

SISTEMA INTELIGENTE PARA DETECÇÃO DE VAZAMENTO DE GÁS GLP COM REDUÇÃO DE FALSOS POSITIVOS

João Victor Possamai Della¹, Valter Blauth Júnior²

Resumo: A detecção de vazamentos de Gás Liquefeito de Petróleo é vital para evitar acidentes residenciais graves. Contudo, sistemas de alarme baseados em sensores de baixo custo, como o MQ-6, sofrem com alta sensibilidade cruzada, gerando falsos positivos na presença de interferentes como o álcool isopropílico. Este trabalho objetiva propor um sistema inteligente embarcado para detecção de Gás Liquefeito de Petróleo com redução de alarmes indevidos, utilizando um microcontrolador ESP32 e técnicas de aprendizado de máquina na borda (*Tiny Machine Learning*). A metodologia experimental consistiu na coleta de séries temporais de gás e temperatura para treinar uma rede neural quantizada (int8) na plataforma *Edge Impulse*. Os resultados mostraram que o modelo atingiu 97,3% de acurácia, identificando vazamentos reais e rejeitando 91,7% das interferências causadas pelo álcool, consumindo apenas 320 Bytes de memória RAM. Embora o estudo apresente limitações, como a ocasional sobreposição de sinais em baixas concentrações devido à física do sensor, conclui-se que o uso de TinyML atua como uma solução viável para mitigar falhas de hardware, aumentando a segurança residencial.

Palavras-chave: TinyML; Internet das Coisas; GLP; Sensores MOS; Aprendizado de Máquina.

ABSTRACT: The detection of Liquefied Petroleum Gas leaks is vital to prevent serious residential accidents. However, alarm systems based on low-cost sensors, such as the MQ-6, suffer from high cross-sensitivity, generating false positives in the presence of interferents like isopropyl alcohol. This work aims to propose an embedded intelligent system for Liquefied Petroleum Gas detection with a reduction in false alarms, using an ESP32 microcontroller and edge machine learning techniques (*Tiny Machine Learning*). The experimental methodology consisted of collecting gas and tem-

¹Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. joaovictor_pd13@unesc.net

²Orientador, Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. valterblauth@unesc.net

perature time series to train a quantized neural network (int8) on the *Edge Impulse* platform. The results showed that the model achieved 97.3% accuracy, identifying real leaks and rejecting 91.7% of the interferences caused by alcohol, consuming only 320 Bytes of RAM. Although the study presents limitations, such as occasional signal overlap at low concentrations due to the sensor's physics, it is concluded that the use of TinyML acts as a viable solution to mitigate hardware failures, increasing residential safety.

Keywords: TinyML; Internet of Things; LPG; MOS Sensors; Machine Learning.

1 INTRODUÇÃO

O Gás Liquefeito de Petróleo (GLP) é amplamente utilizado no cenário nacional, presente em 91% das residências brasileiras e em 100% dos municípios, superando serviços como energia elétrica e saneamento básico (SINDIGAS, 2024). Devido às suas propriedades físicas, especificamente a densidade superior à do ar, a dissipação do GLP em ambientes fechados ocorre de forma restrita, resultando no acúmulo do composto em níveis próximos ao solo (CBMPR, 2018). Esse comportamento físico eleva o risco de asfixia e explosões, transformando a manipulação e o armazenamento desse combustível em um desafio crítico para a segurança pública e urbana. Na prática, o perigo iminente dessas características físicas se traduz em um volume expressivo de acidentes e chamados de emergência cotidianos. Como reflexo estatístico dessa problemática, o Corpo de Bombeiros Militar do Ceará registrou 1.588 ocorrências relacionadas a vazamentos de gás em 2024 (CBMCE, 2024), o que fundamenta a necessidade de sistemas de monitoramento contínuo.

