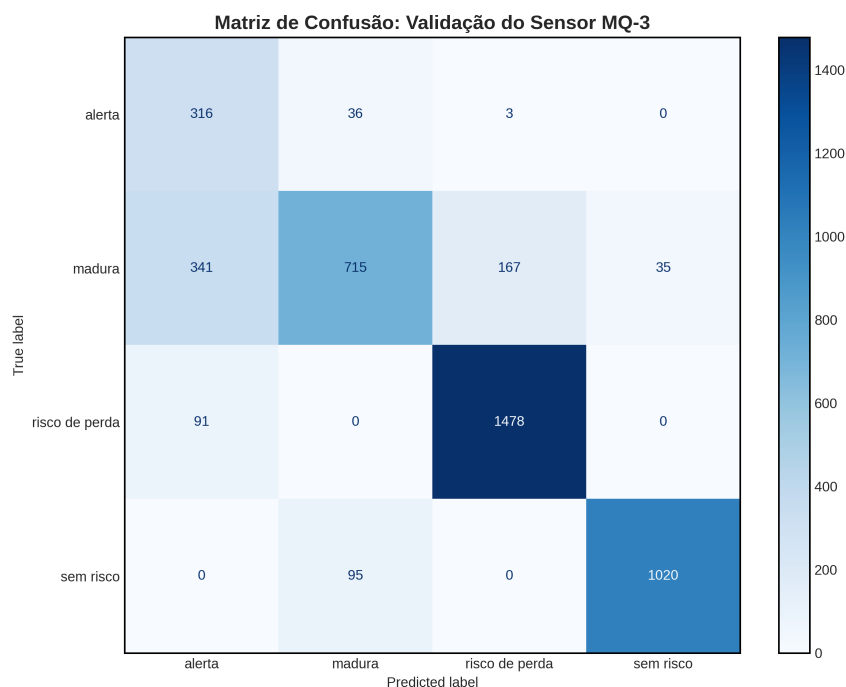


Figura 2. Matriz de confusão do modelo de classificação aplicado ao monitoramento fisiológico das frutas.

A classe “Risco de Perda” apresentou *Recall* de 0,94 e *F1-Score* de 0,92, evidenciando elevada eficiência na detecção precoce de deterioração. Para a classe “Sem Risco”, o modelo alcançou precisão de 0,97 e *F1-Score* de 0,94, indicando baixa incidência de falsos positivos durante o monitoramento. Já a classe “Alerta” obteve *Recall* de 0,89, demonstrando comportamento preventivo adequado para antecipação de estágios críticos de amadurecimento. A baixa variabilidade observada no *K-Fold* reforça a consistência estatística do modelo, reduzindo o impacto da predominância da classe “Madura”.

Os testes evidenciaram diferenças nas *baselines* do sensor MQ-3 conforme o fruto monitorado, como o tomate com cerca de 1300 ADC. A análise via *SHAP* confirmou o MQ-3 como variável mais relevante do modelo, reforçando os VOCs como biomarcadores da maturação. Para mitigar o desbalanceamento entre classes, foram utilizadas métricas como *Recall*, *F1-Score* e validação cruzada estratificada *Stratified K-Fold*. Contudo, por se tratar de uma prova de conceito em ambiente controlado, limitações como a seletividade química do sensor e o desbalanceamento residual devem ser investigadas em estudos futuros em ambientes comerciais reais.

5.3. Correlação Ambiental e Dinâmica Metabólica

A Figura 3 ilustra o comportamento térmico e ambiental durante os ciclos monitorados no armazenamento das bananas climatéricas.

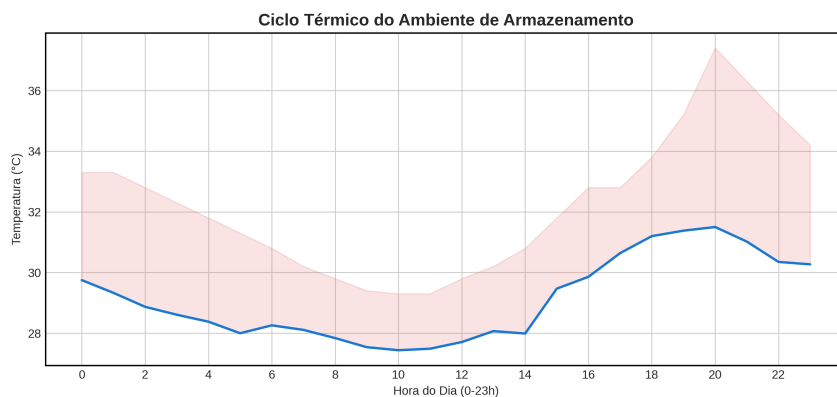


Figura 3. Ciclo térmico e comportamento ambiental durante o armazenamento monitorado.