Como alternativa para a redução desses incidentes, uma opção viável e amplamente adotada é a implementação de sistemas eletrônicos de detecção que utilizam, predominantemente, sensores semicondutores de óxido metálico (MOS), como os da série MQ. Esses componentes operam por meio da alteração de condutividade elétrica em resposta a gases redutores (Nikolic et al., 2020; Arbia; Helal; Comini, 2024). Contudo, a literatura documenta uma limitação físico-química intrínseca a esses dispositivos: a sensibilidade cruzada. Essa característica faz com que os sensores MOS apresentem variações de leitura não apenas na presença de GLP, mas também em contato com Compostos Orgânicos Voláteis (VOCs), como vapores de álcool e produtos de higienização (Sayago; Mercadante;

Andrade, 2021; Muniz, 2023).

A literatura recente apresenta diversas abordagens para a detecção de gases, variando desde lógicas tradicionais até a implementação de modelos preditivos complexos. Neto et al. (2020) desenvolveram um sistema de detecção de gás voltado para áreas de risco, utilizando hardware de baixo custo para acionamento de atuadores e envio de notificações. O estudo baseou-se em uma lógica de limiar fixo (*threshold*), na qual o alarme é ativado ao atingir uma concentração pré-definida.

Para superar as limitações físicas dos sensores isolados, Tozlu (2024) propôs um modelo de nariz eletrônico focado na detecção de metanol. O autor utilizou um conjunto de oito sensores da família MQ e comparou a eficácia de diferentes algoritmos de Aprendizado de Máquina, como Máquinas de Vetores de Suporte (SVM) e Análise de Discriminante Linear (LDA). Os resultados demonstraram alta taxa de classificação, evidenciando que a aplicação de algoritmos de inteligência artificial é capaz de contornar a baixa seletividade do hardware.

Em âmbito nacional, Muniz (2023) desenvolveu um arranjo multisensorial composto por treze sensores para o monitoramento de gases poluentes em aterros sanitários. A pesquisa aplicou Redes Neurais Artificiais (RNA) para processar os sinais simultâneos e estimar a concentração dos compostos de forma paralela. O trabalho reforça a viabilidade do uso de redes neurais para a identificação de padrões complexos em sensores de baixo custo.

Embora os trabalhos correlatos demonstrem a eficácia do aprendizado de máquina para a classificação de gases, identifica-se uma lacuna na literatura científica quanto à aplicabilidade prática dessas soluções em cenários residenciais com restrição de recursos. As abordagens inteligentes atuais dependem de matrizes complexas de múltiplos sensores ou exigem o envio contínuo de dados para processamento externo, elevando o custo da solução. Em contrapartida, os sistemas comerciais baratos mantêm a detecção por limiar fixo, permanecendo vulneráveis aos falsos positivos. Diante disso, o problema desta pesquisa consiste em determinar como reduzir a frequência de falsos positivos em sensores de gás de baixo custo utilizando processamento embarcado na borda.

Parte-se da hipótese de que a aplicação de modelos de TinyML embarcados é capaz de reduzir a incidência de falsos positivos em sensores de gás de baixo custo, sem a necessidade de processamento externo.

Para responder a este problema e testar a hipótese estabele-

cida, este trabalho tem como objetivo avaliar a aplicação de um sistema embarcado baseado em *Tiny Machine Learning (TinyML)* para a detecção de GLP com redução de falsos positivos. O escopo da pesquisa delimita-se ao ambiente residencial, focando na identificação de vazamentos de GLP e na supressão exclusiva de alarmes indevidos gerados por interferências de vapores de álcool. Para isso, a solução utiliza um microcontrolador ESP32 integrado a um sensor de gás (MQ-6) e a um sensor de temperatura, processando os dados de forma estritamente local.

A pesquisa justifica-se pelo impacto direto na segurança preventiva. A alta taxa de falsos positivos em sensores de óxido metálico compromete severamente a eficácia dos sistemas de alerta. Conforme documentado na literatura recente, a repetição de alarmes indevidos cria uma falsa sensação de segurança, sendo a principal causa para que os usuários desativem ou ignorem os dispositivos de proteção (Milli; Milli, 2025). Ao embarcar inteligência artificial em microcontroladores acessíveis, este projeto mitiga limitações físicas do hardware por meio de processamento avançado. Essa abordagem amplia a viabilidade de implementação de sistemas de maior precisão em dispositivos de baixo custo, além de contribuir para o aumento da confiabilidade de dispositivos de Internet das Coisas (IoT) voltados à proteção da vida.

2 MATERIAIS E MÉTODOS

Este trabalho caracteriza-se como uma pesquisa tecnológica e experimental, com abordagem quantitativa, tendo como objetivo a proposição e avaliação de um sistema embarcado inteligente para detecção de vazamentos de gás GLP, com foco na redução de falsos positivos. O sistema integra hardware de baixo custo e um modelo de aprendizado de máquina no paradigma TinyML, sendo desenvolvido e validado por meio de experimentos controlados.

2.1 VISÃO GERAL DO SISTEMA


O sistema proposto é composto por três principais componentes: módulo de hardware, responsável pela aquisição dos dados; módulo de coleta e transmissão, realizado pelo microcontrolador; e módulo de processamento e modelagem, executado na plataforma *Edge Impulse*.

O fluxo de funcionamento consiste na leitura contínua dos sensores, envio dos dados para a plataforma de desenvolvimento, construção do conjunto de dados (*dataset*), treinamento do modelo de aprendizado

de máquina e validação por meio de testes com dados não utilizados no treinamento.

A Figura 1 apresenta a arquitetura geral do sistema proposto, evidenciando a integração entre os módulos de aquisição de dados, coleta e transmissão via comunicação serial USB e processamento na plataforma *Edge Impulse*.

Figura 1 - Fluxo de Funcionamento do Sistema.



Fonte: Do autor (2026).

2.2 MÓDULO DE HARDWARE

Desenvolveu-se o protótipo utilizando o microcontrolador ESP32, devido à sua capacidade de processamento, conectividade e compatibilidade com aplicações de Internet das Coisas (IoT).


Utilizaram-se os seguintes sensores:

- Sensor MQ-6: responsável pela detecção de gases combustíveis, com alta sensibilidade ao GLP (butano e propano). Conforme documentado nas especificações técnicas do fabricante Pololu Robotics (s.d.), o sensor opera baseado em uma camada de dióxido de estanho (SnO_2) e possui inerente sensibilidade cruzada, apresentando variações de condutividade também na presença de interferentes orgânicos, como vapores de álcool;
- Sensor DHT22: utilizado para medição de temperatura e umidade do ambiente.

O sensor MQ-6 fornece leituras analógicas proporcionais à concentração de gás no ambiente, enquanto o DHT22 fornece dados digitais de temperatura e umidade. No entanto, durante os experimentos, utilizaram-se apenas os dados de temperatura e nível de gás no modelo de classificação, sendo a variável umidade descartada por não contribuir significativamente para a separação das classes.

Para materializar a arquitetura descrita e validar a integração dos componentes, montou-se o hardware fisicamente. A Figura 2 ilustra o protótipo final montado, destacando o microcontrolador ESP32 conectado aos sensores.

Figura 2 - Protótipo físico do sistema de detecção montado com ESP32, MQ-6 e DHT22.



Fonte: Do autor (2026).

Realizaram-se as coletas em ambiente real, sem o uso de câmara controlada. Consideraram-se dois cenários principais:

- Ambiente aberto, com circulação de ar (porta aberta);
- Ambiente fechado compreendendo um cômodo com dimensões de 12 metros quadrados, com ausência de circulação de ar (porta fechada).

2.3 AQUISIÇÃO DE DADOS

Realizou-se a aquisição de dados utilizando a plataforma *Edge Impulse*, com envio das leituras via comunicação serial a partir do ESP32.

Cada amostra foi coletada com duração fixa de 20 segundos, utilizando uma frequência de amostragem de 4 Hz, resultando em aproximadamente 80 leituras por amostra. Estes parâmetros foram estabelecidos empiricamente durante testes preliminares, observando-se que 20 segundos eram suficientes para capturar tanto o tempo de resposta (subida) quanto o início do tempo de recuperação (descida) do sensor MQ-6. As coletas foram organizadas em três classes distintas:

- **ambiente_normal**: leituras em condições ambientais sem presença de gases ou interferentes;
- **isqueiro**: classe utilizada na plataforma Edge Impulse para representar vazamentos simulados de GLP, gerados por meio da liberação controlada de gás butano proveniente de isqueiro;
- **falso_positivo**: exposição a interferentes, principalmente álcool isopropílico.