As análises confirmaram correlação direta entre o aumento da temperatura, a aceleração metabólica da banana e o crescimento progressivo das leituras do sensor MQ-3. Durante os ciclos monitorados, elevações térmicas acima de 32°C aceleraram significativamente a emissão de compostos voláteis, enquanto níveis elevados de umidade relativa acima de 78% reduziram a estimativa de vida útil residual. As leituras do MQ-3 apresentaram progressão coerente entre os estágios biológicos monitorados, seguindo a transição “Sem Risco, Madura, Alerta, Risco de Perda”. Esse comportamento reforça a capacidade do sistema em detectar alterações fisiológicas associadas ao amadurecimento acelerado e ao estresse térmico.

5.4. Robustez Operacional do Pipeline IoT

A Figura 4 apresenta a consistência temporal do pipeline IoT durante os ciclos de transmissão entre ESP32, Flask e MongoDB.




Figura 4. Consistência temporal do envio de dados entre ESP32 e servidor Flask.

Os testes demonstraram transmissão estável e tolerância a oscilações de rede, sem perda relevante de pacotes. O fluxo de dados consistente entre o módulo embarcado, Flask e MongoDB valida a arquitetura como uma solução escalável e de baixo custo para o monitoramento de frutos climatéricos. O aumento dos gases voláteis evidenciou a sensibilidade das frutas às condições ambientais, indicando que o sistema pode apoiar

ações preventivas antes da deterioração visível. Entre as possíveis intervenções estão a retirada antecipada de lotes críticos, ajuste de temperatura, aumento da ventilação e redução da exposição de outras frutas climatéricas ao etileno.

6. Conclusão

Os resultados demonstraram que a arquitetura IoT proposta foi eficaz no monitoramento fisiológico de frutas climatéricas em ambiente controlado, integrando ESP32, MQ-3 e DHT11 para acompanhar variações ambientais e metabólicas associadas ao amadurecimento e ao risco de deterioração. O modelo de *machine learning* apresentou desempenho satisfatório na identificação da classe “Risco de Perda”, enquanto o filtro EMA estabilizou as leituras analógicas e a análise via *SHAP* confirmou a relevância dos compostos voláteis detectados pelo MQ-3 como principal variável preditiva. A estabilidade das transmissões entre ESP32, Flask e MongoDB, aliada ao baixo custo de implementação, reforça a viabilidade da solução para pequenos varejistas e centros de armazenamento. Como trabalhos futuros, propõe-se ampliar a base de dados, avaliar grupos de frutas e validar o sistema em ambientes comerciais com diferentes frutas climatéricas.

Referências

- ASSOCIACAO BRASILEIRA DE SUPERMERCADOS (2025). Pesquisa de eficiência operacional: Resultados 2025. Acesso em: 10 nov. 2025.
- Chandrasekaran, N. et al. (2022). Iot sensor-based gas detection device for stored fruits. *Plant Archives*, 22(1):750–756. Acesso em: 17 nov. 2025.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATISTICA (2025). Levantamento sistemático da produção agrícola (Ispa). Acesso em: 10 nov. 2025.
- Ismail, A. H. et al. (2021). Smart banana quality tracking and monitoring system via wifi with database. In *International Conference on Computer and Drone Application (IConDA)*, MARA. Acesso em: 17 nov. 2025.
- Liu, X., Shiomi, S., Nakatsuka, A., Kubo, Y., Nakamura, R., and Inaba, A. (1999). Characterization of ethylene biosynthesis associated with ripening in banana fruit. *Plant physiology*, 121(4):1257–1265.
- Paul, V., Pandey, R., and Srivastava, G. C. (2012). The fading distinctions between classical patterns of ripening in climacteric and non-climacteric fruit and the ubiquity of ethylene—an overview. *Journal of food science and technology*, 49(1):1–21.
- Payasi, A. and Sanwal, G. (2010). Ripening of climacteric fruits and their control. *Journal of food Biochemistry*, 34(4):679–710.
- Pranav, S. B. N., Kumar, T. K., Prakash, J. H., Sharan, S., and Ganesan, M. (2021). Freshness estimator for fruits and vegetables using mq sensors. In *2021 International Conference on Advances in Computing and Communications (ICACC)*, pages 1–6. IEEE.
- Silva, J. (2020). Sistema de iot para monitoramento da maturação de frutas por cor e gás etileno. Acesso em: 17 nov. 2025.
- Wang, H. et al. (2023). Response characteristics study of ethylene sensor for fruit ripening under temperature control. *Sensors*, 23(11):5203. Acesso em: 17 nov. 2025.