Para garantir a consistência das leituras nas classes com agentes externos (isqueiro e falso_positivo), estabeleceu-se um protocolo temporal padronizado para a janela de 20 segundos. Os primeiros 5 a 6 segundos consistiram exclusivamente na leitura da linha de base em ar limpo; em seguida, a fonte geradora foi aproximada do sensor, sendo afastada novamente entre os segundos 10 e 13 da coleta. Esse padrão temporal permitiu que as amostras capturassem não apenas o pico de concentração, mas também a curva de resposta e recuperação inicial do sensor MQ-6. Além disso, para assegurar a qualidade dos dados, novas coletas só eram iniciadas após o retorno completo do sensor à linha de base, evitando influência residual de exposições anteriores.

2.4 CONSTRUÇÃO DO CONJUNTO DE DADOS

O conjunto de dados foi construído de forma incremental e iterativa, com coletas realizadas em diferentes momentos, buscando aumentar a variabilidade das amostras e a capacidade de generalização do modelo. Ao final do processo, obtiveram-se 75 amostras independentes. Procurou-se manter um equilíbrio entre as classes para reduzir possíveis vieses durante o treinamento da rede neural, resultando em 26 amostras para a classe **ambiente_normal**, 25 para a classe **falso_positivo** e 24 para a classe **isqueiro**, utilizada para representar vazamentos simulados de GLP. Para mitigar possíveis vieses experimentais causados por variações climáticas ao longo do


dia, a ordem de coleta das amostras foi realizada de forma intercalada e aleatorizada entre as três classes.

Durante a etapa de preparação dos dados, 15 amostras consideradas inconsistentes ou representativas de ruídos experimentais foram desabilitadas na plataforma Edge Impulse, permitindo avaliar o impacto desses registros no desempenho do modelo e preservar a qualidade do conjunto de treinamento.

Com o intuito de simular cenários de exposição variados, executaram-se coletas sob diferentes níveis de concentração de gás e interferentes. Para isso, variou-se intencionalmente a distância entre a fonte emissora e o sensor MQ-6, contemplando exposições a curtas distâncias (aproximadamente 5 cm), médias (entre 10 e 15 cm) e longas (entre 20 e 30 cm). Essa estratégia permitiu capturar diferentes amplitudes de resposta do sensor e representar condições mais próximas das encontradas em aplicações reais.

A Figura 3 apresenta as curvas médias de resposta temporal do sensor MQ-6 para cada classe coletada. Observa-se que tanto o GLP quanto o álcool isopropílico provocam elevação significativa na leitura do sensor, evidenciando o fenômeno de sensibilidade cruzada. Entretanto, as curvas apresentam diferenças de amplitude e comportamento temporal, características posteriormente exploradas pelo modelo TinyML durante o processo de classificação.

Figura 3 - Curvas médias de resposta temporal do sensor MQ-6 para cada classe do conjunto de dados.



Fonte: Do autor (2026).

2.5 PROCESSAMENTO E MODELAGEM

O processamento dos dados e treinamento do modelo foram realizados na plataforma Edge Impulse. Para a definição dos parâmetros

ideais, foram realizados testes prévios com diferentes configurações de janela e stride. Durante estes testes, foi observado que janelas temporais maiores melhoravam a separação entre as classes, reduzindo confusões entre eventos transitórios e estados estáveis. Com base nestas observações experimentais, o modelo final foi construído utilizando os seguintes parâmetros:

- Tipo de entrada: dados brutos (Raw Data);
- Bloco de aprendizado: Classifier (rede neural);
- Tamanho da janela (window size): 10.000 ms;
- Passo da janela (stride): 5.000 ms;
- Arquitetura da rede neural: camadas densas com 32, 16 e 8 neurônios;
- Número de ciclos de treinamento: 100 ;
- Tipo de modelo: quantizado (int8).

Além da definição da janela temporal e do *stride*, também foram avaliadas diferentes arquiteturas da rede neural e quantidades de épocas de treinamento. Essas configurações foram ajustadas de forma iterativa, analisando-se seu impacto na acurácia, na matriz de confusão e no desempenho durante os testes de *Live Classification*. Observou-se que modelos treinados com menor número de épocas apresentavam maior confusão entre as classes, enquanto arquiteturas mais complexas aumentavam o custo computacional sem proporcionar ganhos relevantes de desempenho.

A configuração final foi composta por três camadas densas de 32, 16 e 8 neurônios, treinadas durante 100 épocas e posteriormente quantizadas para inteiros de 8 bits (int8). Essa configuração foi escolhida por apresentar o melhor equilíbrio entre capacidade de generalização, consumo de memória e desempenho para execução embarcada no ESP32.

2.6 VALIDAÇÃO DO MODELO

Realizou-se a validação do modelo em duas etapas:

- Avaliação interna da plataforma *Edge Impulse*, utilizando métricas como acurácia, matriz de confusão, precisão, recall e F1-score;

- Validação prática por meio do recurso Live Classification, utilizando novas amostras não presentes no conjunto de treinamento.

Diferentemente de abordagens tradicionais, não se utilizou divisão automática fixa entre treino e teste. A validação baseou-se principalmente em testes com dados inéditos, utilizando o recurso Live Classification da plataforma Edge Impulse, permitindo avaliar o comportamento do modelo em condições mais próximas do uso real. Essa estratégia foi adotada com o objetivo de verificar a capacidade de generalização do modelo frente a novas amostras coletadas após o treinamento.

2.7 CONSIDERAÇÕES EXPERIMENTAIS

Durante a fase experimental, o manuseio do hardware demandou controles específicos. Observou-se na prática de bancada que o sensor MQ-6 exige um tempo de recuperação elevado após exposições intensas a gases, o que ditou o intervalo necessário entre cada coleta de dados. Adicionalmente, verificou-se que a intensidade do sinal analógico gerado é estritamente dependente da distância entre o componente e a fonte emissora, e que pequenas flutuações climáticas no ambiente de teste podem influenciar a estabilidade e calibração de sua linha de base.

3 RESULTADOS E DISCUSSÃO

Neste capítulo, apresentam-se os dados obtidos durante os experimentos, a análise do desempenho do modelo de *Machine Learning* e a discussão dos achados frente à literatura correlata.


3.1 EVOLUÇÃO DO MODELO E AJUSTES EXPERIMENTAIS

Durante a fase de modelagem na plataforma *Edge Impulse*, o conjunto de dados e as configurações da rede neural passaram por um processo iterativo de otimização. Os modelos preliminares, que utilizavam apenas os dados brutos do sensor MQ-6 em janelas temporais de 6.000 ms, apresentaram acurácia próxima de 68%. As principais dificuldades observadas foram a elevada confusão entre a classe isqueiro, representativa dos vazamentos simulados de GLP e falso_positivo (álcool), além da instabilidade da linha de base do sensor. Para mitigar esses efeitos, o window size foi ajustado para 10.000 ms com um stride de 5.000 ms.

Essa melhoria significativa no desempenho decorre do comportamento dinâmico transiente dos sensores semicondutores do tipo MOS. Quando o material sensível (SnO_2) é exposto a um gás redutor, a reação

química de liberação de elétrons e a consequente queda de resistência elétrica não ocorrem instantaneamente, demandando um intervalo temporal para consolidar sua curva de inclinação (slope). Ao expandir o tamanho da janela para 10.000 ms, permitiu-se que as camadas densas da rede neural interpretassem o perfil completo da assinatura temporal do gás (o início da reação, a taxa de subida e a estabilização térmica auxiliada pelo sensor DHT22), em vez de fragmentos isolados do sinal que geravam ambiguidades matemáticas entre o GLP e o álcool. A Figura 4 ilustra a configuração final do bloco de processamento estabelecida para a extração de características.

Figura 4 - Configuração do pipeline de dados e parâmetros de janela temporal.




Fonte: Do autor (2026).

A inclusão da variável temperatura, proveniente do sensor DHT22, incorporada como variável de entrada, demonstrou melhora na estabilidade do modelo frente a variações térmicas.

3.2 DESEMPENHO DO MODELO FINAL

A aplicação das otimizações resultou em um desempenho satisfatório, com o modelo atingindo uma acurácia de 97,3% e uma função de perda (Loss) de 0,18 no conjunto de validação. A Figura 5 apresenta a Matriz de Confusão e as métricas detalhadas.

Figura 5 - Matriz de confusão e métricas de desempenho do modelo final.



Fonte: Do autor (2026).

Os resultados indicam que o sistema reconheceu perfeitamente as leituras de linha de base (100% de acerto na classe ambiente_normal) e os vazamentos simulados de GLP (100% na classe isqueiro, utilizada para representar os vazamentos simulados de GLP). O erro residual de 8,3% concentrou-se na classe falso_positivo sendo confundida com a classe isqueiro. Do ponto de vista de segurança, este dado demonstra que o modelo foi capaz de rejeitar corretamente 91,7% das interferências causadas pelo álcool isopropílico, uma melhoria em relação às abordagens baseadas em limiar fixo.

Do ponto de vista físico-químico, esse erro residual de 8,3% encontra amparo na literatura sobre a sensibilidade cruzada de matrizes de óxido metálico. Tanto as moléculas de hidrocarbonetos do GLP (butano/propano) quanto os vapores do álcool isopropílico comportam-se como agentes redutores na superfície aquecida do sensor. Ambos os compostos reagem com o oxigênio adsorvido, reduzindo a barreira de potencial do semicondutor. Consequentemente, em condições específicas de dissipação ou em variações de distância da fonte, as curvas de variação de condutividade elétrica geradas por ambos os gases podem apresentar padrões transientes temporais semelhantes, o que impõe uma limitação física intrínseca ao hardware que desafia a separação absoluta por parte do classificador linear.

3.3 VALIDAÇÃO PRÁTICA E COMPARAÇÃO COM TRABALHOS RELACIONADOS

Ao analisar criticamente os resultados frente ao estado da arte, os dados obtidos sugerem que a abordagem baseada em TinyML apresenta potencial para transferir a inteligência da detecção para a análise do padrão temporal, mitigando limitações físicas de seletividade do hardware sem onerar o custo final do projeto. O estudo de Neto et al. (2020) empregou uma lógica de limiar fixo (*threshold*), na qual a decisão depende exclusivamente do valor instantâneo fornecido pelo sensor, tornando o sistema suscetível à ocorrência de falsos positivos decorrentes da sensibilidade cruzada dos sensores MOS.

Em contraste, o modelo desenvolvido neste trabalho utiliza uma abordagem baseada na análise temporal do sinal ao longo de janelas de observação de 10.000 ms. Os resultados obtidos demonstram que essa estratégia foi capaz de reduzir significativamente os falsos positivos provocados pelo álcool isopropílico, indicando que técnicas de aprendizado de máquina embarcado podem mitigar parte das limitações físicas dos sensores MOS sem a necessidade de alterações no hardware.

Adicionalmente, em termos de eficiência de recursos, a abordagem proposta apresenta vantagens relevantes quando comparada aos trabalhos correlatos. A utilização de um único sensor MQ-6, associado às informações de temperatura fornecidas pelo DHT22, resultou em uma arquitetura simples, de baixo custo e adequada para execução embarcada no ESP32, preservando desempenho satisfatório na identificação das classes analisadas.

Embora Tozlu (2024) tenha obtido elevada capacidade de discriminação entre compostos químicos, sua abordagem depende de uma matriz composta por múltiplos sensores, aumentando o custo, a complexidade eletrônica e o processamento necessário. Em contraste, o presente trabalho demonstrou que um único sensor MQ-6, aliado a um modelo TinyML executado localmente no ESP32, pode alcançar desempenho satisfatório para aplicações residenciais, reduzindo significativamente o custo da solução.


De forma semelhante, Muniz (2023) empregou um nariz eletrônico composto por treze sensores distintos, buscando maximizar a seletividade química. A presente pesquisa adotou uma estratégia oposta, priorizando simplicidade de hardware e inteligência computacional. Os resultados obtidos sugerem que, para aplicações específicas como a detecção de

vazamentos de GLP em ambientes residenciais, o aumento da capacidade de processamento pode compensar parcialmente a menor seletividade física do sensor.

Além disso, diferentemente dos trabalhos correlatos, que concentram suas avaliações principalmente em métricas de classificação obtidas durante o treinamento ou em ambientes laboratoriais específicos, o presente estudo complementou a avaliação por meio de testes práticos utilizando novas amostras coletadas após o treinamento, empregando o recurso *Live Classification* da plataforma Edge Impulse. Essa estratégia permitiu observar o comportamento do modelo em condições mais próximas da aplicação real, reforçando sua capacidade de generalização.

Essa otimização sinaliza que o processamento inteligente na borda pode se consolidar como uma alternativa tecnicamente eficiente e economicamente acessível para cenários de segurança residencial. Ao operar de forma estritamente local no microcontrolador ESP32, o sistema elimina a dependência de processamento em computadores externos. A Figura 6 demonstra o baixo consumo de recursos computacionais do modelo, consumindo apenas 320 Bytes de memória RAM para classificar os dados no próprio dispositivo.

Figura 6 - Separação de características e desempenho estimado no dispositivo.



Fonte: Do autor (2026).

4 CONCLUSÃO

A solução proposta neste trabalho consiste em um sistema acessível, integrado a um modelo de aprendizado de máquina embarcado (*TinyML*) e baseado no microcontrolador ESP32, que analisa o comportamento temporal dos sinais coletados para auxiliar na diferenciação entre vazamentos reais e interferências. O objetivo deste trabalho foi propor e validar um sistema inteligente para a detecção de vazamentos de GLP, visando a redução da ocorrência de falsos positivos em ambientes residenciais. Com essa abordagem, o projeto busca solucionar o problema central identificado: a baixa precisão dos sensores de gás de baixo custo, como o MQ-6, que frequentemente disparam alarmes indevidos na presença de vapores inofensivos devido à sua falta de seletividade química.

O monitoramento contínuo da presença de gás no ambiente é essencial para a prevenção de acidentes graves domésticos. Ao buscar a redução dos falsos positivos, o sistema visa evitar o pânico desnecessário e combater a perigosa prática dos usuários de desativarem os alarmes de segurança por falta de confiança no dispositivo. Dessa forma, o sistema atua para que os moradores sejam alertados prioritariamente quando houver um risco real, permitindo uma ação preventiva rápida e com maior nível de confiabilidade do que as soluções tradicionais de limiar fixo.

Os resultados obtidos demonstram que, embora o sistema atenda ao objetivo de diminuir os alarmes indevidos, a separação perfeita entre o vazamento real (GLP) e a interferência (álcool isopropílico) ainda representa um desafio técnico. O modelo baseado em inteligência artificial conseguiu rejeitar a maior parte das interferências observadas, indicando desempenho superior às abordagens tradicionais baseadas em limiar fixo. Contudo, deve-se ser sincero em afirmar que ainda há uma certa incidência de falsos positivos, decorrente da forte sensibilidade cruzada do sensor, que em algumas ocasiões gera sinais elétricos quase idênticos para ambos os compostos. Os resultados obtidos sugerem que a utilização de *TinyML* constitui uma abordagem viável para mitigar limitações associadas a sensores de baixo custo, mas evidenciam que a solução não é infalível e possui limitações físicas.

As principais contribuições deste trabalho estão na viabilização de uma arquitetura autônoma, que realiza o processamento dos dados localmente no próprio microcontrolador e dispensa o uso de computadores externos ou internet. Isso reduz significativamente os custos do projeto, tor-

nando o sistema acessível a famílias de baixa renda. Além disso, o projeto avança ao oferecer uma validação prática, transparente e mensurável das dificuldades na aplicação de IA em sensores analógicos, servindo de base realista para futuros desenvolvimentos na área de segurança e Internet das Coisas (IoT).

Como trabalhos futuros, recomenda-se a ampliação do conjunto de dados por meio da inclusão de diferentes condições ambientais, concentrações de gás e novos compostos interferentes, como acetona, perfumes e produtos de limpeza domésticos.

Além disso, recomenda-se a aplicação de estratégias estatísticas complementares de validação, como validação cruzada (*cross-validation*), com o objetivo de ampliar a robustez da avaliação experimental e investigar de forma mais aprofundada a capacidade de generalização do modelo em diferentes conjuntos de dados.

Adicionalmente, sugere-se a investigação de diferentes arquiteturas de aprendizado de máquina embarcado, incluindo modelos baseados em redes neurais convolucionais e algoritmos de classificação alternativos, a fim de comparar desempenho, consumo computacional e capacidade de discriminação entre compostos químicos.

Recomenda-se também a avaliação da solução utilizando outros sensores de gás da família MQ ou sensores com tecnologias distintas, permitindo verificar o impacto das características físicas dos sensores na taxa de falsos positivos.

Por fim, estudos futuros podem contemplar a validação do sistema em ambientes residenciais reais e por períodos prolongados, visando analisar seu comportamento em condições de uso contínuo.

DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL

Os autores declaram que ferramentas de Inteligência Artificial generativa foram utilizadas exclusivamente como apoio auxiliar à elaboração deste trabalho, incluindo assistência na revisão linguística, estruturação textual e organização de ideias. Nenhuma ferramenta de IA foi utilizada para substituição da autoria intelectual, análise científica, interpretação dos resultados ou tomada de decisões acadêmicas. A responsabilidade integral pelo conteúdo, originalidade, veracidade das informações e conformidade com os princípios de integridade científica permanece integralmente atribuída aos autores.

REFERÊNCIAS

ARBIA, M. B.; HELAL, H.; COMINI, E. **Recent advances in low-dimensional metal oxides via sol-gel method for gas detection.** *Nanomaterials*, v. 14, n. 4, p. 359. 2024.

CORPO DE BOMBEIROS MILITAR DO ESTADO DO CEARA. **O Corpo de Bombeiros do Ceará registrou 1.588 ocorrências com gases em 2024.** 2024. Disponível em: <<https://www.bombeiros.ce.gov.br/2024/10/19/o-corpo-de-bombeiros-do-ceara-registrou-1-588-ocorrencias-com-gases-em-2024/>>. Acesso em: 20 ago. 2025.

CORPO DE BOMBEIROS MILITAR DO PARANÁ. **Gás de cozinha ou GLP.** 2018. Disponível em: <<https://www.bombeiros.pr.gov.br/Pagina/Gas-de-cozinha-ou-GLP>>. Acesso em: 25 mar. 2026.

MILLI, M.; MILLI, M. **Reducing false positives in building fire detection systems via multiple metal oxide sensors.** *IEEE Access*, v. 13, p. 157537–157550. 2025.

MUNIZ, J. d. S. D. **Desenvolvimento de um Nariz Eletrônico para Monitoramento de Gases Poluentes em Aterros Sanitários.** Dissertação (Mestrado) — Universidade Federal da Paraíba (UFPB), João Pessoa, 2023.

NETO, A. V. d. C. L. et al. **Sistema de detecção de gás para áreas de riscos (sdgrl).** In: **Anais da Universidade Tecnológica Federal do Paraná.** [S.l.: s.n.], 2020. 2020.

NIKOLIC, M. V. et al. **Semiconductor gas sensors: Materials, technology, design, and application.** *Sensors*, v. 20, n. 22, p. 6694. 2020.

POLOLU ROBOTICS. **MQ-6 Semiconductor Sensor for LPG.** [S.l.], s.d. Disponível em: <https://www.pololu.com/file/download/mq6.pdf?file_id=0j312>. Acesso em: 29 mai. 2026.

SAYAGO, I.; MERCADANTE, L.; ANDRADE, A. **A review on improving the selectivity of metal-oxide semiconductor gas sensors.** *Chemosensors*, v. 9, n. 8, p. 214. 2021.

SINDICATO NACIONAL DAS EMPRESAS DISTRIBUIDORAS DE GAS LIQUEFEITO DE PETROLEO. **O GLP no Brasil.** 2024. Disponível em: <https://www.sindigas.org.br/?page_id=12>. Acesso em: 20 ago. 2025.

TOZLU, B. H. **A fast and cost-effective electronic nose model for methanol detection using ensemble learning.** *Chemosensors*, v. 12, n. 11, p. 225. 2024.